



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK
DİYARBAKIR İÇME SUYU ŞEBEKESİNDEKİ YATAY MİLLİ SU
POMPASI SESİNDEN ARIZA TAHMİNİ**

İdris SAÇAKLIDIR

**Haziran-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK
DİYARBAKIR İÇME SUYU ŞEBEKESİNDEKİ YATAY MİLLİ SU
POMPASI SESİNDEN ARIZA TAHMİNİ**

İdris SAÇAKLIDIR

**Danışman
Dr. Öğr. Üyesi Savaş KOÇ**

**Haziran-2024
BATMAN**

TEZ KABUL VE ONAYI

İdris SAÇAKLIDIR tarafından hazırlanan “**Makine Öğrenmesi Yöntemleri Kullanılarak Diyarbakır İçme Suyu Şebekesindeki Yatay Milli Su Pompası Sesinden Arıza Tahmini**” adlı tez çalışması 26.06.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Makine Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi İsmail BAYAR

.....

Danışman

Dr. Öğr. Üyesi.Savaş KOÇ

.....

Üye

Dr. Öğr. Üyesi Nülfir GÜNDOĞAN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BİLDİRİMİ

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 bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

İdris SAÇAKLIDIR

Tarih: 26.07.2024

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK DİYARBAKIR İÇME SUYU ŞEBEKESİNDEKİ YATAY MİLLİ SU POMPASI SESİNDEN ARIZA TAHMİNİ

İdris SAÇAKLIDIR

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Makine Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Savaş KOÇ

2024, 97 Sayfa

Jüri

Danışman: Dr. Öğr. Üyesi Savaş KOÇ

Üye: Dr. Öğr. Üyesi İsmail BAYAR

Üye: Dr. Öğr. Üyesi Nülifer GÜNDOĞAN

Makineler, mekanik bileşenlerinin doğrusal veya döner hareketinin bir sonucu olarak gürültü üretir. Çalışma sırasında, ses, makineyi oluşturan bileşenlerin eksenel yanlış hizalanması, aşırı gerilmesi ve aşınması sonucu değişir. Sınıflandırma modellerini eğitmek için doğrudan seslerden elde edilen dizileri veya görüntüleri kullanmanın yanı sıra, zaman ve frekans değerlerinden özellikler çıkarılarak modeller için çoklu diziler oluşturulur. Bu çalışmada, CNN (Convolutional Neural Network) gibi derin öğrenme modellerinde kullanılacak verileri oluşturmak üzere her ses için MFCC'lerden (Mel-Frequency Cepstral Coefficients) oluşan 15 adet 1D (tek boyutlu) dizi ve 15 adet 2D (iki boyutlu) görüntü kullanılmıştır. Makine öğrenmesi modellerinde ise her sesteki Genlik-zaman, Mel-spektrogram, MFCC'ler, ZCR'ler (Sıfır Geçiş Oranları) ve RMS (Ortalama Enerji Karekökü) özelliklerinden 18 özellik çıkarılarak bir veri kümesi oluşturulmuştur. Makine öğrenme modellerinde SVM (Destek Vektör Makinesi), KNN (K-En Yakın Komşular) ve Ensemble Öğrenme modelleri kullanılmıştır. Ensemble öğrenme modeli SVM, KNN ve RF (Random Forest) modellerini birleştirmektedir. Pompa fanı için en yüksek doğruluk oranı %98,83 ile topluluk modelinde, en düşük doğruluk oranı ise %63,38 ile DVM modelinde, pompa ön yatağı için en yüksek doğruluk oranı %99,68 ile topluluk modelinde, en düşük doğruluk oranı ise %84,08 ile DVM modelinde elde edilmiştir. Buna ek olarak, pompa arka yatağı için en yüksek doğruluk topluluk modelinde %99,66 ve en düşük doğruluk DVM modelinde %89,53'tür ve pompa motoru fanı ve yatağı için en yüksek doğruluk KNN modelinde %98,19 ve en düşük doğruluk DVM modelinde %75,60'tır. Tüm sistem için en yüksek doğruluk topluluk modelinde %93,57 ve en düşük doğruluk DVM modelinde %65,11 olarak hesaplanmıştır. Bu sonuçlar, bir santrifüj pompanın erken arıza teşhisinin sağlanabileceğini ve arızaların önlenilebileceğini göstermektedir. Çalışma sırasında bozulan veya arızalanan makinelerin neden olduğu arızaları önlemek için erken arıza teşhisi ve kestirimci bakım planlamasının uygulanması önemli bir ekonomik ve enerji tasarrufu sağlamaktadır.

Anahtar Kelimeler: Erken arıza teşhisi, Santrifüj pompa, Ses özniteliklerin çıkartılması, Sınıflandırma modelleri, Yapay zeka

ABSTRACT

MS THESIS

FAULT PREDICTION FROM HORIZONTAL NATIONAL WATER PUMP SOUND IN DYARBAKIR DRINKING WATER NETWORK USING MACHINE LEARNING METHODS

İdris SAÇAKLIDIR

**BATMAN UNIVERSITY GRADUATE EDUCATION INSTITUTE
THE DEGREE OF MASTER OF SCIENCE IN MECHANICAL ENGINEERING**

Advisor: Asst. Prof. Savaş KOÇ

2024, 97 Pages

Jury

Advisor : Asst. Prof. Savaş KOÇ

Asst. Prof. İsmail BAYAR

Asst. Prof. Nülifer GÜNDOĞAN

Machines generate noise as a result of the linear or rotary motion of their mechanical components. During operation, the sound changes as a result of axial misalignment, over-stressing and wear of the components that make up the machine. In addition to using sequences or images obtained directly from sounds to train classification models, multiple sequences are created for the models by extracting features from time and frequency values. In this study, 15 1D (one-dimensional) sequences of MFCCs (Mel-Frequency Cepstral Coefficients) and 15 2D (two-dimensional) images were used for each voice to create data to be used in deep learning models such as CNN (Convolutional Neural Network). In machine learning models, a dataset was created by extracting 18 features from Amplitude-time, Mel-spectrogram, MFCCs, ZCRs (Zero Crossing Ratios) and RMS (Root Mean Square Energy) features from each sound. SVM (Support Vector Machine), KNN (K-Nearest Neighbours) and Ensemble Learning models were used in the machine learning models. Ensemble learning model combines SVM, KNN and RF (Random Forest) models. The highest accuracy for the pump fan is 98.83% in the ensemble model and the lowest accuracy is 63.38% in the SVM model, and the highest accuracy for the pump front bearing is 99.68% in the ensemble model and the lowest accuracy is 84.08% in the SVM model. In addition, the highest accuracy for the pump rear bearing is 99.66% in the ensemble model and the lowest accuracy is 89.53% in the SVM model, and the highest accuracy for the pump motor fan and bearing is 98.19% in the KNN model and the lowest accuracy is 75.60% in the SVM model. The highest accuracy for the complete system is calculated as 93.57% in the ensemble model and the lowest accuracy was calculated as 65.11% in the SVM model. These results show that early fault diagnosis of a centrifugal pump can be achieved and faults can be prevented. The implementation of early fault diagnosis and predictive maintenance planning to prevent failures caused by broken or malfunctioning machines during operation is an important economic and energy saving.

Keywords: Artificial intelligence, Audio feature extraction, Centrifugal pump, Classification models, Early fault diagnosis

ÖNSÖZ

Birçok alanda kullanılan (Endüstri, yangın, içme suyu, sulama vb.) yatay milli santrifüj su pompaları alanında “Makine Öğrenmesi Yöntemleri Kullanılarak Diyarbakır İçme Suyu Şebekesindeki Yatay Milli Su Pompası Sesinden Arıza Tahmini” konusunda çalışma fırsatı veren danışman hocam Dr. Öğr. Üyesi Savaş KOÇ’a, DİSKİ Genel Müdürlüğündeki çalışma arkadaşlarıma ve aileme çalışma boyunca sabır, destek ve hoşgörülerini için teşekkür ederim.

İdris SAÇAKLIDIR
BATMAN-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
TABLO LİSTESİ	x
ŞEKİLLER LİSTESİ	Error! Bookmark not defined.
1. GİRİŞ	1
1.1. Santrifüj Pompalar	2
1.2. Santrifüj Pompaların Sınıflandırılması	2
1.2.1. Tek kademeli(salyangoz tipi) pompalar	3
1.2.2. Çok kademeli pompalar	3
1.2.3. Yatay milli santrifüj pompa	4
1.2.4. Dikey(düşey) milli santrifüj pompa	5
1.3. Yatay Milli Santrifüj Pompa Elemanları	5
1.3.1. Yatay milli santrifüj pompa mili	5
1.3.2. Fan.....	5
1.3.3. Rulman(Bilye).....	7
1.3.4. Pompa gövdesi	7
1.4. Bakım Yönetimi	8
1.5. Yapay Zekâ	9
1.6. Makine Öğrenme Modelleri.....	9
1.6.1. KNN modeli	10
1.6.2. SVM modeli	11
1.6.3. Topluluk öğrenme modeli	11
1.7. Derin Öğrenme Modelleri.....	12
1.7.1. 1D CNN modeli	13
1.7.2. 2D CNN modeli	13
1.8. Özniteliklerin Çıkartılması.....	14
1.9. Amaç	17
2. KAYNAK ARAŞTIRMASI.....	19
3. MATERYAL VE YÖNTEM	26
3.1. Deney Sistemi Elemanları.....	27
3.1.1. Terfi merkezi pompa teknik bilgileri.....	27
3.2. Ses Dinleme Ölçüm Cihazı	32
3.3. Makine Öğrenme Modelleri.....	32
3.3.1. KNN modeli	33
3.3.2. SVM modeli	33

3.3.3.	Topluluk modeli	33
3.4.	Derin Öğrenme Modelleri	33
3.4.1.	1D CNN modeli	34
3.4.2.	2D CNN modeli	34
3.5.	Özniteliklerin Çıkartılması.....	34
3.6.	Sınıflandırma Metrikleri ve Tahminler İçin Karmaşıklık Matrisi	35
4.	ARAŞTIRMA SONUÇLARI ve TARTIŞMA	38
4.1.	Yatay Milli Santrifüj Pompa Fanı Eğitim Sonuçları ve Tahminler	38
4.1.1.	1D CNN modeli sonuçları	38
4.1.2.	2D CNN modeli sonuçları	39
4.1.3.	KNN modeli sonuçları.....	40
4.1.4.	SVM modeli ses analizi	42
4.1.5.	Topluluk modeli ses analizi.....	43
4.2.	Yatay Milli Santrifüj Pompa Ön Rulman Arıza Sınıflandırma Sonuçları	46
4.2.1.	1D CNN modeli sonuçları.....	46
4.2.2.	2D CNN model ses analizi	48
4.2.3.	KNN modeli ses analizi	49
4.2.4.	SVM modeli ses analizi	50
4.2.5.	Topluluk modeli ses analizi	52
4.3.	Yatay Milli Santrifüj Pompa Arka Rulman Model Çalışması	55
4.3.1.	1D CNN modeli sonuçları.....	55
4.3.2.	2D CNN model ses analizi	57
4.3.3.	KNN modeli ses analizi	58
4.3.4.	SVM modeli ses analizi	59
4.3.5.	Topluluk modeli ses analizi	61
4.4.	Yatay Milli Santrifüj Pompa Motoru Fan + Rulmanı Model Çalışması....	64
4.4.1.	Pompa motoru fan+rulman 1D CNN model sonuçları	64
4.4.2.	Pompa motoru fan+rulman 2D CNN model sonuçları	66
4.4.3.	KNN modeli sonuçları.....	67
4.4.4.	SVM modeli ses analizi	68
4.4.5.	Topluluk modeli ses analizi.....	70
4.5.	Yatay Milli Santrifüj Pompa Tüm Sistem (Pompa Fanı, Pompa Ön Rulman, Pompa Arka Rulman, Pompa Motoru Fan + Rulman) Model Çalışması ..	73
4.5.1.	Pompa tüm sistem 1D CNN model ses analizi.....	73
4.5.2.	Pompa tüm sistem 2D CNN model ses analizi	76
4.5.3.	Pompa tüm sistem KNN modeli ses analizi.....	79
4.5.4.	SVM modeli ses analizi	81
4.5.5.	Topluluk modeli ses analizi	82
5.	SONUÇLAR VE ÖNERİLER.....	89
5.1.	Sonuçlar	89
5.2.	Öneriler	91
KAYNAKLAR	93	

SİMGELER VE KISALTMALAR

Simgeler

W	: Watt
D	: Rulman ortalama çapı (mm)
d	: Bilye çapı (mm)
B	: Rulman genişliği (mm)
k	: Dönem sayısı
n	: Bilye sayısı
N	: Dönme hızı (d/d)
v	: Hız (mm/sn)
ω	: Açısal frekans (rad/s)
X	: Herhangi bir andaki yer değiştirme (mm)
Φ	: Faz açısı (rad, deg)
f	: Frekans (Hz)
w_c	: Kafes frekansı
w_b	: Bilye dönme frekansı
w_{bp}	: Dış bilezik bilye geçiş frekansı
w_{bpi}	: İç bilezik bilye geçiş frekansı

Kısaltmalar

dB	: Desibel
AI	: Yapay zekâ (Artificial Intelligent)
ML	: Makine Öğrenmesi (Machine Learning)
PdM	: Kestirimci bakım (Predictive Maintenance)
R2F	: Çalışmaya dayalı (Run-to-Failure)
CBM	: Koşula dayalı izleme (Condition Based Monitoring)
CPS	: Saniye başına titreşim (cycle per second)
ISO	: Uluslararası Standard Organizasyonu (International Standart Organization)
BSF	: Bilye Dönme Frekansı (Ball Spin Frequency)
BPFO	: Dış Bilezik Bilye Geçiş Frekansı (Ball Pass Frequency Outer Race)
BPFI	: İç Bilezik Bilye Geçiş Frekansı (Ball Pass Frequency Inner Race)
RPM	: Dakikadaki Devir Sayısı (Revolution Per Minute)
TS	: Türk Standartları
NPSH	: Net Pozitif Emme Yüksekliği - Net Positive Suction Head
SDP	: Simetrik nokta deseni (Symmetrised Dot Pattern)

TABLO LİSTESİ

Tablo 3.1. Bismil terfi istasyonu 1 nolu pompa ve motoru etiket bilgileri.....	28
Tablo 3.2. Bismil terfi istasyonu 2 nolu pompa ve motoru etiket bilgileri.....	29
Tablo 3.3. Bismil terfi istasyonu 3 nolu pompa ve motoru etiket bilgileri.....	29
Tablo 3.4. Bismil terfi istasyonu 4 nolu pompa ve motoru etiket bilgileri.....	30
Tablo 3.5. Bismil terfi istasyonu 5 nolu pompa ve motoru etiket bilgileri.....	31
Tablo 3.6. Bismil terfi istasyonu 6 nolu pompa ve motoru etiket bilgileri.....	32
Tablo 3.7. Ses dinlemesi yapılan cihaz bilgileri	32
Tablo 4.1. Yatay milli santrifüj pompa fanı sınıflandırma metrik sonuçları	45
Tablo 4.2. Yatay milli santrifüj pompa ön rulman sınıflandırma ölçüm sonuçları	54
Tablo 4.3. Yatay milli santrifüj pompa arka rulman sınıflandırma ölçüm sonuçları ..	63
Tablo 4.4. Yatay milli pompa motoru fan+rulman sınıflandırma ölçüm sonuçları	72
Tablo 4.5. Yatay milli santrifüj pompa tüm sistem sınıflandırma metrik sonuçları	85
Tablo 4.5. Yatay milli santrifüj pompa tüm sistem sınıflandırma metrik sonuçları(Tablonun devamı)	86

ŞEKİLLER LİSTESİ

Şekil 1.1.	Elektrik motoru yapısı(Silvan Tünel Terfi Merkezi 1 nolu Gamak marka 90 kW Rotor, arka rulman – stator ve dış gövde)	2
Şekil 1.2.	Tek kademeli pompa salyangozu (a) ve fanı (b) (Silvan Terfi Merkezi 1 nolu pompa)	3
Şekil 1.3.	Tek kademeli pompa gövde kapağı (a) ve rulman yatağı (b) (Silvan Terfi Merkezi 1 nolu pompa)	3
Şekil 1.4.	Çok kademeli grup pompa(Bismil Terfi Merkezi 1 nolu pompa, 3 kademeli)	4
Şekil 1.5.	Yatay milli santrifüj pompa (Bismil Terfi Merkezi, B 3'lü grup).....	4
Şekil 1.6.	kademeli pompa mili (Bismil Terfi Merkezi 5 nolu pompa)	5
Şekil 1.7.	Yatay milli santrifüj pompa arızalı ve sağlam fanı(Bismil Terfi Merkezi 5 nolu pompa)	6
Şekil 1.8.	Tek kademeli yatay milli santrifüj pompa montajı(Dicle Pompa İstasyonu, 4.000 kW)	6
Şekil 1.9.	Bismil Terfi İstasyonu A3 nolu pompa a) Arızalı b) Sağlam Rulman	7
Şekil 1.10.	Bismil Terfi Merkezi A1 1 nolu 3 kademeli pompa gövdesi	8
Şekil 1.11.	Yapay zekâ, makine öğrenme ve derin öğrenme ilişkisi	9
Şekil 1.12.	Makine öğrenmesi süreci	10
Şekil 1.13.	Derin öğrenme süreci	12
Şekil 1.14.	1D CNN Modeli örnek diyagramı	13
Şekil 1.15.	2D CNN Model örnek diyagramı	14
Şekil 1.16.	Genlik(Amplitude) zaman diyagramı	14
Şekil 1.17.	Mel spectrogram diyagramı	15
Şekil 1.18.	MFCC(Mel frekans kepstrum katsayısı) diyagramı	15
Şekil 1.19.	ZCRs diyagramı	16
Şekil 1.20.	MFCC(Mel frekans kepstrum katsayısı) diyagramı	16
Şekil 1.21.	MFCC özellik çıkarma adımları	17
Şekil 1.22.	Yatay milli 3 kademeli snatrifüj pompa önden görünümü	18
Şekil 3.1.	Yatay milli santrifüj pompanın ses dinleme noktaları; a) Pompa fan b) Pompa ön rulman c) Pompa arka rulman d) Motor fan+rulman	27
Şekil 3.2.	Bismil Terfi Merkezi 1 nolu(A1) Pompa	28
Şekil 3.3.	Bismil Terfi Merkezi 2 nolu(A2) Pompa	28

Şekil 3.4.	Bismil Terfi Merkezi 3 nolu(A3) Pompa	29
Şekil 3.5.	Bismil Terfi Merkezi 4 nolu(B1) Pompa	30
Şekil 3.6.	Bismil Terfi Merkezi 5 nolu(B2) Pompa	31
Şekil 3.7.	Bismil Terfi Merkezi 6 nolu(B3) Pompa	31
Şekil 3.8.	Ses kayıt cihazı	32
Şekil 3.9.	Ses dosyasından özniteliklerin çıkartılması işlemi	35
Şekil 3.10.	Tahminler için karmaşıklık matrisi	36
Şekil 4.1.	Pompa fanı 1D CNN her döngüdeki eğitim ve test verisinin doğruluk/kayıp durumu ve metrikler	38
Şekil 4.2.	Pompa fanı 1D CNN Modeli ROC eğrisi ve karmaşıklık matrisi.	39
Şekil 4.3.	Pompa fanı 2D CNN her döngüdeki eğitim ve test verisinin doğruluk/kayıp durumu ve metrikler	40
Şekil 4.4.	Pompa fanı 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi	40
Şekil 4.5.	Pompa fanı KNN modeli için öğrenme eğrisi ve ROC eğrisi	41
Şekil 4.6.	Pompa fanı KNN modeli karmaşıklık matrisi	41
Şekil 4.7.	Pompa fanı SVM modeli için öğrenme eğrisi ve ROC eğrisi	42
Şekil 4.8.	Pompa fanı SVM modeli karmaşıklık matrisi	42
Şekil 4.9.	Pompa fanı Topluluk modeli için öğrenme eğrisi ve ROC eğrisi	43
Şekil 4.10.	Pompa fanı Topluluk modeli karmaşıklık matrisi	44
Şekil 4.11.	Pompa fanı test verileri için doğru ve yanlış tahminler	45
Şekil 4.12.	Pompa fanı doğruluk değerleri	46
Şekil 4.13.	Pompa ön rulman 1D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler	47
Şekil 4.14.	Pompa ön rulman 1D CNN modeli ROC eğrisi ve karmaşıklık matrisi	47
Şekil 4.15.	Pompa ön rulman 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler	48
Şekil 4.16.	Pompa ön rulman 2D CNN modeli ROC eğrisi ve karmaşıklık matrisi	49
Şekil 4.17.	Pompa ön rulman KNN modeli için öğrenme eğrisi ve ROC eğrisi	50
Şekil 4.18.	Pompa ön rulman KNN modeli karmaşıklık matrisi	50
Şekil 4.19.	Pompa ön rulman SVM modeli için öğrenme eğrisi ve ROC eğrisi	51
Şekil 4.20.	Pompa ön rulman SVM modeli karmaşıklık matrisi	52
Şekil 4.21.	Pompa ön rulman Topluluk modeli için öğrenme eğrisi ve ROC eğrisi	52
Şekil 4.22.	Pompa ön rulman Topluluk modeli karmaşıklık matrisi	53
Şekil 4.23.	Pompa ön rulman test verileri için doğru ve yanlış tahminler	54

Şekil 4.24. Pompa ön rulman doğruluk değerleri	55
Şekil 4.25. Pompa arka rulman 1D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk/kayıp durumu ve metrikler	56
Şekil 4.26. Pompa arka rulman 1D CNN modeli ROC eğrisi ve karmaşıklık matrisi ..	56
Şekil 4.27. Pompa arka rulman 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk/kayıp durumu ve metrikler	57
Şekil 4.28. Pompa arka rulman 2D CNN modeli ROC eğrisi ve karmaşıklık matrisi ..	58
Şekil 4.29. Pompa arka rulman KNN modeli için öğrenme eğrisi ve ROC eğrisi	59
Şekil 4.30. Pompa arka rulman KNN modeli karışıklık matrisi	59
Şekil 4.31. Pompa arka rulman SVM modeli için öğrenme eğrisi ve ROC eğrisi	60
Şekil 4.32. Pompa arka rulman SVM modeli karışıklık matrisi	61
Şekil 4.33. Pompa arka rulman Topluluk modeli için öğrenme eğrisi ve ROC eğrisi ..	61
Şekil 4.34. Pompa arka rulman Topluluk modeli karışıklık matrisi	62
Şekil 4.35. Pompa arka rulman test verileri için doğru ve yanlış tahminler	63
Şekil 4.36. Pompa arka rulman doğruluk değerleri	64
Şekil 4.37. Pompa motoru fan+rulman 1D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk/kayıp durumu ve metrikler	65
Şekil 4.38. Pompa motoru fan+rulman 1D CNN modeli ROC eğrisi ve karmaşıklık matrisi	65
Şekil 4.39. Pompa motoru fan+rulman 2D CNN modeli her döngüdeki eğitim ve test verisinin doğruluk/kayıp durumu ve metrikler	66
Şekil 4.40. Pompa motoru fan+rulman 2D CNN modeli ROC eğrisi ve karmaşıklık matrisi	67
Şekil 4.41. Pompa motoru fan+rulman KNN modeli için öğrenme eğrisi ve ROC eğrisi	68
Şekil 4.42. Pompa motoru fan+rulman KNN modeli karışıklık matrisi	68
Şekil 4.43. Pompa motoru fan+rulman SVM modeli için öğrenme eğrisi ve ROC eğrisi	69
Şekil 4.44. Pompa motoru fan+rulman SVM modeli karışıklık matrisi	70
Şekil 4.45. Pompa motoru fan+rulman Topluluk modeli için öğrenme eğrisi ve ROC eğrisi	70
Şekil 4.46. Pompa motoru fan+rulman Topluluk modeli karışıklık matrisi	71
Şekil 4.47. Pompa motoru fan+rulman test verileri için doğru ve yanlış tahminler	72
Şekil 4.48. Pompa motoru fan+rulman doğruluk değerleri	73

Şekil 4.49. Pompa tüm sistem 1D CNN Eğitim ve testin dönemlere göre doğruluk/kayıp durumu	74
Şekil 4.50. Pompa tüm sistem 1D CNN için ROC eğrisi	75
Şekil 4.51. Pompa tüm sistem 1D CNN modeli karmaşıklık matrisi	75
Şekil 4.52. Pompa tüm sistem 2D CNN Model Eğitim ve testin dönemlere göre doğruluk/kayıp durumu	77
Şekil 4.53. Pompa tüm sistem 2D CNN için ROC eğrisi	77
Şekil 4.54. Pompa tüm sistem 2D CNN modeli karmaşıklık matrisi	78
Şekil 4.55. Pompa tüm sistem KNN modeli için öğrenme eğrisi ve ROC eğrisi	79
Şekil 4.56. Pompa tüm sistem KNN modeli karışıklık matrisi	80
Şekil 4.57. Pompa tüm sistem SVM modeli için öğrenme eğrisi ve ROC eğrisi	81
Şekil 4.58. Pompa tüm sistem SVM modeli karışıklık matrisi	82
Şekil 4.59. Pompa tüm sistem Topluluk modeli için öğrenme eğrisi ve ROC eğrisi	83
Şekil 4.60. Pompa tüm sistem Topluluk modeli karışıklık matrisi	84
Şekil 4.61. Pompa tüm sistem test verileri için doğru ve yanlış tahminler	87

1. GİRİŞ


İçinde bulunduğumuz bilgi ve teknoloji çağında gün geçtikçe her alanda gelişmeler olmaktadır. Aynı zamanda nüfus artmakta ve bununla paralel olarak tüketim de artmaktadır. Temel ihtiyaçlardan olan suya talep de artarken dünyada sınırlı miktarda olan insani tüketim amaçlı sular da ise ters orantılı olarak kişi başına düşen temiz içilebilir su miktarı nüfus artışıyla azalmaktadır. Mevcut eldeki su kaynaklarının tasarruflu kullanılması zorunlu hale gelmektedir. Gün geçtikçe önemi artan su kaynakları iki şekilde yeryüzüne çıkmaktadır. Kendi cazibesi ile yeryüzüne çıkan artezyen sular ve pompalar vasıtasıyla barajlardan, nehirlerden, derelerden ve yeraltından emilerek çıkarılan sular olarak adlandırılmaktadır. Kendi cazibesi ile kanallar ve borular ile taşınan sular çok az miktarda şanslı yerlerde bulunmaktadır. Diğer sular ise az derin su alma yapılarından yatay milli santrifüj pompalarla ve derin su kuyulardan dalgıç pompalar vasıtasıyla elde edilmektedir.

Yatay milli ve dalgıç pompalar vasıtasıyla elde edilen sular için elektrik tahrikli motorlar kullanılmaktadır. Yani su tasarrufunun yanında kullanılan elektrik, pompa ve işletme maliyeti konularındaki tasarruf da çok önem arz etmektedir. Bu maliyetlerin karşılanması için su ihtiyacını temin edip dağıtan idareler tüketicilere bu maliyeti yansıtmak zorunda kalmaktadır. Burada en önemli maliyet işletme maliyeti olduğu ifade edilmektedir. Çünkü ihtiyaç devam ettiği sürece su alma yapısındaki elektrik ve bakım-onarım gideri devam edecektir. Yatay milli santrifüj pompalar dalgıç tipi pompalardan işletme maliyeti açısından daha maliyetli olan su temin araçları olarak ifade edilmektedir. Daha sık periyodik bakım yapılması gerekmektedir. Zamanında yapılmayan periyodik bakımlar ve arızalar maliyetlerin kat kat artmasına ve zaman bakımından üretimin azalmasına neden olabilmektedir. İlk etapta tespit edilen arızalar daha az maliyetle ve daha kısa sürede üretime başlamayı sağladığı ifade edilmektedir.

Pompalar çalışma şekline göre pistonun ileri geri hareketi ile oluşturulan basınçla çalışan pistonlu pompalar ve fan(çark) kanatçıklarının dönmesi ile elde edilen vakum ve itme kuvvetiyle sıvıda oluşturulan hız ve basınç çalışma prensibine göre çalışan santrifüj(dinamik) pompalar olarak ikiye ayrılmaktadır. Sıvıları ve gazları elektrik ve fosil yakıtlı motorlardan mil vasıtasıyla aldıkları mekanik hareketi kullanarak aktarma işleminde kullanılan santrifüj pompalar tek kademeli salyangoz tipi ve çok kademeli pompalar olarak ifade edilmektedir.

1.1. Santrifüj Pompalar

Elektrikli motorun milinden kaplin vasıtasıyla santrifüj pompa milinin pompa yatağı içerisinde rulmanlı veya rulmansız dönmesi sayesinde milin üzerindeki fanın tek veya çift tarafından emici gövdedeki flanştan vakumlanan sıvının sınırlandırılmış üst kanallardan basınçlandırılarak çıkış gövdesindeki flanştan itilmesi şeklinde ifade edilmektedir. Motor, elektrik enerjisini mekanik enerjiye çeviren motor gövdesi içerisinde tellerin sarılması neticesinde oluşan bobinin (S ve N zıt kutuplarının) oluşturduğu mıknatıs sabit parça stator, ortasında mile(şafta) çakılı iletken parça rotor/endüvi ve balanslı şekilde dönmesini sağlayan ön ve arka rulmanlar ile motor gövde kapaklarından oluşan parça olarak ifade edilebilmektedir. Ayrıca arka rulmandan sonra soğutma fanı bulunmaktadır. Motor ana iki bileşeni Şekil 1.1’de görülmektedir.



Şekil 1.1. Elektrik motoru yapısı(Silvan Tünel Terfi Merkezi 1 nolu Gamak marka 90 kW Rotor, arka rulman – stator ve dış gövde)

Santrifüj pompa, yan tarafında giriş ve genelde üst tarafında da çıkış flanşı bulunan tek kademelide salyangoz tip ve çok kademelide difüzör tip pompa gövdesi içerisinde mil üzerine partikül yoğunluğu az olan sıvılarda kapalı tip çark, sabitleme kaması ve burçlar, radyal ve eksenel yüklere karşı balanslı çalışmasını sağlamak için rulman ve mil gövdesinden oluşan sıvının vakumlanarak basınçlandırıldıktan sonra iletilmesini sağlayan parçalar grubu olarak ifade edilmektedir.


1.2. Santrifüj Pompaların Sınıflandırılması

Basma yüksekliğine göre, santrifüj basma yüksekliğine bağlı olarak tek kademeli ve çok kademeli pompalar olarak tercih edilmektedir. Ayrıca, konumlarına bağlı olarak

da yatay milli santrifüj pompa ve dikey(düşey) milli santrifüj pompa olmak üzere ikiye ayrılmaktadırlar.

1.2.1. Tek kademeli(salyangoz tipi) pompalar

Tek kademeli santrifüj pompalar diğer adıyla salyangoz gövdeli pompalar genelde su, atık su(kanalizasyon), tesislerdeki kimyasalların enjeksiyonunda, fosil atıklarla çalışan motorların motor soğutmasında ve merkezi soğutma sistemlerindeki soğutma suyu sirkülasyonunda kullanılmaktadır. Şekil 1.2. ve Şekil 1.3’de salyangoz tipi yatay milli santrifüj pompa parçaları görülmektedir. Silvan ilçesi tünel kesiminden şehir merkezine su temininde kullanılan MAS pompa 150 – 500 tipi NM serisi pompanın bakımı için yapılan demontajı sırasında parça resimleri çekilmiştir. Pompa 60 – 100 metre yüksekliğe 55 – 165 litre/saniye ($200 - 600 \text{ m}^3/\text{h}$) debi ürettiği üretici firma karakteristik eğrilerinde ifade edilmiştir (Anonim, 2018).



Şekil 1.2. Tek kademeli pompa a) salyangoz ve b) fan (Silvan Terfi Merkezi 1 nolu pompa)



Şekil 1.3. Tek kademeli pompa a) gövde kapağı ve b) rulman yatağı (Silvan Terfi Merkezi 1 nolu pompa)

1.2.2. Çok kademeli pompalar

Çok kademeli santrifüj pompalar, su temini terfi tesislerinde, hidrofor, kazan beslenmesi ve iklimlendirme sirkülasyonları gibi basma yüksekliği fazla olan sıvıların taşınmasında kullanılmaktadır. Her bir fan sıvı basıncını artırarak sarmalayan difüzörler vasıtasıyla çıkış flanşına aktarır. Şekil 1.4’de 2 ve 3 kademeli 6 adet grup pompa görülmektedir.



Şekil 1.4. Çok kademeli grup pompa (Bismil Terfi Merkezi 1 nolu pompa, 3 kademeli)

1.2.3. Yatay milli santrifüj pompa



Şekil 1.5. Yatay milli santrifüj pompa (Bismil Terfi Merkezi, B 3’lü grup)

Pompa ve motor milinin konumuna bağlı olarak adlandırılır. Santrifüj pompalar su seviyesinin yüksek olmadığı durumlarda kullanılır. Yatay milli santrifüj pompalar

yer olarak geniş bir alan kaplamakla birlikte balans verilmesi daha kolay ve dikey milli santrifüj pompalara göre problemi daha azdır. Bu nedenle yer problemi olmayan tesislerde genelde yatay milli santrifüj pompalar kullanılmaktadır. Şekil 1.5’de yatay milli santrifüj pompa ve motoru görülmektedir.

1.2.4. Dikey milli santrifüj pompa

Pompa ve motoru milinin dikey konumlandığı santrifüj pompalara denilmektedir. Dikey milli santrifüj pompalar, alan olarak dar olan barajların su alma yapılarında, evlerdeki hidroforlarda, yangın söndürme ve kimyasal madde dozaj sirkülasyon sistemlerinde kullanılmaktadır.

1.3. Yatay Milli Santrifüj Pompa Elemanları

1.3.1. Yatay milli santrifüj pompa mili

Elektrik motorundan aldığı tahriki kaplin vasıtasıyla santrifüj pompanın içindeki fan, sabitleme kama yuvası, yataklama rulmanı ve salmastra kovani, fan sabitleme bileziği üzerinde pompa gövdesinin içinde dönen uzun parçaya denmektedir. Santrifüj pompaların mili çelik malzemeden yapılmaktadır. Basma yüksekliğini artırmak için pompa kademe sayısının artırılması gerekmektedir. Kademe sayısının artırılması mil uzunluğunun artırılması neden olmaktadır (Şekil 1.6).



Şekil 1.6. kademeli pompa mili (Bismil Terfi Merkezi 5 nolu pompa)

1.3.2. Fan

Pompa gövdesinin içinde mil üzerine kama ile sabitlenen tek kademeli pompalarda salyangozun içerisinde ve çok kademeli pompalarda difüzör içerisinde yer almaktadır. Yan orta kısmındaki kanatçıklar ile giriş flanşından vakumlama yaparak ve üst kısmındaki kanatçıklar ile çıkış flanşına basınçlı itme sağlayarak balanslı çalışması gereken, eni dar yuvarlak ve çark malzemesi olarak ise dökme demir, alüminyum ve bronz malzemelerden oluşmaktadır.



Şekil 1.7. Yatay milli santrifüj pompa fanı a) arızalı ve b) sağlam (Bismil Terfi Merkezi 5 nolu pompa)



Şekil 1.8. Tek kademeli yatay milli santrifüj pompa montajı (Dicle Pompa İstasyonu, 4.000 kW)

Şekil 1.8’de gösterilen tipine ve uygulama alanına göre yılda 10 - 25 arasında değişebilmekte olan ekonomik (faydalı) ömrünü yüksek bir performansla tamamlayabilmesi için fandaki titreşim ve gürültü düzeylerinin belirli sınırlar arasında olması gerektiği ifade edilmektedir. Şekil 1.7’de gösterilen fanlarda erken uyarıcı dinamik

bakım yöntemi kullanılarak oluşabilecek gürültü problemlerinin teşhis ve çözülmesi deneysel olarak da yapılabilmektedir.

1.3.3. Rulman(Bilye)



Şekil 1.9. Bismil Terfi İstasyonu A3 nolu pompa rulmanı a) Arızalı ve b) Sağlam

Pompa gövdesinin içinde milin dönerken sürtünmesini azaltmak için yatak ile mil arasına bırakılan dış bilezik ile gövde yatağına temaslı iç bilezik ile mile temaslı yuvarlanma yolundaki bilyelerden adını almaktadır. Şekil 1.9’da gösterilen rulman malzemesi olarak genelde karbon ve krom ile zenginleştirilmiş çelik kullanılmaktadır.

1.3.4. Pompa gövdesi

Elektrik motorunun rotorundan kaplin vasıtasıyla alınan dönme hareketini içerisinde bulunan dönen mil ve üzerinde iki adet rulman(ön ve arkada yataklar içerisinde) ve basma yüksekliğine göre dizayn edilmiş kademe sayısı kadar fan bulunan parça olduğu, Şekil 1.10’da gösterilen pompa gövdesinin ön yan kısmında ön rulman yatak, verici gövde, kademe gövdeleri, alıcı gövde ve dış rulman yatağı bulunan pompa parçası olarak ifade edilmektedir.



Şekil 1.10. Bismil Terfi Merkezi A1 1 nolu 3 kademeli pompa gövdesi

1.4. Bakım Yönetimi

Bakım yönetimi genel olarak üç başlık altında toplayabiliriz:

Düzeltilici bakım, yalnızca bir ekipman çalışmayı durdurduğunda gerçekleşir. Bu, bakım yaptırmanın en kolay yoludur. Çünkü hem üretimin durdurulması hem de değiştirilecek parçaların onarımı gereklidir ve bu da sürece doğrudan bir maliyet eklemektedir (Carvalho ve ark., 2019).


Önleyici Bakım (PvM), zamana dayalı bakım veya planlı bakım, proses/ekipman arızalarını tahmin etmek için planlı bir zaman çizelgesi veya proses yinelenmeleri ile periyodik olarak gerçekleştirilen bir bakım tekniğidir. Başarısızlıkları önlemek için genellikle etkili bir yaklaşımdır. Bununla birlikte, gereksiz düzeltici faaliyetler yapılır ve bu da işletme maliyetlerinde artışa neden olur (Carvalho ve ark., 2019). Bu yöntem işletmelerde çok kullanılan bakım yöntemidir. Önceden belirlenmiş program çerçevesinde makinenin hangi zaman aralıklarında durdurularak bakıma alınacağı belirlenir. Böylece üretim duruşlarına veya yıpranmalara neden olabilecek durumları ortaya çıkarmak için ekipman veya tesislerin periyodik olarak bakımının yapılması gerekmektedir (Tatar, 2010).

Kestirimci Bakım (PdM), bakım eylemlerinin ne zaman gerekli olduğunu belirlemek için tahmine dayalı araçlar kullanır. Bir makinenin veya proses bütünlüğünün sürekli izlenmesine dayanır ve bakımın yalnızca ihtiyaç duyulduğunda yapılmasına olanak tanır. Ayrıca sistem, geçmiş verilere dayalı araçların kullanılmasıyla mümkün olan bir süreç olan arızaların erken tespit edilmesini sağlar. Sistem bütünlük

faktörlerini, istatistiksel çıkarım yöntemlerini ve mühendislik yaklaşımlarını kullanmaktadır (Carvalho ve ark., 2019).

1.5. Yapay Zekâ

İnsan beynini modelleyen yapay zekâ çalışmaları tahmin, sınıflandırma ve kümeleme gibi amaçların yanı sıra günlük hayatın çeşitli alanlarında ürün sağlamak için de kullanılmaktadır. Genel anlamda yapay zekâ, insan zekâsının, sinir sistemi gibi fizyolojik ve nörolojik yapıların, genetik yapının ve doğa olaylarının modelleme yoluyla makinelere aktarılması olarak ifade edilmektedir. Özetle yapay zekâ, “insan gibi düşünen, insan gibi davranan, rasyonel düşünen ve davranan” olarak tanımlanabilir (Balaban ve Kartal, 2015: 16) ve zeki kabul edilen bir canlının davranışlarına sahip olan bir bilgisayar sistemi olduğu ve makine öğrenmesi bu anlamda yapay zekânın son aşaması olarak kabul edilmektedir (Atalay, 2017). Yapay zeka ile öğrenme modellerinden makine öğrenme ve alt kümesi olan sinir ağları üzerine kurgulanmış derin öğrenme modellerinin yöntemlerini kullanarak ses analiz çalışmaları yapılmıştır. Yapay zekâ, makine öğrenmesi ve derin öğrenme kapsamı Şekil 1.11’de verilmiştir.




Şekil 1.11. Yapay zekâ, makine öğrenme ve derin öğrenme ilişkisi

1.6. Makine Öğrenme Modelleri

Makine öğrenmesi, bir bilgisayarın ne yapacağına karar vermesi noktasında insanların net komutlarına ihtiyaç duymaksızın öğrenmesine yardımcı olacak matematiksel modellerin kullanımınıdır. Başka bir deyişle makine öğrenmesini, insanların nasıl öğrendiğinden yola çıkan, verilerdeki kalıpları algoritmalar ile şekillendiren ve böylece tahmin yapabilen veri modeli oluşturan, yapay zekânın bir alt kümesi olarak adlandırılır (Anonim, 2022). Endüstriyel ortamlarda makine sağlığının izlenmesi ve arıza tespiti, makine öğrenimi için en önemli uygulama alanlarından biridir. Ani bir

arıza çok maliyetli olabilir. Genel olarak hata tespiti ve durum izleme çalışmaları veri toplama, özellik çıkarma, özellik seçimi ve özellik sınıflandırma adımlarından oluşur (Huang, 1996).

- Veri toplama: Ekipman durumu ile ilgili sensörlerden veri toplanmasıdır. Bunlar titreşim, gürültü, emisyon vb. verilerdir (Dündar ve ark., 2021).
 - Öznitelik çıkarma: Orijinal sinyaller makine durumunu gösteren istatistiksel parametrelerle eşleştirilir. Sinyal öznitelikleri, zaman domeni, frekans domeni ve zaman - frekans domeninden çıkarılabilir (Dündar ve ark., 2021).
 - Öznitelik seçimi: Özellik seçimi aşamasında özelliklerin alt kümeleri doğruluktan ödün verilmeden seçilmektedir. İlgisiz veriler silinerek yüksek boyut indirgenmesi ve doğruluk değerinin bulunması hedeflenmektedir. (Tunç ve Ülger, 2016). Büyük veri setine sahip özellik kümesi hesaplama süresini artırır ve çözümü zorlaştırır. Bu veri kümesi içerisinde seçim ile hesaplama yapmak süreyi azaltmaktadır. Seçimde kullanılan en yaygın tekniklerden biri PCA (Temel Bileşen Analizi) dır (Malhi ve Gao, 2004).
 - Öznitelikler sınıflandırma: Sınıflandırıldıktan sonra arıza tespiti için makine öğrenmesi algoritmaları (KNN, SVM) uygulanmaktadır (Dündar ve ark., 2021).
- Şekil 1.12’de makine öğrenme süreci gösterilmiştir.



Şekil 1.12. Makine öğrenmesi süreci

1.6.1. KNN modeli

KNN (k en yakın komşular), hem sınıflandırma hem de regresyon tahmin analizlerinde kullanılabilen basit ancak etkili bir parametrik olmayan denetimli makine öğrenmesi algoritmasıdır. Sınıflandırılacak veri için k en yakın komşu alınarak bu verinin bir komşuluğu oluşturulur. İşlevselliği yalnızca en yakın komşu sayısının tanımına bağlıdır. Ancak optimum sınıflandırma performansı için uygun k değeri seçilmelidir. Algoritmanın başarılı olabilmesi için k değerinin uygunluğuna göre eğitilmesi gerekmektedir. Daha sonra en iyi başarı yüzdesine sahip k değeri

seçilmelidir. KNN algoritması örüntü tanıma, veri madenciliği, saldırı tespiti, büyük veri işleme ve tıbbi görüntüleme verilerinde başarıyla kullanılmıştır (Guo ve ark., 2003; Xiong ve Yao, 2021).

1.6.2. SVM modeli

Denetimli öğrenme kategorisinde kabul edilen SVM (Destek Vektör Makineleri) modeli, kümeleme algoritmalarından farklıdır. Aykırı değer sınıflandırma, tahmin ve tespit gibi teknikler arasında en etkili yöntemlerden biridir. SVM, veri setlerinin sınıflandırılmasında iki eğitim ve bir test sürecinden geçer. Bu yöntem önceki sınıflandırma yöntemlerine göre üstün performans göstermekte ve operasyonel sınıflandırma riskini azaltmaktadır. Yöntem, kategorizasyon için en iyi bilinen yöntemlerden biri olarak istatistiksel bir model sağlayarak, çekirdek performansının doğrusal bir kombinasyonunu kullanarak ve tahmin modellerinde bir dizi eğitim verisi üzerinde destek vektörleri çalıştırılarak sunulmaktadır. SVM yöntemi, farklı veri setlerinin ayrılmasını optimize edebilen uzayda destek vektör düzlemlerinin oluşturulmasına dayanmaktadır. Bu yöntem, başta makine ve inşaat mühendisliği olmak üzere çok sayıda mühendislik alanında kullanılmaktadır. Diğer yöntemlerle karşılaştırıldığında, kullanımı nispeten kolaydır ve yüksek boyutlu verilerde iyi performans gösterir (Jueyendah ve ark., 2021).

1.6.3. Topluluk öğrenme modeli

Topluluk öğrenme yöntemleri, birçok makine öğrenmesi probleminde en gelişmiş çözümleri temsil etmektedir. Birden fazla modeli eğiterek tahminleri birleştiren ve tek bir model gibi çalışan sınıflandırma ve tahmin modellerini oluşturmaktadır. Denetimli öğrenme uygulamalarında topluluk öğrenme modelleri, uyarıcıları karar verici olarak birleştirerek tek bir çatı altında toplamaktadır. Temel öğrenme unsuru olarak da tanımlanan uyarıcılar, bir grup etiketli sınıf örneğini girdi verisi olarak alan ve örnekleri genelleştiren bir modeldir. Bir Topluluk öğrenme modeli, herhangi bir türdeki makine öğrenme modellerini birleştirebilmektedir. Temel prensibi, birden fazla modeli birleştirmesi ve hataları azaltarak genel tahmin performansını tek bir modele göre iyileştirmesi olduğu bildirilmiştir (Sagi ve Rokach, 2018). Yukarıda incelenen

yöntemlere ek olarak, birkaçının birlikte çalıştırılmasıyla elde edilen Topluluk modeli de kullanılmaya başlanmıştır.

1.7. Derin Öğrenme Modelleri

Çoklu soyutlama seviyelerine sahip verilerin, çoklu işlem katmanlarından oluşan hesaplama modelleri ile temsil edilmesine olanak tanımaktadır. Amaç, adım adım bir program inşa etmek yerine modelin kurguyu oluşturabilmesine zemin hazırlamak ve bu şekilde alternatif senaryolara karşı çözümler üretebildiği ifade edilmiştir (Çakıroğlu ve Süzen, 2020). Derin öğrenme, iç parametrelerin bir önceki katmana göre nasıl değiştirilmesi gerektiğini göstermek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfetmektedir. Derin ağlar görüntü, video, konuşma ve ses işleme alanlarında çığır açmış olduğu bildirilmiştir (LeCun ve ark., 2015).


Derin öğrenme, yukarıda bahsedilen karmaşık doğrusal olmayan süreçlerin çoklu katmanlarından oluşmaktadır. Her katman bir önceki katmanın çıktısını girdi olarak alır. Her bir katmanı oluşturan süreçler denetimli veya denetimsiz algoritmalar olabilmektedir. Derin öğrenme, verilerin çoklu seviyelerde özelliklerini veya temsillerini öğrenmeye dayalı bir yapıya sahiptirler. Daha yüksek seviyeli özellikler, hiyerarşik bir temsil oluşturmak için daha düşük seviyeli özelliklerden türetilir. Bu temsil, gerektiğinde farklı soyutlama seviyelerine karşılık gelen çoklu temsil seviyelerini öğrenme ve kullanma kapasitesine sahiptir. Derin öğrenme esasen verilerin temsilinden öğrenmeye dayanır. Bir görüntü için temsil, piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller vb. gibi özellikler olabilir. Bu özelliklerden bazıları verileri diğerlerinden daha iyi temsil edebilir. Bu yaklaşımın bir avantajı, derin öğrenme yöntemlerinin el yapımı özellikler yerine verileri temsil etmek için en uygun olan verimli hiyerarşik özellik çıkarma algoritmalarını kullanmasıdır. (Anonim, 2022). Şekil 1.13’de derin öğrenme sürecini göstermektedir.



Şekil 1.13. Derin öğrenme süreci

1.7.1 1D CNN modeli

CNN (evrişimsel Sinir Ağları) mimarilerinin büyük veri setleri üzerinde iki boyutlu görüntüleri eğitmedeki başarısı ve görüntülerden elde edilen verilerin bolluğu göz önüne alındığında, ses ve titreşim sinyallerinin oluşturduğu tek indeksli matrislerin analizi için 1D CNN mimarisi önerilmiştir. Hastaya özgü EKG (Elektrokardiyogram) sinyalleri üzerinde çalışmak üzere uyarlanmış bir 1D CNN mimarisinin etkinliği gösterilmiştir. Sınırlı veri, eğitimde kullanılan bilgisayarların sınırlı kapasitesi ve sinyallerin oluşturduğu veri kümeleri göz önüne alındığında sonuçlar daha kısa sürede elde edilmiştir. EKG sinyal işlemenin yanı sıra yapısal sağlık uygulamalarında ve yapısal hasar teşhisinde de kullanılmıştır. Ayrıca, derin ağlardan oluşan 1D CNN mimarileri, yüksek güçlü motor arıza sistemlerinde rulman arızalarını tespit etmek, sınıflandırmak ve ölçmek için kullanılmıştır (Kiranyaz ve ark., 2021). 1D CNN'in örnek diyagramı Şekil 1.14'de gösterilmiştir.




Şekil 1.14. 1D CNN Modeli örnek diyagramı

1.7.2. 2D CNN modeli

Görüntü sınıflandırmada kullanılan 2D CNN modeli, bir evrişim katmanı, bir havuzlama katmanı ve bir tam bağlantı katmanından oluşan çok katmanlı bir sinir ağı modelidir. Evrişim katmanları, her biri küçük ağırlıklı matrislerden ve N filtreden oluşan bir giriş görüntüsünün doğrusal olmayan Relu aktivasyon fonksiyonu ile evrişim sonucu elde edilen çıkış verilerini işleyerek N adet özellik haritası oluşturur. Gereksiz bilgi içeren özellik haritaları, ortalama havuzlama veya maksimum havuzlama


katmanında ortalama veya maksimum değeri hesaplanarak küçük matrislere dönüştürülür. Bu süreçlerin oluşturulmasında ezberci öğrenmenin önüne geçmek için veri düşürme değeri kullanılır. Veri düşürme değerine göre verilerin bir kısmı elenmektedir. Nihai veriyi düzgünleştirmek için tam bağlantı katmanı kullanılır ve sinir ağlarından geçirilerek sınıflandırma yapılır (Yang ve ark., 2018). 2D CNN'in örnek bir diyagramı Şekil 1.15'de gösterilmiştir.



Şekil 1.15. 2D CNN Model örnek diyagramı


1.8. Öz niteliklerin Çıkartılması

Öznitelik çıkarma, ses sinyallerinin işlenmesinin çok önemli bir yönü olduğu bildirilmektedir. Ses sinyallerini zamansal, spektral ve prozodik gibi üç özellik kategorisine ayrılmaktadır. Ses sinyalleri, sınıflandırma sistemlerinde özellik uzayında bir vektör tanımlamak için çıkarılan ve kullanılan çok sayıda özellikten oluştuğu, zamansal özellikler veya zaman içindeki genlik dalgalanmaları, başlangıçta veri olmadan doğrudan ilk sestene elde edildiği ifade edilmiştir. Genlik-zaman (Şekil 1.16), Mel-spektrogram (Şekil 1.17), MFCCs (Mel-Frekans Cepstral Katsayıları) (Şekil 1.18), ZCRs (Sıfır geçiş oranları) (Şekil 1.19) ve RMS (Ortalama enerji karekökü) Enerjisi (Şekil 1.20) gibi özellik çıkarma yöntemleri kullanılmaktadır.




Şekil 1.16. Genlik(Amplitude) zaman diyagramı

Ses genellikle genlik ve zamanın iki boyutlu bir temsili olan bir hava dalgası olarak görselleştirilir. Ses, zamanla değiştiği için bir ses sinyalinin frekans spektrumu olarak da temsil edilebildiği ve buna spektrogram dendiği bildirilmiştir. FFT (Hızlı Fourier dönüşümü) kullanılarak bir zaman sinyalinin bir ses spektrogramı oluşturulabildiği ifade edilmiştir. "Mel" melodinin kısaltması olduğu, bunun, perdelerin karşılaştırılmasına dayanan algısal bir ölçek ölçümü olduğunu ima edilmiştir (Tran ve Lundgren, 2020).




Şekil 1.17. Mel spectrogram diyagramı

MFCCs, insan kulağının çalışma şekline benzer bant genişlikleri kullandığı, ses örnekleri üzerinde bir Fourier dönüşümü gerçekleştirdikleri ve elde edilen spektral güçleri mel ölçeğine yansıttıkları, mel frekanslarında bu değerleri içeren logları hesapladıkları ve bu frekanslar bir sinyal olarak kullanılarak, ayrık kosinüs dönüşümünden geçirilerek MFCCs oluşturulduğu bildirilmiştir (Prashanth ve ark., 2024).




Şekil 1.18. MFCCs diyagramı

ZCR'ler, genlik tabanlı özellikler ve güç tabanlı özellikler dahil olmak üzere çeşitli özellik türlerinden oluşturulduğu, bu özellikleri kullanarak ses sinyallerini işlemek nispeten kolay olsa da, genellikle spektral özelliklerle birlikte kullanıldığı, bir ses çerçevesinin ZCR'leri, ses sinyalinin birim zamanda sıfırı geçme sayısı veya alternatif olarak ses sinyalinin işaretindeki değişikliklerin sayısı olarak tanımlandığı ifade edilmiştir (Babae ve ark., 2017).




Şekil 1.19. ZCRs diyagramı

RMS Enerji, bir sinyaldeki enerjiyi ölçmek için kullanılan bir yöntem olduğu, genliğin karelerinin toplamının karekökü alınarak hesaplanmaktadır. RMS Enerji, çerçevedeki tüm örneklerin kök-ortalama-kare değeri olduğu dile getirilmiştir. Aynı zamanda ses yüksekliğinin bir göstergesi, ancak aykırı değerlere karşı daha az duyarlı olduğu, RMS Enerjisinin çıkarılması çoğunlukla ses segmentasyonu ve müzik sınıflandırması için kullanıldığı vurgulanmıştır (Underwood ve Tashakkori, 2022).



Şekil 1.20. RMS enerji diyagramı

Şekil 1.21’de Python dili kullanılarak librosa kütüphanesine yüklenen ses, sinyal örnekleme frekansı belirlendiği, her bir örnek kısa sürelerle işlendiği, sonra FFT uygulandığı, Mel ölçeğinde ölçeklendirildiği, filtre bankası ölçeğinde logaritmik dönüşüm uygulanarak çıktı kepsstral katsayısı olarak adlandırıldığı ifade edilmiştir.




Şekil 1.21. MFCC özellik çıkarma adımları

1.9. Amaç

Literatürde yatay milli santrifüj pompalar ile ilgili genelde tekil olarak rulman titreşim ve ses analizi ile ilgili ve de motor soğutma fan ses analizleri ile ilgili çalışmalar bulunmaktadır. Bu incelemede yatay milli santrifüj pompalar ile ilgili hem rulman ve hem de fan gürültü analizinin beraber incelendiği arıza teşhisi ile ilgili bir çalışma yapılmıştır. Bu çalışmada şehir içme suyu terfi merkezinde bulunan dört ve altı tonluk iki ayrı depoyu besleyen su alma yapısı incelenmiştir. Bu su alma yapısında birer adedi yedek üçer adet pompadan oluşan 90 ve 132 kW gücünde motorlar tarafından tahrik edilen, 2 ve 3 kademeli altı adet pompa ses analizleri yapılmıştır. 01 Eylül 2023 ile 5 Ocak 2024 tarihleri arasında haftalık periyodik zaman diliminde her Cuma günü ses dinleme kayıtları alınmıştır. Bu çalışmada önce pompa fan dış sesi, pompa ön rulman, pompa elektrik motoru ön rulman, pompa elektrik motoru fan-rulman ve pompa arka rulman seslerinin pompa dışından kayıt cihazı yardımı ile ses dinlemesi yapılmıştır. Daha sonra bilgisayara aktarılarak tarih sırasına göre dosyalanmıştır. Yapılan çalışmanın ana hedefi, yerleşim yerinin içme suyu ihtiyacını karşılayan Şekil 1.22’de gösterilen yatay milli santrifüj pompaların elektrik motoru yanmasının dışında en fazla karşılaşılan pompa arızası durumlarından olan ve pompanın en önemli iki elemanı arızasının ses analizinden tespit edilip edilemeyeceğinin incelenmesi amaçlanmıştır.

Hem çalışma ortamındaki istenmeyen gürültüyü ortadan kaldırmak hem de tekil arızanın başka yerlere sirayet etmeden ortadan kaldırılmasını sağlanması amaçlanmıştır.



Şekil 1.22. Yatay milli 3 kademeli snatrifüj pompa önden görünümü

2. KAYNAK ARAŞTIRMASI

Alan Turing 1950'de, "Makine düşünebilir mi?" ve "Bilgisayarlar ve Zekâ" adlı ünlü Turing testini ortaya atmıştır. O zamandan beri, akademik topluluklar makine düşüncesi konusunu tartışmaya başlanmış ve 1956'daki Dartmouth toplantısı "yapay zekâ" kavramının doğuşuna işaret etmiştir. Şu anda yapay zekâ yavaş yavaş ticari uygulama aşamasına girmekte ve her alanda kullanımı yaygınlaşmaktadır. Yapay zekâ, insan üretimine ve yaşam alanına tamamen girerek yeniden şekillenmektedir. Akıllı robotlardan, akıllı evlerden insansız araçlara ve insansız fabrikalara kadar yapay zeka teknolojisi, sosyal yaşamın ve üretimin çeşitli alanlarında yaygın olarak kullanılmakta, geleneksel bilişimizi tarım, imalat ve kolluk kuvvetlerinin geleceğine değiştirmekte ve hatta altüst etmektedir (Liu ve ark. , 2017).

Endüstriyel sistemler tarafından toplanan büyük miktarda verinin, bir endüstriyel üretim hattı boyunca meydana gelen süreçler, olaylar ve alarmlar hakkında değerli bilgiler sağlayabileceğini belirtmek gerekir. Ayrıca, bu veriler işlenip analiz edildiğinde, üretim süreci ve sistem dinamikleri hakkında içgörüler ortaya çıkarabilir. Verilere dayalı analitik yaklaşımlar uygulayarak, stratejik karar verme için yorumlayıcı sonuçlar bulmak mümkündür ve diğerlerinin yanı sıra bakım maliyetinin azaltılması, makine arızalarının azaltılması, onarımın durması, yedek parça envanterinin azaltılması, yedek parça ömrünün artırılması, üretimin artması, operatör güvenliğinde iyileşme, onarım doğrulaması, genel kâr gibi avantajlar sağlar (Perez ve ark., 2018).

Bir miktar titreşim ve gürültünün mekanik ve hidrolikten meydana gelen dinamik kuvvetler nedeniyle mutlaka olacağını bildirilmiştir. Bu nedenle titreşim ve gürültünün kabul edilebilir durumda tutulması gerektiğini ifade edilmiştir (Birajdar ve ark., 2009). Titreşimler temel olarak bir kütlenin statik konumundan ileri geri yer değiştirmesidir. Bir kuvvet bir titreşime neden olur ve bu titreşim hızlanma, hız veya yer değiştirme açısından tanımlanabilir. Titreşime neden olacak kuvvetin yapının kütle, sertlik ve sönümleme özelliklerinin üstesinden gelmesi gerektiğine dikkat etmek önemlidir. Bu özellikler yapının doğasında vardır ve makinenin malzemelerine ve tasarımına bağlı olacaktır. Gürültünün de titreşimlerin potansiyel sonuçlarından biri olduğunu belirtmek gerekir. Her iki durumun da santrifüj pompanın performansını ve hizmet ömrünü etkileme potansiyeline sahip olduğu görülmektedir (Birajdar ve ark., 2009).

Günümüzde, yapay zeka yeteneklerine sahip akıllı sistemler genellikle makine öğrenimine dayanmaktadır. Makine öğrenimi, analitik modelleme sürecini otomatikleştirmek ve ilgili görevleri çözmek için sistemlerin probleme özgü eğitim verilerinden öğrenme yeteneğini tanımlar. Derin öğrenme, yapay sinir ağlarına dayalı bir makine öğrenimi yaklaşımıdır. Yüzeysel makine öğrenimi modellerinden ve geleneksel veri analizi çalışmalarından çok sayıda uygulama için derin öğrenme modelleri daha iyi performans gösterir (Janiesch ve ark., 2021).

Üretim süreçlerinde algılama teknolojisinin kullanımı yaygınlaşmıştır. Bu teknolojiye en önemli etkenler verileri not etmek ve bu bilgilerin analizini çıkarmaktır. Bu analizlerden çalışma süresini ve verimliliği etki eden nedenleri tespit etmektir. Makine Öğrenme Metodu kullanılarak Kestirici Bakım uygulamaları değerlendirilerek üretim aşamasındaki kapanmalardan kaynaklı üretim kayıplarının önüne geçilebilir (Carvalho ve ark., 2019).

Makinelerin çalışırken çıkardıkları sesler genellikle çalışma durumunu yansıtır. Belirli bir çevrimde çalışan makinelerin veya makine elemanlarının çıkardığı sesler o makinenin ses karakteristiğini oluşturur. Makinenin durumundaki değişiklikler bu özyapıyı değiştirir ve makinenin çalışma durumunda ne tür bozuklukların ya da arızaların meydana geldiğini gösterir. (Ersoy ve Özdemir, 2011).

Dijital ses kaydı ile bilgisayar ortamına aktarılan ses sinyalleri, ses analiz programları kullanılarak görselleştirilebilmektedir. Bu sinyallerin genliklerinin zaman içindeki değişimleri incelenerek, makinelerin arıza ve normal çalışma koşullarındaki akustik profilini belirlemek mümkündür. (Ersoy ve Özdemir, 2011).

Endüstri 4.0 ortamında bakım, bireysel varlıkların arıza sürelerini önlemekten çok daha fazlasını yapmalıdır. Kestirimci bakım, çalışma süresini %10-20 artırırken, genel bakım maliyetlerini %5-10 ve bakım planlama süresini de %20-50 azaltır. Ayrıca, artan ara bağlantı ve bilgi toplama, işleme ve analiz etme konusundaki yeni fırsatlar nedeniyle, tahmine dayalı bakım çok güçlü bir strateji olabilir (Mourtzis ve ark., 2020).

Üretim yaşam döngüsünün bir parçası olarak endüstriyel ekipmanların bakımı, toplam üretim maliyetinin %60-70'ine yaklaşmaktadır. Bu nedenle, makine bakım işlemlerini kısa sürede tahmin edebilmek ve gerçekleştirebilmek, başarılı sorun gidermeye yol açabilir ve aynı zamanda takım tezgahlarının kullanılabilirliğini artırabilir (Mourtzis ve ark., 2016). Tesisin toplam üretim kabiliyetini %5 ile 20 arasında azaltan etkenin yetersiz bakım teknikleri olduğunu ifade etmiştir (Wollenhaupt, 2016).

Geleneksel olarak bakım uzmanları, potansiyel sorunları önceden tahmin etmek ve üretim tesislerindeki arıza süresini azaltmak amacıyla hem niceliksel hem de niteliksel çeşitli teknikleri birleştirirler. Kestirimci bakım, onlara bakım görevlerini gerçek zamanlı olarak optimize etme potansiyeli vererek, operasyonların kesintiye uğramasını önlerken ekipmanlarının kullanım ömrünü en üst düzeye çıkarma potansiyelini verir. Son araştırmalar ayrıca planlanmamış kesintilerin küresel üreticiler için yılda 50 milyar ABD Doları tutarında bir tahminle maliyetli olduğunu göstermektedir (Coleman ve ark., 2017).

Rulmanların bilgileri ve sinyal izleme durumları hakkında bilgi vererek, sinyal ölçme ve tespitinde kullanılan üç aşama hakkında deney izlemesinde bulunmuşlardır. Bu aşamaları 2001 yılı öncesi, 2001 – 2010 yılları arası ve 2011 yılından sonraki teşhis olarak ayırmışlardır. Gelişmiş zaman yani 2011 sonrasını da birden fazla aralığa ayırarak avantaj ve dezavantajlarını tartışmışlardır (Rai ve Upadhyay, 2016)

Yapay zekânın bir alt kümesi olan makine öğrenimi, bilgisayar sistemlerinin deneyimlerden öğrenmesini ve zaman içinde performanslarını geliştirmesini sağlar. Makine öğrenimi, makineye veri kümeleri sağlayarak ve bunları belirli algoritmalar kullanarak işleyerek, sistemin belirli bir hedefe ulaşmak için bir işlevi yerine getiren bir mantık geliştirmesine olanak tanır. Makine öğrenimi algoritmaları sınıflandırma, kümeleme, transkripsiyon, makine çevirisi ve anormallik tespiti gibi çeşitli görevlere uygulanabilir. Kestirimci bakım bağlamında makine öğrenimi yöntemleri, üretim hatlarındaki ekipman arızalarını önlemek için umut verici çözümler sunmaktadır. Geleneksel araçları kullanarak yakalamamanın zor olabileceği veriler içindeki karmaşık ilişkileri ortaya çıkarabilirler. Makine öğrenimi, yaklaşımakta olan arızaların tespit edilmesini sağlar ve bir makinenin durumu hakkında daha doğru tahminler sağlayabileceğini ifade etmişlerdir (Wagner ve Rondinelli, 2016).

CBM (Koşula dayalı izleme), birçok endüstriyel uygulamanın makine arızalarını operasyon sırasında erken tespit etmesi için yaygın bir tarz olduğunu bildirmişlerdir. Bu alandaki kapsamlı bir araştırma, rulman arızalarının sağlam tespiti ve sınıflandırılmasına odaklandığını ifade etmişlerdir. Yuvarlanma elemanı yatakları, mekanik güç iletim sistemleri de dahil olmak üzere birçok endüstriyel makine türünde kilit bir bileşen olduğu ve dönen makinelerin güvenilirliği açısından en kritik bileşenler arasında yer aldığını dile getirmişlerdir. Küçük rulman arızaları bile endüstriyel makinelerin beklenmedik davranışlarına neden olarak uzun duruş sürelerine yol açarak

ekonomik kayıplara veya en kötü durumda insan yaralanmalarına neden olabileceği söylemişlerdir (Sohaib ve ark., 2017).

Pompaların balanslı bir şekilde çalışabilmesi için rulmanların oldukça ehemmiyet arz ettiği, sistemi bilen herkes tarafından bilinmektedir. Pompaların sağlıklı çalışması için rulman arızalarının erken tespit etmek zaman ve ekonomik açıdan önemli olduğu bildirilmiştir. Plastik kafesli 6208 tipi bir rulmanda meydana getirilen arızaların gürültü ölçme kullanılarak incelemesi yapılmıştır. İç bilezik yuvarlanma kısmı, dış bilezik yuvarlanma kısmına hasar verilerek gürültü ölçümü deneyleri yapılmıştır. Ses gücü miktarı, ses şiddeti miktarı, ses basınç miktarları incelenmişlerdir. Sağlıklı ve hasarlı iki tip rulman gürültü değerleri dB (desibel) olarak karşılaştırılması çalışmaları yapılmıştır (Demir ve Müştak, 2021).

Makine arızalarına neden olabilecek parametrelerin, dönen makine parçaları olarak ifade etmişlerdir. Buradaki yatakların en önemli elemanı olan rulmanların arızalarının ciddiyle takibi teknikleri makine arızasını önleyebilir. Titreşim kaynakları ve ölçümleri tekniği özerinde önemli çalışmalarda bulunmuşlardır (Gupta ve Pradhan, 2017).

Makaralı rulmanlarda makine titreşimleri ve yapı kaynaklı sesler incelenerek değerlendirdiklerini ayrıca sızıntı izleme, emme ve çıkış basıncı, hareket gücü, akış hızı gibi ölçütleri de değerlendirmelerine kattıklarını bildirmişlerdir. Yatay santrifüj pompalarda yeni çıkabilecek hataları bu değerlendirmelerinde elde ettikleri titreşim analizi ve akım sinyallerini kullanarak kestirebileceklerini aktarmışlardır (Albraik ve ark., 2012).

Endüstri sektöründe kullanılan makine fanlarının devre dışı kalması üretimdeki ekonomik açıdan çok kritik kayıplara neden olur. Bu makinelerin dönen elemanı olan fanın arızalanmadan tetkik etmek gerektiğini deneylerinde incelemişlerdir (Gong ve ark., 2018). Makine arıza tespitinde ehemmiyet verdikleri sinyalleri ayırma ve ortaya çıkarmak için Fouriyer dönüşümü ve Filtrelemeye dayanan Kurtogram kullanmışlardır. Kısa süreli bu sinyal ve filtrelemeler ile arıza tespiti durumunu iyileştirildiğini bildirmişlerdir (Lei ve ark., 2011). Bir jeneratörde kullanılan rotorun soğutulması için kullanılan fanın rotor ve stator arası sıcaklıktan arızalanmasına ve büyük mali külfetler getirmesini önlemeyi çalışmışlardır. İncelemelerinde soğutmada kullandıkları fan kanatları kırılma incelemesinde bulunarak hata incelemesi ve bu kırılmaları önlemek için yaptıkları incelemeleri paylaşmışlardır (Torshizi ve ark., 2009).

3 metre apındaki bir kocaman Radyal fanın alıřmasında deneysel ve sayısal lmlerle hata durumları gzlemleyerek meydana gelen fazla gerilimlerden titreřim tanısı lm iin deneysel alıřmalarda bulunmuřlardır. Hurda erimesinde kullanılan iki adet fandan birinin daha fazla titreřimden dolayı arızası analiz etmiřlerdir. Arızalı fanın aşırı titreřiminden dolayı bina kaidesinde hasarlara neden olduėu, deneysel ve sayısal lmlerle beraber operasyonel mdahaleler yapılarak yaptıkları alıřmaları aktarmıřlardır (Trebuna ve ark., 2014).

Planlı ve zamanında yapılan bakım faaliyetleri ile řirketlerin verimli ve etkin bir řekilde alıřması mmkndr. Planlı bakım faaliyetleri, ekipman kapasitesinin daha iyi kullanılmasını saėlar ve ekipman duruř srelerini azaltır. Bakım planlaması, nceden planlanmış bakım faaliyetlerinin belirlenen zamanlarda, iyi tanımlanmış yntemler kullanılarak, ekipman arızası meydana gelmeden nce gerekleřtirilmesini saėlar (Tatar, 2010).

Zamana dayalı havayolu bakım planlaması, arıza tahminlerini hesaba katmamakta, ancak sabit zaman aralıklarında gerekleřmektedir. Bu, gereksiz bakım mdahalelerine ve ayrıca bileřenlerin tasarlanan arıza riskini aşmalarına raėmen hizmet dıřı bırakılmadıėı durumlara neden olabilir. Bu sorunu ele almak iin, bir bileřenin/sistemin gelecekte ne zaman arıza riski altında olacaėını tahmin edebilen ve bu nedenle bakım nlemlerinin ne zaman alınması gerektiėi konusunda tavsiyede bulunabilen bir ereve nerilmektedir (Baptista ve ark., 2018).

Arıza teřhisi, izleme verileri ile makinelerin saėlık durumları arasındaki iliřkinin izlenmesinde nemli bir rol oynar ve bu da makine saėlıėı ynetiminde yaygın olarak endiře duyulan bir konudur. Geleneksel olarak, iliřki bol miktarda deneyim ve mhendislerin byk uzman bilgisi ile yakalanır. rneėin, deneyimli bir mhendis, anormal sese baėlı olarak motorların arızalarını teřhis edebilir veya titreřim sinyallerini analiz etmek iin geliřmiş sinyal iřleme yntemlerini kullanarak yatak arızalarını tespit edebilir. Bununla birlikte, mhendislik senaryolarında, makine kullanıcıları bakım dngsn kısaltmak ve teřhis doėruluėunu artırmak iin otomatik bir yntem ister. zellikle, yapay zekanın yardımıyla, arıza teřhisi prosedrnn, makinelerin saėlık durumlarını otomatik olarak tespit edecek ve tanıyacak kadar akıllı olması beklenmektedir (Lei ve ark., 2020).

Arařtırmalar, arızalı rulmanların elektromanyetik tahrik sistemlerindeki arızaların yzde 40 ila 70'ine neden olduėunu tahmin etmektedir (Bell vd, 1985; Heng vd., 2009; Lee vd., 2011). Bu nedenle, yuvarlanma elemanlı rulman arızalarının

varlığını ve ciddiyetini doğru bir şekilde tespit etmek ve teşhis etmek çok önemlidir (Mueller ve ark., 2023). Dönen makinelerdeki arızaları teşhis etmenin bir yöntemi olarak, rulmanlar tarafından üretilen akustik sinyallerdeki değişikliklere dikkat edilmektedir. Ses sinyalleri rulman yatağından belirli bir mesafede ölçülebildiğinden, bu durum sensörlerin kurulumunu basitleştirme avantajına sahiptir. Bununla birlikte, sinyal-gürültü oranı titreşim ivmesine kıyasla düşüktür, bu da normal ve arızalı rulmanlar tarafından üretilen ses sinyalleri arasındaki herhangi bir karakteristik farkın belirlenmesini zorlaştırır. Bu raporda, ses sinyallerini şematik bir gösterimle görselleştiren SDP (Simetrik Nokta Deseni) yöntemi açıklanmaktadır. Fanlar için ölçülen ses sinyallerini görselleştirmek için SDP kullanılarak, normal ve arızalı rulmanlar arasındaki farkları ayırt etmek mümkün olmuştur. Buna ek olarak, ses sinyallerini zaman-frekans alanında analiz ederek ve dalgacık analizi kullanarak, bir arızanın göstergesi olan sinyal bileşenini tanımlamak mümkün olmuştur. Ses sinyalleri yukarıdaki bileşen çıkarılarak modifiye edildiğinde, modifiye edilmiş arızalı sinyal ile SDP arızalı olmayan duruma benzer olmuştur (Shibata vd., 2000).

Gürültü ölçümünün amacı bir işyerindeki gürültü seviyelerinin istenilen sınırlar içinde olup olmadığını kontrol etmek olduğuna göre, gürültü kaynağından istenilen mesafelerde yapılacak gürültü ölçümleri, frekans analizleri ile birlikte gürültü kontrol çalışmalarında istenilen amaca ulaşılmasını sağlayacaktır. Bunun nedeni, gürültünün çalışanlar üzerindeki etkisinin gürültü kaynağı ile alıcı arasındaki mesafeye bağlı olmasıdır. Bu mesafe arttıkça gürültüyü oluşturan ses dalgaları hızla zayıfladığı için gürültü seviyesi düşmektedir (Ertürk, 2001).

Yapay zekâ kavramından ilk kez 1956 yılında Dortmund Konferansı'nda John McCarthy, Marvin L. Minsky, Nathaniel Rochester ve Claude E. Shannon tarafından sunulan bir öneri mektubunda bahsedilmiştir. Ancak kavramın mucidi olarak John McCarthy kabul edilmektedir (Alpaydın, 2013). 1980'li yıllar, bilgisayarların bilgi depolama ve işleme işlevlerinin yanı sıra bilgiler arasında ilişki kurabildiği bir dönemdi. Bu dönemde geliştirilen algoritmik yapılar ve birçok kurum ya da kuruluşun sağladığı fonlarla, daha önce depolanmış ya da kullanılmış bilgilerin yeni deneyimlerde kullanılması olarak tanımlanabilecek bir teknik olan 'derin öğrenme', John Hopfield ve David Rumelhart tarafından yapay zekâ alanına kazandırılmıştır. Aynı dönemde Edward Feigenbaum da uzman insanların karar verme mekanizmalarına benzer bir süreci taklit edebilen 'uzman sistemler' programını geliştirmiştir (Arslan, 2020).

Yapay zeka 21. yüzyılda, diğerlerinin yanı sıra mühendislik, bilim, eğitim, tıp, işletme, muhasebe, finans, pazarlama, ekonomi, borsa ve hukuk gibi tüm alanlarda önemli bir araştırma alanı haline gelmiştir. Yapay zekâ yelpazesi, makine öğrenme yeteneklerine sahip makinelerin zekâsının iş dünyası, hükümetler ve toplum üzerinde derin etkiler yaratmasından bu yana muazzam bir şekilde büyümüştür. Ayrıca küresel sürdürülebilirlikteki daha büyük eğilimleri de etkilemiştir. Yapay zekâ, sürdürülebilir üretim için kritik sorunu çözmek için yararlı olabilir. Bu bağlamda, akıllı üretimde, daha katı çevre politikaları için yapay zekayı yeşil üretim süreçlerine dahil etme eğilimi vardır (Cioffi ve ark., 2020).

Böylece yapay zekânın makine öğrenimi, doğal dil işleme, görüntü işleme ve veri madenciliği gibi alt alanları da günümüz teknoloji devleri için önemli bir konu haline geldi. Yapay zeka konusu, günümüzde mevcut teknolojilerin sürekli evrimi sayesinde bilim camiasına büyük ilgi uyandırmaktadır (Cioffi ve ark., 2020).

Gürültü, herhangi bir santrifüj pompanın önemli bir kalite ve konfor özelliğidir. Pompalama sistemindeki ani gürültü çoğu zaman pompalama sisteminde oluşan titreşimlerin bir sonucudur. Santrifüj pompalardan ve tahriklerinden belirli bir miktarda gürültü beklenmesine rağmen, genellikle yüksek gürültü seviyeleri (100 db'yi aşan) potansiyel mekanik arıza veya titreşim sorunlarının bir göstergesidir. Santrifüj pompalarda ve sistemlerde gürültü, pompa bileşenlerinin mekanik hareketi ve pompaların ve sistemin sıvı hareketi ile üretilebilir (Brajdar ve ark., 2009).

3. MATERYAL VE YÖNTEM

Pompalar, günlük yaşamımızda su temininde ve endüstriyel çalışmalarda kullanılmaktadır. Kullanma alanı olarak devridaim ve iletim yapmak olarak ifade edilmektedir. Pompalar çalışırken ihtiyaca uygun olarak seçilmesi ve çalıştırırken de bakımının zamanında yapılması önemlidir. Bakımının zamanında yapılması enerji verimliliği ve bakım maliyeti açısından da önem arz etmektedir. İçmesuyu temininde en fazla kullanılan dalgıç pompalar ve yatay milli santrifüj pompalardır. Derin kuyularda dalgıç pompalar ve 6 metreye kadar yüzeysel sularda ise santrifüj pompalar kullanılmaktadır.

Yatay milli pompaların en yaygın kullanılan iki modeli norm tipi ve monoblok yatay milli pompalardır. Suyun hareketini kontrol etmek ve yönlendirmek için oldukça etkili bir yoldur. Şekil 1'de ve serbest ölçekli çizimde gösterilen 3 kademeli yatay milli santrifüj pompanın çalışma koşullarını değerlendirmek için sesler kaydedilmiş ve bilgisayar ortamında analiz edilmiştir.

Bu çalışmada, içmesuyu temininde kullanılan yatay milli santrifüj pompaların en önemli iki parçası olan rulman ve fan kullanılmıştır. Terfi merkezinde kullanılan 3 adet 132 kW'lık ve 3 adet de 90 kW'lık yatay milli santrifüj pompalar 500 metre küp (500 bin litrelik) biriktirme deposunu besleyen 7 adet dalgıç pompa motoru tarafından sağlanan içme suyunu 2.750 metre mesafedeki 81 metre kot farkı olan 6.000 litrelik depo ve 2.225 metre mesafedeki 58 metre kot farkı olan 2 adet 2.000 litrelik su deposunu beslemektedir.

DİSKİ (Diyarbakır Su ve Kanalizasyon İdaresi) Genel Müdürlüğü yetki alanında bulunan Bismil ilçesi terfi merkezinde kapalı alanda bulunan 3 adet 132 kW 3 kademeli(A Grubu) ve 3 adet 90 kW 2 kademeli(B Grubu) yatay milli santrifüj pompaya ait rulman ve fanlarının sesleri 01 Eylül 2023 - 05 Ocak 2024 tarihleri arasında kaydedilmiş ve sınıflandırma modellerinde kullanılmak üzere üç farklı grupta sınıflandırılmıştır. Şekil 3.1'de tez çalışmasına ait terfi merkezindeki 6 adet yatay milli santrifüj pompanın ses kayıt cihazı ile ses kaydı alınma yerleri gösterilmiştir.



a)



b)



c)



d)

Şekil 3.1. Yatay milli santrifüj pompanın ses dinleme noktaları a) Pompa fan b) Pompa ön rulman c) Pompa arka rulman d) Motor fan+rulman

3.1. Deney Sistemi Elemanları

3.1.1. Terfi merkezi pompa teknik bilgileri

Bu tez çalışmasında Diyarbakır İli ve ilçelerinin su ihtiyacını karşılayan santrifüj pompaların ses kayıtları alınmıştır. Şekil 3.2’de Bismil ilçe merkezinde bulunan Diyarbakır Büyükşehir Belediyesi DİSKİ genel müdürlüğüne bağlı terfi merkezinde bulunan 1 nolu (A1) pompasının resmi görülmektedir. Kullanılan pompanın teknik özellikleri ise Tablo 3.1’de verilmiştir. EMTAŞ marka 132 kW gücünde, 3 kademeli, 1450 d/d hızına sahip ve debisi 324 m³/h değerindedir.



Şekil 3.2. Bismil Terfi Merkezi 1 nolu(A1) Pompa

Tablo 3.1. Bismil terfi istasyonu 1 nolu pompa ve motoru etiket bilgileri

Parça adı	Özelliği
Pompa Sıra No	A1
Pompa Motoru Markası	EMTAŞ
Pompa Motoru Gücü	132 kW
Pompa Motor Verimi ($\cos\phi$)	0,87
Pompa Markası	Standart
Pompa Tipi	150 - 3
Pompa Kademe Sayısı	3
Pompa Devir Sayısı	1450 d / d
Pompa Debisi	324 m ³ /h

Şekil 3.3’de Bismil ilçe merkezinde bulunan Diyarbakır Büyükşehir Belediyesi DİSKİ genel müdürlüğüne bağlı terfi merkezinde bulunan 2 nolu (A2) pompanın resmi görülmektedir. Kullanılan pompanın teknik özellikleri ise Tablo 3.2’de verilmiştir. EMTAŞ marka 132 kW gücünde, 3 kademeli, 1450 d/d hızına sahip ve debisi 324 m³/h değerindedir.



Şekil 3.3. Bismil Terfi Merkezi 2 nolu(A2) Pompa

Tablo 3.2. Bismil terfi istasyonu 2 nolu pompa ve motoru etiket bilgileri

Parça adı	Özelliği
Pompa Sıra No	A2
Pompa Motoru Markası	EMTAŞ
Pompa Motoru Gücü	132 kW
Pompa Motor Verimi ($\cos\phi$)	0,87
Pompa Markası	Standart
Pompa Tipi	150 - 3
Pompa Kademe Sayısı	3
Pompa Devir Sayısı	1450 d / d
Pompa Debisi	324 m ³ /h

Şekil 3.4’de Bismil ilçe merkezinde bulunan Diyarbakır Büyükşehir Belediyesi DİSKİ genel müdürlüğüne bağlı terfi merkezinde bulunan 3 nolu (A3) pompanın resmi görülmektedir. Kullanılan pompanın teknik özellikleri ise Tablo 3.3’de verilmiştir. EMTAŞ marka 132 kW gücünde, 3 kademeli, 1450 d/d hızına sahip ve debisi 324 m³/h değerindedir.



Şekil 3.4. Bismil Terfi Merkezi 3 nolu(A3) Pompa

Tablo 3.3. Bismil terfi istasyonu 3 nolu pompa ve motoru etiket bilgileri

Parça adı	Özelliği
Pompa Sıra No	A3
Pompa Motoru Markası	EMTAŞ
Pompa Motoru Gücü	132 kW
Pompa Motor Verimi ($\cos\phi$)	0,87
Pompa Markası	Standart
Pompa Tipi	150 - 3
Pompa Kademe Sayısı	3
Pompa Devir Sayısı	1450 d / d
Pompa Debisi	324 m ³ /h

Şekil 3.5’de Bismil ilçe merkezinde bulunan Diyarbakır Büyükşehir Belediyesi DİSKİ genel müdürlüğüne bağlı terfi merkezinde bulunan 4 nolu (B1) pompasının

resmi görülmektedir. Kullanılan pompanın teknik özellikleri ise Tablo 3.4’de verilmiştir. EMTAŞ marka 90 kW gücünde, 2 kademeli, 1450 d/d hızına sahip ve debisi 82 l/s değerindedir.



Şekil 3.5. Bismil Terfi Merkezi 4 nolu(B1) Pompa

Tablo 3.4. Bismil terfi istasyonu 4 nolu pompa ve motoru etiket bilgileri

Parça adı	Özelliği
Pompa Sıra No	B1
Pompa Motoru Markası	EMTAŞ
Pompa Motoru Gücü	90 kW
Pompa Motor Verimi (cosφ)	0,89
Pompa Markası	MAS
Pompa Tipi	150 – 2
Pompa Kademe Sayısı	2
Pompa Devir Sayısı	1450 d / d
Pompa Debisi	82 l/s

Şekil 3.6’de Bismil ilçe merkezinde bulunan Diyarbakır Büyükşehir Belediyesi DİSKİ genel müdürlüğüne bağlı terfi merkezinde bulunan 5 nolu (B2) pompasının resmi görülmektedir. Kullanılan pompanın teknik özellikleri ise Tablo 3.5’de verilmiştir. EMTAŞ marka 90 kW gücünde, 2 kademeli, 1450 d/d hızına sahip ve debisi 82 l/s değerindedir.




Şekil 3.6. Bismil Terfi Merkezi 5 nolu(B2) Pompa

Tablo 3.5. Bismil terfi istasyonu 5 nolu pompa ve motoru etiket bilgileri

Parça adı	Özelligi
Pompa Sıra No	B2
Pompa Motoru Markası	EMTAŞ
Pompa Motoru Gücü	90 kW
Pompa Motor Verimi (cosφ)	0,89
Pompa Markası	MAS
Pompa Tipi	150 - 2
Pompa Kademe Sayısı	2
Pompa Devir Sayısı	1450 d / d
Pompa Debisi	82 l/s

Şekil 3.7’de Bismil ilçe merkezinde bulunan Diyarbakır Büyükşehir Belediyesi DİSKİ genel müdürlüğüne bağlı terfi merkezinde bulunan 6 nolu (B3) pompasının resmi görülmektedir. Kullanılan pompanın teknik özellikleri ise Tablo 3.6’de verilmiştir. EMTAŞ marka 90 kW gücünde, 2 kademeli, 1450 d/d hızına sahip ve debisi 82 l/s değerindedir.



Şekil 3.7. Bismil Terfi Merkezi 6nolu(B3) Pompa

Tablo 3.6. Bismil terfi istasyonu 6 nolu pompa ve motoru etiket bilgileri

Parça adı	Özellği
Pompa Sıra No	B3
Pompa Motoru Markası	EMTAŞ
Pompa Motoru Gücü	90 kW
Pompa Motor Verimi (cosφ)	0,89
Pompa Markası	MAS
Pompa Tipi	150 - 2
Pompa Kademe Sayısı	2
Pompa Devir Sayısı	1450 d / d
Pompa Debisi	82 l/s

3.2. Ses Dinleme Ölçüm Cihazı

Santrifüj pompalardan seslerin alınmasında Şekil 3.8’de gösterilen ses kayıt cihazı kullanılmıştır. Ses kayıt cihazının teknik özellikleri de Tablo 3.7’de gösterilmiştir.



Şekil 3.8. Ses kayıt cihazı

Tablo 3.7. Ses dinlemesi yapılan cihaz bilgileri

Parça adı	Özellği
Marka	OLYMPUS
Tipi	VN-8700PC
Cihaz adı	DİGİTAL VOİCE RECORDER
Cihaz bellek kapasitesi	
Cihaz depolama alanı	1 GB
Cihaz ekran boyutu	29 x 29 mm / 1.61

3.3. Makine Öğrenme Modelleri

Makine öğrenmesi, insanların nasıl öğrendiğinden yola çıkan, verilerdeki kalıpları algoritmalar ile şekillendiren ve böylece tahmin yapabilen veri modeli oluşturan, yapay zekânın bir alt kümesi olarak adlandırılabilir. Endüstriyel ortamlarda

makine sađlıđının izlenmesi ve arıza tespiti, makine ğrenimi iin en nemli uygulama alanlarından biridir. Makine ekipmanlarının vazgeilmez bir parası olan rulman sađlıđı sadece ekipmanı deđil tm sistemi etkilemektedir. Bu alıřmada makine ğrenmesi modellerinden SVM, KNN ve topluluk ğrenme modelleri kullanılmıřtır.

3.3.1. KNN modeli

KNN, hem sınıflandırma hem de regresyon tahmin analizlerinde kullanılabilen basit ancak etkili bir parametrik olmayan denetimli makine ğrenmesi algoritmasıdır. Sınıflandırılacak veri iin k en yakın komřu alınarak bu verinin bir komřuluđu oluřturulur. Bu alıřmada k komřu sayısı 3 olarak seilmiřtir.

3.3.2. SVM modeli

Denetimli ğrenme kategorisinde kabul edilen SVM modeli, kmeleme algoritmalarından farklıdır. Aykırı deđer sınıflandırma, tahmin ve tespit gibi teknikler arasında en etkili yntemlerden biridir. SVM, veri setlerinin sınıflandırılmasında iki eđitim ve bir test srecinden geer. Bu alıřmada kernel olarak “linear” seilmiřtir.

3.3.3. Topluluk modeli

Topluluk ğrenme yntemleri, birok makine ğrenmesi probleminde en geliřmiř zmleri temsil etmektedir. Birden fazla modeli eđiterek tahminleri birleřtiren ve tek bir model gibi alıřan sınıflandırma ve tahmin modellerini oluřturmaktadır. Bu alıřmada sınıflandırma iin RF(Random Forest), KNN ve SVM birlikte kullanılmıřtır. Bir araya getirilen yeni rnekler ile farklı bir yol oluřturulmuřtur. Bu tekrarlamaya rnekler arttırılmıř ve buna gre tahminler yapılmıřtır.

3.4. Derin ğrenme Modelleri

Derin ğrenme, verilerin oklu seviyelerde zelliklerini veya temsillerini ğrenmeye dayalı bir yapıya sahiptirler. Daha yksek seviyeli zellikler, hiyerarřık bir temsil oluřturmak iin daha dřk seviyeli zelliklerden tretilmektedir. Bu temsil,

farklı soyutlama seviyelerine karşılık gelen çoklu temsil seviyelerini öğrenmektedir. Derin öğrenme esasen verilerin temsilden öğrenmeye dayanmaktadır. Bir görüntü için temsil, piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller vb. gibi özellikler olabilmektedir. Bu özelliklerden bazıları verileri diğerlerinden daha iyi temsil edebilmektedir. Bu çalışmada bir sesten oluşturulan MFCCs dizilerinden veri setleri oluşturularak 1D ve 2D CNN modellerinde eğitilmiştir.

3.4.1. 1D CNN modeli

Ses gibi tek boyutlu veri modelleme ve eğitiminde daha az parametre ile kullanılan 1D CNN modeli, evrişim katmanları, havuzlama ve veri küçültme adımlarından oluşmaktadır. Bu çalışmada, her bir ses sinyaline ait 15 özellikten oluşan bir ses veri dizisi kullanılmıştır. Evrişim katmanında 3x1 boyutunda üç filtre kullanılmıştır. Evrişim katmanlarında sırasıyla 16, 32, 64 ve 128 filtre kullanılmıştır.


3.4.2. 2D CNN modeli

Bu çalışmada, librosa kütüphanesi kullanılarak üç sınıf ses dosyası yüklenmiş ve işlenmiştir. Kütüphanedeki ses sinyallerinden oluşturulan MFCC görüntülerinden 15 özellik haritası üretilmiştir. MFCC görüntüleri 2D CNN mimarisi için giriş verisi olarak kullanılmıştır. Daha sonra verilerin %20'si test seti olarak belirlenirken kalan %80'lik kısım eğitim setini oluşturmuştur. Ses dosyaları Conv. 2D ve Maxpooling 2D katmanlarından oluşan bir CNN modelinde işlenerek sınıflandırılmıştır. Ayrıca aktivasyon fonksiyonu olarak Relu ve dolgu için 'same' seçilmiştir. Bu 2D CNN modelinde, evrişimsel süreç için tek bir adımda 16x3x3 filtreler ve 2x2 maksimum havuzlama işlemleri kullanılmıştır. Diğer adımlarda ise sırasıyla 32, 64 ve 128 filtre ve havuzlama yapıldıktan sonra veriler tam bağlı bir işleme tabi tutularak 128 sinir ağından oluşan bir sinir ağından geçirilmiştir. Sınıflandırma Softmax fonksiyonu kullanılarak gerçekleştirilmiştir.

3.5. Özniteliklerin Çıkartılması

Öznitelik çıkarma, ses sinyallerinin işlenmesinin çok önemli bir yönü olduğu bildirilmektedir. Ses sinyallerini zamansal, spektral ve prozodik gibi üç özellik

kategorisine ayrılmaktadır. Ses sinyalleri, sınıflandırma sistemlerinde özellik uzayında bir vektör tanımlamak için çıkarılan ve kullanılan çok sayıda özellikten oluştuğu, zamansal özellikler veya zaman içindeki genlik dalgalanmaları, başlangıçta veri olmadan doğrudan ilk sestten elde edildiği ifade edilmiştir. Bu çalışmada Genlik-zaman, Mel-spektrogram, MFCC'ler, ZCR'ler ve RMS Enerjisi gibi özellik çıkarma yöntemlerinden öznitelik çıkarma Şekil 3.9'da gösterilmiştir. Bu çalışmada her bir ses için özniteliklerin çıkartılması işlemlerinde 18 adet özelliklerden oluşan veri seti oluşturulmuştur.



Şekil 3.9. Ses dosyasından özniteliklerin çıkartılması işlemi

3.6. Sınıflandırma Metrikleri ve Tahminler İçin Karmaşıklık Matrisi

Çoklu sınıflandırmalarda performansı değerlendirmek için doğruluk, kesinlik, geri çağırma ve F1 puanı gibi ölçütler kullanılır. AUC (Eğri altındaki alan) ise ROC (Alıcı işletim karakteristiği) eğrisi altında kalan bölgenin alanı olarak hesaplanmaktadır.

ROC eğrisi analizi kullanılarak testin tanısal veya sağlam olmayan olayları ayırma doğruluğu değerlendirilebileceğini ifade etmişlerdir (Metz, 1978; Zweig ve Campbell, 1993). İki veya daha fazla laboratuvar veya tanı testinin tanısal performansını karşılaştırmak için ROC eğrileri kullanılabileceğini bildirmişlerdir (Griner ve ark., 1981). Bu puanlar Eşitlik 1-5'e göre hesaplanır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Geri Çağırma} = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 \frac{\text{Hassasiyet} * \text{Geri çağırma}}{\text{Hassasiyet} + \text{Geri çağırma}} \quad (4)$$

$$AUC = \frac{\text{Hassasiyet} * \text{Geri çağırma}}{2} \quad (5)$$

Burada TP doğru pozitiflerin sayısı, TN doğru negatiflerin sayısı, FP yanlış pozitiflerin sayısı ve FN yanlış negatiflerin sayısıdır.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3.10. Tahminler için karmaşıklık matrisi

Tahminlerin yapılmasında kullanılan Şekil 3.10'daki karmaşıklık matrisinde köşegenlerde bulunan değerlerin doğru tahmin olarak ve diğer matris elemanlarının ise yanlış tahmin olarak kabul edilmektedir.


Literatürde yatay milli santrifüj pompaların rulman arıza teşhisi ile ilgili çok sayıda inceleme bulunmaktadır. Ancak fan ile ilgili genellikle motor soğutma fanı gürültü analizi üzerine çalışmalar bulunmaktadır. Bu çalışmada yatay milli santrifüj pompaların rulman ve fan gürültü analizi ile arıza teşhisi üzerine bir çalışma gerçekleştirilmiştir. Diyarbakır ili Bismil ilçesi şehir içme suyu terfi merkezinde bulunan dört ve altı tonluk iki ayrı depoyu besleyen biri yedek olmak üzere üç pompadan oluşan 90 ve 132 kW gücünde, 2 ve 3 kademeli altı adet pompa, 01 Eylül 2023 tarihinden 05 Ocak 2024 tarihine kadar haftalık periyotta her Cuma günü pompa rulmanı ve fan dış sesleri kaydedilmiştir. İç mekânda bulunan pompalar, rulman ve fan gövdelerinin dış kısmına ses kayıt cihazı bırakılarak ses dinlemesi yapılmıştır. Bu çalışmada santrifüj pompası fan sesinden 699 arızalı, 1247 az arızalı ve 1044 sağlam sesler kaydedilmiştir. Pompa ön rulman sesinden 461 arızalı, 408 az arızalı ve 699 adet sağlam sesler kaydedilmiştir. Aynı şekilde pompa arka rulman seslerinde 329 arızalı, 801 az arızalı ve 350 sağlam rulman sesi kaydedilmiştir. Pompayı döndüren asenkron motorun fanı ve arka rulman sesinden 391 arızalı, 752 az arızalı ve 513 sağlam ses kaydedilmiştir. Ayrıca tüm sistem için 4 farklı yerden kaydedilen seslerin tümünü kullanarak sınıflandırma tahmini yapılmıştır. Seslerin %80'i eğitim verisi olarak seçilirken, kalan %20'si test verisi olarak seçilmiştir.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

4.1. Yatay Milli Santrifüj Pompa Fanı Eğitim Sonuçları ve Tahminler


4.1.1. 1D CNN modeli sonuçları

Makine öğrenmenin alt birimi olan derin öğrenmenin 1D CNN modeli ile yatay milli santrifüj pompa fan ses kaydı 25 döngü (epoch) kullanılarak eğitilmiştir. 1D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.1.'de verilmiştir.



Şekil 4.1. Pompa fanı 1D CNN model her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler

Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa fan ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. Santrifüj pompa fanı ses kaydı çalışmalarındaki arızalı, az arızalı ve sağlam ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.2'de verilmiştir. ROC eğrisinde eğri altında kalan alanın hesaplanmasıyla modelin performansı ölçülmektedir. Karmaşıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sınıflandırma etiketleri 1 (Arızalı), 2 (az arızalı) ve 3 (sağlam) olarak sınıflandırılmıştır.




Şekil 4.2. Pompa fanı 1D CNN Modeli ROC eğrisi ve karmaşıklık matrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. 1D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 156 test verisinin 147 sesin doğru tahmin edildiğini, 4 sesi 2 ve 5 sesi 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 245 ses verisinden 229 sesi 2 olarak doğru tahmin ederken, 11 sesi 1 ve 5 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 197 veriden 177 sesi 3 olarak tahmin ederken, 6 sesi 1 ve 14 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %94,23, 2 için %93,47 ve 3 için de %89,85 olarak hesaplanmıştır.


4.1.2. 2D CNN modeli sonuçları

Derin öğrenmenin 2D CNN modeli ile santrifüj pompa fan ses kaydı 25 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.3.'de gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa fan ses kaydı 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.



Şekil 4.3. Pompa fanı 2D CNN model her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler


Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine aait ROC eğrisi ve tahminlerin gösterildiği karmaşıklık matrisleri Şekil 4.4.'de gösterilmiştir. 2D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 156 test verisinden 151 sesin doğru tahmin edildiğini, 3 sesin 2 olarak yanlış 2 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 245 ses verisinden 226 sesi 2 olarak doğru tahmin ederken, 8 sesi 1 ve 11 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 197 veriden 185 sesi 3 olarak doğru tahmin ederken, 3 sesi 1 ve 9 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %96,80, 2 için %92,25 ve 3 için de %93,91 olarak hesaplanmıştır.



Şekil 4.4. Pompa fan 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi


4.1.3. KNN modeli sonuçları

Makine öğrenmesi modellerinden biri olan KNN modeli ile santrifüj pompa fan ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.5.'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkcı başarı ve skor oranlarının çok değışmediğı görölmektedir.



Şekil 4.5. Pompa fanı KNN modeli için öğrenme eğrisi ve ROC eğrisi

Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiğı karmaşıklık matrisi Şekil 4.6'da gösterilmiştir.




Şekil 4.6. Pompa fanı KNN modeli karışıklık matrisi

KNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 156 ses verisinden 155 sesin doğru tahmin edildiğini, 1 sesin 2 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 245 ses verisinden 239 sesi 2 olarak doğru tahmin ederken 2 sesi 1 ve 4 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan

197 veriden 194 sesi 3 olarak doğru tahmin ederken 3 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %99,36, 2 için %97,55 ve 3 için de %98,48 olarak hesaplanmıştır.


4.1.4. SVM modeli ses analizi

Makine öğrenmesi modellerinden biri olan SVM modeli ile santrifüj pompa fan ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.7.'de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça başarı ve skor oranlarının arttığı görülmektedir.



Şekil 4.7. Pompa fanı SVM modeli için öğrenme eğrisi ve ROC eğrisi


Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.8'de gösterilmiştir. SVM modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 156 ses verisinden 90 sesin doğru tahmin edildiğini, 41 sesin 2 olarak ve 25 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 245 ses verisinden 175 sesi 2 olarak doğru tahmin ederken 27 sesi 1 ve 43 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 197 veriden 114 sesi 3 olarak doğru tahmin ederken 16 sesi 1 ve 67 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %57,69, 2 için %71,43 ve 3 için de %57,87 olarak hesaplanmıştır.



Şekil 4.8. Pompa Fanı SVM modeli karmaşıklık matrisi

4.1.5. Topluluk modeli ses analizi


Makine öğrenmesi modellerinden topluluk öğrenme modelinde RF, SVM ve KNN öodelleri birlikte kullanılarak sonuçlar elde edilmiştir. Topluluk modeli ile santrifüj pompa fan ses analizi öznelitliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.9.'da verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelitlikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıka RF modeli için başarı ve skor oranlarının çok değışmediğı, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4.9. Pompa fanı Topluluk modeli için öğrenme eğrisi ve ROC eğrisi

Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.10'da gösterilmiştir.

Topluluk modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 156 ses verisinden 156 ses doğru tahmin edilmiştir. Model, 2 olarak tanımlanan 245 ses verisinden 240 sesi 2 olarak doğru tahmin ederken 2 sesi 1 ve 3 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 197 veriden 195 sesi 3 olarak doğru tahmin ederken 2 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %100, 2 için %97,96 ve 3 için de %98,98 olarak hesaplanmıştır.




Şekil 4.10. Pompa fanı Topluluk modeli karışıklık matrisi

Sınıflandırma modellerinde kullanılan metriklerin her modelde sınıf etiketleri için değerler hesaplandığı gibi model içinde hesaplanmaktadır. Fan sesi için yapılan 5 farklı makine öğrenmesi ve derin öğrenme modelleri sınıflandırılmasında en iyi başarıyı topluluk öğrenme modeli ile elde edilmiştir. Tablo 4.1’de verilen her bir modelin sınıflar için yaptığı eğitim ve test verisine ait doğruluk, hassasiyet, geri çağırma ve F1 skorları ve tahminlerde kullanılan numune sayıları verilmiştir. Doğruluk skorunda en iyi başarı topluluk öğrenme modelinde %98,83 ve en düşük başarı ise SVM modelinde %63,38 olarak elde edilmiştir. Bu değerlere paralel olarak da hassasiyet, geri çağırma ve F1 skorlarında da en yüksek değeri %100 ile topluluk öğrenme modelinde elde edilirken en düşük değerler de SVM modelinde hesaplanmıştır.


Tablo 4.1. Yatay milli santrifüj pompa fanı sınıflandırma metrik sonuçları

Model	Sınıflandırma	Doğruluk Skoru (%)	Hassasiyet skoru (%)	Geri çağırma skoru (%)	F1 skoru (%)	Numune sayısı
1 D CNN	Arızalı		90	94	92	156
	Az arızalı	92,47	93	93	93	245
	Sağlam		95	90	92	197
2 D CNN	Arızalı		93	97	95	156
	Az arızalı	93,98	95	92	94	245
	Sağlam		93	94	94	197
KNN	Arızalı		99	99	99	156
	Az arızalı	98,33	98	98	98	245
	Sağlam		98	98	98	197
SVM	Arızalı		68	58	62	156
	Az arızalı	63,38	62	71	66	245
	Sağlam		63	58	60	197
Topluluk	Arızalı		99	100	99	156
	Az arızalı	98,83	99	98	99	245
	Sağlam		98	99	99	197

Ayrıca sınıflandırma eğitimlerinde yapılan tahminleri belirleyerek kaç sesin doğru ve kaç sesin yanlış tahmin edildiği Şekil 4.11’de gösterilmiştir. Bu grafiğe göre arızalı sesi için yapılan tahminlerde, 1D CNN modelinde 147 doğru ve 9 yanlış tahmin yapılmıştır. Az arızalı sesler için 229 doğru ve 16 yanlış tahmin edilirken sağlam sesler için ise 177 doğru ve 20 yanlış tahmin yapmıştır. Aynı şekilde diğer sınıflandırma modellerinde de doğru ve yanlış tahminler görülmektedir.

**Şekil 4.11.** Pompa fanı test verileri için doğru ve yanlış tahminler

Eğitim test verileri doğruluk oranı sonuçları Şekil 4.12’de görüldüğü gibi, 1D CNN modelinde %92,47, 2D CNN modelinde %93,98, KNN modelinde %98,33, SVM modelinde %63,38 ve ensemble öğrenme modelinde %98,83 olarak hesaplanmıştır. Topluluk öğrenme modeli, arızalı fan sesleri için tüm sesleri tahmin etmede %100’e yakın doğruluk oranı gösterirken, SVM modeli ile en düşük doğruluk oranı elde edilmiştir.



Şekil 4.12. Pompa fanı doğruluk değerleri


Bu kısımda yatay milli santrifüj pompa fan sisteminin kestirimci bakım çalışmalarında ortaya çıkabilecek arızalara ait örnekler ve bu örneklerle ait ses analizi verilmiştir. Ses ölçümlerinin makine ve derin öğrenme modellerinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri incelendiğinde genel itibari ile uygulanmasının kabul edilebilir seviyelerde olduğu tespit edilmiştir. Verilere dayalı yaklaşımlar uygulayarak, stratejik karar verme için yorumlayıcı sonuçlar bulmanın mümkün olduğu ve bakım maliyetinin azaltılması, pompa fan arızalarının azaltılması, onarımın durması, üretimin artması, operatör güvenliğinde iyileşme, genel kâr gibi avantajlar sağlayabileceği düşünülmüştür.

4.2. Yatay Milli Santrifüj Pompa Ön Rulman İçin Arıza Sınıflandırma Sonuçları

4.2.1. 1D CNN modeli sonuçları


Makine öğrenmenin alt birimi olan derin öğrenmenin 1D CNN modeli ile yatay milli santrifüj pompa ön rulman ses kaydı 25 döngü (epoch) kullanılarak eğitilmiştir. 1D

CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.13.'de verilmiştir.



Şekil 4.13. Pompa ön rulman 1D CNN Modeli her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler

Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa ön rulman ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. Santrifüj pompa ön rulman ses kaydı çalışmalarındaki arızalı, az arızalı ve sağlam ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.14'te verilmiştir. ROC eğrisinde eğri altında kalan alanın hesaplanmasıyla modelin performansı ölçülmektedir. Karmaşıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sınıflandırma etiketleri 1 (Arızalı), 2 (az arızalı) ve 3 (sağlam) olarak sınıflandırılmıştır.




Şekil 4.14. Pompa ön rulman 1D CNN Modeli ROC eğrisi ve karmaşıklık matrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. 1D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 95 test verisinin 90 sesin doğru tahmin edildiğini, 1 sesin 2 olarak ve 4 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 81 ses verisinden 77 sesi 2 olarak doğru tahmin ederken, 1 sesi 1 ve 3 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 138 veriden 135 sesi 3 olarak doğru tahmin ederken, 2 sesi 1 ve 1 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %94,74, 2 için %95,06 ve 3 için de %,97,83 olarak hesaplanmıştır.


4.2.2. 2D CNN model ses analizi

Derin öğrenmenin 2D CNN modeli ile santrifüj pompa ön rulman ses kaydı 25 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.15'de gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa ön rulman ses kaydı 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.



Şekil 4.15. Pompa ön rulman her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler


Yatay milli santrifüj pompa ön rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine aait ROC eğrisi ve tahminlerin gösterildiği karmaşıklık matrisleri Şekil 4.16.'da gösterilmiştir. 2D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 95 test verisinin 93 sesin doğru tahmin edildiğini, 2 sesin 2 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 81 ses verisinden 78 sesi 2 olarak doğru tahmin ederken, 1 sesi 1 ve 2 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 138 veriden 133 sesi 3 olarak doğru tahmin ederken, 2 sesi 1 ve 3 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %97,89, 2 için %96,30 ve 3 için de %96,38 olarak hesaplanmıştır.



Şekil 4.16. Pompa ön rulman 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi


4.2.3. KNN modeli ses analizi

Makine öğrenmesi modellerinden biri olan KNN modeli ile santrifüj pompa ön rulman ses analizi özneliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.17'de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça başarı ve skor oranlarının çok değişmediği görülmektedir.



Şekil 4.17. Pompa ön rulman KNN modeli için öğrenme eğrisi ve ROC eğrisi

Yatay milli santrifüj pompa ön rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.18’de gösterilmiştir.




Şekil 4.18. Pompa ön rulman KNN modeli karışıklık matrisi

KNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 95 ses verisinden 94 sesin doğru tahmin edildiğini, 1 sesin 2 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 81 ses verisinden 79 sesi 2 olarak doğru tahmin ederken 1 sesi 1 ve 1 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 138 veriden 138 sesi 3 olarak doğru tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %98,95, 2 için %97,53 ve 3 için de %100 olarak hesaplanmıştır.

4.2.4. SVM modeli ses analizi


Makine öğrenmesi modellerinden biri olan SVM modeli ile santrifüj pompa ön rulman ses analizi özneliliklerin çıkartılması sonucu elde edilen veriler kullanılarak

sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.19'da verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkcı başarı ve skor oranlarının arttığını görölmektedir.



Şekil 4.19. Pompa ön rulman SVM modeli için öğrenme eğrisi ve ROC eğrisi


Yatay milli santrifüj pompa ön rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.20’de gösterilmiştir. SVM modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 95 ses verisinden 79 sesin doğru tahmin edildiğini, 12 sesin 2 olarak ve 4 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 81 ses verisinden 63 sesi 2 olarak doğru tahmin ederken 6 sesi 1 ve 12 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 138 veriden 122 sesi 3 olarak doğru tahmin ederken 3 sesi 1 ve 13 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %83,16, 2 için %77,78 ve 3 için de %88,41 olarak hesaplanmıştır.



Şekil 4.20. Pompa ön rulman SVM modeli karışıklık matrisi

4.2.5. Topluluk modeli ses analizi


Topluluk modeli ile santrifüj pompa ön rulman ses analizi öznelitliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.21'de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelitlikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı arttıkça RF modeli için başarı ve skor oranlarının çok değişmediği, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4.21. Pompa ön rulman Topluluk modeli için öğrenme eğrisi ve ROC eğrisi

Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.22'de gösterilmiştir. Topluluk modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 95 ses

verisinden 95 ses doğru tahmin edilmiştir. Model, 2 olarak tanımlanan 81 ses verisinden 80 sesi 2 olarak doğru tahmin ederken ve 1 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 138 veriden 138 sesi 3 olarak tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %100, 2 için %98,77 ve 3 için de %100 olarak hesaplanmıştır.




Şekil 4.22. Pompa ön rulman Topluluk modeli karmaşıklık matrisi

Sınıflandırma modellerinde kullanılan metriklerin her modelde sınıf etiketleri için değerler hesaplandığı gibi model içinde hesaplanmaktadır. Pompa ön rulman sesi için yapılan 5 farklı makine öğrenmesi ve derin öğrenme modelleri sınıflandırılmasında en iyi başarı topluluk öğrenme modeli ile elde edilmiştir. Tablo 4.2.'de verilen her bir modelin sınıflar için yaptığı eğitim ve test verisine ait doğruluk, hassasiyet, geri çağırma ve F1 skorları ve tahminlerde kullanılan numune sayıları verilmiştir. Doğruluk skorunda en iyi başarı topluluk öğrenme modelinde %99,68 ve en düşük başarı ise SVM modelinde %84,08 olarak elde edilmiştir. Bu değerlere paralel olarak da hassasiyet, geri çağırma ve F1 skorlarında da en yüksek değeri %100 ile topluluk öğrenme modelinde elde edilirken en düşük değerler de SVM modelinde hesaplanmıştır.


Tablo 4.2. Yatay milli santrifüj pompa ön rulman sınıflandırma ölçüm sonuçları

Model	Sınıflandırma	Doğruluk Skoru (%)	Hassasiyet skoru (%)	Geri çağırma skoru (%)	F1 skoru (%)	Numune sayısı
1 D CNN	Arızalı		97	95	96	95
	Az arızalı	96,18	97	95	96	81
	Sağlam		95	98	96	138
2 D CNN	Arızalı		97	98	97	95
	Az arızalı	96,85	94	96	95	81
	Sağlam		99	96	97	138
KNN	Arızalı		99	99	99	95
	Az arızalı	99,04	99	98	98	81
	Sağlam		99	100	100	138
SVM	Arızalı		90	83	86	95
	Az arızalı	84,08	72	78	75	81
	Sağlam		88	88	88	138
Topluluk	Arızalı		100	100	100	95
	Az arızalı	99,68	100	99	99	81
	Sağlam		99	100	100	138

Ayrıca sınıflandırma eğitimlerinde yapılan tahminleri belirleyerek kaç sesin doğru ve kaç sesin yanlış tahmin edildiği Şekil 4.23'te gösterilmiştir. Bu grafiğe göre arızalı sesi için yapılan tahminlerde, 1D CNN modelinde 90 doğru ve 5 yanlış tahmin yapılmıştır. Az arızalı sesler için 77 doğru ve 4 yanlış tahmin edilirken sağlam sesler için ise 135 doğru ve 3 yanlış tahmin yapmıştır. Aynı şekilde diğer sınıflandırma modellerinde de doğru ve yanlış tahminler görülmektedir.

**Şekil 4.23.** Pompa ön rulman test verileri için doğru ve yanlış tahminler

Eğitim test verileri doğruluk oranı sonuçları Şekil 4.24'te görüldüğü gibi, 1D CNN modelinde %96,18, 2D CNN modelinde %96,85, KNN modelinde %99,04, SVM modelinde %84,08 ve ensemble öğrenme modelinde %99,68 olarak hesaplanmıştır. Topluluk öğrenme modeli, arızalı ve sağlam sesleri KNN modeli sağlam sesleri tahmin etmede %100 doğruluk oranı gösterirken, SVM modeli ile en düşük doğruluk oranı elde edilmiştir.



Şekil 4.24. Pompa ön rulman test verileri doğruluk değerleri


Bu kısımda yatay milli santrifüj pompa ön rulman sisteminin kestirimci bakım çalışmalarında ortaya çıkabilecek arızalara ait örnekler ve bu örneklerle ait ses analizi verilmiştir. Ses ölçümlerinin makine ve derin öğrenme modellerinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri incelendiğinde genel itibari ile uygulanmasının kabul edilebilir seviyelerde olduğu tespit edilmiştir. Verilere dayalı yaklaşımlar uygulayarak, stratejik karar verme için yorumlayıcı sonuçlar bulmanın mümkün olduğu ve bakım maliyetinin azaltılması, pompa ön rulman arızalarının azaltılması, onarımın durması, üretimin artması, operatör güvenliğinde iyileşme, genel kâr gibi avantajlar sağlayabileceği düşünülmüştür.

4.3. Yatay Milli Santrifüj Pompa Arka Rulman Model Çalışması

4.3.1. 1D CNN modeli sonuçları


Makine öğrenmenin alt birimi olan derin öğrenmenin 1D CNN modeli ile yatay milli santrifüj pompa arka rulman ses kaydı 25 döngü (epoch) kullanılarak eğitilmiştir.

1D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.25.'te verilmiştir.



Şekil 4.25. Pompa arka rulman 1D CNN her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler

Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa arka rulman ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. Santrifüj pompa arka rulman ses kaydı çalışmalarındaki arızalı, az arızalı ve sağlam ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.26'da verilmiştir. ROC eğrisinde eğri altında kalan alanın hesaplanmasıyla modelin performansı ölçülmektedir. Karmaşıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sınıflandırma etiketleri 1 (Arızalı), 2 (az arızalı) ve 3 (sağlam) olarak sınıflandırılmıştır.




Şekil 4.26. Pompa arka rulman 1D CNN Modeli alıcı işletim karakteristiği doğru – yanlış pozitif oranı eğrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. 1D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 63 test verisinin 63 sesin doğru tahmin edildiğini, hiçbir sesin yanlış tahmin edilmediğini göstermektedir. Model, 2 olarak tanımlanan 164 ses verisinden 150 sesi 2 olarak doğru tahmin ederken, 10 sesi 1 ve 4 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 69 veriden 67 sesi 3 olarak tahmin ederken, 2 sesi 1 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %100, 2 için %91,46 ve 3 için de %97,10 olarak hesaplanmıştır.


4.3.2. 2D CNN model ses analizi

Derin öğrenmenin 2D CNN modeli ile santrifüj pompa arka rulman ses kaydı 25 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.27'de gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa arka rulman ses kaydı 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.



Şekil 4.27. Pompa arka rulman 2D CNN Her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler


Yatay milli santrifüj pompa arka rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait ROC eğrisi ve tahminlerin gösterildiği karmaşıklık matrisleri Şekil 4.28.'de gösterilmiştir. 2D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 63 test verisinin 63 sesin doğru tahmin edildiğini ve hiçbir sesin yanlış tahmin edilmediğini göstermektedir. Model, 2 olarak tanımlanan 164 ses verisinden 160 sesi 2 olarak doğru tahmin ederken, 2 sesi 1 ve 2 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 69 veriden 69 sesi 3 olarak doğru tahmin ederken ve hiçbir sesi de yanlış tahmin etmemiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %100, 2 için %97,56 ve 3 için de %100 olarak hesaplanmıştır.



Şekil 4.28. Pompa arka rulman 2D CNN Modeli ROC eğrisi ve karmaşıklık matrisi


4.3.3. KNN modeli ses analizi

Makine öğrenmesi modellerinden biri olan KNN modeli ile santrifüj pompa arka rulman ses analizi özneliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.29.'da verilmiştir. Makine öğrenimi modellerinin eğitiminde kullanılan verileri oluşturan öznelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıktıkça başarı ve skor oranlarının çok değişmediği görülmektedir.



Şekil 4.29. KNN modeli için öğrenme eğrisi ve ROC eğrisi

Yatay milli santrifüj pompa arka rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.30’da gösterilmiştir.




Şekil 4.30. KNN modeli karışıklık matrisi

KNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 63 ses verisinden 63 sesin doğru tahmin edildiğini ve hiçbir sesin yanlış tahmin edilmediğini göstermektedir. Model, 2 olarak tanımlanan 164 ses verisinden 162 sesi 2 olarak doğru tahmin ederken 1 sesi 1 ve 1 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 69 veriden 68 sesi 3 olarak tahmin ederken 1 sesi de 1 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %100, 2 için %98,78 ve 3 için de %98,55 olarak hesaplanmıştır.


4.3.4. SVM modeli ses analizi

Makine öğrenmesi modellerinden biri olan SVM modeli ile santrifüj pompa arka rulman ses analizi özneliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.31'de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça başarı ve skor oranlarının arttığı görülmektedir.



Şekil 4.31. Pompa arka rulman SVM Eğitim örnek sayısının doğruluk durumu eğrisi


Yatay milli santrifüj pompa arka rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.32'de gösterilmiştir. SVM modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 63 ses verisinden 59 sesin doğru tahmin edildiğini, 4 sesin 2 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 164 ses verisinden 144 sesi 2 olarak doğru tahmin ederken 12 sesi 1 ve 8 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 69 veriden 62 sesi 3 olarak doğru tahmin ederken ve 7 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %93,65, 2 için %87,81 ve 3 için de %89,86 olarak hesaplanmıştır.



Şekil 4.32. Pompa arka rulman SVM modeli karışıklık matrisi

4.3.5. Topluluk modeli ses analizi


Topluluk modeli ile santrifüj pompa arka rulman ses analizi özneliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.33'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkcı RF modeli için başarı ve skor oranlarının çok değışmediğı, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4.33. Pompa arka rulman Topluluk modeli için öğrenme eğrisi ve ROC eğrisi

Yatay milli santrifüj pompa arka rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiğı karışıklık matrisi Şekil 4.34.'te gösterilmiştir. Topluluk modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 63 ses

verisinden 63 ses doğru tahmin edilmiştir. Model, 2 olarak tanımlanan 164 ses verisinden 163 sesi 2 olarak doğru tahmin ederken ve 1 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 69 veriden 69 sesi 3 olarak doğru tahmin ederken hiçbir ses yanlış tahmin etmemiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %100, 2 için %99,39 ve 3 için de %100 olarak hesaplanmıştır.




Şekil 4.34. Pompa arka rulman Topluluk Modeli yatay milli santrifüj pompa arka rulmanı karmaşıklık matrisi

Sınıflandırma modellerinde kullanılan metriklerin her modelde sınıf etiketleri için değerler hesaplandığı gibi model içinde hesaplanmaktadır. Pompa arka rulman sesi için yapılan 5 farklı makine öğrenmesi ve derin öğrenme modelleri sınıflandırılmasında en iyi başarıyı Topluluk Öğrenme Modeli ile elde edilmiştir. Tablo 4.3.'te verilen her bir modelin sınıflar için yaptığı eğitim ve test verisine ait doğruluk, hassasiyet, geri çağırma ve F1 skorları ve tahminlerde kullanılan numune sayıları verilmiştir. Doğruluk skorunda en iyi başarı topluluk öğrenme modelinde %99,66 ve en düşük başarı ise SVM modelinde %89,53 olarak elde edilmiştir. Bu değerlere paralel olarak da hassasiyet, geri çağırma ve F1 skorlarında da en yüksek değeri %100'e yakın değer ile Topluluk Öğrenme modelinde elde edilirken en düşük değerler de SVM modelinde hesaplanmıştır.

Tablo 4.3. Yatay milli santrifüj pompa arka rulman sınıflandırma ölçüm sonuçları


Model	Sınıflandırma	Doğruluk Skoru (%)	Hassasiyet skoru (%)	Geri çağırma skoru (%)	F1 skoru (%)	Numune sayısı
1 D CNN	Arızalı	94,59	84	100	91	63
	Az arızalı		100	91	96	164
	Sağlam		94	97	96	69
2 D CNN	Arızalı	98,65	97	100	98	63
	Az arızalı		100	98	99	164
	Sağlam		97	100	99	69
KNN	Arızalı	98,98	97	100	98	63
	Az arızalı		100	99	99	164
	Sağlam		99	99	99	69
SVM	Arızalı	89,53	83	94	88	63
	Az arızalı		93	88	90	164
	Sağlam		89	90	89	69
Topluluk	Arızalı	99,66	100	100	100	63
	Az arızalı		100	99	100	164
	Sağlam		99	100	99	69

Ayrıca sınıflandırma eğitimlerinde yapılan tahminleri belirleyerek kaç sesin doğru ve kaç sesin yanlış tahmin edildiği Şekil 4.35.'te gösterilmiştir. Bu grafiğe göre arızalı ses için yapılan tahminlerde, 1D CNN modelinde 63 doğru ve 0 yanlış tahmin yapılmıştır. Az arızalı sesler için 150 doğru ve 14 yanlış tahmin edilirken sağlam sesler için ise 67 doğru ve 2 yanlış tahmin yapmıştır. Aynı şekilde diğer sınıflandırma modellerinde de doğru ve yanlış tahminler görülmektedir.

**Şekil 4.35.** Pompa arka rulman test verileri için doğru ve yanlış tahminler

Eğitim test verileri doğruluk oranı sonuçları Şekil 4.36.'da görüldüğü gibi, 1D CNN modelinde %94,59, 2D CNN modelinde %98,65, KNN modelinde %98,99, SVM

modelinde %89,53 ve Topluluk Öğrenme modelinde %99,66 olarak hesaplanmıştır. Topluluk Öğrenme modeli, arızalı pompa arka rulman sesleri için tüm sesleri tahmin etmede %100'e yakın doğruluk oranı gösterirken, SVM modeli ile en düşük doğruluk oranı elde edilmiştir.




Şekil 4.36. Pompa arka rulman test verileri doğruluk değerleri

Bu kısımda yatay milli santrifüj pompa arka rulman sisteminin kestirimci bakım çalışmalarında ortaya çıkabilecek arızalara ait örnekler ve bu örneklerle ait ses analizi verilmiştir. Ses ölçümlerinin makine ve derin öğrenme modellerinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri incelendiğinde genel itibari ile uygulanmasının kabul edilebilir seviyelerde olduğu tespit edilmiştir. Verilere dayalı yaklaşımlar uygulayarak, stratejik karar verme için yorumlayıcı sonuçlar bulmanın mümkün olduğu ve bakım maliyetinin azaltılması, pompa arka rulman arızalarının azaltılması, onarımın durması, üretimin artması, operatör güvenliğinde iyileşme, genel kâr gibi avantajlar sağlayabileceği düşünülmüştür.

4.4. Yatay Milli Santrifüj Pompa Motoru Fan+Rulmanı Model Çalışması


4.4.1. Pompa motoru fan+rulman 1D CNN model sonuçları

Makine öğrenmenin alt birimi olan derin öğrenmenin 1D CNN modeli ile yatay milli santrifüj pompa motor fan+rulman ses kaydı 25 döngü (epoch) kullanılarak eğitilmiştir. 1D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.37.'de verilmiştir.



Şekil 4.37. Pompa motoru fan+rulman her döngüdeki eğitim ve test verisinin doğruluk / kayıp durumu ve metrikler

Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa motoru fan+rulman ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. Santrifüj pompa motoru fan+rulman ses kaydı çalışmalarındaki arızalı, az arızalı ve sağlam ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.38.'de verilmiştir. ROC grisinde gri altında kalan alanın hesaplanmasıyla modelin perormansı ölçülmektedir. Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir.




Şekil 4.38. Pompa motoru fan+rulman 1D CNN Modeli alıcı işletim karakteristiği doğru – yanlış pozitif oranı eğrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. 1D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 84 test verisinin 70 sesin doğru tahmin edildiğini, 13 sesin 2 olarak ve 1 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 149 ses verisinden 146 sesi 2 olarak doğru tahmin ederken ve 3 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 99 veriden 92 sesi 3 olarak doğru tahmin ederken ve 7 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %83,33, 2 için %97,99 ve 3 için de %92,93 olarak hesaplanmıştır.


4.4.2. Pompa motoru fan+rulman 2D CNN model sonuçları

Derin öğrenmenin 2D CNN modeli ile santrifüj pompa motoru fan+rulman ses kaydı 25 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.39.'da gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa motoru fan+rulman ses kaydı 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.



Şekil 4.39. Pompa motoru fan+rulman eğitim ve testin dönemlere göre doğruluk / kayıp durumu


Yatay milli santrifüj pompa motoru fan+rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait ROC eğrisi ve tahminlerin gösterildiği karmaşıklık matrisleri Şekil 4.40.'ta gösterilmiştir. 2D CNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 84 test verisinin 79 sesin doğru tahmin edildiğini, 4 sesin 2 olarak ve 1 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 149 ses verisinden 137 sesi 2 olarak doğru tahmin ederken, 2 sesi 1 ve 10 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 99 veriden 97 sesi 3 olarak tahmin ederken ve 2 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %94,05, 2 için %91,95 ve 3 için de %97,98 olarak hesaplanmıştır.



Şekil 4.40. Pompa motoru fan+rulman 2D CNN Modeli alıcı işletim karakteristiği doğru – yanlış pozitif oranı eğrisi


4.4.3. KNN modeli sonuçları

Makine öğrenmesi modellerinden biri olan KNN modeli ile santrifüj pompa motoru fan+rulman ses analizi özneliliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.41.'de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelilikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkcı başarı ve skor oranlarının çok değışmediğı görölmektedir.



Şekil 4.41. Pompa motoru fan+rulman KNN Eğitim örnek sayısının doğruluk durumu eğrisi

Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.42.'de gösterilmiştir.




Şekil 4.42. Pompa motoru fan+rulman KNN Modeli karmaşıklık matrisi

KNN modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 84 ses verisinden 155 sesin doğru tahmin edildiğini ve 1 sesin 2 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 149 ses verisinden 145 sesi 2 olarak doğru tahmin ederken 2 sesi 1 ve 2 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 99 veriden 98 sesi 3 olarak tahmin ederken ve 1 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %98,81, 2 için %97,32 ve 3 için de %98,99 olarak hesaplanmıştır.


4.4.4. SVM modeli ses analizi

Makine öğrenmesi modellerinden biri olan SVM modeli ile santrifüj pompa motoru fan+rulman ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.43.'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıka başarı ve skor oranlarının arttığı görölmektedir.



Şekil 4.43. Pompa motoru fan+rulman SVM modeli için öğrenme eğrisi ve ROC eğrisi


Yatay milli santrifüj pompa motoru fan+rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.44.'te gösterilmiştir. SVM modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 84 ses verisinden 69 sesin doğru tahmin edildiğini, 14 sesin 2 olarak ve 1 sesin 3 olarak yanlış tahmin edildiğini göstermektedir. Model, 2 olarak tanımlanan 149 ses verisinden 111 sesi 2 olarak doğru tahmin ederken 24 sesi 1 ve 14 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 99 veriden 71 sesi 3 olarak tahmin ederken ve 28 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %82,14, 2 için %74,50 ve 3 için de %71,72 olarak hesaplanmıştır.



Şekil 4.44. Pompa motoru fan+rulman SVM modeli karışıklık matrisi

4.4.5. Topluluk modeli ses analizi


Topluluk modeli ile santrifüj pompa motoru fan+rulman ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.45'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı arttıkça RF modeli için başarı ve skor oranlarının çok değişmediği, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4.45. Pompa motoru fan+rulman Topluluk modeli karışıklık matrisi

Yatay milli santrifüj pompa motoru fan+rulman ses kaydı çalışmalarındaki 1, 2 ve 3 ses etiketlerine ait tahminlerin gösterildiği karmaşıklık matrisi Şekil 4.46.'da gösterilmiştir. Topluluk modelinin tahmin matrisi incelendiğinde, 1 olarak tanımlanan 84

ses verisinden 82 ses doğru tahmin ederken, 1 sesi 2 ve 1 ses de 3 olarak yanlış tahmin edilmiştir. Model, 2 olarak tanımlanan 149 ses verisinden 143 sesi 2 olarak doğru tahmin ederken, 2 sesi 1 ve 4 sesi de 3 olarak yanlış tahmin etmiştir. 3 olarak tanımlanan 99 veriden 98 sesi 3 olarak tahmin ederken ve 1 sesi de 2 olarak yanlış tahmin etmiştir. Bu sonuçlara göre tahmin başarı yüzdesi 1 için %97,62, 2 için %95,97 ve 3 için de %98,99 olarak hesaplanmıştır.




Şekil 4.46. Pompa motoru fan+rulman Topluluk Modeli karışıklık matrisi

Sınıflandırma modellerinde kullanılan metriklerin her modelde sınıf etiketleri için değerler hesaplandığı gibi model içinde hesaplanmaktadır. Motor fan+rulman sesi için yapılan 5 farklı makine öğrenmesi ve derin öğrenme modelleri sınıflandırılmasında en iyi başarıyı KNN öğrenme modeli ile elde edilmiştir. Tablo 4.4.'te verilen her bir modelin sınıflar için yaptığı eğitim ve test verisine ait doğruluk, hassasiyet, geri çağırma ve F1 skorları ve tahminlerde kullanılan numune sayıları verilmiştir. Doğruluk skorunda en iyi başarıyı KNN öğrenme modelinde %98,19 ve en düşük başarıyı ise SVM modelinde %75,60 olarak elde edilmiştir. Bu değerlere paralel olarak da hassasiyet, geri çağırma ve F1 skorlarında da en yüksek değeri %98 ile KNN öğrenme modelinde elde edilirken en düşük değerler de SVM modelinde hesaplanmıştır.


Tablo 4.4. Yatay milli pompa motoru fan+rulman sınıflandırma ölçüm sonuçları

Model	Sınıflandırma	Doğruluk Skoru (%)	Hassasiyet skoru (%)	Geri çağırma skoru (%)	F1 skoru (%)	Numune sayısı
1 D CNN	Arızalı	92,77	100	83	91	84
	Az arızalı		88	98	93	149
	Sağlam		96	93	94	99
2 D CNN	Arızalı	94,27	98	94	96	84
	Az arızalı		96	92	94	149
	Sağlam		90	98	94	99
KNN	Arızalı	98,19	98	99	98	84
	Az arızalı		99	97	98	149
	Sağlam		98	99	98	99
SVM	Arızalı	75,60	74	82	78	84
	Az arızalı		73	74	74	149
	Sağlam		83	72	77	99
Topluluk	Arızalı	97,29	98	98	98	84
	Az arızalı		99	96	97	149
	Sağlam		95	99	97	99

Ayrıca sınıflandırma eğitimlerinde yapılan tahminleri belirleyerek kaç sesin doğru ve kaç sesin yanlış tahmin edildiği Şekil 4.47.'de gösterilmiştir. Bu grafiğe göre arızalı ses için yapılan tahminlerde, 1D CNN modelinde 70 doğru ve 14 yanlış tahmin yapılmıştır. Az arızalı sesler için 146 doğru ve 3 yanlış tahmin edilirken sağlam sesler için ise 92 doğru ve 7 yanlış tahmin yapmıştır. Aynı şekilde diğer sınıflandırma modellerinde de doğru ve yanlış tahminler görülmektedir.

**Şekil 4.47.** Pompa motoru fan + rulman test verileri için doğru ve yanlış tahminler

Eğitim test verileri doğruluk oranı sonuçları Şekil 4.48.'de görüldüğü gibi, 1D CNN modelinde %92,77, 2D CNN modelinde %94,28, KNN modelinde %98,19, SVM modelinde %75,60 ve Topluluk öğrenme modelinde %97,29 olarak hesaplanmıştır. KNN öğrenme modeli, arızalı ve sağlam ve de Topluluk modeli de sağlam motor fan+rulman sesleri için tüm sesleri tahmin etmede %100'e yakın doğruluk oranı gösterirken, SVM modeli ile en düşük doğruluk oranı elde edilmiştir.




Şekil 4.48. Pompa motoru fan + rulman test verileri doğruluk değerleri

Bu kısımda yatay milli santrifüj pompa motoru fan+rulman sisteminin kestirimci bakım çalışmalarında ortaya çıkabilecek arızalara ait örnekler ve bu örneklerle ait ses analizi verilmiştir. Ses ölçümlerinin makine ve derin öğrenme modellerinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri incelendiğinde genel itibari ile uygulanmasının kabul edilebilir seviyelerde olduğu tespit edilmiştir. Verilere dayalı yaklaşımlar uygulayarak, stratejik karar verme için yorumlayıcı sonuçlar bulmanın mümkün olduğu ve bakım maliyetinin azaltılması, pompa fan arızalarının azaltılması, onarımın durması, üretimin artması, operatör güvenliğinde iyileşme, genel kâr gibi avantajlar sağlayabileceği düşünülmüştür.


4.5. Yatay Milli Santrifüj Pompa Tüm Sistem (Pompa Fanı, Pompa Ön Rulman, Pompa Arka Rulman, Pompa Motoru Fan+Rulman) Model Çalışması

4.5.1. Pompa tüm sistem 1D CNN model ses analizi

Makine öğrenmenin alt birimi olan derin öğrenmenin 1D CNN modeli ile yatay milli santrifüj pompa tüm sistem ses kaydı 25 döngü (epoch) kullanılarak eğitilmiştir. 1D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri, Şekil 4.49'da verilmiştir.




Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa tüm sistem ses kaydı 1D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir. Santrifüj pompa tüm sistem ses kaydı çalışmalarındaki arızalı, az arızalı ve sağlam ses verilerine ait ROC eğrisi ve karmaşıklık matrisi Şekil 4.50. ve Şekil 4.51.'de verilmiştir. ROC eğrisinde eğri altında kalan alanın hesaplanmasıyla modelin performansı ölçülmektedir. Karmaşıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir.



Şekil 4.50. Pompa tüm sistem 1D CNN için ROC eğrisi

Yatay milli santrifüj pompa tüm sistem ses kaydı çalışmalarındaki arızalı, az arızalı ve sağlam ses verilerine ait ROC eğrisi Şekil 4.50.'de verilmiştir.




Şekil 4.51. Pompa tüm sistem 1D CNN Modeli karışıklık matrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri

gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sınıflandırma etiketleri 1 (pompa arka rulman arızalı), 2 (pompa arka rulman az arızalı), 3 (pompa arka rulman sağlam), 4 (Pompa fan arızalı), 5 (pompa fan az arızalı), 6 (pompa fan sağlam), 7 (motor fan+rulman arızalı), 8 (motor fan+rulman az arızalı), 9 (motor fan+rulman sağlam), 10 (pompa ön rulman arızalı), 11 (pompa ön rulman az arızalı) ve 12 (pompa ön rulman sağlam) olarak tanımlanmıştır. Sonuçlar, Şekil 4.76.'de gösterildiği gibi, 1D CNN modelinin tahmin matrisi incelendiğinde, arka rulman arızalı olarak belirlenen 77 test verisinden 73 verinin doğru 4 verinin yanlış tahmin edildiği, arka rulman az arızalı olarak belirlenen 160 veriden 150 verinin az arızalı olarak doğru 10 verinin yanlış tahmin edildiği, arka rulman sağlam olarak belirlenen 60 veriden 58 veri sağlam olarak 2 veri yanlış tahmin etmiştir. Yine fan arızalı olarak belirlenen 124 test verisinden 109 veri doğru ve 15 verinin yanlış tahmin edildiği, fan az arızalı olarak belirlenen 253 test verisinden 221 veri doğru ve 32 veri yanlış tahmin edildiği, fan sağlam olarak belirlenen 202 test verisinden 178 veri doğru ve 24 veri yanlış tahmin edilmiştir. Motor fan+rulman arızalı olarak belirlenen 84 test verisinden 81 veri doğru ve 3 verinin yanlış tahmin edildiği, motor fan+rulman az arızalı olarak belirlenen 139 test verisinden 121 veri doğru ve 18 veri yanlış tahmin edildiği, motor fan+rulman sağlam olarak belirlenen 101 test verisinden 93 veri doğru ve 8 veri yanlış tahmin edilmiştir. Ön rulman arızalı olarak belirlenen 95 test verisinden 90 verinin doğru 5 verinin yanlış tahmin edildiği, ön rulman az arızalı olarak belirlenen 85 veriden 73 verinin az arızalı olarak doğru 12 verinin yanlış tahmin edildiği, ön rulman sağlam olarak belirlenen 159 veriden 133 veri sağlam olarak 26 veri yanlış tahmin etmiştir.


4.5.2. Pompa tüm sistem 2D CNN model ses analizi

Derin öğrenmenin 2D CNN modeli ile santrifüj pompa tüm sistem ses kaydı 25 döngü kullanılarak eğitilmiştir. 2D CNN modelinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri ve her döngüdeki eğitim ve test verisi sınıflandırma metrik değerlerini gösteren grafikler Şekil 4.52.'de gösterilmiştir. Bu grafiklerde gösterilen sonuçlar incelendiğinde, 5. dönemden sonraki eğitim döngüleri boyunca başarı oranlarının, kayıpların ve skorların büyük ölçüde sabit kaldığı görülmektedir. Santrifüj pompa tüm sistem ses kaydı 2D CNN eğitim sürecinde, her bir ses dosyasından elde edilen MFCC görüntülerinden türetilen 15 özellik eğitim prosedürüne dahil edilmiştir.




Şekil 4.52. Pompa tüm sistem 2D CNN Model Eğitim ve testin dönemlere göre doğruluk / kayıp durumu

Yatay milli santrifüj pompa fanı ses kaydı çalışmalarındaki 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11 ve 12 ses etiketlerine ait ROC eğrisi aşağıda şekil 4.53.'te verilmiştir.



Şekil 4.53. Pompa tüm sistem 2D CNN için ROC eğrisi




Şekil 4.54. Pompa tüm sistem 2D CNN Modeli karışıklık matrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sonuçlar, Şekil 4.54.'te gösterildiği gibi, 2D CNN modelinin tahmin matrisi incelendiğinde, arka rulman arızalı olarak belirlenen 77 test verisinden 71 verinin doğru 6 verinin yanlış tahmin edildiği, arka rulman az arızalı olarak belirlenen 160 veriden 153 verinin az arızalı olarak doğru 7 verinin yanlış tahmin edildiği, arka rulman sağlam olarak belirlenen 60 veriden 55 veri sağlam olarak 5 veri yanlış tahmin etmiştir. Yine fan arızalı olarak belirlenen 124 test verisinden 107 veri doğru ve 17 verinin yanlış tahmin edildiği, fan az arızalı olarak belirlenen 253 test verisinden 235 veri doğru ve 18 veri yanlış tahmin edildiği, fan sağlam olarak belirlenen 202 test verisinden 186 veri doğru ve 16 veri yanlış tahmin edilmiştir. Motor fan+rulman arızalı olarak belirlenen 84 test verisinden 82 veri doğru ve 2 verinin yanlış tahmin edildiği, motor fan+rulman az arızalı olarak belirlenen 139 test verisinden 127 veri doğru ve 12 veri yanlış tahmin edildiği, motor fan+rulman sağlam olarak belirlenen 101 test verisinden 93 veri doğru ve 8 veri yanlış tahmin

edilmiştir. Ön rulman arızalı olarak belirlenen 95 test verisinden 92 verinin doğru 3 verinin yanlış tahmin edildiği, ön rulman az arızalı olarak belirlenen 85 veriden 81 verinin az arızalı olarak doğru 4 verinin yanlış tahmin edildiği, ön rulman sağlam olarak belirlenen 159 veriden 148 veri sağlam olarak 11 veri yanlış tahmin etmiştir.

4.5.3. Pompa tüm sistem KNN modeli ses analizi


Makine öğrenmesi modellerinden biri olan KNN modeli ile santrifüj pompa tüm sistem ses analizi özneteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. KNN modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.55'te verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznetelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkcı başarı ve skor oranlarının çok değışmediğı görölmektedir.



Şekil 4.55. Pompa tüm sistem KNN modeli için öğrenme eğrisi ve ROC eğrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sonuçlar, Şekil 4.56'da gösterildiği gibi, KNN modelinin tahmin matrisi incelendiğinde, pompa arka rulman arızalı olarak belirlenen 77 test verisinden 74 verinin doğru 3 verinin yanlış tahmin edildiği, arka rulman az arızalı olarak belirlenen 160 veriden 147 verinin az arızalı olarak doğru 13 verinin yanlış tahmin edildiği, arka rulman sağlam olarak


belirlenen 60 veriden 56 veri sağlam olarak 4 veri yanlış tahmin etmiştir. Yine fan arızalı olarak belirlenen 124 test verisinden 118 veri doğru ve 6 verinin yanlış tahmin edildiği, fan az arızalı olarak belirlenen 253 test verisinden 241 veri doğru ve 12 veri yanlış tahmin edildiği, fan sağlam olarak belirlenen 202 test verisinden 196 veri doğru ve 6 veri yanlış tahmin edilmiştir. Motor fan+rulman arızalı olarak belirlenen 84 test verisinden 83 veri doğru ve 1 verinin yanlış tahmin edildiği, motor fan+rulman az arızalı olarak belirlenen 139 test verisinden 133 veri doğru ve 6 veri yanlış tahmin edildiği, motor fan+rulman sağlam olarak belirlenen 101 test verisinden 97 veri doğru ve 4 veri yanlış tahmin edilmiştir. Ön rulman arızalı olarak belirlenen 95 test verisinden 95 verinin doğru 0 verinin yanlış tahmin edildiği, ön rulman az arızalı olarak belirlenen 85 veriden 80 verinin az arızalı olarak doğru 5 verinin yanlış tahmin edildiği, ön rulman sağlam olarak belirlenen 159 veriden 156 veri sağlam olarak 3 veri yanlış tahmin etmiştir.



Şekil 4.56. Pompa tüm sistem KNN Modeli karışıklık matrisi

4.5.4. SVM modeli ses analizi


Makine öğrenmesi modellerinden biri olan SVM modeli ile santrifüj pompa tüm sistem ses analizi öz niteliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. SVM modelinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.57.'de verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öz nitelikler, genlik-zaman, mel-spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça başarı ve skor oranlarının arttığı görülmektedir.



Şekil 4.57. SVM Eğitim örnek sayısının doğruluk durumu eğrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sonuçlar, Şekil 4.58.'de gösterildiği gibi, SVM modelinin tahmin matrisi incelendiğinde, arka rulman arızalı olarak belirlenen 77 test verisinden 55 verinin doğru 22 verinin yanlış tahmin edildiği, arka rulman az arızalı olarak belirlenen 160 veriden 134 verinin az arızalı olarak doğru 26 verinin yanlış tahmin edildiği, arka rulman sağlam olarak belirlenen 60 veriden 43 veri sağlam olarak 17 veri yanlış tahmin etmiştir. Yine fan arızalı olarak belirlenen 124 test verisinden 56 veri doğru ve 68 verinin yanlış tahmin edildiği, fan az arızalı olarak belirlenen 253 test verisinden 146 veri doğru ve 107 veri yanlış tahmin edildiği, fan sağlam olarak belirlenen 202 test verisinden 98 veri doğru ve 104 veri yanlış tahmin edilmiştir. Motor fan+rulman arızalı olarak belirlenen 84 test verisinden

63 veri doğru ve 21 verinin yanlış tahmin edildiği, motor fan+rulman az arızalı olarak belirlenen 139 test verisinden 104 veri doğru ve 35 veri yanlış tahmin edildiği, motor fan+rulman sağlam olarak belirlenen 101 test verisinden 69 veri doğru ve 32 veri yanlış tahmin edilmiştir. Ön rulman arızalı olarak belirlenen 95 test verisinden 73 verinin doğru 22 verinin yanlış tahmin edildiği, ön rulman az arızalı olarak belirlenen 85 veriden 61 verinin az arızalı olarak doğru 24 verinin yanlış tahmin edildiği, ön rulman sağlam olarak belirlenen 159 veriden 97 veri sağlam olarak 62 veri yanlış tahmin etmiştir.




Şekil 4.58. Pompa tüm sistem SVM Modeli karışıklık matrisi

4.5.5. Topluluk modeli ses analizi

Topluluk modeli ile santrifüj pompa tüm sesler ses analizi özneliklerin çıkartılması sonucu elde edilen veriler kullanılarak sınıflandırılmıştır. Topluluk modelinde kullanılan RF, SVM ve KNN modellerinin eğitim ve doğrulama skorlarının gösterildiği öğrenme eğrisi ve ROC eğrisi Şekil 4.59.'da verilmiştir. Makine öğrenimi modellerin eğitiminde kullanılan verileri oluşturan öznelikler, genlik-zaman, mel-


spektrogram, MFCC, ZCR ve RMS Enerji özelliklerden 18 adet çıkartılmıştır. Grafikler incelendiğinde eğitim örnekleme sayısı artıkça RF modeli için başarı ve skor oranlarının çok değişmediği, ancak SVM ve KNN modelleri için ise artmıştır.



Şekil 4.59. Topluluk Eğitim örnek sayısının doğruluk durumu eğrisi

Karışıklık matrisi, sınıflandırma için test verileri tarafından oluşturulan tahminleri ve aynı zamanda bir sınıflandırma modelinin eğitimi yoluyla elde edilen doğruluk oranlarını göstermektedir. Her bir sınıflandırma için köşegenler doğru tahminleri gösterirken, diğer değerler hatalı tahminleri göstermektedir. Sonuçlar, Şekil 4.60.'de gösterildiği gibi, Ensemble modelinin tahmin matrisi incelendiğinde, arka rulman arızalı olarak belirlenen 77 test verisinden 74 verinin doğru 3 verinin yanlış tahmin edildiği, arka rulman az arızalı olarak belirlenen 160 veriden 150 verinin az arızalı olarak doğru 10 verinin yanlış tahmin edildiği, arka rulman sağlam olarak belirlenen 60 veriden 58 veri sağlam olarak 2 veri yanlış tahmin etmiştir. Yine fan arızalı olarak belirlenen 124 test verisinden 122 veri doğru ve 2 verinin yanlış tahmin edildiği, fan az arızalı olarak belirlenen 253 test verisinden 248 veri doğru ve 5 veri yanlış tahmin edildiği, fan sağlam olarak belirlenen 202 test verisinden 199 veri doğru ve 3 veri yanlış tahmin edilmiştir. Motor fan+rulman arızalı olarak belirlenen 84 test verisinden 83 veri doğru ve 1 verinin yanlış tahmin edildiği, motor fan+rulman az arızalı olarak belirlenen 139 test verisinden 133 veri doğru ve 6 veri yanlış tahmin edildiği, motor fan+rulman sağlam olarak belirlenen 101 test verisinden 96 veri doğru ve 5 veri yanlış tahmin edilmiştir. Ön rulman arızalı olarak belirlenen 95 test verisinden 95 verinin doğru 0 verinin yanlış tahmin edildiği, ön rulman az arızalı olarak belirlenen 85 veriden 81 verinin az arızalı olarak doğru 4 verinin yanlış tahmin edildiği, ön rulman

sağlam olarak belirlenen 159 veriden 155 veri sağlam olarak 4 veri yanlış tahmin etmiştir.



Şekil 4.60. Pompa tüm sistem Topluluk Modeli karışıklık matrisi


Tablo 4.5. Yatay milli santrifüj pompa tüm sistem sınıflandırma metrik sonuçları

Model	Sınıflandırma	Doğruluk Skoru (%)	Hassasiyet skoru (%)	Geri çağırma skoru (%)	F1 skoru (%)	Numune sayısı
1 D CNN	Arka rulman arızalı	89,67	97	95	96	77
	Arka rulman az arızalı		96	94	95	160
	Arka rulman sağlam		87	97	91	60
	Fan arızalı		95	88	91	124
	Fan az arızalı		82	87	84	253
	Fan sağlam		84	88	86	202
	Motor fan+rulman arızalı		96	96	96	84
	Motor fan+rulman az arızalı		89	87	88	139
	Motor fan+rulman sağlam		95	92	93	101
	Ön rulman arızalı		92	95	93	95
	Ön rulman az arızalı		88	86	87	85
	Ön rulman sağlam		94	84	88	159
2D CNN	Arka rulman arızalı	92,92	99	92	95	77
	Arka rulman az arızalı		96	96	96	160
	Arka rulman sağlam		80	92	85	60
	Fan arızalı		96	86	91	124
	Fan az arızalı		90	93	91	253
	Fan sağlam		89	92	91	202
	Motor fan+rulman arızalı		99	98	98	84
	Motor fan+rulman az arızalı		94	91	93	139
	Motor fan+rulman sağlam		92	92	92	101
	Ön rulman arızalı		95	97	96	95
	Ön rulman az arızalı		92	95	94	85
	Ön rulman sağlam		96	93	95	159

Tablo 4.5. Yatay milli santrifüj pompa tüm sistem sınıflandırma metrik sonuçları(Tablonun devamı)

KNN	Arka rulman arızalı	95	96	95	77
	Arka rulman az arızalı	95	92	94	160
	Arka rulman sağlam	92	93	93	60
	Fan arızalı	96	95	96	124
	Fan az arızalı	93	95	94	253
	Fan sağlam	96	97	96	202
	Motor fan+rulman arızalı	99	99	99	84
	Motor fan+rulman az arızalı	98	96	97	139
	Motor fan+rulman sağlam	97	96	97	101
	Ön rulman arızalı	98	100	99	95
	Ön rulman az arızalı	99	94	96	85
	Ön rulman sağlam	97	98	98	159
SVM	Arka rulman arızalı	73	71	72	77
	Arka rulman az arızalı	67	84	74	160
	Arka rulman sağlam	70	72	71	60
	Fan arızalı	49	45	47	124
	Fan az arızalı	50	58	53	253
	Fan sağlam	48	49	48	202
	Motor fan+rulman arızalı	91	75	82	84
	Motor fan+rulman az arızalı	72	75	73	139
	Motor fan+rulman sağlam	85	68	76	101
	Ön rulman arızalı	95	77	85	95
	Ön rulman az arızalı	71	72	71	85
	Ön rulman sağlam	74	61	67	159
Topluluk	Arka rulman arızalı	99	96	97	77
	Arka rulman az arızalı	98	94	96	160
	Arka rulman sağlam	92	97	94	60
	Fan arızalı	96	98	97	124
	Fan az arızalı	95	98	96	253
	Fan sağlam	97	99	98	202
	Motor fan+rulman arızalı	99	99	99	84
	Motor fan+rulman az arızalı	97	96	96	139
	Motor fan+rulman sağlam	99	95	97	101
	Ön rulman arızalı	100	100	100	95
	Ön rulman az arızalı	99	95	97	85
	Ön rulman sağlam	98	98	98	159

Eğitim test verileri doğruluk oranı sonuçları Şekil 4.61.'de görüldüğü gibi, 1D CNN modelinde %89,67, 2D CNN modelinde %92,92, KNN modelinde %95,93, SVM modelinde %64,91 ve ensemble öğrenme modelinde %97,14 olduğunu göstermiştir. Ensemble öğrenme modeli, arızalı pompa motoru fan+rulman sesleri için tüm sesleri tahmin etmede %97,14 doğruluk oranı ile en yüksek, SVM öğrenme modeli %64,91 ile en düşük doğruluk oranı elde edilmiştir.



Şekil 4.61. Pompa tüm sistem test verileri doğruluk değerleri

Bu kısımda yatay milli santrifüj pompa tüm sisteminin kestirimci bakım çalışmalarında ortaya çıkabilecek arızalara ait örneklerin ses analizi verilmiştir. Ses ölçümlerinin makine ve derin öğrenme modellerinin eğitim başarısı ile birlikte her döngü sonundaki kayıp değerleri, test verisinin doğruluk başarısı ve kayıp değerleri incelendiğinde genel itibari ile uygulanmasının parçaların tek tek ses dinleme analizine göre daha az kabul edilebilir seviyelerde olduğu tespit edilmiştir. Verilere dayalı yaklaşımlar uygulayarak, stratejik karar verme için yorumlayıcı sonuçlar bulmanın mümkün olduğu ve bakım maliyetinin azaltılması, pompa ve motoru parçalarının arızalarının azaltılması, onarımın durması, üretimin artması, operatör güvenliğinde iyileşme, genel kâr gibi avantajlar sağlayabileceği düşünülmüştür.

Santrifüj pompalarda en sık rastlanan arızaların başında rulman ve fan arızalarıdır. Bu arızaların tespit edilmesinde en sık rastlanan yöntemlerin başında titreşim analizleri gelmektedir (Zhao ve ark., 2019). Yapay zekanın ortaya çıkmasıyla birlikte titreşimlerden elde edilen veriler kullanılarak arızaların tahmin edilmesi ve sınıflandırılması işlemlerinde makine öğrenmesi regresyon ve sınıflandırma modelleri kullanılarak yapılmıştır. Son zamanlarda modellerin geliştirilmesiyle birlikte artık titreşim sinyalleri yerine ses sinyallerinden yararlanmaya başlanılmıştır. Ses sinyallerinin makine öğrenmesi modellerinde ve derin öğrenme modellerinde kullanılmasıyla birlikte başta sağlık alanında yapılan çalışmalar olmak üzere pek çok

alana yayılmıştır. Bu çalışmalardan yola çıkarak ses sinyallerinden oluşan grafiklerden bazı özniteliklerin çıkartılmasıyla elde edilen verilerin yanı sıra direk ses sinyallerinin kullanılarak sınıflandırma ve regresyon modelleriyle tahmin ve sınıflandırma yapılmıştır. Pek çok çalışmada titreşim sinyalleri kullanılarak arıza teşhisi yapılırken ses sinyallerinin işlenmesiyle rulman ve fan arızalarının teşhis edilmesi amaçlanmıştır. Böylece makinelere ait arıza ve gürültüden kaynaklı hataların tespit edilmesi işlemlerinde ses sinyallerinin kullanılmasıyla bu alanda çalışmaların yoğunlaşmasını sağlayacaktır.

Ses sinyalleri kullanılarak rulman ve fan arızalarının teşhis edilebilmesiyle titreşimlerin ölçülmesinde ve gürültünün tespitinde kullanılan yöntemleri yerine ses sensörleri veya kayıt cihazı kullanılarak santrifüj pompalar ve arızalı durumlarda sestten oluşabilecek değişikliklerden yararlanabilir. Bir makinenin çıkardığı sesi kaydetmek kolay bir işlem ve daha ekonomik olduğundan dolayı da arıza teşhislerinde, erken arıza ve kestirimci bakım programlarında ses sinyallerinden de yararlanabileceği görülmüştür. Bu çalışma sayesinde alternatif bir çalışma alanı olarak makinelerde ve mekanizmalarda oluşan ses değişikliklerinden yola çıkılarak çeşitli arıza sınıflandırma veya özelliklerin sınıflandırılması işlemleri de yapılarak daha kolay yöntemlerin kullanılması sağlanacaktır.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Yatay milli santrifüj pompa gibi dönen makinelerin parçalarının aşınması, kırılması, bozulması veya sürtünme gevşekliğinden kaynaklanabilecek olumsuz sonuçları önlemek için arızaları erken bir aşamada teşhis edebilmek büyük önem taşımaktadır. Makinelerde arızalı parçaların kullanılmaya devam edilmesi, düşük verimle çalışan makinelerde meydana gelen enerji kayıplarının yanı sıra ekonomik kayıplara da neden olabilir. Santrifüj pompada kullanılan parçalardan en sık arızalanan en önemli iki parçası rulman ve fanın çıkardığı sesler arızalı, hafif arızalı ve sağlam olarak kategorize edilmiştir. Diyarbakır Büyükşehir Belediyesi Su ve Kanalizasyon İdaresi Genel Müdürlüğü hizmet alanında bulunan Bismil İlçesi'ne içme suyu sağlayan terfi istasyonunda bulunan 3 adet 132 kW ve 3 adet 90 kW'lık 6 adet yatay milli santrifüj pompalarda kullanılan rulmanların ve fanların durumunu tespit etmek için üç-dört aylık bir süre boyunca pompa fanların, pompa ön rulmanların, pompa arka rulmanların, pompa motoru fan+rulmanların ve tüm sistem beraber çıkardığı sesler ses kayıt cihaz ile dinlenerek kaydedilmiştir. Sesler bilgisayar ortamında işlenerek sınıflandırma modellerinde veri olarak kullanılmıştır. Eğitim sürecinde MFCCs(Mel-Frequency Cepstral Coefficients) görüntülerinden 15 özellik dizisi ve 15 özellik görüntüsü derin öğrenmenin 1D(1 boyutlu) CNN(Evrişimsel Sinir ağları) ve 2D CNN modellerinde kullanıldı. Buna karşılık, makine öğrenmenin KNN(k-en yakın komşular), SVM (Destek Vektör Makineleri) ve Topluluk modellerinde kullanılmak üzere genlik-zaman, Mel-spektrogram, MFCCs, ZCR (Sıfır Geçiş Oranları) ve RMS (Ortalama Enerji Karekökleri) Enerji özelliklerinden 18 özellik çıkarılmıştır. Çalışma boyunca kayıt ve ölçümler sonucu elde edilen istatistiksel veriler şu şekilde olmuştur.

1. sırada yatay milli santrifüj pompa fanı eğitim ve test çalışmasında; 699 arızalı, 1.247 az arızalı ve 1.044 sağlam pompa fan sesi eğitim verisi ile 156 arızalı, 245 az arızalı ve 197 sağlam pompa fan sesi test verisi olmak üzere 855 arızalı, 1.492 az arızalı ve 1.241 sağlam yatay milli santrifüj pompa fan sesi kullanılmıştır. Eğitim test verileri doğruluk oranı sonuçları, 1D CNN modelinde %92,47, 2D CNN modelinde %93,98, KNN modelinde %98,33, SVM modelinde %63,38 ve ensemble öğrenme modelinde %98,83 olduğunu göstermiştir. Ensemble öğrenme modeli, arızalı fan sesleri için tüm

sesleri tahmin etmede %100'e yakın doğruluk oranı gösterirken, SVM öğrenme modeli ile en uzak doğruluk oranı elde edilmiştir.

2. sırada yatay milli santrifüj pompa ön rulman eğitim ve test çalışmasında; 461 arızalı, 408 az arızalı ve 699 sağlam pompa ön rulman sesi eğitim verisi ile 95 arızalı, 81 az arızalı ve 138 adet sağlam pompa ön rulman sesi test verisi olmak üzere 556 arızalı, 489 az arızalı ve 837 sağlam yatay milli santrifüj pompa ön rulman sesi kullanılmıştır. Eğitim test verileri doğruluk oranı sonuçları, 1D CNN modelinde %96,18, 2D CNN modelinde %96,85, KNN modelinde %99,04, SVM modelinde %84,08 ve ensemble öğrenme modelinde %99,68 olduğunu göstermiştir. Ensemble öğrenme modeli, arızalı pompa ön rulman sesleri için tüm sesleri tahmin etmede %100'e yakın doğruluk oranı gösterirken, SVM öğrenme modeli ile en uzak doğruluk oranı elde edilmiştir.

3. sırada yatay milli santrifüj pompa arka rulman eğitim ve test çalışmasında; 329 arızalı, 801 az arızalı ve 350 sağlam pompa arka rulman sesi eğitim verisi ile 63 arızalı, 164 az arızalı ve 69 sağlam pompa arka rulman sesi test verisi olmak üzere 392 arızalı, 965 az arızalı ve 419 sağlam yatay milli santrifüj pompa arka rulman sesi kullanılmıştır. Eğitim test verileri doğruluk oranı sonuçları, 1D CNN modelinde %94,59, 2D CNN modelinde %98,65, KNN modelinde %98,99, SVM modelinde %89,53 ve Ensemble öğrenme modelinde %99,66 olduğunu göstermiştir. Ensemble öğrenme modeli, arızalı pompa arka rulman sesleri için tüm sesleri tahmin etmede %100'e yakın doğruluk oranı gösterirken, SVM öğrenme modeli ile en uzak doğruluk oranı elde edilmiştir.

4. sırada yatay milli santrifüj pompa motoru fan+rulman eğitim ve test çalışmasında: 391 arızalı, 752 az arızalı ve 513 sağlam pompa motoru fan+rulman sesi eğitim verisi ile 84 arızalı, 149 az arızalı ve 99 sağlam pompa motor fan + rulman sesi test verisi olmak üzere 475 arızalı, 901 az arızalı ve 612 sağlam yatay milli santrifüj pompa motoru fan+rulman sesi kullanılmıştır. Eğitim test verileri doğruluk oranı sonuçları, 1D CNN modelinde %92,77, 2D CNN modelinde %94,28, KNN modelinde %98,19, SVM modelinde %75,60 ve Topluluk öğrenme modelinde %97,29 olduğunu göstermiştir. KNN öğrenme modeli, arızalı pompa motoru fan+rulman sesleri için tüm sesleri tahmin etmede %100'e yakın doğruluk oranı gösterirken, SVM öğrenme modeli ile en uzak doğruluk oranı elde edilmiştir.

5. sırada yatay milli santrifüj pompa tüm sistem (pompa fanı, pompa ön rulman, pompa arka rulman, pompa motoru fan + rulman) eğitim ve test çalışmasında; 308 arızalı

pompa arka rulman, 640 az arızalı pompa arka rulman, 240 sağlam pompa arka rulman, 496 arızalı pompa fan, 1012 az arızalı pompa fan, 808 sağlam pompa fan, 336 arızalı pompa motoru fan + rulman, 556 az arızalı pompa motoru fan + rulman, 404 sağlam pompa motoru fan + rulman, 380 arızalı pompa ön rulman, 340 az arızalı pompa ön rulman, 636 sağlam pompa ön rulman sesi olmak üzere tüm sistem sesi eğitim verisi ile 77 arızalı pompa arka rulman, 160 az arızalı pompa arka rulman, 60 sağlam pompa arka rulman, 124 arızalı pompa fan, 253 az arızalı pompa fan, 202 sağlam pompa fan, 84 arızalı pompa motoru fan + rulman, 139 az arızalı pompa motoru fan + rulman, 101 sağlam pompa motoru fan + rulman, 95 arızalı pompa ön rulman, 85 az arızalı pompa ön rulman, 159 sağlam pompa ön rulman sesi olmak üzere tüm sistem sesi test verisi olmak üzere 385 arızalı pompa arka rulman, 800 az arızalı pompa arka rulman, 300 sağlam pompa arka rulman, 620 arızalı pompa fan, 1265 az arızalı pompa fan, 1010 sağlam pompa fan, 420 arızalı pompa motoru fan + rulman, 695 az arızalı pompa motoru fan + rulman, 505 sağlam pompa motoru fan + rulman, 475 arızalı pompa ön rulman, 425 az arızalı pompa ön rulman, 795 sağlam pompa ön rulman sesi olmak üzere tüm sistem sesi kullanılmıştır. Eğitim test verileri doğruluk oranı sonuçları, 1D CNN modelinde %89,67, 2D CNN modelinde %92,92, KNN modelinde %95,93, SVM modelinde %64,91 ve Topluluk öğrenme modelinde %97,14 olduğunu göstermiştir. Ensemble öğrenme modeli, arızalı pompa tüm sistem sesleri için tahmin etmede %97,14 doğruluk oranı ile en yüksek, SVM öğrenme modeli %64,91 ile en düşük doğruluk oranı elde edilmiştir.

Bu sonuçlar Makine öğrenme ve derin öğrenme modellerinin kullanılmasının arızaların erken teşhisini kolaylaştıracağını ve yatay milli santrifüj pompa gibi dönen makinelerin büyük hasarların oluşmasını engelleyebileceğini göstermektedir.

5.2. Öneriler

Yatay milli santrifüj pompalar ile ilgili yapılan öğrenme modelleri çalışmalarında; aşağıda belirtilen işlemler uygulanırsa ses analizinde arıza tespitinde daha iyi sonuçlar elde edilecektir.

Pompa grupları mümkün olduğunca mesafeli olarak dizayn edilmelidir. Pompa ve motorlarının birbirine ısı ve gürültü yaymaları önlenmelidir.

Yatay milli santrifüj pompa fanı değiştirilirken fan ölçülerine dikkat edilmelidir. Ölçünün küçük veya büyük seçilmesi ortam gürültüsüne etki edecektir.

Aynı şekilde rulman seçilirken de pompa ve motorunun büyüklüğü ve yatak durumuna uygun seçilmelidir. Zira pompa arızalarının en önemli nedeni rulmanların ısınması ve fark edilmeden arızalı şekilde çalıştırılmasından kaynaklanmaktadır.

Çalışma esnasında kullanılan pompanın bakım talimatına uygun içerikli malzeme ihtiva eden yağ kullanılmalıdır. Ayrıca yine kullanılan pompanın bakım talimatında belirtilen zaman diliminde yağlama yapılmalıdır. Zira yüzey gerilimine karşı kullanılan yağın viskozitesini kaybetmemesi rulmanın gürültülü çalışmasına neden olacaktır.

Pompa ve motorunun dinlenmesi sırasında dinleme cihazının uygun mesafede tutulması ve sabitlenmesi arıza teşhisinin yapılmasında daha sağlıklı sonuçlar elde edilmesinde önemli rol oynamaktadır.

Yine dinlenme sırasında aynı ortamda birkaç adet pompa ve motoru varsa bunların dinlenmesi sırasında diğerlerinin dinlenme süresince durdurulmasında yarar vardır.

Dinlenme sırasında seçilen öğrenme modelinin dinlenmesi yapılacak parçalara uygun olanı seçilmelidir. Çalışmamız incelendiğinde; farklı parçalarda model tahmin ölçümlerinde değişiklik gösterdiği görülmüştür.

Özellikle birden fazla yatay milli santrifüj pompanın çalıştığı pompa istasyonlarında belirli aralıklar bırakılarak bilgisayara bağlanacak ses sensörleri ve ses izolasyonu kullanılarak(çalışma ortam ısısının sağlanarak) üretim ve maliyet kaybı en aza indirilebileceği kanaatine varılmıştır.

KAYNAKLAR

- Albraik, A., Althobiani, F., Gu, F., & Ball, A. (2012, May). Diagnosis of centrifugal pump faults using vibration methods. In *Journal of Physics: Conference Series* (Vol. 364, No. 1, p. 012139). IOP Publishing.
- Alpaydın, E. (2013). Yapay öğrenme (4. baskı). *Boğaziçi Üniversitesi*.
- Anonim, (2022), https://www.etiya.com/tr/blog/makine-ogrenmesimachine-learning-ve-derin-ogrenme-nedir?gad_source=1&gclid=Cj0KCQjwxeyxBhC7ARIsAC7dS39U-eqroHSZPF6Y71Dg1MkpxYw5mFKBIUFGThexWF6X0-vfO7GjWs-8aAtfeEALw_wcB
- Anonim, (2018), MAS DAF Teknik Doküman
https://masdaf.com/_upload/pdf/TR_NM_TD.pdf
- Arslan, K. (2020). Artificial intelligence and applications in education. *Western Anatolia Journal of Educational Sciences*, 11(1), 71-80.
- Atalay, M., & Çelik, E. (2017). Artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Babaei, E., Anuar, N. B., Abdul Wahab, A. W., Shamshirband, S., & Chronopoulos, A. T. (2017). An overview of audio event detection methods from feature extraction to classification. *applied artificial intelligence*, 31(9-10), 661-714.
- Balaban, M. E., & Kartal, E. (2015). Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları. *Çağlayan Kitabevi, İstanbul*.
- Baptista, M., Sankararaman, S., de Medeiros, I. P., Nascimento Jr, C., Prendinger, H., & Henriques, E. M. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41-53.
- Birajdar, R., Patil, R., & Khanzode, K. (2009, July). Vibration and noise in centrifugal pumps-Sources and diagnosis methods. In *3rd International conference on Integrity, Reliability and Failure* (pp. 20-24).
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- Cioffi, R., Travagliani, M., Piscitelli, G., Petrillo, A., & De Felice, F. (2020). Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions. *Sustainability*, 12(2), 492.
- Coleman, C., Damofaran, S., & Deuel, E. (2017). Predictive maintenance and the smart factory. *Deloitte Consulting LLP*.

- Çakıroğlu, M. A., & Süzen, A. A. (2020). Assessment and application of deep learning algorithms in civil engineering. *El-Cezeri*, 7(2), 906-922.
- Demir, H. G., & Müştak, O. (2021). Rulman Hasarlarının Titreşim ve Gürültü Analizi ile Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (25), 571-581.
- Dündar, D. R., Sarıçiçek, İ., Çınar, E., & Yazıcı, A. (2021). Kestirimci Bakımda Makine öğrenmesi: Literatür Araştırması. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 29(2), 256-276.
- Ersoy, H., & Özdemir, L. (2011). İklimlendirme Sistemlerine Ait Performans Tespitlerinin Akustik Analizlere Göre Yapılması. *Engineer & the Machinery Magazine*, (623).
- Ertürk, B. (2001). Hidrolik gürültü ve azaltma yöntemleri, II. *Ulusal Hidrolik Ve Pnömatik Kongresi ve Sergisi Bildiriler Kitabı*, 8-11.
- Gong, C. S. A., Lee, H. C., Chuang, Y. C., Li, T. H., Su, C. H. S., Huang, L. H., ... & Chang, C. H. (2018). Design and implementation of acoustic sensing system for online early fault detection in industrial fans. *Journal of Sensors*, 2018.
- Griner, P. F., Mayewski, R. J., Mushlin, A. I., & Greenland, P. (1981). Selection and interpretation of diagnostic tests and procedures. *Annals of internal medicine*, 94(4 II).
- Guo, G., Wang, H., Bell, D., Bi, Y., & Greer, K. (2003). KNN model-based approach in classification. In *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE: OTM Confederated International Conferences, CoopIS, DOA, and ODBASE 2003, Catania, Sicily, Italy, November 3-7, 2003. Proceedings* (pp. 986-996). Springer Berlin Heidelberg.
- Gupta, P., & Pradhan, M. K. (2017). Fault detection analysis in rolling element bearing: A review. *Materials Today: Proceedings*, 4(2), 2085-2094.
- Huang, D. S. (1996). Systematic theory of neural networks for pattern recognition. *Publishing House of Electronic Industry of China, Beijing*, 201.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Jueyendah, S., Lezgy-Nazargah, M., Eskandari-Naddaf, H., & Emamian, S. A. (2021). Predicting the mechanical properties of cement mortar using the support vector machine approach. *Construction and Building Materials*, 291, 123396.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151, 107398.

- Lei, Y., Lin, J., He, Z., & Zi, Y. (2011). Application of an improved kurtogram method for fault diagnosis of rolling element bearings. *Mechanical systems and signal processing*, 25(5), 1738-1749
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., & Nandi, A. K. (2020). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Liu, H., Guo, K., Zhang, Z., Yu, D., Zhang, J., Ning, P., ... & Niu, P. (2017). High-power LED photoelectrothermal analysis based on backpropagation artificial neural networks. *IEEE Transactions on Electron Devices*, 64(7), 2867-2873.
- Malhi, A., & Gao, R. X. (2004). PCA-based feature selection scheme for machine defect classification. *IEEE transactions on instrumentation and measurement*, 53(6), 1517-1525.
- Metz, C. E. (1978, October). Basic principles of ROC analysis. In *Seminars in nuclear medicine* (Vol. 8, No. 4, pp. 283-298). WB Saunders.
- Mourtzis, D., Angelopoulos, J., & Panopoulos, N. (2020). Intelligent predictive maintenance and remote monitoring framework for industrial equipment based on mixed reality. *Frontiers in Mechanical Engineering*, 6, 578379.
- Mourtzis, D., Vlachou, E., Milas, N., & Xanthopoulos, N. (2016). A cloud-based approach for maintenance of machine tools and equipment based on shop-floor monitoring. *Procedia Cirp*, 41, 655-660.
- Mueller, P. N., Woelfl, L., & Can, S. (2023). Bridging the gap between AI and the industry—A study on bearing fault detection in PMSM-driven systems using CNN and inverter measurement. *Engineering Applications of Artificial Intelligence*, 126, 106834.
- Prashanth, A., Jayalakshmi, S. L., & Vedhapriyavadhana, R. (2024). A review of deep learning techniques in audio event recognition (AER) applications. *Multimedia Tools and Applications*, 83(3), 8129-8143.
- Rai, A., & Upadhyay, S. H. (2016). A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribology International*, 96, 289-306.
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 8(4), e1249.
- Shibata, K., Takahashi, A., & Shirai, T. (2000). Fault diagnosis of rotating machinery through visualisation of sound signals. *Mechanical Systems and Signal Processing*, 14(2), 229-241.

- Sohaib, M., Kim, C. H., & Kim, J. M. (2017). A hybrid feature model and deep-learning-based bearing fault diagnosis. *Sensors*, 17(12), 2876.
- Tatar, V. (2010). *Su pompa istasyonunda kestirimci bakım ve yönetim organizasyonu* (Doctoral dissertation, Sakarya Üniversitesi (Turkey)).
- Torshizi, S. M., Nikraves, S. Y., & Jahangiri, A. (2009). Failure analysis of gas turbine generator cooling fan blades. *Engineering Failure Analysis*, 16(5), 1686-1695.
- Tran, T., & Lundgren, J. (2020). Drill fault diagnosis based on the scalogram and mel spectrogram of sound signals using artificial intelligence. *Ieee Access*, 8, 203655-203666.
- Trebuňa, F., Šimčák, F., Bocko, J., Huňady, R., & Pástor, M. (2014). Complex approach to the vibrodiagnostic analysis of excessive vibration of the exhaust fan. *Engineering Failure Analysis*, 37, 86-95.
- Tunç, A., & Ülger, İ. (2016). Veri madenciliği uygulamalarında özellik seçimi için finansal değerlere binning ve five number summary metotları ile normalizasyon işleminin uygulanması. *XVIII. Akademik Bilişim Konferansı, Adnan Menderes Üniversitesi*, 30, 3.
- Underwood, B., & Tashakkori, R. (2022, March). Detecting anomalies in honey bee hives using their audio recordings. In *SoutheastCon 2022* (pp. 173-177). IEEE.
- Wagner, N., & Rondinelli, J. M. (2016). Theory-guided machine learning in materials science. *Frontiers in Materials*, 3, 28.
- Wollenhaupt, G. (2016). Iot slashed downtime with predictive maintenance. *PTC*, Retrieved from <http://www.ptc.com/productlifecycle-report/iot-slashes-downtime-with-predictivemaintenance>.
- Xiong, L., & Yao, Y. (2021). Study on an adaptive thermal comfort model with K-nearest-neighbors (KNN) algorithm. *Building and Environment*, 202, 108026.
- Yang, X., Ye, Y., Li, X., Lau, R. Y., Zhang, X., & Huang, X. (2018). Hyperspectral image classification with deep learning models. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5408-5423.
- Zhao, D., Wang, T., & Chu, F. (2019). Deep convolutional neural network based planet bearing fault classification. *Computers in Industry*, 107, 59-66.
- Zweig, M. H., & Campbell, G. (1993). Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clinical chemistry*, 39(4), 561-577.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı ve Soyadı : İdris SAÇAKLIDIR
Uyuğu : Türkiye Cumhuriyeti
Doğum Tarihi : 03.04.1972
Doğum Yeri : Silvan, Diyarbakır

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
İlkokul	Bayraklı İlkokulu, Batman, Batman	1983
Ortaokul-Lise	Diyarbakır İmam Hatip Lisesi Yenişehir, Diyarbakır	1991
Üniversite	Dicle Üniversitesi, Sur İlçesi, Diyarbakır	1997
Yüksek Lisans	Batman Üniversitesi, Batman, Batman	
Doktora		

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
1995 – 1998	DİSKİ Genel Müdürlüğü	İşçi
1998 – 2023	DİSKİ Genel Müdürlüğü	Mühendis

UZMANLIK ALANI

YABANCI DİLLER

İngilizce