

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AÇIKLANABİLİR YAPAY ZEKA VE AKUSTİK SİNYALLER
KULLANILARAK ENDÜSTRİYEL MAKİNELERDE
ANOMALİ TESPİTİ

YÜKSEK LİSANS TEZİ

Betül Sena ÇAĞLAR

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

OCAK 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AÇIKLANABİLİR YAPAY ZEKA VE AKUSTİK SİNYALLER
KULLANILARAK ENDÜSTRİYEL MAKİNELERDE
ANOMALİ TESPİTİ

YÜKSEK LİSANS TEZİ

Betül Sena ÇAĞLAR

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Devrim AKGÜN

OCAK 2025

Betül Sena Çağlar tarafından hazırlanan “Açıklanabilir Yapay Zeka ve Akustik Sinyaller Kullanılarak Endüstriyel Makinelerde Anomali Tespiti” adlı tez çalışması 16.01.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Doç. Dr. Süleyman UZUN**
Sakarya Uygulamalı Bilimler Üniversitesi

Jüri Üyesi : **Prof. Dr. Devrim AKGÜN (Danışman)**
Sakarya Üniversitesi

Jüri Üyesi : **Doç. Dr. Ünal ÇAVUŞOĞLU**
Sakarya Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Açıklanabilir Yapay Zeka Ve Akustik Sinyaller Kullanılarak Endüstriyel Makinelerde Anomali Tespiti” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(16/01/2025).

Betül Sena ÇAĞLAR





Aileme ve beni seven herkese...



TEŞEKKÜR

Tez yazım sürecimde beni destekleyen ve bana yol gösteren değerli danışmanım Prof. Dr. Devrim Akgün'e, katkıları ve emeği için teşekkür ederim.

Yüksek lisans eğitimim boyunca, farklı uluslararası projelerde ve bu teze konu olan alanla ilgilenmemi sağlayan projede çalışmama olanak sağlayan; akademik gelişimimin temel taşlarını oluşturan yayınlar yapmamda bana öncülük eden Dr. Barış Bulut'a sunduğu fırsatlar ve desteği için teşekkür ederim. Aynı projedeki çalışma arkadaşım Hasan Burak Ketmen'e, önerilen yöntemi geliştirirken sağladığı değerli katkıları için teşekkür ederim.

Bu teze konu olan çalışmanın bir kısmı, Akıllı Güvenilirlik 4.0 (iRel40) başlıklı proje kapsamında, Avrupa Birliği tarafında Horizon 2020 ECSEL JU'dan 876659 numaralı hibe sözleşmesi ve Türkiye tarafında TÜBİTAK ARDEB 119N348 numaralı proje kapsamında eş desteklenme yöntemi ile desteklenmiştir. Çalışmaya katkı sağlayan tüm ortak kurumlara teşekkür ederim.

Her daim yanımda olan, sabırları ve destekleriyle bu yoğun tez yazma dönemini daha kolay atlatmamı sağlayan; sevgili annem Sema, babam Ömer Fahri ve abim Mustafa Enes Çağlar'a destekleri için teşekkür ederim.

Betül Sena ÇAĞLAR



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	3
2.1. Sinyal İşlemenin Endüstriyel Arıza Tespitindeki Rolü	3
2.2. Ses Sinyallerinin Kullanımı	7
2.2.1. Arıza ve anomali teşhisinde ses sinyallerin önemi ve avantajları.....	7
2.2.2. Ses sinyali işleme teknikleri.....	8
2.2.3. Ses sinyalleri ile mevcut arıza tespiti yöntemleri.....	8
2.2.3.1. Gözetimsiz akustik anomali tespiti çalışmaları.....	9
2.2.3.2. Gözetimli akustik anomali tespiti çalışmaları.....	12
2.2.3.3. Literatür özet tablosu.....	14
3. MATERYAL VE YÖNTEM.....	19
3.1. Veri Setleri	19
3.1.1. MIMII veri seti.....	19
3.1.2. ToyADMOS veri seti	20
3.1.3. Elektrik motorları veri seti	20
3.2. Veri Ön İşleme	21
3.3. Sinyal İşleme ve Ses Özellikleri Çıkarma.....	22
3.3.1. Spektral ağırlık merkezi	23
3.3.2. Spektral bant genişliği.....	26
3.3.3. Spektral rolloff	28
3.3.4. Spektral kontrast	29
3.3.5. Spektral düzlük	31
3.3.6. Spektral yayılma	31
3.3.7. Güç spektral yoğunluğu	32
3.3.8. Genlik zarfı	33
3.3.9. RMS enerji	35
3.3.10. Renk (chroma) özellikleri	36
3.3.11. CQT dönüşümü.....	38
3.3.12. Hilbert dönüşümü.....	39
3.3.13. Sıfır geçiş oranı	41
3.3.14. Basıklık ve çarpıklık	42
3.3.15. Bant enerji oranı.....	42
3.3.16. Desibel özellikleri	43

3.3.17. Büyüklükler	44
3.4. Kullanılan Algoritmalar	45
3.4.1. Gözetimli öğrenme yöntemleri	45
3.4.1.1. Rastgele orman	45
3.4.1.2. XGBoost	46
3.4.1.3. Açıklanabilir güçlendirme makinesi	46
3.4.1.4. Derin sinir ağı	47
3.4.2. Gözetimsiz öğrenme yöntemleri	47
3.4.2.1. Autoencoder	48
3.4.2.2. İzolasyon ormanı	49
3.5. Deneysel Sonuçların Analizi İçin Kullanılan Performans Ölçütleri	50
3.6. Açıklanabilir Yapay Zeka Modelleri İle Ses Özelliklerinin Analizi	51
3.6.1. Kullanılan yöntemler	51
3.6.1.1. RF	51
3.6.1.2. IG	51
3.6.1.3. SHAP	52
3.6.1.4. LIME	52
3.6.1.5. EBM	53
3.6.1.6. LASSO	53
3.6.2. Analiz süreci	54
3.6.3. Özellik analizi sonuçlarının model optimizasyonuna etkisi	55
4. UYGULAMA VE DENEYSEL SONUÇLAR	57
4.1. Deney 1: MIMII Veri Seti	58
4.1.1. Pompa verileri	58
4.1.1.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme	58
4.1.1.2. XAI yöntemleri ile özellik analizi ve öznitelik seçimi	59
4.1.1.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme	63
4.1.2. Fan verileri	67
4.1.2.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme	67
4.1.2.2. XAI yöntemleri ile özellik analizi ve öznitelik seçimi	68
4.1.2.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme	71
4.1.3. Sürgülü ray verileri	73
4.1.3.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme	73
4.1.3.2. XAI yöntemleri ile özellik analizi ve öznitelik seçimi	74
4.1.3.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme	76
4.1.4. Valf verileri	79
4.1.4.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme	79
4.1.4.2. XAI yöntemleri ile özellik analizi ve öznitelik seçimi	80
4.1.4.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme	82
4.2. Deney 2: ToyADAMOS Veri Seti	84
4.3. Gerçek Vaka Çalışması: Elektrik Motorları Veri Seti	86
4.4. Karşılaştırmalı Değerlendirme	89
5. SONUÇ VE ÖNERİLER	93
5.1. Elde Edilen Sonuçların Analizi	93
5.2. Gelecek Çalışmalar İçin Öneriler	94
KAYNAKLAR	97
ÖZGEÇMİŞ	105

KISALTMALAR

AE	: Autoencoder
AUC	: Area Under the Curve
CBM	: Condition-Based Maintenance
CQT	: Constant-Q Transform
DNN	: Deep Neural Network
EBM	: Explainable Boosting Machine
IF	: Isolation Forest
IG	: Integrated Gradients
LASSO	: Least Absolute Shrinkage and Selection Operator
LIME	: Local Interpretable Model-agnostic Explanations
LSTM	: Long Short-Term Memory
MCC	: Matthews Correlation Coefficient
MFCC	: Mel-Frequency Cepstral Coefficients
MSE	: Mean Squared Error
PdM	: Predictive Maintenance
PCA	: Principal Component Analysis
RF	: Random Forest
RMS	: Root Mean Square
ROC	: Receiver Operating Characteristic
RUL	: Remaining Useful Life
SHAP	: SHapley Additive exPlanations
STFT	: Short-time Fourier Transform
t-SNE	: t-Distributed Stochastic Neighbor Embedding
XAI	: Explainable Artificial Intelligence
XGBoost	: eXtreme Gradient Boosting



TABLO LİSTESİ

Sayfa

Tablo 2.1. Literatür özet tablosu.	15
Tablo 3.1. Makinelerin çalışma ve anormal koşullar listesi [19].	20
Tablo 3.2. Perde sınıfları ve ton karşılıkları.	37
Tablo 4.1. Pompa sinyallerinde anomali sınıflandırması için performans ölçümleri	59
Tablo 4.2. Pompa sesi XAI yöntemlerine göre özelliklerin önem dereceleri.	61
Tablo 4.3. Pompa sinyallerinde IF ve AE modellerinin AUC değerleri.	66
Tablo 4.4. Fan sinyallerinde anomali sınıflandırması için performans ölçümleri.....	67
Tablo 4.5. Fan sesi XAI yöntemlerine göre özelliklerin önem dereceleri.....	68
Tablo 4.6. Fan sinyallerinde IF ve AE modellerinin AUC değerleri.	72
Tablo 4.7. S. ray sinyallerinde anomali sınıflandırması için performans ölçümleri.	73
Tablo 4.8. S. ray sesi XAI yöntemlerine göre özelliklerin önem dereceleri.	74
Tablo 4.9. Sürgülü ray sinyallerinde IF ve AE modellerinin AUC değerleri.....	78
Tablo 4.10. Valf sinyallerinde anomali sınıflandırması için performans ölçümleri..	79
Tablo 4.11. Valf sesi XAI yöntemlerine göre özelliklerin önem dereceleri.	80
Tablo 4.12. Valf sinyallerinde IF ve AE modellerinin AUC değerleri.	84
Tablo 4.13. Oyuncak araba anomali sınıflandırması için performans ölçümleri.	84
Tablo 4.14. Elektrik motorları anomali sınıflandırması için performans ölçümleri..	87
Tablo 4.15. Literatürdeki gözetimli yöntemlerle önerilen karşılaştırması.	89
Tablo 4.16. Literatürdeki gözetimsiz yöntemlerle önerilen karşılaştırması.	90



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Endüstriyel bakım stratejilerinin evrimi.	4
Şekil 3.1. Spektral ağırlık merkezi.....	24
Şekil 3.2. Spektral bant genişliği.	26
Şekil 3.3. Spektral bant genişliğinin PSD değişimi.	27
Şekil 3.4. Spektral rolloff.....	28
Şekil 3.5. Spektral kontrast.	30
Şekil 3.6. Güç spektral yoğunluğu.....	32
Şekil 3.7. Genlik zarfı.	34
Şekil 3.8. RMS enerji.....	35
Şekil 3.9. Normal ve anormal ses sinyallerinin kromogramları.	37
Şekil 3.10. CQT dönüşümü spektrogramları.	39
Şekil 3.11. Anlık genlik ve anlık faz ilerleyişleri.	41
Şekil 3.12. Hilbert anlık genlik haritası.	41
Şekil 3.13. Bant enerji oranı.	43
Şekil 3.14. Frekans spektrumlarında büyüklük değerleri.	44
Şekil 3.15. Rastgele orman yapısı örneği [67].....	46
Şekil 3.16. İkili sınıflandırma için örnek derin sinir ağı mimarisi [71].	47
Şekil 3.17. Autoencoder mimarisi [72].....	48
Şekil 3.18. Isolation forest mekanizması [73].	49
Şekil 4.1. Deney düzeni akış şeması.....	57
Şekil 4.2. SHAP değerlerini içeren özet grafik.....	60
Şekil 4.3. Pompa 00 verilerinde önemli özelliklerin normal ve anormal dağılımı. ...	63
Şekil 4.4. Pompa seslerinde PCA ve IF ile anomali tespiti sonuçları.....	65
Şekil 4.5. Pompa seslerinde t-SNE ve AE ile anomali tespiti sonuçları.....	66
Şekil 4.6. Fan 02 verilerinde önemli özelliklerin normal ve anormal dağılımı.	71
Şekil 4.7. Fan seslerinde PCA ve IF ile anomali tespiti sonuçları.....	71
Şekil 4.8. Fan seslerinde t-SNE ve AE ile anomali tespiti sonuçları.....	72
Şekil 4.9. S. ray 06 verilerinde önemli özelliklerin normal ve anormal dağılımı.....	76
Şekil 4.10. Sürgülü ray seslerinde PCA ve IF ile anomali tespiti sonuçları.	77
Şekil 4.11. Sürgülü ray seslerinde t-SNE ve AE ile anomali tespiti sonuçları.	78
Şekil 4.12. Valf 02 verilerinde önemli özelliklerin normal ve anormal dağılımı.	82
Şekil 4.13. Valf seslerinde PCA ve IF ile anomali tespiti sonuçları.....	83
Şekil 4.14. Valf seslerinde t-SNE ve AE ile anomali tespiti sonuçları.....	83
Şekil 4.15. Oyuncak araba seslerinde IG ile belirlenen en önemli özellikler.	85
Şekil 4.16. Eğitim ve test veri setleri için karışıklık matrisleri.....	86
Şekil 4.17. XGBoost modeline göre belirlenen en önemli özellikler.	87
Şekil 4.18. EBM ile belirlenen en önemli özellikler.....	88
Şekil 4.19. Elektrik motorları önemli özelliklerin normal ve anormal dağılımı 1.....	88
Şekil 4.20. Elektrik motorları önemli özelliklerin normal ve anormal dağılımı 2.....	89



AÇIKLANABİLİR YAPAY ZEKA VE AKUSTİK SİNYALLER KULLANILARAK ENDÜSTRİYEL MAKİNELERDE ANOMALİ TESPİTİ

ÖZET

Endüstriyel sistemlerde meydana gelen arızalar, yalnızca üretim kesintileri ve maliyet artışlarına yol açmakla kalmaz, aynı zamanda güvenlik riskleri ve müşteri memnuniyetsizliği gibi sorunlara da neden olmaktadır. Bu nedenle, anomalilerin erken tespit edilmesi, üretim süreçlerinde verimliliğin artırılması ve hataların piyasaya sürülmeden önce belirlenmesi açısından büyük önem taşımaktadır. Bu tezde, endüstriyel makinelerden toplanan ses sinyalleri kullanılarak, makine sağlığındaki anormalliklerin ve arıza durumlarının tespit edilmesine yönelik hafif ve etkili gözetimli ve gözetimsiz öğrenme yöntemleri geliştirilmiştir.

Tez çalışmasında kullanılan yöntem, sensörlerden elde edilen ses sinyallerinin özellik mühendisliği süreçleriyle işlenmesi ve farklı makine öğrenmesi modelleri ile test edilmesini kapsamaktadır. Ses sinyallerinden 17 farklı ses sinyali özelliği çıkarılmış, çoğu bir dizi olan bu 17 farklı ses sinyali özelliğinden de çeşitli istatistiksel metrikler çıkarılarak her bir ses sinyali verisi için 110 özniteliğin bulunduğu bir veri seti oluşturulmuştur. RF, XGBoost, EBM ve DNN olmak üzere dört farklı gözetimli öğrenme yöntemiyle oluşturulan modeller ve yapılan analizler sonucunda, MIMII veri setindeki dört makine türü için ortalama, %99.78 doğruluk ve %99.95 AUC değeri elde edilmiştir. Önerilen yöntem, ayrıca ToyADMOS veri setindeki oyuncak arabalar ile gerçek bir vaka çalışması olan beyaz eşya elektrik motorlarından elde edilen ses sinyalleri üzerinde test edilmiş ve sırasıyla %95.62 ve %99.38 AUC değerleriyle literatürdeki mevcut yöntemlerden daha iyi sonuçlar elde etmiştir.

Çalışmada, gerçek zamanlı akustik izleme ve kestirimci bakım sistemleri için değerli bilgiler sunmak amacıyla, RF, IG, SHAP, LIME, EBM ve LASSO olmak üzere altı farklı açıklanabilir yapay zekâ (XAI) yöntemlerini kullanarak elektrik motoru, pompa, fan, sürgülü ray ve valf makine türleri için anomali tespitinde kullanılabilecek kritik ses sinyali özellikler belirlenmiştir. Özellik seçimi ve azaltımı süreçleriyle, yalnızca önemli olarak belirlenen özelliklerin bulunduğu veri setleri ile gözetimsiz öğrenme modelleri eğitilmiştir. Bu yöntem yalnızca ayırt edici özellikler verilerek etiketli veri olmadan anomali tespiti yapmayı çalışan modellerin performansını güçlendirmek için kullanılmıştır. Gözetimsiz öğrenme yöntemlerinden Autoencoder (AE) modelinin, çoğu makine türünde İzolasyon Ormanı (IF) modeline göre daha başarılı performans gösterdiği gözlemlenmiştir. Gözetimsiz modellerde her makine kimliği için elde edilen ortalama AUC değerleri; pompalar için %99.11, fanlar için %99.54, sürgülü raylar için %98.85, valfler için %98.12 olmuştur.

Sonuç olarak, bu çalışma, endüstriyel makinelerde anomali ve arıza tespiti için hafif, etkili ve açıklanabilir bir yöntem sunarak literatüre ve endüstriyel uygulamalara katkı sağlamaktadır. Önerilen yöntem hem performans hem de hafif bir yöntem oluşunun getirdiği maliyet avantajlarıyla mevcut çözümlerin önemli ölçüde önüne geçmiştir.



ANOMALY DETECTION IN INDUSTRIAL MACHINES USING EXPLAINABLE AI AND ACOUSTIC SIGNALS

SUMMARY

Industrial systems play a critical role in modern manufacturing, where efficiency, reliability, and sustainability are essential. Failures in these systems not only disrupt production and increase operational costs but also pose safety risks and lead to customer dissatisfaction. Early detection of anomalies and faults is vital for ensuring process continuity, improving product quality, and identifying potential issues before they escalate. This thesis focuses on the development of lightweight and effective supervised and unsupervised learning methods for detecting anomalies and fault conditions in industrial machines using audio signals collected from machine operations. By leveraging these methods, the study aims to enhance production efficiency and reliability while minimizing the risks associated with unexpected system failures.

The thesis involves processing audio signals from sensors with feature engineering processes and testing them using various machine learning and deep learning models. Initially, 17 audio features were directly extracted from the raw audio signals. After these features were extracted, statistical feature extraction techniques were applied, such as mean, variance, standard deviation, skewness, kurtosis, maximum, and median absolute deviation autocorrelation coefficients, in order to derive additional attributes.

As a result of the feature enhancement process, the initial set of 17 audio features was significantly expanded, leading to the creation of a robust and comprehensive dataset encompassing 110 distinct attributes for each instance. This expanded feature set allowed for a more in-depth and nuanced analysis of the acoustic characteristics of the signals, ultimately enabling a deeper understanding of the underlying machine behaviors and facilitating more accurate anomaly detection.

These features were tested using supervised learning models, including Random Forest (RF), Extreme Gradient Boosting (XGBoost), Explainable Boosting Machines (EBM), and Deep Neural Networks (DNN), as well as unsupervised learning models like Autoencoder (AE) and Isolation Forest (IF). Supervised models demonstrated remarkable performance, achieving an average accuracy of 99.78% and an AUC of 99.95% on the MIMII dataset, which includes four distinct machine types. It is noteworthy that the study found that no single supervised model consistently outperformed others across all machine types. However, DNN and XGBoost generally exhibited superior performance across most machine types.

Among the unsupervised models, the AE demonstrated superior performance compared to the IF across most machine types, except for the 'Pump 00' machine, where the IF model showed a slight edge. Specifically, the best average AUC values achieved by unsupervised models for each machine type were as follows: pumps (99.11%), fans (99.54%), slide rails (98.85%), and valves (98.12%).

The thesis further substantiated the efficacy of its proposed methodologies by rigorously validating them on a variety of diverse datasets. Among these, the ToyADMOS dataset, comprising toy car audio signals, and a real-world case study involving acoustic signals from electric motors of white goods appliances, were employed. The proposed methods demonstrated remarkable performance, achieving competitive AUC values of 95.62% and 99.38%, respectively. These results not only highlight the robustness of the approach but also position it as a superior alternative, outperforming several state-of-the-art techniques documented in the current literature.

In addition to evaluating performance, the thesis also explores the use of Explainable Artificial Intelligence (XAI) techniques to improve the interpretability of the machine learning models. Six different XAI techniques—SHAP, LIME, RF, IG, EBM, and LASSO—were integrated into the proposed framework to identify critical features specific to different machine types. This integration allowed for a better understanding of which features played the most significant role in detecting anomalies in pumps, fans, slide rails, and valves. By reducing the number of features to just 20–50 important attributes, the models not only maintained but also improved their accuracy, achieving a balance between computational efficiency and model effectiveness. The feature reduction process, particularly when applied to unsupervised models, significantly improved their classification performance. These findings suggest that focusing on the most relevant features is key to achieving better anomaly detection outcomes.

The study identified several key features critical for detecting anomalies in machine behavior. Notably, the Standard Deviation of the Magnitudes, Standard Deviation of Instantaneous Amplitude, Kurtosis of the Signal, Standard Deviation of the RMS Energy, Maximum Spectral Bandwidth, and Maximum Spectral Rolloff emerged as crucial indicators across all machine types. These features, derived from acoustic signals, effectively captured subtle variations in the machine's operational characteristics, which were essential for distinguishing between normal and faulty conditions.

A systematic comparison between supervised and unsupervised methods revealed a notable difference in performance. Supervised models achieved a higher average AUC score of 99.95%, compared to 98.91% for unsupervised methods, emphasizing the importance of labeled data in achieving reliable and accurate anomaly detection. Despite this, the unsupervised models still showed promising results, especially when coupled with feature selection techniques and XAI methods.

One of the most significant contributions of this thesis is the development of lightweight models that are suitable for deployment in real-world industrial settings. Given the limitations of computational power and energy consumption in many industrial applications, the proposed models are designed to be computationally efficient without sacrificing performance. The lightweight nature of the models, which use architectures like DNN with just 3–4 hidden layers and Autoencoders, makes them particularly well-suited for edge devices. These models can be deployed on devices with limited resources, such as industrial sensors and controllers, thus addressing key challenges in practical applications. By focusing on models that are both interpretable and efficient, this thesis makes a substantial contribution to the field of industrial machine monitoring and fault detection.

In conclusion, this thesis proposes a robust solution for anomaly detection in industrial machines, leveraging both supervised and unsupervised machine learning techniques. The proposed methods achieve high accuracy, strong interpretability, and

computational efficiency, making them suitable for real-time monitoring and predictive maintenance applications in industrial settings. Moreover, the integration of XAI techniques enhances the transparency of the models, enabling actionable insights for maintenance teams and improving decision-making processes. The lightweight nature of the proposed models further ensures that they can be deployed on edge devices, offering a scalable and energy-efficient solution for industrial anomaly detection. Ultimately, this work not only addresses the current needs of industrial systems but also paves the way for future research in the field of explainable, scalable, and efficient fault detection systems for industrial applications.





1. GİRİŞ

Endüstriyel sistemlerin verimliliği ve sürekliliği, modern üretim faaliyetlerinin temelini oluşturmaktadır. Bu sistemlerde meydana gelen arızalar, sadece maliyet artışlarına neden olmakla kalmaz; aynı zamanda güvenlik riskleri ve üretimde ciddi kesintilere yol açabilir. Hatalı bir ürün piyasaya sürüldükten sonra ise müşteri memnuniyetsizliği, marka itibarının zedelenmesi ve zaman kaybı gibi çeşitli sorunlara neden olmaktadır. Bu nedenle, anomalileri erken tespit etmek, ürün piyasaya sürülmeden önce hataların fark edilmesi özellikle karmaşık üretim süreçlerinde ve endüstriyel operasyonlarda büyük önem taşımaktadır.

Son yıllarda yaşanan Endüstri 4.0 devrimiyle birlikte, büyük veri, nesnelerin interneti (IoT) ve bulut bilişim gibi teknolojiler sayesinde, endüstriyel makinelerden ve sistemlerden sürekli veri toplanabilmektedir. Bu teknolojik ilerlemeler, sistemlerin normal davranışlarını otomatik olarak öğrenen ve anomali olduğunda bunları tanıyan akıllı algoritmaların geliştirilmesine olanak tanıyarak, makine öğrenmesinin endüstriyel uygulamalarda daha etkin bir şekilde kullanılmasını sağlamıştır.

Makine öğrenmesi ve sinyal işleme teknikleri, endüstriyel sistemlerdeki potansiyel sorunları tespit etmede ve önlemekte kritik role sahiptir. Üretim hattı boyunca ses, akım, titreşim vb. sensörler aracılığıyla toplanan çeşitli sinyallerden özellik mühendisliği uygulanarak çıkarılan değerli bilgiler, makine öğrenmesi algoritmalarının daha doğru ve etkili bir şekilde çalışmasını sağlar. Böylece, üretim süreçlerinde anormal durumlar erken aşamalarda tespit edilerek, olası hatalar ve maliyetli duruşlar önlenabilir.

Bu çalışmanın amacı, ses sinyallerini kullanarak makinelerin sağlık durumundaki anormallikleri ya da arıza durumlarını tespit eden makine öğrenmesi modelleri geliştirmektir. Bu kapsamda, çeşitli makinelerden toplanan ses sinyalleri işlenerek özellikler çıkarılacak ve elde edilen veri seti farklı makine öğrenmesi ve derin öğrenme algoritmalarında test edilerek en iyi performansı gösteren algoritma belirlenecektir. Önerilen yöntem, endüstriyel makinelerdeki anomalilerin belirlenmesi ve arıza tespiti amacıyla mevcut literatürdeki ses sinyali ile anomali tespiti yapan modeller ile

karşılaştırılacaktır. Bu doğrultuda, önerilen yöntemin, literatürdeki mevcut modellere kıyasla yüksek doğruluğa sahip olmasına yanı sıra daha hafif ve uygulama dostu bir çözüm sunması amaçlanmaktadır.

Anormal ses verilerinin toplanması, gerçek dünyadaki çeşitlilik ve nadirlikleri nedeniyle zorlu bir süreçtir. Ayrıca, endüstriyel ortamlarda toplanan verilerde sıklıkla karşılaşılan etiketsiz veri sorunu, her zaman gözetimli öğrenme modelleri ile çalışmayı mümkün kılmamaktadır. Bu nedenle, bu çalışma kapsamında gözetimli öğrenme yöntemlerinin yanı sıra gözetimsiz öğrenme yöntemleri de kullanılarak anormal ve arızalı sinyallerin tespit edilmesi sağlanacaktır. Çalışma, beş farklı endüstriyel makineden toplanan halka açık veri setleri ile test edilecektir. Bunun yanı sıra, Enforma Bilişim A.Ş.'de çalışırken dahil olduğum, Avrupa Birliği tarafından finanse edilen “Akıllı Güvenilirlik 4.0 (iRel40)” başlıklı uluslararası proje kapsamında [1], bir beyaz eşya elektrik motoru üreticisi tarafından sağlanan veri seti ile gerçek vaka çalışması yapılarak, test edilecektir.

Bu çalışmada ayrıca, ses sinyallerinden elde edilen özelliklerin açıklanabilir yapay zeka (XAI) yöntemleri kullanılarak analizi gerçekleştirilecektir. XAI yöntemleri, makine öğrenmesi modellerinin karar mekanizmalarını anlamak ve model çıktılarının güvenilirliğini artırmak için kritik bir rol oynamaktadır. Bu çalışmada, XAI kullanılarak farklı endüstriyel makine türlerinin anomali tespitinde en etkili ses özellikleri belirlenerek, farklı makine türlerine özgü ayırt edici özelliklerin anlaşılması sağlanacaktır. Bu yaklaşımın, yalnızca modelin şeffaflığını artırmakla kalmayıp, aynı zamanda gerçek zamanlı akustik durum izleme ve kestirimci bakım sistemleri için değerli bilgiler sunması hedeflenmektedir. Ayrıca, XAI yöntemleri ile önemli olarak belirlenen özelliklerin anomali tespitinde gözetimsiz öğrenme modellerin performansını arttırmak için kullanılması amaçlanmaktadır.

Bu çalışma, endüstride kalite kontrol için kritik öneme sahip anomali ve arıza tespiti alanında, ses sinyallerinin işlenmesi ve sınıflandırılması konusunda önerilecek yöntemle literatüre yeni bir katkı sağlamayı hedeflemektedir. Teknolojik açıdan, geliştirilecek olan bu hafif yöntemle, endüstriyel tesislerde kullanılan sensör verilerini daha etkili bir şekilde değerlendirme potansiyelinin artırılması, işletmelerin daha sürdürülebilir ve verimli bir şekilde çalışmasını destekleyerek ekonomik büyümeye ve istihdama olumlu bir etki sağlaması hedeflenmektedir.


2. LİTERATÜR ARAŞTIRMASI

Bu bölümde, endüstriyel sistemlerde arıza tespiti ile ilgili mevcut literatür incelenecektir. Özellikle, Endüstri 4.0 kapsamında kullanılan sinyal işleme ve makine öğrenmesi teknikleri üzerine yapılan çalışmalar gözden geçirilecek ve bu tekniklerin ses sinyalleriyle birlikte nasıl kullanıldığı değerlendirilecektir. Mevcut araştırmaların kapsamı, metodolojisi ve sonuçları ele alınacaktır.

2.1. Sinyal İşlemenin Endüstriyel Arıza Tespitindeki Rolü

Otomasyonun başlangıcında makineler daha basitti. Bu nedenle, mümkün olduğunca uzun süre çalıştırılabilirdi ve yalnızca arızalandıktan sonra bakımları yapılıyor yani tamir ediliyorlardı. Bu bakım yaklaşımı, *reaktif* ya da *düzeltilici bakım* olarak adlandırılmaktadır. Ancak makineler biraz daha karmaşık hale geldikçe, beklenmeyen arızalardaki önemli artışların uzun süreli ve maliyetli duruşların yanı sıra, arıza durumuna gelene dek makine parçalarında ciddi hasarlara neden olduğu görüldü [2].

Bu durum, makinenin düzenli bir sıklıkta veya belirli bir kullanım uzunluğundan sonra bakıma tabi tutulduğu *önleyici bakım (PM)* stratejilerine giden yolu açtı [3]. Örneğin, bir arabanın belirli sayıda kilometre yaptıktan sonra servise gitmesi gerektiği söylenebilir. Önleyici bakım; sistem duruş sürelerini, parça arızalarından kaynaklanan tehlikeleri ve ayrıca bakım maliyetini azaltma gibi potansiyel avantajları sahip olsada sınırlamaları da vardır. Makinenin bakım için ayarlanan çalışma saatleri veya zamanı yanlış olabilir. Örneğin, engebeli bir yolda sürülen bir araba, daha az kilometre yapmasına rağmen erken bakım gerektirebilir. Bu durumda, arabanın zamanında bakımının yapılmaması tehlikeli olabilir. Tam tersi, araba düzgün bir arazide gittiğinde, önceden ayarlanmış kilometrelere ulaştıktan sonra bile bakım gerektirmeyebilir. Bu nedenle, zamanından önce bakımı yapılması kaynak israfına yol açmaktadır. Huang ve arkadaşları [4], önleyici bakım stratejisi ile makinelerin çoğunun, hala büyük miktarda faydalı ömürleri varken çok erken bakıma alındığını bildirmiştir.



Şekil 2.1. Endüstriyel bakım stratejilerinin evrimi.

Elektronik sensörlerin gelişmesiyle, makinelerin birçok parçası durum izleme (condition monitoring) tekniklerinin yardımıyla gerçek zamanlı takip edilebilir ve makinelerdeki anormal durumlar tespit edilebilir hale gelmiştir. Teknisyenler, makinelerin bakım gerektirip gerektirmediğini belirli eşik değerler aşıldığında anlayarak **koşul tabanlı bakım** (CBM) stratejisini uyguladılar. Bu strateji, bir makinenin durumunu gösteren parametrelerin, normal çalışma koşullarından sapması durumunda bakım sağlayarak, gereksiz bakımı ve plansız duruşları azaltmaktadır [5].

Makine öğrenmesi ve veri analitiği teknolojilerinin gelişmesi, koşul tabanlı bakımın sınırlı analiz yeteneklerini gölgede bırakmış ve daha ileri seviye bakım stratejilerine geçişi teşvik etmiştir. Koşul tabanlı bakım, çeşitli sensörlerden (titreşim, sıcaklık, akım, basınç, akustik vb.) elde edilen verilerin her birini bağımsız olarak değerlendirir ve sadece bu veriler belirli eşik değerleri aştığında bakım işlemi gerçekleştirilir. Ancak, makine durumunu temsil edebilecek benzersiz bir özellik yoktur. Makinelerin arızaları genellikle birden fazla sensör verisinin birlikte analiz edilmesiyle önceden tahmin edilebilir. Koşul tabanlı bakım, çoklu veri kaynaklarının etkileşimlerini değerlendiremeyerek erken arıza sinyallerini kaçırabilir ve bu durum, plansız duruş riskini artırır.

Makine öğrenmesi teknolojileri, **öngörücü bakım** (PdM) stratejisini giderek daha etkin bir çözüm olarak öne çıkarmaktadır. Öngörücü bakım, sensörlerden toplanan çoklu verileri birleştirerek makine öğrenmesi algoritmaları ile analiz etmekte, böylece veriler arasındaki karmaşık ilişkileri ortaya çıkararak arızaları önceden tahmin edebilmektedir. Öngörücü bakım arıza olasılıklarını analiz ederek proaktif müdahale imkânı tanır.

Günümüzde birçok işletme, koşul tabanlı bakım ve öngörücü bakım yöntemlerini birlikte kullanarak bakım süreçlerini daha verimli hale getirmektedir. Bu iki strateji, sistemlerde meydana gelebilecek başlangıç aşamasındaki arızaların tespitinde birbirini tamamlayıcı bir rol üstlenmektedir. Başlangıç aşamasındaki bir arıza, bir sistemin bozulmaya başladığı ilk değişim noktasıdır ve bu durumun tespiti genellikle oldukça zordur. Bu zorluğun üstesinden gelebilmek için, yalnızca tek bir veri kaynağından elde edilen bilgiler yerine, birden fazla kaynaktan toplanan verilerin entegre edilmesi ve bu doğrultuda karar verilmesi büyük önem taşımaktadır [6].

Klasik koşul tabanlı bakım yöntemlerinde, yalnızca belirli sinyallerin eşik değerlerini aşması durumunda uyarı mekanizmaları devreye girmektedir. Ancak bu yaklaşımlar, yalnızca yüzeysel sinyal değişimlerine dayandığı için, sistemdeki daha karmaşık anomalileri veya gelecekteki arızaları tespit etmekte yetersiz kalmaktadır. Makine öğrenmesi ve derin öğrenme gibi daha gelişmiş veri analitiği algoritmaları, birden fazla veri kaynağından gelen bilgileri entegre ederek, sistemdeki çok boyutlu verilerin derinlemesine analiz edilmesini sağlar. Bu tür analizler, gerçek zamanlı anomali tespiti ve gelecekteki arızaların tahmin edilmesi gibi alanlarda etkili bir araç olarak kullanılır. Örneğin, bir çalışmada yalnızca normal çalışma koşullarında toplanan çeşitli sensör verileri kullanılarak eğitilmiş uzun-kısa vadeli bellek (LSTM) hücreli bir Autoencoder modelinin yeniden yapılandırma hatası, eşik değer üzerinden gerçek zamanlı makine izleme için kullanılmış ve bu yöntemin rüzgar türbinlerindeki arızaları yaklaşık üç gün önceden tahmin edilebildiği raporlanmıştır [7]. Yine LSTM-AE kullanan bir çalışmada, metro trenlerindeki arızalar eşik değer aşımaları izlenerek tespit edilmiş ve arıza nedenlerini açıklayabilen çevrimiçi anomali tespiti yapılmıştır [8].

Makinenin kalan faydalı ömrünü (RUL) tahmin ederek, arızanın tam olarak ne zaman meydana geleceğini daha hassas bir şekilde öngörerek bakım planlanan stratejiye **kestirimci bakım** denilmektedir. Literatürde, kestirimci bakım ve öngörücü bakım terimleri sıklıkla birbirinin yerine kullanılmakla birlikte, bu iki yaklaşım arasında önemli bir fark bulunmaktadır. Öngörücü bakım (predictive maintenance), mevcut verileri kullanarak arızaları tanımlamaya yönelik daha diagnostik bir yaklaşım sergilerken, kestirimci bakım (prognostic maintenance), sistemin gelecekteki durumunu tahmin etmeye odaklanan prognostik bir yaklaşım sunar. Bu nedenle öngörücü bakım algoritmaları genellikle arıza belirtilerini tespit etmek için sınıflandırma ve anomali tespiti yöntemlerini kullanırken, kestirimci bakım

algoritmaları zaman serisi analizi, regresyon ve RUL tahmini gibi metodolojilere dayanır [9].

Kestirimci bakım sürecinde, makinenin genel performansı ve zamanla nasıl aşındığı da dikkate alınır. Örneğin, rüzgar türbini üzerinde yapılan çalışmalarda, bir sonraki arızaya kadar geçen süre tahmin edilip, tahmin edilen arıza sürelerine göre bakım işlemlerinin planlanmasına olanak sağladığı gösterilmiştir [10]. Başka bir çalışmada, rulmanların kalan faydalı ömrünü tahmin etmek için dinamik regresyon modellerine dayalı bir yaklaşım önerilmiştir. Rulman sağlığını izlemek için birimsiz bir sağlık göstergesi (HI) kullanılarak, gelişen eğilimler yakalanmış ve önerilen yöntem, diğer tekniklerle benzer derecede başarılı sonuçlar elde etmiştir [11].

Öngörücü ve kestirimci bakım yaklaşımları, genellikle arızaların gerçekleşmesini tahmin etmeye odaklanırken, **reçeteli bakım** bu yaklaşımlardan bir adım öteye geçerek, arıza risklerine yönelik en uygun çözüm önerilerini sunar. Reçeteli bakımda, yapay zekâ ve makine öğrenmesi algoritmaları, geçmiş bakım verilerini, sensör verilerini, operasyonel verileri ve arıza geçmişini analiz ederek spesifik bakım eylemleri önerir. Ancak, bu önerilerin yalnızca "bakım yapılması gerektiği" şeklinde bir çıktıdan öteye geçmesi, kritik öneme sahiptir. Önerilerin, hangi bileşenlerde (örneğin rulman, jeneratör vb.) bakım yapılması gerektiğini, hangi parametrelerin anormal olduğunu ve hangi tür bakımın uygulanması gerektiğini açıkça belirtmesi önemlidir [12].

Açıklanabilir yapay zekâ teknikleri, bu süreci şeffaflaştırmak için önemli bir rol oynar. XAI, özellikle LIME ve SHAP gibi yöntemlerle, modelin verdiği bakım önerilerinin arkasındaki mantığı netleştirir. Bu teknikler, bakım önerilerinin hangi sensör verilerine dayandığını ve bu verilerdeki sapmaların hangi bileşende potansiyel arıza riski oluşturduğunu somut bir şekilde ortaya koyar. Örneğin, bir motor için bakım önerisi verildiğinde; LIME, titreşim sensöründen alınan sinyalin normalden sapma gösterdiğini ve bu sapmanın motor rulmanlarında bir arıza riskine işaret ettiğini açıklayabilir. Böylece kullanıcı, yalnızca bakımın gerekli olduğunu değil, aynı zamanda hangi bileşenin (rulman), hangi parametresinin (titreşim) arıza riski oluşturduğunu, ne zaman müdahale edilmesi gerektiğini ve nasıl bir çözüm uygulanması gerektiğini anlayabilir. Bu şeffaflık, makinelerdeki bağımlılıkların daha iyi anlaşılmasını ve reçeteli bakım çözümüne olan güvenin tesis edilmesini sağlar [12].

Bu çalışma, açıklanan bakım stratejileri arasında öngörücü bakım (predictive maintenance) yaklaşımını temsil etmektedir. Çalışma kapsamında, ses sinyallerinden çıkarılan özellikler kullanılarak makine öğrenmesi algoritmaları yardımıyla makinelerdeki anomalilerin tespiti hedeflenmiştir. Kullanılan veri setlerinin doğası gereği, her bir makine için yalnızca tek bir ses kaydı bulunduğundan, analizler mevcut durumdaki anomalileri belirlemeye odaklanmaktadır. Ancak, bu çalışmada önerilen yöntemde çıkarılan ses sinyali özelliklerinin, daha kapsamlı veya farklı türde veri setleri kullanıldığında, kestirimci bakım ve reçeteli bakım stratejileri için de değerli bir temel oluşturabileceği düşünülmektedir. Aynı zamanda, XAI teknikleri kullanılarak ses sinyalleri ile arıza tespiti için önemli özelliklerin belirlenmesi, makinelerde gerçek zamanlı akustik durum izleme süreçlerine katkı sağlayacak etkili özelliklerin sunulmasına olanak tanıyacaktır.

2.2. Ses Sinyallerinin Kullanımı

2.2.1. Arıza ve anomali teşhisinde ses sinyallerin önemi ve avantajları

Ses sinyalleri ile arıza tespitinin kendine özgü avantajları vardır; ses sinyallerini toplamak, sensörlerin test edilen ekipmanla tam temas halinde olmasına gerek olmadığı anlamına gelir ve bu da belirli karmaşık senaryolarda uygulanabilir hale getirir [13].

Ses sinyali analizine dayalı mekanik arıza teşhisi, geleneksel yöntemlerden farklı olarak sinyalleri toplamak için mikrofonları kullanır. Mikrofonların yüksek hassasiyeti, geniş bant genişliği ve düşük maliyeti, bu yöntemin belirgin avantajlarından biridir. Buna ek olarak, özel avantajları vardır:

- Ekipman sökülmeden, doğrudan temassız ve invaziv olmayan ölçümler yapılabilir.
- Zorlu ortamlara iyi uyum sağlar ve yüksek sıcaklık, yüksek korozyon, nükleer radyasyon ve toksik durumlarda bile teşhis sağlayabilir.
- Sinyal toplama işlemi, ekipmanın yüzeyiyle doğrudan ilişkili değildir; yüzeyin yağlı, kaygan veya geometrik olarak düzensiz olması durumunda bile ses sinyali başarılı bir şekilde alınabilir.
- Ses sinyali analizine dayalı teşhis, ekipmanın normal çalışmasını etkilemez ve ekipman çalışırken arıza tespiti yapılmasını sağlayarak kesintisiz çalışmaya olanak tanır.

Bu nedenlerle, ses sinyali ile yapılan arıza tespiti, erken arıza teşhisi, uzaktan arıza tespiti ve çevrimiçi izleme gibi özel senaryolar için idealdir. Gelişen makine öğrenmesi ve derin öğrenme algoritmaları, mekanik arıza tespiti konusunun önemli ölçüde gelişmesine katkı sağlanmıştır. Bunula birlikte bahsedilen faydaları nedeniyle ses sinyaline dayalı arıza teşhisi; oldukça güncel, önemli ölçüde ilgi gören bir konu olmuştur. 2023 yılında yapılan bir araştırmaya göre Google'da [audio, mechanical fault diagnosis, sound, mechanical fault detection] anahtar kelimeleri için 29.400 akademik arama sonucu bulunmaktadır ve bunların 17.300'ü son 3 yılda yayınlanmıştır, bu da toplamın %58.8'ini oluşturmaktadır [14].

Ses sinyalleri ile arıza tespiti yalnızca Endüstri 4.0'a geçmiş üretim fabrikalarında değil; demiryolu taşımacılığı [15], elektrik enerjisi [16] ve kömür madeni [17] dahil olmak üzere çeşitli endüstrilerde yaygın olarak kullanılmıştır. Endüstriyel alanların ötesinde, ses analizi biyolojik araştırmalar gibi çok daha farklı alanlarda da öne çıkmaktadır. Örneğin, arı kolonilerinde kraliçe arıların tespiti ve zararlı parazitlerin izlenmesi gibi biyolojik süreçlerin izlenmesinde, ses tabanlı yöntemler etkili ve güvenilir çözümler sunmaktadır. Bu sayede, arıcılıkla ilgili verimlilik artırılırken, aynı zamanda daha az istilacı bir süreçle arı kolonilerinin sağlığı üzerindeki olumsuz etkiler de minimize edilmektedir [18].

2.2.2. Ses sinyali işleme teknikleri

Literatürdeki çalışmalarda genellikle Mel-spektrogram, Mel-frekans cepstral katsayıları, timbral metrikler, spektral özellikler, Hilbert dönüşümü ve EMD-Gammatone gibi teknikler kullanılarak, sesin zaman ve frekans alanındaki özellikleri çıkarılmıştır.

Özellik çıkarımı sırasında, hem kısa süreli hem de zamansal analizlerin birlikte kullanıldığı durumlarda daha iyi performans sergilendiği görülmüştür. Zaman-frekans analizlerinin birleşimi, sesin dinamik özelliklerini daha doğru bir şekilde yakalayarak, daha etkili sonuçlar elde edilmesine olanak tanımaktadır. Ayrıca, dalgacık dönüşümü gibi alternatif analiz teknikleri, sesin çok ölçekli yapısını yakalayarak yüksek frekanslı ve düşük frekanslı bileşenleri daha ayrıntılı bir şekilde ayırmada fayda sağlamaktadır.

2.2.3. Ses sinyalleri ile mevcut arıza tespiti yöntemleri

Endüstriyel makinelerde ses sinyallerine dayalı arıza ve anomali tespiti, son yıllarda giderek artan bir ilgi görmüştür. Bu alandaki çalışmaların değerlendirilmesi ve

yöntemlerin performansının karşılaştırılması için kullanılan veri setleri, yöntemin geliştirilebilirliğini ve uygulanabilirliğini test etmek açısından kritik öneme sahiptir. Literatürde, ses sinyalleriyle anomali tespiti üzerine yapılan çalışmalarda en sık tercih edilen veri setleri arasında MIMII ve ToyADMOS öne çıkmaktadır.

Bu veri setleri, geniş bir makine türü ve çeşitli çalışma koşullarını içermeleri sayesinde, ses sinyali tabanlı yöntemlerin performansını değerlendirmek ve karşılaştırmak için sağlam bir zemin sunmaktadır. Farklı makine türlerine ait anomalileri ve çeşitli çevresel koşulları simüle edebilme yetenekleri, bu veri setlerini literatürde standart hale getirmiştir. Bu tezde önerilen yöntemin etkinliğini ve literatürdeki konumunu analiz etmek amacıyla, MIMII ve ToyADMOS veri setleri üzerinde gerçekleştirilen başlıca çalışmalar ve bu çalışmalardan elde edilen bulgular detaylı bir şekilde incelenmiştir.

Literatürde farklı makine öğrenimi ve derin öğrenme algoritmaları kullanılarak hem gözetimli hem de gözetimsiz yöntemlerle akustik sinyaller üzerinden anomali ve arıza tespiti gerçekleştirilmiştir. Gözetimsiz yöntemler, genellikle yalnızca normal durumdaki verilerle eğitilerek, yeniden yapılandırma hatasına veya yoğunluk tahmini gibi istatistiksel modellere dayalı olarak anomali tespiti gerçekleştirirken; gözetimli yöntemler, hem normal hem de anormal durumları içeren etiketli veri setleri ile eğitilerek belirli bir sınıflandırma doğruluğuna ulaşmayı hedefler.

2.2.3.1. Gözetimsiz akustik anomali tespiti çalışmaları

Endüstriyel makinelerin arıza tespiti amacıyla geliştirilen MIMII veri setinin tanıtıldığı bu çalışmada, gerçek fabrika ortamlarında kaydedilmiş seslerden oluşturulan normal ve anormal ses segmentleri kullanılmıştır. Anomali tespiti için log mel spektrogramlar giriş özelliği olarak kullanılmış ve Autoencoder modeli yalnızca normal ses segmentleriyle eğitilmiştir. Yeniden yapılandırma hatası üzerinden yapılan değerlendirme, 6, 0 ve -6 dB gibi farklı SNR seviyelerinde AUC ile ölçüm yapılmıştır. Çalışmada, durağan olmayan seslerin ve fabrika gürültüsünün anomali tespitini zorlaştırdığı, buna karşın fan gibi durağan makinelerde daha yüksek doğruluk elde edildiği belirtilmiştir. Bu çalışma, hem MIMII veri setini tanıtmaya hem de gözetimsiz öğrenme yöntemleri için bir referans noktası sunması açısından önemlidir [19].

Bir çalışmada, endüstriyel makine sesleri için ArcFace sınıflandırıcısı ve Gauss Karışım Modeline (GMM) dayalı bir yöntem önerilmiştir. ArcFace sınıflandırıcısı, ses

verilerinin gizli özelliklerini daha ayrılabilir şekilde öğrenirken, GMM anomali skorlarını hesaplamıştır. ToyADMOS ve MIMII veri setlerinde yapılan deneyler, önerilen gözetimsiz yöntemin geleneksel yaklaşımlara göre daha yüksek doğruluk sağladığını göstermiştir [20].

Başka bir çalışmada, ses sinyallerindeki zaman ve spektral bilgileri birleştiren T-Net ve F-Net tabanlı bir model önerilmiştir. MIMII ve ToyADMOS veri setlerinde gerçekleştirilen deneylerde, önerilen modelin AUC değerinde %1,51 oranında bir iyileşme sağladığı rapor edilmiştir. Bu bulgular, zamansal ve spektral özelliklerin entegre kullanımının anomali tespit doğruluğunu artırdığını göstermiştir [21].

Mel spektrogramı özellikleri çıkarılıp, Convolutional Autoencoder (CAE) ve Dense Autoencoder (DAE) modelleri kullanılarak akustik verilerde anomali tespiti gerçekleştirilmiştir. Yapılan değerlendirmelerde, DAE modeli ile 6 dB SNR seviyesinde en yüksek doğruluğa ulaşıldığı görülmüştür. Bununla birlikte, düşük SNR seviyelerinde modelin ayırt etme performansında düşüş gözlemlenmiştir [22].

Bir diğer gözetimsiz anomali tespiti çalışmasında, GMDNN (Gaussian Mixture Density Neural Network) tabanlı bir model önerilmiş ve bu modelde yeniden yapılandırma karşıtlık ağı, boyut indirgeme ve yoğunluk tahmini ağları birleştirilmiştir. MIMII DUE veri setinde STFT ve Mel filtre bankaları kullanılarak eğitilen modelin, AE-GMM gibi yöntemlere kıyasla daha yüksek AUC ve pAUC değerlerine ulaştığı bildirilmiştir [23].

GAN tabanlı bir diğer çalışmada, EDGAN adlı model ile anomali tespitinde yeni bir yaklaşım önerilmiştir. Model, kanal, mel frekansı ve zaman boyutlarında çoklu-dikkat mekanizması içeren bir diskriminatör (discriminator) ve derin evrimsel otomatik kodlayıcı tabanlı bir üretici (generator) kullanmaktadır. Diskriminatör, çoklu-dikkat mekanizmaları sayesinde farklı boyutlarda dikkati yeniden kalibre ederek ayırım performansını artırmıştır. Anomali değerlendirmesi için yeniden yapılandırma hatasını içeren yenilikçi bir anomali skoru tasarlanmıştır. MIMII veri seti üzerinde yapılan deneylerde, EDGAN'ın mevcut yöntemlere kıyasla ortalama AUC değerinde %8,29'luk bir iyileşme sağladığı rapor edilmiştir [24].

Sha ve arkadaşları tarafından akustik anomali tespiti için GRLNet (Global-Regional Local Network) yöntemi önerilmiştir. GRLNet, yerel ve bölgesel desenleri modellemek için iki farklı otomatik kodlayıcı (local ve regional) ve uzun vadeli

frekans etkileşimlerini öğrenmek için bir global filtre katmanı içermektedir. Çekişmeli (adversarial) bir yapı kullanan model, üretici ve diskriminatör bileşenleriyle hem normal desenlerin yeniden yapılandırılmasını hem de yerel ve bölgesel desenlerin ayrımını hedeflemiştir. MIMII ve SAMSON AG veri setlerinde, farklı SNR seviyelerinde yapılan deneylerde, GRLNet'in AE, VAE ve GAN gibi yöntemlere kıyasla daha yüksek AUC sonuçlarına ulaştığı görülmüştür [25].

Başka bir çalışmada, MIMII veri seti üzerinde ID koşullu bir Autoencoder (IDCAE), Heteroskedastic Variational Autoencoder (HVAE) ve WaveNet tabanlı modelleri birleştiren bir ensemble yöntem önerilmiştir. Log-mel güç spektrumu ve OpenL3 gömülemelerinin giriş özellikleri olarak kullanıldığı bu yöntem, U-Net tabanlı gürültü giderimi ile ön işleme uygulanmış verilere dayanmaktadır. Anomali skorları, her modelin yeniden yapılandırma hatası veya ID uyumsuzluğu gibi kriterlere göre hesaplanmış ve ensemble yaklaşımıyla birleştirilmiştir. Yapılan değerlendirmede, önerilen modelin bireysel modellere kıyasla daha yüksek AUC ve pAUC değerlerine ulaştığı gösterilmiştir [26].

Yine bir çalışmada, ID koşullu bir Autoencoder (IDCAE) kullanılarak mel-spektrograma dönüştürülen ses sinyalleri ve makine kimlik bilgileri birleştirilmiştir. Model, encoder ve decoder mimarisi ile eğitilmiş ve kimlik bilgileri, one-hot encoding yöntemiyle sayısal vektöre dönüştürülerek modelin farklı makinelerin normal ses davranışlarını öğrenmesi sağlanmıştır. Anomali skorları, modelin yeniden yapılandırma hatasına dayalı olarak hesaplanmış ve doğru ile yanlış ID eşleştirmeleriyle modelin ayırt etme kapasitesi artırılmıştır. Bu yöntemin, düşük bellek kullanımı ve düşük gecikme süreleriyle uç bilişim (edge computing) senaryolarına uygun verimli bir çözüm olduğu belirtilmiştir [27].

Mel-Frekans Bant (MFB) özellikleri kullanılarak AE, VAE, CAE ve CVAE modelleri ile akustik anomali tespiti yapılan bir çalışmada; CVAE modelinin segment bazlı giriş özelliklerini ve Gaussian tabanlı latent alan düzenliliğini kullanarak genellikle diğer yöntemlerden daha iyi performans gösterdiği vurgulanmıştır. Anomali tespiti için kullanılan tüm Autoencoder modellerinde olduğu gibi, modeller yalnızca normal ses segmentleriyle eğitilmiş ve anomali tespiti, yeniden yapılandırma hatasına dayalı olarak gerçekleştirilmiştir [28].

Bir çalışmada, sesler Mel-spektrograma dönüştürülmüş ve bu temsiller, $\text{OutlierNets}_\alpha$ ve OutlierNets_β adlı iki farklı derin evrişimli Autoencoder modelinin eğitiminde kullanılarak akustik anomali tespiti yapılmıştır. Bu modeller, düşük kaynak tüketimi ve gerçek zamanlı akustik anomali tespiti için optimize edilmiştir. $\text{OutlierNets}_\alpha$, bellek kısıtlaması olan cihazlar için, OutlierNets_β ise düşük gecikme gereksinimi olan uygulamalar için tasarlanmıştır. Model tasarımında, generative synthesis yöntemi ile ağ mimarisi keşfi yapılmış ve derin evrişimsel otomatik kodlayıcılar, 3×3 konvolüsyonel filtreler ile batch normalizasyonu kullanılarak optimize edilmiştir [29].

Shul ve arkadaşları tarafından, derin sinir ağı (DNN) tabanlı bir çoklu görevli öğrenme (multitask learning) yapısına sahip bir model geliştirilmiştir. Çamaşır makinelerinde akustik anomali tespiti için geliştirilen bu model, ToyADMOS ve MIMII veri setleri ile de test edilmiştir. WaveNet, ses verisinin spektral yeniden yapılandırılmasından sorumlu iken, ResNet modülü ise çamaşır yükü sınıflandırması ve devir hızı tahmini için kullanılmıştır. Model, her iki görevi birlikte öğrenerek daha genel özelliklerin çıkarılmasını sağlamış ve gözetimsiz bir yaklaşım ile operasyonel gürültüye dayalı anomalileri tespit etmiştir [30].

2.2.3.2. Gözetimli akustik anomali tespiti çalışmaları

Gamaton spektrumundan elde edilen doku özellikleri ve EMD (deneysel mod ayrıştırma) tabanlı hibrit bir yaklaşımı, öz-dikkat mekanizması ile genişletilmiş bir SqueezeNet modeliyle birleştiren başka bir çalışmada, ToyADMOS ve MIMII veri setlerinde sırasıyla %96.46 ve %89.32 doğruluk oranlarına ulaşmıştır. Geleneksel SqueezeNet modellerine göre daha az parametre kullanımı ve düşük hesaplama karmaşıklığı dikkat çeken bu yöntem, gözetimli akustik anomali tespiti yaklaşımlarına bir örnektir [31].

2021 yılında yapılan bir çalışmada (tez yazarının önceki çalışması), MIMII veri setindeki pompa seslerinden Mel spektrogramı özellikleri çıkarılmış ve farklı öğrenme yaklaşımlarıyla anomali tespiti gerçekleştirilmiştir. Gözetimsiz öğrenme yöntemi olarak Autoencoder modeli, gözetimli öğrenme yöntemi olarak ise Mel spektrogramı görüntüleriyle eğitilen CNN modeli kullanılmıştır. Gözetimli yaklaşımda %97.8 doğruluk ve %91.4 AUC elde edilirken, gözetimsiz yaklaşımda %91.6 doğruluk ve %68.0 AUC performansı elde edilmiştir [32].

Ota ve Unoki, endüstriyel makinelerde anormal ses tespiti için timbral özelliklere dayalı bir yöntem (TF-ASD) geliştirmiştir. Çalışmada, insan işitme algısındaki "fark edilebilir farklılık" ilkesine dayanarak, beş timbral metrik (pürüzlülük, ton yüksekliği vb.) ve iki yeni kısa dönemli özellik (ses dalgası dalgalanma analizi ve perde değişimi) kullanılmıştır. Sinyallerden çıkarılan bu özellikler, Destek Vektör Makinesi (SVM) ile sınıflandırılmıştır. MIMII veri seti üzerinde yapılan deneylerde, dört makine türü için %98,4 doğruluk elde edilmiştir. Çalışma, timbral özelliklerin insan işitme algısına dayalı olarak akustik anomali tespitinde güçlü bir araç olduğunu göstermiştir [33].

Bir diğer çalışmada, ses sinyalleri Hilbert dönüşümü ile analitik hale getirilerek anlık genlik değerlerinden 2D gri tonlu görüntüler elde edilmiştir. Bu görüntüler, derin evrimsel sinir ağı (DCNN) ve LSTM katmanlarını birleştiren hibrit bir modelde kullanılmıştır. Üç farklı veri seti (MFPT, ToyADMOS ve MIMII) üzerinde test edilen modelin, transfer öğrenme sayesinde eğitim süresini beş kat azalttığı; MIMII veri setinde %99,6, ToyADMOS veri setinde ise %99,8 F1 skoru elde ederek yüksek performans gösterdiği ve geleneksel yöntemlere göre 12 kat daha az eğitim parametresi gerektirdiği rapor edilmiştir [34].

Bir başka çalışmada, hibrit özellik çıkarımı ve topluluk öğrenimi teknikleri kullanılmıştır. Ses sinyallerinin ön işleme aşamasında özellik çıkarımı için Mel spektrogramı, spektral çarpıklık, spektral ağırlık merkezi ve sıfır geçiş oranı gibi akustik özellikler kullanılmıştır. Çıkarılan bu özellikler, XGBoost, Destek Vektör Sınıflandırıcısı (SVC), Rastgele Orman (RF) gibi farklı sınıflandırıcılarla eğitilmiştir. Değerlendirme sonuçlarına göre, Mel spektrogram, spektral çarpıklık ve spektral ağırlık merkezi özellikleri ile eğitilen XGBoost modeli, %98,4 doğruluk ve 0,98 F1 skoru ile en yüksek performansı elde etmiştir [35].

Gantert ve arkadaşları, MIMII veri setindeki ses sinyallerinden, Chroma, Mel Frekansı Kepstral Katsayıları (MFCC), Spektral Bant Genişliği (SB) ve Spektral Kontrast (SC) gibi spektral özellikler çıkarılmıştır. Bu özellikler, Destek Vektör Makineleri (SVM) ve Çok Katmanlı Algılayıcı (MLP) gibi sınıflandırıcı modellerle anomali tespiti için kullanılmıştır. Özelliklerin model performansına katkısı, artımlı analiz yöntemi ile incelenmiş ve 6 dB SNR seviyesinde MLP modelinin ortalama %97,4 AUC elde ederek daha başarılı sonuçlar verdiği tespit edilmiştir [36].

Bir çalışmada, endüstriyel makinelerin akustik sağlık durumlarını değerlendirmek için hafif bir derin öğrenme modeli olan HM-Net önerilmiştir. Yalnızca 67 bin parametreye sahip olan bu önceden eğitilmiş CNN modeli, endüstriyel makine seslerini temsil etmek amacıyla kullanılmıştır. HM-Net tarafından çıkarılan gömülü temsiller, log-mel spektrogram tabanlı zaman-frekans temsilleri ve SoundNet transfer öğrenme modeli ile birlikte değerlendirilmiş, elde edilen özellikler doğrusal bir SVM sınıflandırıcısında kullanılmıştır. HM-Net ve diğer yöntemlerden elde edilen özelliklerin, sınıflandırma performansını artırdığı belirtilmiştir [37].

MFCC, spektral özellikler ve zaman domaini özellikleri gibi birden fazla yöntemle çıkarılan ses özelliklerini içeren bir çalışmada; AFExplorer adlı etkileşimli bir sistem, endüstriyel ses verilerindeki zaman, frekans ve cepstrum tabanlı özelliklerin seçimi ve görselleştirilmesi için geliştirilmiştir. Sistem, seçilen özelliklerin önem derecelerini görselleştirerek düşük korelasyonlu ve yüksek bilgi değeri taşıyan özellikleri belirlemiştir. Çıkarılan özellikler, AdaBoost gibi denetimli sınıflandırıcılarla işlenerek anomali tespiti gerçekleştirilmiştir. AFExplorer, seçilen özellik alt kümelerini doğruluk ve F1 skoru gibi performans metrikleriyle değerlendirmiş ve daha küçük özellik alt kümeleriyle başarılı sonuçlar elde edildiği bildirilmiştir. Bu çalışmada ortalama 0.84 F1 skoru elde edilmiştir [38].

Bir çalışmada, ses sinyallerinden MFCC, Spektral Ağırlık Merkezi, Spektral Bant Genişliği, Spektral Rolloff ve Sıfır Geçiş Oranı (ZCR) özellikleri çıkarılmıştır. Dengesiz veri kümeleri SMOTE yöntemi ile dengelenmiş ve Z-Score normalizasyonu uygulanmıştır. Anomali tespiti için çeşitli sınıflandırıcı algoritmalar (QDA, LDA, ERT, RF, XGB, LGBM vb.) kullanılarak iki sınıflı ve çok sınıflı modeller geliştirilmiştir: Bu modellerden kısmi karışık model, farklı SNR seviyelerini ayrı ayrı ele alırken; tamamen karışık model, tüm seviyeleri bir arada değerlendirerek genel bir model sunmuştur. Çalışmada, çok sınıflı modellerin, ikili modellere kıyasla sınıflandırıcı sayısını %83 oranında azalttığı ve genel performans metriklerinde iyileşmeler sağladığı bildirilmiştir [39].

2.2.3.3. Literatür özet tablosu

Literatür araştırması sırasında incelenen çalışmalar, kullanılan veri setleri, yöntemler ve elde edilen metrikler dikkate alınarak bir tablo halinde özetlenmiştir. Tablo 2.1’de, her çalışmanın temel özellikleri ve sonuçları bir araya getirilerek farklı yaklaşımlar arasındaki benzerlikler ve farklılıklar ortaya konulmuştur.

Tablo 2.1. Literatür özet tablosu.

Çalışma	Yıl	Veri Seti	Yöntem	Metrikler (%)
[19]	2019	MIMII	MIMII veri setinin tanıtıldığı çalışmadır. Mel spektrogramlarının giriş özelliği olarak kullanıldığı Autoencoder ile anomali tespiti yapılmıştır. (Gözetimsiz)	SNR = 6 dB için: Fan: 91.3 AUC Pump: 80.5 AUC Slider: 87.8 AUC Valve: 67.0 AUC Ort. AUC: 81.7
[20]	2023	MIMII, ToyADMOS	ArcFace kayıp fonksiyonu tabanlı sınıflandırıcı ve Gauss karışım modeli (GMM) tabanlı bir yöntem önerilmiştir. (Gözetimsiz)	Fan: 97.61 AUC Pump: 96.54 AUC Slider: 98.33 AUC Valve: 90.39 AUC Toycar: 95.58 AUC ToyConveyor: 81.35 AUC Ort. AUC: 93.3
[21]	2024	MIMII, ToyADMOS	Zamansal ve Mel spektrogramına dayalı özellikler GhostNet kullanılarak sınıflandırılmadan önce tek bir boyuta dönüştürülür ve birleştirilir. (Gözetimsiz)	Fan: 90.07 AUC Pump: 86.44 AUC Slider: 91.84 AUC Valve: 97.67 AUC Toycar: 89.84 AUC ToyConveyor: 67.64 AUC Ort. AUC: 87.25
[22]	2024	MIMII	Her ses sinyali Mel spektrogramına dönüştürülüp, 9 segment halinde işlenmiştir. CAE ve DAE modelleri ile anomali tespiti yapılmıştır. DAE modeli ile 6 dB SNR seviyesinde en yüksek AUC elde edilmiştir. (Gözetimsiz)	SNR = 6 dB için: Fan: 91.9 AUC, 86.9 ACC, 86.7 F1 skor Pump: 84.7 AUC, 85.6 ACC, 80.0 F1 skor
[23]	2022	MIMII DUE	STFT ve 128 Mel filtre bankaları kullanılıp; GMDNN yöntemi, boyut indirgeme ağı, yeniden yapılandırma karşıtlık ağı ve yoğunluk tahmin ağı bir arada optimize edilerek anomali tespiti yapılmıştır. (Gözetimsiz)	Fan: 76.0 AUC Pump: 76.7 AUC Slider: 88.6 AUC Valve: 72.8 AUC Ort. AUC: 78.5
[24]	2024	MIMII	GAN tabanlı; kanal, mel frekansı ve zaman boyutlarında çoklu-dikkat mekanizmalı diskriminatör ve yeniden yapılandırma hatasına dayalı anomali skorlaması yapılmıştır. (Gözetimsiz)	SNR = 6 dB için: Fan: 99.3 AUC Pump: 99.6 AUC Slider: 99.7 AUC Valve: 98.4 AUC Ort. AUC: 99.25

Tablo 2.1. (Devamı) Literatür özet tablosu.

Çalışma	Yıl	Veri Seti	Yöntem	Metrikler (%)
[25]	2022	MIMII	GRLNet yöntemi önerilmiştir. GRLNet, çoklu desen öğrenimi ve adversaryal bir yapı kullanarak hem üretici hem de diskriminatör modelleri kullanır. İki farklı Autoencoder içerir: yerel ve bölgesel. (Gözetimsiz)	SNR = 6 dB için: Fan: 95.3 AUC Pump: 90.1 AUC Slider: 91.1 AUC Valve: 63.9 AUC Ort. AUC: 85.1
[26]	2020	MIMII, ToyADMOS	Gürültü giderimi için U-Net ile ön işleme yapılmıştır. Heteroskedastic Variational AE, ID Conditioned AE ve WaveNet benzeri bir ağdan oluşan ensemble model kullanmıştır. Giriş verileri, Mel güç spektrumu ve OpenL3 gömülemeleri kullanılarak işlenmiştir. (Gözetimsiz)	Fan: 94.1 AUC Pump: 97.3 AUC Slider: 97.9 AUC Valve: 98.4 AUC Toycar: 98.3 AUC ToyConveyor: 89.0 AUC Ort. AUC: 95.8
[27]	2022	MIMII	Mel spektrograma dönüştürülen sinyaller ve one-hot kodlanmış makine kimlikleri, ID koşullu bir Autoencoder modeli ile işlenmiştir. Doğru ve yanlış ID eşleştirmesi ile model, farklı makinelerin normal davranışını öğrenmiş, anomali skorlaması yapılmıştır. (Gözetimsiz)	Fan: 71.1 AUC Pump: 78.3 AUC Slider: 91.0 AUC Valve: 74.7 AUC Ort. AUC: 78.8
[28]	2021	MIMII	Mel-frekans bant özellikleri kullanılarak AE, VAE ve konvolüsyon tabanlı CAE, CVAE modelleri ile anomali tespiti yapılmıştır. Genellikle en iyi performansı CVAE modeli göstermiştir. (Gözetimsiz)	SNR = 6 dB için: Fan: 95.4 AUC Pump: 89.8 AUC Slider: 92,1 AUC Valve: 65.5 AUC Ort. AUC: 85,7
[29]	2021	MIMII	Sesler Mel spektrograma dönüştürülmüş, generative synthesis ile optimize edilen OutlierNets α ve OutlierNets β mimarileri kullanılarak anomali tespiti yapılmıştır. (Gözetimsiz)	SNR = 6 dB için: Fan: 95.8 AUC Slider: 96.3 AUC Ort. AUC: 96.1
[30]	2023	MIMII, ToyADMOS	DNN tabanlı multitask learning yapısına sahip olan model, WaveNet rekonstrüksiyon modülünden elde edilen Mel-spektrogram ve ResNet modülünden elde edilen sonuçları kullanarak anomali tespiti yapmıştır. (Gözetimsiz)	Fan: 91.8 AUC Pump: 91.4 AUC Slider: 98.6 AUC Valve: 98.2 AUC Toycar: 97.5 AUC ToyConveyor: 83.2 AUC Ort. AUC: 93.5

Tablo 2.1. (Devamı) Literatür özet tablosu.

Çalışma	Yıl	Veri Seti	Yöntem	Metrikler (%)
[31]	2024	MIMII, ToyADMOS	Deneyisel mod ayrıştırma (EMD) ve gammatone spektrogramı filtresi kullanan bir hibrit doku gösterim tekniği ile Self-Attention SqueezeNet kullanılmıştır. (Gözetimli)	MIMII: 89.32 ACC ToyADMOS: 96.46 ACC
[32]	2021	MIMII	Mel Spektrogramı özellikleri çıkarılarak Autoencoder modeliyle gözetimsiz öğrenme yaklaşımı ve Mel spektrogramı görüntüleri ile CNN modeli eğitilerek gözetimli öğrenme yaklaşımı uygulanmıştır. (Gözetimli)	Gözetimli Pump: 97.8 ACC 91.4 AUC Gözetimsiz Pump: 91.6 ACC 68.0 AUC
[33]	2023	MIMII, ToyADMOS	Beş timbral metrik ve iki kısa dönemli özellikten (ses dalgası dalgalanma analizi ve perde değişimi) oluşan bir kombinasyon, SVM ile sınıflandırılmıştır. (Gözetimli)	Fan: 98.5 F1 skor Pump: 95.9 F1 skor Slider: 93.7 F1 skor Valve: 79.8 F1 skor Ort. MIMII: 0.92 F1 skor Toycar: 98.4 F1 skor
[34]	2023	MIMII, ToyADMOS	Hilbert dönüşümü ile elde edilen 2D görüntüler CNN ve LSTM katmanları içeren hibrit bir modelle sınıflandırılmıştır. (Gözetimli)	MIMII: 99.6 F1 skor ToyADMOS: 99.8 F1 skor
[35]	2024	MIMII	Mel spektrogram, spektral çarpıklık ve spektral ağırlık merkezi özellikleriyle eğitilen XGBoost modeli en iyi performansı göstermiştir. (Gözetimli)	98.4 ACC 98.0 F1 skor
[36]	2021	MIMII	Spektral özellikler (Chroma, MFCC, SC, SB, SR, ZCR) çıkarılarak, SVM ve MLP modelleriyle sınıflandırma yapılmıştır. 6 dB SNR seviyesinde en iyi sonuçlar MLP ile elde edilmiştir. (Gözetimli)	Fan: 99.7 AUC Pump: 98.3 AUC Slider: 98.5 AUC Valve: 92.9 AUC Ort. AUC: 97.4
[37]	2023	MIMII	M-Net (67k parametrelili) ve SoundNet tabanlı transfer öğrenme ile özellik çıkarımı yapılmıştır. Ayrıca, Mel spektrogram temelli zaman-frekans temsilleri kullanılmıştır. SVM modeli ile sınıflandırılmıştır. (Gözetimli)	Fan: 100.0 AUC Pump: 90.0 AUC Slider: 94.0 AUC Valve: 84.0 AUC Ort. AUC: 92.0 ToyCar, ToyConveyor: 85.0+ AUC

Tablo 2.1. (Devamı) Literatür özet tablosu.

Çalışma	Yıl	Veri Seti	Yöntem	Metrikler (%)
[38]	2022	MIMII, ToyADMOS	AFExplorer, ses sinyallerinden çıkarılan zaman, frekans ve cepstrum özellikleri için özellik seçimi yapılmasını sağlamıştır. AdaBoost gibi sınıflandırıcılar kullanılarak anomali tespiti yapılmıştır. (Gözetimli)	Fan: 86.6 F1 skor Valve: 83.3 F1 skor Toycar: 82.2 F1 skor Ort. F1 skor: 84.0
[39]	2024	MIMII	Sesten çıkarılan özellikler arasında MFCC, Spectral Centroid, Spectral Bandwidth, Spectral Rolloff ve ZCR bulunmaktadır. Dengesiz veriler SMOTE yöntemiyle dengelenmiş, anomali tespiti için QDA, LDA ERT, RF, XGB ve LGBM vb. algoritmalar kullanılmıştır. (Gözetimli)	İkili sınıflandırma SNR = 6 dB için: Fan: 65.0 AUC Pump: 79.0 AUC Slider: 66.3 AUC Valve: 73.6 AUC Ort. AUC: 71.0

3. MATERYAL VE YÖNTEM

Bu bölümde, deneysel çalışmada kullanılan veri setleri, verilerin hazırlanması, eğitim ve özellik seçimi için kullanılan modeller ve bu modellerin performanslarının değerlendirilmesi adımları detaylı olarak açıklanacaktır.

3.1. Veri Setleri

Bu bölümde kullanılan veri setleri, çalışmanın amaçlarına uygun olarak seçilmiştir. Her bir veri seti, makinelerin normal ve anormal seslerini içeren geniş bir veri yelpazesi sunarak anomali tespiti ve sınıflandırma çalışmalarında model performansının test edilmesine olanak tanımaktadır.

3.1.1. MIMII veri seti

Arızalı Endüstriyel Makine Araştırma ve Muayenesi için Ses Veri Seti (MIMII), kirlenme, sızıntı, dengesiz dönüş ve ray hasarını içeren farklı anomalilere karşılık gelen seslerin, gerçek bir fabrikadaki bir fan, pompa, vana ve kızak rayından oluşan dört makineden gelen arka plan gürültüsüyle toplandığı endüstriyel bir ses veri setidir. Her makine tipi yedi ayrı ürün modeli içerir ve her model için normal ve anormal ses verileri bulunmaktadır. Her bir kayıttaki 10 saniyelik sesler, 16 kHz örnekleme hızı ve örnek başına 16 bit ile sekiz kanallı mikrofona dizisi ile kaydedilmiştir [19].

Makinenin normal ve anormal çalışma koşullarını ayırt etme performansı farklı gürültü koşullarında değerlendirilmesi için, birden fazla gerçek fabrikada kaydedilen arka plan gürültüsü farklı sinyal-gürültü oranı (SNR) seviyeleri (6 dB, 0 dB, -6 dB) dikkate alınarak makine sesleriyle karıştırılmıştır. SNR, istenmeyen gürültüye kıyasla istenen sinyalin göreceli gücünün bir ölçüsüdür. Bu çalışmada 6 dB SNR oranına sahip ses kayıtları kullanılacaktır.

Her makinenin çalışma sürecinde çeşitli sorunlar ortaya çıkmakta ve bu sorunlar anormal seslerin oluşumuna neden olmaktadır. Veri setinde yer alan makine türlerinin çalışma şekilleri ve karşılaşılan anormal koşullara ilişkin örnekler Tablo 3.1’de verilmiştir.

Tablo 3.1. Makinelerin çalışma ve anormal koşullar listesi [19].

Makine Türü	Çalışma Şekli	Anormal Koşul Örnekleri
Pompa	Su havuzundan emiş / boşaltma	Sızıntı, kirlenme, tıkanma, vb.
Valf	Farklı zamanlarda açma / kapama tekrarı	İki türden fazla kirlenme
Fan	Normal çalışma	Dengesizlik, voltaj değişimi, tıkanma, vb.
Sürgülü Ray	Farklı hızlarda kaydırma tekrarı	Ray hasarı, gevşek kayış, yağsızlık, vb.

3.1.2. ToyADMOS veri seti

ToyADAMOS, 48 kHz örnekleme hızında dört mikrofondan toplanan bir makine çalışma sesi veri setidir. Makine çalışma seslerinde anormallik tespiti (ADMOS) için minyatür makineler (oyuncaklara) kasıtlı olarak hasar vererek anormal çalışma sesleri toplanmıştır. Veri seti; makine durumu denetimi, geometrik olarak sabit görevlerle çalışan makinelerin arıza teşhisi ve hareketli makinelerin arıza teşhisi için üç alt veri kümesinden oluşmaktadır. Bir oyuncak araba (makine durumu denetimi), oyuncak konveyörü (sabit) ve oyuncak tren (hareketli) olmak üzere üç farklı oyuncak makinesi için normal ve anormal seslerden oluşan iki tür ses vardır [40].

Bu veri setindeki makineler gerçek endüstriyel makineler yerine oyuncaklardan oluşturulduğu için yalnızca literatürdeki yöntemlerle sonuçları karşılaştırmak için kullanılacaktır. Literatürde en çok oyuncak araba (ToyCar) verileri için sonuçlar bulunduğundan bu çalışmada da oyuncak araba verisindeki sonuçlar değerlendirilecektir. Oyuncak arabada anormallikler, motor ve yatağı değiştirerek üretilmiştir. Oyuncak araba veri seti, toplam 72.000 ayrı örnek içermektedir.

3.1.3. Elektrik motorları veri seti

Akıllı Güvenilirlik 4.0 (iRel40) başlıklı uluslararası projede, beyaz eşya elektrik motoru üreticisi tarafından sağlanan veri seti ile önerilen yöntem test edilecektir. Mevcut test sisteminde titreşim verileri eşik değerler ile karşılaştırılarak elektrik motorları için başarılı/başarısız kararı verilmektedir. Bu karşılaştırmada kararın başarısız olduğu bazı durumlar da arızaların bir kısmı sistem tarafından tespit edilemez

ve bunun bir nedeni olarak nihai karar makine operatörüne bağlıdır. Operatörün motorun sesini dinlemesi ve başarılı/başarısız nihai kararını vermesi gerekir. Bu projede amaç, tam otomatik kalite testini gerçekleştiren yapay zeka destekli yeni bir test sistemi kurulmasıdır [41].

Mevcut durumda karar operatör tarafından ses verisine göre verildiği için toplanacak en önemli sinyallerden biri ses sinyalleridir. Proje kapsamında sağlanan etiketli veri seti, elektrik motorlarından toplanan 20 kHz örnekleme sıklığı ile yaklaşık 13 saniyelik akım, titreşim ve ses verilerini içermektedir. Bu çalışma kapsamında bu veri setindeki ses sinyalleri kullanılarak sağlıklı ve hatalı motorların tespiti için gözetimli modeller eğitilecektir.

3.2. Veri Ön İşleme

Bu bölüm, ses sinyali özellikleri çıkarımı aşamasından önce verinin hazırlanması aşamasında yapılabilecek işlemleri içerir. Ses verisi genellikle ham haliyle doğrudan kullanılmaya uygun olmadığı için bu nedenle önceden bazı işlemler yapılması gerekmektedir.

- **Veri Yükleme ve Çok Kanallı (Multichannel) Veri Dönüşümü:** Ses verileri genellikle bir ses dosyasından yüklenir. Librosa gibi kütüphaneler, ses dosyalarının yüklenmesini sağlar. Ses verileri bazen çok kanallı (stereo gibi) olabilir ancak bazı analizler için mono ses verisi gerekmektedir. Bu çalışmada da 8 kanallı ses verileri, ilk kanal seçilerek mono ses verisine dönüştürülmektedir
- **Offset Alınması:** Librosa gibi kütüphaneler, ses dosyasını yüklerken ses dosyasının başındaki belirli bir süreyi atlamayı sağlayan offset parametresi kullanılabilmektedir. Bu parametre, ses dosyasının ilk birkaç saniyesindeki sessiz veya gereksiz kısımları atlayarak yalnızca ihtiyaç duyulan kısmın yüklenmesini mümkün kılar. Bu, verinin daha temiz ve odaklanmış bir şekilde işlenmesini sağlar. Bu çalışmada yalnızca elektrik motorlarına ait ses verileri için bu atlama işlemi kullanılmaktadır.
- **Yeniden Örnekleme (Resampling):** Ses verisi, farklı örnekleme oranlarına sahip olabilir. Farklı cihazlar veya kayıttan kaynaklanan bu farklılıklar, modelin veriyi tutarlı bir şekilde analiz etmesini zorlaştırır. Bu nedenle, verinin

belirli bir örnekleme oranına dönüştürülmesi gerekebilir. Bu işlem, veri setindeki seslerin aynı temel formatta olmasını sağlamak için kullanılmaktadır.

- **Segmentasyon:** Ses sinyalleri, genellikle uzun süreli süreklilik gösterir. Ancak, belirli bir görev için ses sinyalinin daha kısa zaman dilimlerine ayrılması gerekebilir. Bu işlem, segmentasyon olarak adlandırılır ve ses sinyalini küçük zaman dilimlerine (örneğin, 2-3 s) bölerek her bir dilim için özellik çıkarımı yapılmasını sağlar. Bu işlem, ses verisinin zaman içindeki özelliklerini daha detaylı analiz edebilmek için önemlidir.

Segmentasyon gürültü azaltma için de kullanılmaktadır. Ses sinyalindeki gürültüler genellikle belirli bir zaman diliminde daha belirgin olmaktadır. Segmentasyon, bu dilimleri ayırarak her bir dilimdeki gürültüyü izole etmenize olanak tanır. Ayrıca, segmentasyon sayesinde, gürültü içeren bölgeler ile sesin gerçek bileşenleri arasındaki farklar daha net bir şekilde görülebilir, bu da gürültüyü daha kolay ayıklamayı sağlar.

- **Gürültü Azaltma (Noise Reduction):** Ses sinyalleri, kaydedildiği ortamdan kaynaklanan çeşitli gürültüleri içerebilir. Bu tür gürültüler, sesin doğru şekilde analiz edilmesini engelleyebilir. Bu nedenle, ses sinyali üzerinde yumuşatma (smoothing) gibi gürültü azaltma teknikleri uygulanabilir.

Bu çalışmada, gürültü azaltma amacıyla doğrudan bir yumuşatma veya filtreleme işlemi uygulanmamıştır. Bunun yerine, sinyalin özellik çıkarım aşamasında, gürültüyü ortadan kaldırmaya yönelik teknikler dolaylı olarak kullanılmaktadır. Özellik çıkarımı sırasında sinyalin daha belirgin yapısal özelliklerine odaklanılırken, rastgele ve düzensiz bileşenler doğal olarak etkisiz hale gelmektedir.

3.3. Sinyal İşleme ve Ses Özellikleri Çıkarma

Ses sinyalleri üzerinde uygulanan farklı yöntemlerle makine öğrenmesi modeline girdi olacak metrikler oluşturulmuştur. Bu çalışmada, ses sinyallerini analiz etmek ve makine öğrenmesi modellerine uygun özellikler çıkarmak için çeşitli Python kütüphaneleri kullanılmıştır. Aşağıda, bu kütüphanelerin kısa açıklamaları ve sağladıkları işlevler yer almaktadır:

- **Librosa:** Ses sinyallerinin işlenmesi ve özellik çıkarımı için yaygın olarak kullanılan bir kütüphanedir. Özellikle spektral analizler, zaman-frekans dönüşümleri ve ses özelliklerinin çıkarılması konularında kullanılmıştır [42].
- **SciPy:** Bilimsel hesaplamalar ve optimizasyon için kullanılan bu kütüphane, özellikle sinyal işleme, güç spektral yoğunluğu (PSD) ve Hilbert dönüşümü hesaplamaları için kullanılmıştır [43].
- **Statsmodels:** İstatistiksel analizler için kullanılan bir kütüphanedir. İstatistiksel testler, zaman serisi analizi ve otokorelasyon hesaplamaları gibi işlemler için kullanılmıştır [44].
- **Statistics:** Bu kütüphane, veri setinin harmonik ortalaması, medyanı, varyansı gibi temel istatistiksel metrikleri hesaplamak için kullanılmıştır.
- **NumPy ve Math:** Sayısal hesaplamalar ve matematiksel işlemler için kullanılmıştır.

Çeşitli ses sinyali özellikleri, makine öğrenmesi modelleri için anlamlı girişler oluşturmak amacıyla çıkarılmıştır. Alt bölümlerde, çıkarılan her bir sinyal özelliği ve bu özelliklerin ses sinyali analizindeki önemi detaylandırılacaktır. Bu özelliklerin her biri, sinyalin genel yapısını, tonunu, spektral karakterini ya da zaman-frekans özelliklerini anlamak için önemli bilgiler sunar.

3.3.1. Spektral ağırlık merkezi


Spektral Ağırlık Merkezi (Spectral Centroid), spektrumun yani bir sesin kütle merkezinin nerede olduğunu gösterir ve seste bulunan frekansların ağırlıklı ortalaması alınarak hesaplanır. Öncelikle ses sinyallerinin frekans alanına dönüştürülmesi için STFT kullanılarak hesaplanmaktadır. Tüm frekans bileşenlerinin birleştiği bir merkez noktasını temsil eden bu özellik genellikle Hz cinsinden ifade edilir ve sinyalin enerji dağılımını gösterir. Örneğin, düşük frekans bileşenleri ağırlıklı olarak bir sinyalin sol tarafında bulunurken, yüksek frekans bileşenleri sağ tarafında yer alır. Spektral ağırlık merkezinin değeri, C_i her ses çerçevesi için şu şekilde hesaplanır [45]:

$$C_i = \frac{\sum_{k=1}^{W_f} L_k X_i(k)}{\sum_{k=1}^{W_f} X_i(k)} \quad (3.1)$$

Bu formülde:

- W_f , Fourier dönüşümündeki frekans bileşenlerinin sayısını,
- L_k k -inci frekans bileşeninin frekans değerini,
- $X_i(k)$, i -inci ses çerçevesinin k -inci frekans bileşenine karşılık gelen genliği gösterir.

Müzikal enstrümanların tanınması, konuşma tanıma, sinyal sınıflandırması, sinyaller aracılığıyla hastalık tanısı ve duygusal analiz gibi uygulamalarda yaygın olarak kullanılmaktadır [46]. MIMII veri setindeki gibi 16.000 Hz kayıt frekansına sahip 10 saniyelik bir ses sinyali için 1024 pencere uzunluğu (window size) ve 512 atlama boyutu (hop size) tercih edildiğinde, STFT sonucunda 312 çerçeve (frame) oluşmaktadır. Her çerçeve için ortalama spektral ağırlık merkezi (centroid) hesaplanarak, toplamda 312 değer elde edilir. Normal ve anormal pompa makinesine ait ses sinyallerinden birer örnek alınarak oluşturulan ve spektral ağırlık merkezi değerlerini içeren görseller aşağıda yer almaktadır.



Şekil 3.1. Spektral ağırlık merkezi.

Bu çalışmada, ses sinyallerinin analizi için elde edilen 312 spektral ağırlık merkezi değeri, makine öğrenmesi modellerine girdi olacak şekilde doğrudan kullanılmak yerine çeşitli istatistiksel metrikler oluşturularak özetlenmiştir. Aşağıda, spektral ağırlık merkezinden elde edilip veri setini oluşturacak istatistiksel metriklerin açıklamaları yer almaktadır:

- **Ortalama:** *spectralCentroidsMean* olarak adlandırılan bu özellik, tüm spektral ağırlık merkezlerinin aritmetik ortalamasını temsil eder. Bu, sinyalin genel frekans eğilimlerini anlamaya yardımcı olur.
- **Harmonik Ortalama:** *spectralCentroidsHMean*, verilerin harmonik ortalamasını hesaplar. Bu metrik, özellikle düşük değerlerin etkisini vurgulamak için kullanılır.

- **Varyans:** *spectralCentroidsPvariance*, spektral ağırlık merkezlerinin nasıl dağıldığını gösterir. Bu değer, verilerin dağılımındaki değişkenliği ortaya koyar.
- **Medyan:** *spectralCentroidsMedian*, 312 spektral ağırlık merkezi değerinin ortasında kalan değerdir.
- **Maksimum ve Minimum:** *spectralCentroidsMax* ve *spectralCentroidsMin*, veri setindeki en yüksek ve en düşük spektral ağırlık merkezi değerlerini temsil eder. Bu değerler, sinyalin frekans aralığını belirlemede yardımcı olur.
- **Standart Sapma:** *spectralCentroidsStd*, verilerin ne kadar yayıldığını gösteren bir ölçüttür. Yüksek bir standart sapma, verilerin geniş bir aralıkta dağıldığını gösterirken, düşük bir değer daha homojen bir dağılımı işaret eder.
- **Toplam:** *spectralCentroidsSum*, toplam spektral ağırlık merkezi değerinin zamanla normalize edilerek hesaplanmış halidir.
- **Çarpıklık:** *spectralCentroidsSkew*, veri dağılımının simetrikliğini ölçer. Pozitif bir değer, sağa çarpık bir dağılımı; negatif bir değer ise sola çarpık bir dağılımı gösterir.
- **Medyan Mutlak Sapma:** *spectralCentroidsMAD*, verilerin medyan etrafındaki dağılımını gösterir. Bu metrik, verilerin merkez etrafında ne kadar yayıldığını ölçmekte faydalıdır.
- **Anderson Testi:** *SpectralCentroidsAnderson*, ağırlık merkezi verilerinin verinin normal dağılıma uygunluğunu test etmek için kullanılır.
- **Kurtosis Testi:** *SpectralCentroidsKurtosisTestPvalue*, spektral ağırlık merkezi verisinin dağılımının normal dağılıma uygunluğunu test etmek için kurtosis testi kullanır. Kurtosis Testi verinin uç noktalarındaki yoğunluk ve dağılımının keskinliği hakkında bilgi verir.
- **Jarque-Bera Testi:** *SpectralCentroidsJarqueBeraPvalue*, veri setinin normal dağılıma uygunluğunu değerlendiren bir başka istatistiksel testtir. Bu testin p-değeri, normal dağılımdan ne kadar uzak olduğumuzu gösterir. Kurtosis testinden farklı olarak uç noktalarındaki yoğunluğun yanı sıra asimetric (skewed) olup olmadığına da bakar.

3.3.2. Spektral bant genişliği


Spektral Bant Genişliği (Spectral Bandwidth), bir ses sinyalinin frekans spektrumunda kapladığı bant genişliğini ölçen bir spektral özelliktir. Spektral bant genişliği, ses sinyalinin dalga genişliğinin maksimum tepe noktasının yarısını tanımlar. Spektral bant genişliği, spektral ağırlık merkezinde de olduğu gibi STFT dönüşümü sonrası elde edilen her bir çerçeve için ayrı ayrı hesaplanır ve tanımlanır. Spektral bant genişliği, her bir çerçeve için Librosa kütüphanesinde şu şekilde hesaplanır [47]:

$$BW = \left(\sum_k |S[k, t]|^p \cdot (f[k, t] - \mu_f)^p \right)^{\frac{1}{p}} \quad (3.2)$$

Burada:

- $S[k, t]$: Bu, spektrogram değerlerini temsil eder, yani zaman-frekans çözünürlüğündeki genlik verilerini içerir.
- $f[k, t]$: Her bir frekans bileşeni k ve zaman dilimi t 'deki frekans değeri.
- μ_f : Spektral ağırlık merkezi, yani spektrumun ağırlıklı ortalama frekansı.
- p : Bu parametre p-norm'u ifade eder, Euclidean norm'a eşdeğer olması için bu parametre genellikle 2 olarak ayarlanır.


Aşağıdaki grafikte, normal ve anormal pompa makinelerinin ses sinyalleri için hesaplanan spektral bant genişliği değerlerinin zaman içerisindeki değişimi gösterilmektedir.



Şekil 3.2. Spektral bant genişliği.

Spektral bant genişliği değerlerinin zaman içindeki değişimlerini daha iyi anlamak ve anomali tespiti için gerekli veriyi sağlamayı amaçlamaktadır. Aşağıda, spektral bant genişliğinden elde edilen ve veri setine dahil edilen çeşitli istatistiksel metrikler verilmiştir:

- **Otokorelasyon Katsayıları:** *autocorrCoeffSB2* ve *autocorrCoeffSB3*, spektral bant genişliğinin 2. ve 3. gecikmelerdeki otokorelasyon katsayılarını temsil eder. Otokorelasyon, bir sinyalin kendisiyle olan benzerliğini ölçer ve bu katsayılar sinyaldeki düzenliliği paternlerini incelemeye yardımcı olabilir.
- **Ortalama:** *spectralBandwidthMean*, tüm spektral bant genişliği değerlerinin aritmetik ortalamasını temsil eder. Bu metrik, sinyalin frekans yayılımının genel eğilimlerini anlamayı sağlar.
- **Maksimum ve Minimum:** *spectralBandwidthMax*, spektral bant genişliği değerlerinin maksimum değerini temsil eder. Sinyalin en geniş frekans aralığını kapsayan bölgesini gösterir. Normalden yüksek bir maksimum değer, sinyaldeki frekans bileşenlerinin daha geniş bir alana yayıldığını ve bunun da potansiyel olarak anormal bir durumu işaret edebileceğini gösterebilir. *spectralBandwidthMin* ise spektral bant genişliği değerlerinin minimum değerini temsil eder.
- **PSD Standart Sapma:** *spectralBandwidthWelchPsdStd*, spektral bant genişliğinin, güç spektral yoğunluğunun (PSD) standart sapmasını gösterir. Bu değer, sinyaldeki güç dağılımının değişkenliğini ölçer ve yüksek bir standart sapma, frekans bileşenlerinin düzensiz dağıldığını işaret eder. Şekil 3.3'te, bu metriğin normal ve anormal sinyal örnekleri için hesaplanan görseli yer almaktadır.



Şekil 3.3. Spektral bant genişliğinin PSD değişimi.

3.3.3. Spektral rolloff

Spektral Rolloff, belirli bir frekansın (genellikle %85) üzerindeki enerji miktarını ölçerek hesaplanır [48]. Belirli bir yüzdede bu toplam enerjiye ulaşan ilk frekansa "rolloff frekansı" denir. Bu, spektrumun yüksek frekans bileşenlerinin "kesilme" noktasını ifade eder. Yani, bu frekans, sinyalin büyük kısmının enerjisini kapsayan ve sinyaldeki düşük frekansların çoğunu içeren ilk noktadır.


Bu hesaplama için öncelikle sinyalin kısa süreli Fourier dönüşümü alınarak, sinyalin frekans bileşenleri çıkarılır ve bir spektrum elde edilir. Spektrumdaki her bir frekansın enerji seviyesi hesaplanır ve toplam enerji birikimli olarak toplanır. Ardından, toplam enerjinin %85'ine (veya belirli bir yüzdede) ulaşan ilk frekans, rolloff frekansı olarak belirlenir. Matematiksel olarak, rolloff frekansı şu şekilde hesaplanır:

$$f_{\text{rolloff}} = \min \{ f \mid \sum_{i=0}^f E(f_i) \geq \alpha \cdot E_{\text{total}} \} \quad (3.3)$$

Burada:

- $E(f_i)$: f_i frekans bileşeninin enerji değeri.
- α : Rolloff yüzdesi (%85).
- E_{total} : Tüm spektrumun toplam enerjisi.

Bu özellik, bir çok ses sınıflandırma çalışmasında öne çıkan özelliklerden biri olmuştur [18, 19]. Normal ve anormal ses sinyallerinden alınan örnekler ile oluşturulan spektral rolloff değerlerini içeren görseller aşağıda sunulmaktadır.



Şekil 3.4. Spektral rolloff.

Spektral rolloff değerleri üzerinden hesaplanan ve veri setine dahil edilen çeşitli istatistiksel metrikler listelenmiştir:

- **Ortalama:** *spectralRolloffMean*, tüm spektral rolloff değerlerinin aritmetik ortalamasını gösterir. Bu metrik, sinyalin enerji dağılımının genel eğilimini anlamamıza yardımcı olur.
- **Medyan:** *spectralRolloffMedian*, spektral rolloff değerlerinin medyanını verir.
- **Maksimum ve Minimum:** *spectralRolloffMax*, sinyalin frekans spektrumunda enerjinin büyük kısmının kapsadığı frekansın en yüksek sınırını gösterir. *spectralRolloffMin*, sinyalin frekans spektrumunda enerjinin büyük kısmının kapsadığı frekansın en düşük sınırını gösterir.
- **Standart Sapma:** *spectralRolloffStd*, spektral rolloff değerlerinin standart sapmasını ifade eder. Bu değer, sinyaldeki frekans bileşenlerinin ne kadar düzensiz olduğunu gösterir.
- **Toplam:** *spectralRolloffSum*, spektral rolloff değerlerinin toplamını verir. Bu metrik, sinyaldeki enerji yoğunluğunun toplamını belirler.
- **Çarpıklık:** *spectralRolloffSkew*, spektral rolloff değerlerinin çarpıklığını (asimetrisini) ölçer.
- **Medyan Mutlak Sapma:** *spectralRolloffMAD*, spektral rolloff değerlerinin medyan mutlak sapmasını gösterir. Bu, verinin merkezden ne kadar saptığını ölçer ve dağılımın ne kadar yaygın olduğunu gösterir.
- **Kurtosis Test P-değeri:** *spectralRolloffKurtosisTestPvalue*, spektral rolloff değerlerinin dağılımının ne kadar "keskin" olduğunu test eden kurtosis testinin p-değerini hesaplar. Düşük p-değeri, normalden belirgin bir sapmayı gösterir.
- **Anderson-Darling Testi:** *spectralRolloffAnderson*, spektral rolloff değerlerinin belirli bir istatistiksel dağılıma ne kadar uygun olduğunu test eder. Bu testin istatistiği, verinin normal dağılımdan sapma düzeyini gösterir.

3.3.4. Spektral kontrast

Spektral Kontrast (Spectral Contrast), frekans spektrumundaki zirveler ve çukurlar arasındaki desibel farkını ölçen bir özelliktir. Müzik sinyallerinde, güçlü spektral tepeler genellikle harmonik bileşenlerle ilişkili iken, daha zayıf ve düzensiz bileşenler, yani harmonik olmayan bileşenler ya da gürültüler, spektral çukurlarda gözlemlenir. Spektral kontrast ise bu tepe ve çukur farklarını her alt bant dikkate alarak hesaplar.

Spektral kontrast özelliğinin, MFCC özelliğine göre daha ayrıntılı spektral bilgiyi sağladığı ve müzik türü sınıflandırmada daha başarılı olduğu görülmüştür [50]. MFCC


yalnızca spektral verinin ortalama bilgisini sunarken; spektral kontrast, relatif spektral özellikleri temsil etmektedir. Yani, bu özellik, yalnızca bir frekans bileşeninin (spektral zirve, vadi) değerine bakmaz, aynı zamanda o frekans bileşeninin, çevresindeki diğer frekans bileşenlerine kıyasla nasıl konumlandığını ve nasıl bir fark oluşturduğunu değerlendirir. Formülü:

$$\text{Tepe (Peak)}_k = \log \left(\frac{1}{\alpha N} \sum_{i=1}^{\alpha N} x'_{k,i} \right) \quad (3.4)$$

$$\text{Çukur (Valley)}_k = \log \left(\frac{1}{\alpha N} \sum_{i=1}^{\alpha N} x'_{k,N-i+1} \right) \quad (3.5)$$

$$\text{Spektral Kontrast}_k = \text{Tepe}_k - \text{Çukur}_k \quad (3.6)$$

Spektral kontrast, seslerin karakteristiklerini anlamak ve tanımak için yararlıdır. Farklı müzik türlerini veya sesleri ayırt etme çalışmalarında kullanılmıştır [20, 21]. Normal ve anormal ses sinyallerinden alınan örneklerle elde edilen spektral kontrast değerlerine ilişkin görseller aşağıda sunulmuştur.



Şekil 3.5. Spektral kontrast.

Spektral kontrast değerleri üzerinden yalnızca aşağıdaki üç özellik hesaplanarak nihai veri setine dahil edilmiştir:

- **Otokorelasyon Katsayıları:** *autocorrCoeffSC2* ve *autocorrCoeffSC3*, spektral kontrastın 2. ve 3. dereceden otokorelasyon katsayılarını temsil eder. Bu katsayılar, kontrastın zaman içindeki tekrar eden desenlerini ve düzenliliğini gösterir.
- **Ortalama:** *spectralContrastMean*, Spektral kontrastın tüm frekans bantlarındaki ortalama değerini ifade eder. Bu, sinyalin genel kontrast

seviyesini temsil eder. Anomali tespitinde, normal sinyallerin ortalama kontrast seviyeleri sabitken, anormal sinyallerde bu ortalama değerlerinde belirgin deęişiklikler gözlemlenebilir.

3.3.5. Spektral düzlük

Spektral Düzlük (Spectral Flatness), bir ses sinyalinin gürültü veya tonal özelliklerini ayırt etmeye yardımcı olan bir özelliktir. Sinyal spektrumundaki düzlük derecesini ölçer. Tonalite katsayısı olarak da bilinen bu özellik, bir sesin ton benzeri olmaktan ziyade ne kadar gürültü benzeri olduğunu nicellemek için bir ölçüdür. Bu, genellikle sesin "düz" veya "keskin" olup olmadığını belirlemek için kullanılır. Düz bir spektrum, sesin daha "gürültülü" veya "parlak" olmasına işaret edebilirken, keskin bir spektrum daha "tonlu" veya "temel" seslere işaret edebilir. Yüksek bir spektral düzlük (1.0'a yakın), spektrumun beyaz gürültüye (white noise) benzediğini gösterir [52].

Bu metrik, geometrik ortalama ile aritmetik ortalama arasındaki oranla hesaplanır: geometrik ortalama, spektrumun her bir zaman dilimindeki logaritmalarının ortalamasıdır, aritmetik ortalama ise spektrumun her bir zaman dilimindeki doğrudan ortalamasıdır.

$$\text{Spektral Düzlük} = \frac{\text{Geometrik Ortalama}}{\text{Aritmetik Ortalama}} = \frac{\exp\left(\frac{1}{N} \sum_{i=1}^N \log(S_i)\right)}{\frac{1}{N} \sum_{i=1}^N S_i} \quad (3.7)$$


Her bir çerçeve için ayrı olarak hesaplanmaktadır. Her bir sinyalden çıkarılan 312 farklı spektral düzlük değerinin, ortalaması alınarak nihai veri setimiz için tek bir temsilci özellik haline getirilmiştir.

3.3.6. Spektral yayılma

Spektral Yayılma (Spectral Spread), bir ses sinyalinin spektrumundaki enerji dağılımının ne kadar geniş olduğunu ölçen bir özelliktir. Sinyalin bant genişliğiyle yakından ilişkili olan bu özellik, frekans bileşenlerinin merkez frekansına olan uzaklıklarının ne kadar dağıldığını gösterir ve genellikle sesin "zenginliğini" veya "karmaşıklığını" değerlendirirken kullanılır [53]. Spektral yayılmanın sadece ortalaması, modelde özellik olarak kullanılmıştır.

3.3.7. Güç spektral yoğunluğu

Güç spektral yoğunluğunu (Power Spectral Density, PSD) tahmin etmek için *welch* yöntemi kullanılmaktadır. Bu yöntem, verileri örtüşen segmentlere bölerek, her segment için değiştirilmiş bir periyodogram hesaplayarak ve periyodogramların ortalamasını alarak güç spektral yoğunluğunun bir tahminini hesaplar [54]. Özellikle gürültülü sinyallerde spektral analiz için yaygın olarak kullanılır. *welch* yöntemi, sinyaldeki gürültüyü azaltarak daha güvenilir bir spektral analiz sağlar. Bu sayede, sinyalin frekans bileşenlerini daha net bir şekilde görülmektedir. Aşağıdaki grafikte, normal ve anormal ses sinyallerinin güç spektral yoğunluk değerleri gösterilmektedir.



Şekil 3.6. Güç spektral yoğunluğu.

Güç spektral yoğunluğu üzerinden çıkarılan ve veri setine dahil edilen istatistiksel metrikler aşağıda verilmiştir:

- **Ortalama:** *PowerSpectralDensityMean*, tüm PSD değerlerinin aritmetik ortalamasını temsil eder. Bu metrik, sinyalin genel güç seviyesini, yani tüm frekanslarda sinyalin taşıdığı gücün ortalama dağılımını gösterir. Bir sinyalde bu değer normalden yüksek olması, beklenmedik bir şekilde yüksek güç seviyeleri, gürültü, bozulma veya dışsal parazitlere işaret edebilirken; düşük olması, güç kaybı veya sistemdeki bir arıza nedeniyle sinyalin zayıflaması anlamına gelebilir.


- **Maksimum ve Minimum:** *PowerSpectralDensityMax*, sinyalin frekans bileşenleri içinde elde edilen en yüksek güç değerini temsil eder. *PowerSpectralDensityMin*, sinyalin en düşük güç değerini temsil eder.
- **Standart Sapma:** *PowerSpectralDensityStd*, PSD değerlerinin standart sapmasıdır. Bu metrik, sinyalin güç dağılımının ne kadar değişken olduğunu gösterir. Yüksek bir standart sapma, sinyaldeki güç dağılımının daha düzensiz olduğunu gösterir. Normalde sabit olan bir sinyalin düzensizleşmesi veya aniden çok fazla frekans bileşenine yayılması, sistemin arızalandığını veya dışsal gürültü kaynaklarının etkisini gösteriyor olabilir.

3.3.8. Genlik zarfı

Genlik Zarfı (Amplitude Envelope), bir ses sinyalinin genlik değişimlerinin zaman içindeki genel eğilimini gösteren önemli bir zaman alanı (time-domain) özelliğidir. Genlik zarfı, sesin zamanla değişen şiddetini, yani genlik düzeylerini takip eder ve sesin daha yoğun veya daha zayıf olduğu bölümleri belirlemeye yardımcı olur. Aykırı değerlere karşı hassas olan bu özellik, özellikle sesin dinamik yapısını analiz etmek, belirli ses olaylarını tespit etmek ve müzik türlerini sınıflandırmak için yaygın olarak kullanılmıştır [55].

Ses sinyalinin genlik zarfını hesaplamak için çerçeveleme (framing) yöntemi kullanılır. Her bir çerçevenin maksimum genliği alınır. Bu maksimum değer, sinyalin o çerçeve içindeki "en yüksek şiddet" noktasını gösterir ve bu değer, amplitüd zarfının bir elemanı olarak kaydedilir. Bu işlem sinyalin sonuna kadar, her seferinde atlama boyutu kadar kaydırılarak tekrarlanır. Bu sayede zaman içinde genlikteki değişimler gözlenmektedir [56].

Genlik zarfının daha düzgün bir şekilde belirlenmesi için genellikle düşük geçişli bir filtre (örneğin Hilbert dönüşümü) kullanılarak yumuşatma işlemi yapılır [57]. Ancak, bu özellik anomali tespiti amacıyla kullanılacağından, özellik çıkarma adımlarında yumuşatma işlemi bilerek kaldırılmıştır. Çünkü anomali tespiti, genellikle ani ve keskin değişimlerde bulunan sapmalarla ilgilidir. Yumuşatma, bu tür ani değişimlerin gizlenmesine yol açabileceği için, anomali tespiti için daha doğrudan bir genlik zarfı gereklidir. Aşağıdaki grafikte, normal ve anormal ses sinyallerinin genlik zarfı değerleri gösterilmektedir. Bu örnekte, anormal sinyale ait geçişlerin, normal sinyale kıyasla çok daha keskin ve belirgin olduğu gözlemlenmektedir.



Şekil 3.7. Genlik zarfı.

Genlik zarfı ile elde edilen ve veri setine dahil edilen çeşitli istatistiksel metrikler aşağıda verilmiştir:

- **Toplam:** *amplitudeEnvelopeSum*, sinyalin genlik zarfı değerlerinin toplamını temsil eder. Sinyalin genliğinin tüm zaman dilimi boyunca birikmiş toplam enerjisini ifade eder.
- **Medyan:** *amplitudeEnvelopeMedian*, genlik zarfının orta noktasını bulur.
- **Maksimum ve Minimum:** *amplitudeEnvelopeMax*, genlik zarfındaki en yüksek değeri temsil eder. Sinyaldeki ani patlamalar veya yüksek şiddetli olayları işaret edebilir. *amplitudeEnvelopeMin*, genlik zarfındaki en düşük değeri temsil eder
- **Standart Sapma:** *amplitudeEnvelopeStd*, genlik zarfındaki değerlerin ortalamadan ne kadar farklılaştığını gösterir. Standart sapma yüksekse yani sinyaldeki genlik salınımları normalden çok fazla değişiyorsa, bu bir anomaliyi işaret edebilir.
- **Otokorelasyon Katsayıları:** *autocorrCoeffAE2*, genlik zarfındaki 2. gecikme noktasındaki otokorelasyon katsayısını, *autocorrCoeffAE3* ise 3. gecikme noktasındaki otokorelasyon katsayısını verir. Bu özellikler, sinyaldeki düzenliliği belirli bir zaman dilimleri için araştırır. Düşük otokorelasyon değerleri, sinyalin birbirini takip eden zaman dilimlerinde belirgin farklılıklar

gösterdiğini işaret edebilir. Bu anomali işareti olabilir, çünkü normalde, belirli bir zaman dilimindeki sinyalin sonraki dilimle benzer yapıları olması beklenir.


3.3.9. RMS enerji

RMS Enerji (Root Mean Square Energy), bir ses sinyalinin enerjisinin ölçülmesinde yaygın olarak kullanılan bir diğer zaman alanı özelliğidir. RMS enerjisi, sinyalin genel güç seviyesini temsil eder ve genellikle sesin şiddetini veya yoğunluğunu değerlendirmeyi sağlar. Bir çerçevedeki tüm örnekleri temel alır. Ses yüksekliğinin bir göstergesi olarak işlev görür, çünkü enerji ne kadar yüksekse ses o kadar yüksek/gürültülü olur. Bununla birlikte, Genlik zarfına kıyasla aykırı değerlere daha az duyarlıdır. Bu özellik, ses segmentasyonu ve müzik türü sınıflandırma görevlerinde faydalı olmuştur [55].

RMS enerjisi, ses sinyalinin her bir örneğinin karesinin ortalamasının karekökü alınarak hesaplanır. Sinyal öncelikle belirli bir çerçevelere bölünür ve her çerçeve için RMS değeri hesaplanır. Şu şekilde tanımlanır [58]:

$$E_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.8)$$

Burada: x_i çerçeve içindeki her bir örnek, N ise çerçeve içindeki toplam örnek sayısıdır. Aşağıda, normal ve anormal sinyallerin RMS enerji değerleri görülmektedir.



Şekil 3.8. RMS enerji.

RMS enerjiden elde edilen ve veri setine dahil edilen çeşitli istatistiksel metrikler aşağıda verilmiştir:

- **Toplam:** *rmsTotal*, bir sinyaldeki tüm RMS enerji değerlerinin toplamıdır. Bu değerin normalden yüksek olması güçlü ses olaylarına, ani patlamalara veya bozulmalara işaret edebilir.
- **Standart Sapma:** *rmsStd*, bir sinyalin genlik değerlerinin ne kadar değişken olduğunu gösterir. Eğer bir sinyaldeki RMS değerleri yüksek bir standart sapmaya sahipse, bu sinyalin enerjisindeki ani değişimleri gösterir ve potansiyel olarak anormal bir durumun belirtisi olabilir.
- **Entropi:** RMS enerji değerlerinin Shannon Entropisi hesaplanarak *rmsEntropy* özelliği elde edilir. Yüksek entropi, karmaşık, düzensiz veya anormal ses desenlerini işaret edebilir. Düşük bir entropi ise sesin düzenli ve öngörülebilir olduğunu gösterir.

3.3.10. Renk (chroma) özellikleri

Chroma özellikleri, müzikal bir ses sinyalinin ton içeriğini temsil etmek için yoğunlaştırılmış bir biçimde çıkarılan özelliklerdir. Chroma spektrumu, bir sesin 12 belirgin yarı tonunu (perde sınıfını) yani bir oktavdaki 12 perdenin enerji içeriğini analiz eder ve bu sayede sesin harmonik yapısını ve tonal içeriğini anlamayı sağlar.

Chroma özellikleri, genellikle Short-Time Fourier Transform (STFT) veya Constant-Q Transform (CQT) gibi dönüşümlerle çıkarılır. Bu çalışmada, STFT üzerinden dönüşümle chroma özellikleri çıkaran Librosa kütüphanesinin *chroma_stft* fonksiyonu kullanılmıştır [59].

Bir chroma vektörü, sinyaldeki her bir perde sınıfının (pitch class) enerjisini temsil eden 12 elemanlı bir vektördür. Bu sınıflar, {C, C#, D, D#, E, F, F#, G, G#, A, A#, B} şeklinde tanımlanır. Kromatik filtre bankası, bu 12 frekansı temsil eden 12 “Bandpass Filtresi” içerir. Filtreler, genellikle “Gauss Penceresi” şeklinde tasarlanır ve her biri belirli bir frekans aralığını kapsar. Her bir filtre ile STFT sonucu elde edilen güç spektrumunun çarpılmasıyla, her bir çerçeve için kromatik enerjiler hesaplanır. Her bir chroma ögesi için güç spektrumundaki frekansların birleştirilmesi, o perde sınıfının frekans aralığında ne kadar enerji bulunduğunu gösterir [60].

Tablo 3.2’de 12 perde sınıfı ve bu sınıfların ton karşılığı verilmiştir.


Tablo 3.2. Perde sınıfları ve ton karşılıkları.

Perde Sınıfı	1	2	3	4	5	6	7	8	9	10	11	12
Ton	C	C#	D	D#	E	F	F#	G	G#	A	A#	B

Bir sesin mutlak frekansı (yani orijinal oktav) olmadan sadece chroma dağılımını bilmek, ses hakkında önemli müziksel bilgiler sağlayabilir. Ayrıca, orijinal spektrumlarda görünmeyen, ancak algısal olarak belirgin olan müziksel benzerlikleri ortaya çıkarabilir. Bu özellikler, özellikle akor tanıma, ses kaydı doğrulama, müzik türü sınıflandırması ve harmonik benzerlik tahmini gibi üst düzey müzik analizi görevleri için oldukça kullanışlıdır [61].

Kromatik özelliklerin anormal yoğunlukları ile özellikle ses sinyallerinde ki beklenmedik ton değişiklikleri, notasal hatalar, gürültü veya bozulmalar tespit edilebilir. Makinelerde aşırı yüklenme, stres veya aşırı ısınma gibi durumlar, sesin harmonik yapısını bozabilir. Bir fanın veya pompanın düzgün çalışırken ürettiği ses, özellikle düşük frekanslarda (örneğin, 50-100 Hz aralığında) belirli bir dalgasal desene sahipken, bir arıza olduğunda bu yapı bozulur. Chroma özellikleri, bu tür tonal değişiklikleri tanımak için faydalı olabilir.

Aşağıdaki görselde örnek normal ve anormal ses sinyalleri için hesaplanan kromogramlar görülmektedir. Normal sinyal kromogramında frekans bileşenlerinin enerjileri görece homojen bir yapıya sahipken, anormal sinyal kromogramında belirli perde sınıflarında artan enerji yoğunlukları (daha koyu tonlar) gözlemlenmektedir.

**Şekil 3.9.** Normal ve anormal ses sinyallerinin kromogramları.

Kromogramdan çıkarılan özellikler şu şekildedir:

- **Ortalama** (*chromaPitch[0-11]*): Bu özellikler, her bir tonal perde sınıfı için zaman içinde ölçülen ortalama enerji seviyesini temsil eder. Bu değerler, hangi perdenin seste baskın olduğunu gösterir.
- **Minimum** (*chromaPitch[0-11]Min*): Bu özellikler 12 perde sınıfı için ayrı ayrı hesaplanmıştır. Her bir perde sınıfı için zaman içindeki en düşük enerji seviyesini gösterir.
- **Maksimum** (*chromaPitch[0-11]Max*): Her bir perde sınıfı için zaman içindeki en yüksek enerji seviyesi. Bu özellikler, her bir perde sınıfının dinamik aralığını, yani hangi zaman dilimlerinde güçlü bir şekilde çaldığını ve hangi zaman dilimlerinde daha sessiz olduğunu belirtir.
- **Standart Sapma** (*chromaStd*): Bu özellik, tüm perde sınıflarının enerji yoğunluklarının değişkenliğini gösterir. Yüksek bir standart sapma, enerji seviyelerinin büyük ölçüde değişken olduğu anlamına gelirken, düşük bir değer, perdelerin daha sabit bir enerji seviyesine sahip olduğunu gösterir.
- **Toplam** (*chromaSum*): Tüm perde sınıflarının toplam enerji yoğunluğunu temsil eder.


3.3.11. CQT dönüşümü

CQT (Constant-Q Transform) dönüşümü, müzik ve ses analizi için özel olarak geliştirilmiş bir zaman-frekans dönüşümüdür. CQT, geleneksel Fourier dönüşümünden farklı olarak, frekans çözünürlüğünü sesin frekans aralığına göre dinamik bir şekilde ayarlar. Bu işlemi, logaritmik olarak ölçeklenmiş frekans bantları sunarak yapmaktadır. Bu, özellikle geniş frekans aralığına sahip müzik sinyalleri gibi verilere uygundur.

CQT, frekansları logaritmik olarak ölçeklendirir ve geometrik olarak düzenler, yani düşük frekanslar daha geniş, yüksek frekanslar ise daha dar bantlarla analiz edilir. Bu sayede düşük frekanslarda yüksek çözünürlük, yüksek frekanslarda ise daha düşük çözünürlük sağlanır. Her bir frekans bandının genişliği, Q-faktörü adı verilen bir kavramla belirlenir ve bu, her bandın ne kadar geniş olduğunu gösterir [62].

Bu özellikler, insan kulağının doğal frekans algısına uygun analizler yapar ve müzikal yapıları daha doğru bir şekilde temsil eder. Özellikle ritim, tonlama ve müzikal frekansların analizinde büyük avantaj sağlar.

Aşağıdaki görselde, örnek normal ve anormal ses sinyalleri için hesaplanan CQT spektrogramları yer almaktadır.



Şekil 3.10. CQT dönüşümü spektrogramları.

CQT uygulanan sinyalden elde edilen *cqtSum* (toplam enerji), *cqtStd* (standart sapma), *cqtMax* (maksimum genlik) ve *cqtMin* (minimum genlik) gibi özellikler, sinyalin frekans bileşenlerinin genel dağılımı ve varyasyonlarına dair özet bilgi sağlamak amacıyla veri setine dahil edilmiştir.

3.3.12. Hilbert dönüşümü

Hilbert Dönüşümü (Hilbert Transform), zaman alanındaki sinyaller üzerinde doğrudan spektrum analizi yapabilen etkili bir yöntemdir. Matematiksel sinyal işleme ve mühendislikte yaygın olarak kullanılan bir dönüşüm tekniğidir. Fourier veya dalgacık dönüşümlerinin aksine, sinyalleri uzay veya frekans alanına dönüştürme gerektirmez. Bu dönüşüm, özellikle analitik sinyallerin ve frekans bileşenlerinin çıkarılması, faza dayalı özelliklerin analiz edilmesi ve modülasyon gibi işlemler için çok önemli bir araçtır.

Hilbert dönüşümü, bir zaman alanı sinyali üzerinde uygulandığında, analitik bir sinyal elde edilir. Analitik sinyali elde etmek için Hilbert dönüşümü, orijinal sinyale (gerçek bileşen) bir hayali bileşen ekler. Bu hayali bileşen, orijinal sinyalin Hilbert dönüşümü ile elde edilir. SciPy'nin *hilbert* fonksiyonuna bir sinyal $y(t)$ verildiğinde, şu şekilde analitik bir sinyal oluşturur [63]:

$$y_{\text{analitik}}(t) = y(t) + j \cdot H(y(t)) \quad (3.9)$$


Burada $y(t)$, zaman alanındaki orijinal sinyaldir ve $H(y(t))$ sinyalinin Hilbert dönüşümüdür. Elde edilen analitik sinyalin genliği, gerçekte ve hayali bileşenlerin karelerinin toplamının karekökü olarak hesaplanır:

$$Genlik(t) = \sqrt{y(t)^2 + H(y(t))^2} \quad (3.10)$$

Ses sinyalleri ile endüstriyel arıza teşhisi yapan bir çalışmada [34], sinyaller 2D Hilbert temsiline dönüştürülüp bir CNN modeliyle sınıflandırıldığında oldukça başarılı sonuçlar verdiği görülmüştür. Bu başarı, Hilbert dönüşümünün etkinliğini kanıtladığı için, bu çalışmada da kullanılmasına karar verilmiştir. Ancak, bizim çalışmamızda 2D görüntü temsili yerine, önceki sinyal özelliklerinde olduğu gibi istatistiksel metrikler çıkarılarak kullanılmıştır. Bu metrikler çıkarılırken, bahsettiğimiz analitik sinyalin Anlık Genlik (Instantaneous Amplitude) özelliğinin yanı sıra, Anlık Faz (Instantaneous Phase) ve Anlık Frekans (Instantaneous Frequency) özelliklerinden de metrikler çıkarılmıştır:


- Anlık genlik, analitik sinyalin genlik bilgisini verir. Bu bilginin ortalama (*instantaneousAmplitudeMean*), standart sapma (*instantaneousAmplitudeStd*) ve maksimum (*instantaneousAmplitudeMax*) değerleri alınıp özellik olarak veri setine dahil edilmiştir.
- Anlık faz, analitik sinyalin faz açısını temsil eder ve sinyaldeki faz kaymalarını ve salınım modelini incelememize olanak tanır. Ayrıca fazdaki beklenmedik değişiklikler, arıza durumlarının tespiti için önemli bir ipucu olabilir. Fazın sarma işlemi, anlık fazın kesintisiz bir şekilde takip edilmesini sağlar ve böylece büyük faz değişiklikleri daha net gözlemlenebilir. Bu özellik veri setimizde standart sapması (*instantaneousPhaseChangeStd*) ve entropisi (*instantaneousPhaseEntropy*) alınarak dahil edilmiştir.
- Anlık frekans, sinyalin faz değişim hızını vermektedir. Sinyalin temel salınım frekansını izler ve belirli bir anda sinyalin nasıl bir frekansta değiştiğini gösterir. Bu özelliğin ortalaması (*instantaneousFrequencyMean*) ve standart sapması (*instantaneousFrequencyStd*) alınarak oluşturulan özellikler veri setine eklenmiştir.

Aşağıdaki grafiklerde, normal ve anormal ses sinyali örneklerinin Hilbert dönüşümü sonrası hesaplanan anlık genlik ve anlık faz ilerleyişleri gösterilmektedir.



Şekil 3.11. Anlık genlik ve anlık faz ilerleyişleri.

Her ne kadar çalışmamızda bu yaklaşım kullanılmamış olsa da, bahsedilen çalışmada [34] kullanılan 2D Hilbert temsili görselleri, örnek sinyallerimiz için oluşturulduğunda, aşağıdaki grafikteki sonuçlar elde edilmiştir.



Şekil 3.12. Hilbert anlık genlik haritası.

3.3.13. Sıfır geçiş oranı

Sıfır Geçiş Oranı (Zero Crossing Rate, ZCR), bir sinyalin işaretinin pozitiften negatife veya negatiften pozitifte değişme oranıdır. Zaman alanı özelliklerinden biri olan bu özellik, belirli bir zaman dilimi içerisindeki sinyalin sıfır hattını kaç kez geçtiğini gösterir.

$$ZCR = \frac{1}{N} \sum_{n=1}^{N-1} 1(y[n] \cdot y[n-1] < 0) \quad (3.11)$$

Burada:

- $y[n]$, n-inci örnek değeri, yani ses sinyalinin o andaki değeri. $y[n-1]$ ise bir önceki ses sinyali değeridir.

- **1**, bir gösterge fonksiyonudur. Eğer içindeki koşul doğruysa 1, yanlışsa 0 döndürür. Burada koşul, ardışık iki örneğin çarpımının negatif (zıt işaretli) olması gerektiğini ifade eder, sıfır geçişi anlamına gelir.
- N çerçeve uzunluğu, yani bir çerçevedeki örnek sayısıdır.

3.3.14. Basıklık ve çarpıklık

Sinyal analizinde kullanılan istatistiksel metriklerden basıklık (kurtosis) ve çarpıklık (skewness), sinyalin genlik dağılımını anlamak ve olası anomalileri tespit etmek için önemli özelliklerdir.

Önerilen yöntemde, zaman alanındaki genlik değerlerinden çıkarılan bu özelliklerden *signalKurtosis*, sinyalin uç değerlerinin yoğunluğunu ölçer ve sinyalin "keskin" ya da "yassı" bir yapıya sahip olup olmadığını gösterir. Yüksek basıklık değerleri, sinyalde ani ve keskin değişimlerin varlığını işaret ederken, düşük basıklık daha düzenli ve düz bir sinyali ifade eder. *signalSkew* özelliği de genliklerinin simetrik olup olmadığının değerlendirilmesini sağlamaktadır.

3.3.15. Bant enerji oranı

Bant Enerji Oranı (Band Energy Ratio, BER), bir ses sinyalinin farklı frekans bantları arasındaki enerji oranını ifade eden bir özelliktir. Ses sinyalleri genellikle farklı frekans aralıklarına bölünür ve her bir banttaki enerji, sinyalin toplam enerjisine göre hesaplanır. Sinyalin belirli bir zaman diliminde ki düşük frekanslı enerjilerinin yüksek frekanslı enerjilerine oranını verir [58].


$$BER(t) = \frac{\sum_{f_1}^{f_2} |X(t, f)|^2}{\sum_{f_3}^{f_4} |X(t, f)|^2} \quad (3.12)$$

Burada:

- $X(t, f)$: t anındaki spektrumda, f frekansındaki genlik.
- f_1 ve f_2 : düşük frekans bandının başlangıç ve bitiş frekansları.
- f_3 ve f_4 : yüksek frekans bandının başlangıç ve bitiş frekansları.

BER, özellikle ses analizi, müzik sınıflandırması, melodi ve konuşma tanıma gibi uygulamalarda önemli bir özellik olarak karşımıza çıkar. Sinyaldeki düşük frekansların ne kadar baskın olduğunu gösteren bu özellik, ayrıca harmonik ve düzgün olmayan yapıları tanımlamak için de kullanılabilir [55].

Örnek olarak incelenen normal ve anormal ses sinyallerinin bant enerji oranlarının ilerleyişi Şekil 3.13'te görülmektedir.



Şekil 3.13. Bant enerji oranı.

BER değerlerinin ortalaması, standart sapması ve kurtosis değeri, veri setine özellik olarak eklenmiştir.

3.3.16. Desibel özellikleri

İnsan kulağı, sesin genliğini duyuşal olarak sesin yükseklięi olarak algılar. Yüksek genlikli sesler daha şiddetli, düşük genlikli sesler ise daha sessiz duyulur. Ancak, insan kulağı, mikrofonun ölçtüęü gibi genlikteki deęişimleri doğrudan orantılı olarak algılamaz. Yani, genlikteki deęişim, kulağımızda aynı derecede algılanmamaktadır. Örneğın, bir sesin genlięi iki katına çıktığında, kulağımız bunu daha büyük bir fark olarak algılamaz; bunun yerine, genlikteki artış kulağımızda belirli bir logaritmik fark yaratır. Bu özellik, sesin şiddetinin insanın algılama kapasitesine göre ölçeklendirildięi desibel (dB) ölçümünü gerekli kılar [64].

0 dB ile 100 dB arasındaki fark, ses enerjisinde 10 milyar katlık bir farkı ifade eder. Bu dinamik aralık, logaritmik bir ölçekle ifade edilmedięi takdirde, fısıltıların ve hışırdayan yaprakların arasındaki farkı bile algılamak neredeyse imkansız hale gelir. Desibel, insan duyusunun logaritmik algılama biçimine uygun olarak ses seviyelerini daha anlamlı hale getirir. Bu nedenle genlięin desibel gibi logaritmik bir ölçüyle ifade edilmesi, sesin düşük ile yüksek seviyeleri arasındaki farkları insanlar için daha anlamlı bir şekilde sunar [65].


Ses sinyaline öncelikle STFT uygulanarak sinyalin frekans bileşenleri çıkarılmıştır. Ardından, bu frekans bileşenlerinin genlikleri desibel cinsine dönüştürülmüştür. Desibel değerlerinin ortalama, maksimum ve minimum değerleri özellik olarak nihai veri setine dahil edilmiştir. Bu özellikler, sinyalin en düşük, en yüksek ve ortalama ses seviyelerini ifade eder. Anomali tespiti açısından önemli olabilirler, çünkü anormal sinyaller genellikle beklenmedik yüksek veya düşük ses seviyeleriyle kendini gösterir.

3.3.17. Büyüklükler

Büyüklükler (Magnitudes), ses sinyalinin frekans bileşenlerinin gücünü temsil eden değerlerdir. Bu çalışmada, büyüklükler *librosa.piptrack* fonksiyonu ile çıkarılmıştır. Bu fonksiyon, her bir zaman dilimindeki frekans bileşenlerinin büyüklüklerini ve bu bileşenlere karşılık gelen frekansları (pitches) hesaplar, böylece sesin zaman içindeki frekans bileşenlerinin dinamiklerini analiz etmeye olanak tanır.

Genlik (Amplitude) ve Büyüklük (Magnitude) terimleri sıklıkla karıştırılsa da, aralarındaki fark oldukça basittir. Bir dalganın genliği, dalganın denge noktasıyla arasındaki pozitif veya negatif mesafeyi ifade ederken; büyüklük, genliğin mutlak değeridir. Ses sinyalini örneklediğimizde, elde ettiğimiz ham veriler, ses dalgasının zaman içindeki genlik değişimlerini yansıtan örneklerdir [65].

Aşağıdaki görselde, normal ve anormal ses sinyallerinin frekans spektrumlarında büyüklük değerleri gösterilmektedir. Normal sinyal spektrogramında, tüm frekans bandı boyunca düşük büyüklük değerleri gözlenmektedir. Bu durum, sinyalde dikkate değer bir aktivitenin olmadığını ve normal bir ses yapısını yansıttığını göstermektedir. Anormal sinyal spektrogramında ise özellikle düşük frekans bölgelerinde daha açık renklerde (yeşil ve sarı) belirgin büyüklük artışları görülmektedir. Bu, söz konusu frekans aralığında anormal bir aktiviteye veya sıra dışı bir desene işaret etmektedir.



Şekil 3.14. Frekans spektrumlarında büyüklük değerleri.

Büyükölükler çıkarıldıktan sonra, bu büyükölükler üzerinde özet istatistikler (toplam, ortalama, maksimum ve standart sapma) hesaplanarak nihai veri setine dahil edilmiştir. Bu metrikler, sinyalin frekans bileşenlerinin genel gücü hakkında bilgi verir. *magnitudesStd*, büyükölüklerin dağılımını ölçer ve değışkenlik derecelerini gösterir. Bu bilgiler, makine öğrenmesi modellerinin sinyaldeki düzensizlikleri veya anormallikleri tespit etmesine yardımcı olabilir.

3.4. Kullanılan Algoritmalar


Makine öğrenmesi algoritmaları, gözetimsiz öğrenme ve gözetimli öğrenme olarak iki ana kategoriye ayrılmaktadır. Bu çalışmada, ses sinyallerindeki anormallikleri tespit etmek amacıyla hem gözetimli hem de gözetimsiz öğrenme algoritmaları kullanılmaktadır.

3.4.1. Gözetimli öğrenme yöntemleri

Gözetimli öğrenme, etiketli verilerle modelin eğitildiğı ve çıkarsama yapıldığı bir makine öğrenme yaklaşımıdır. Bu yöntem, etiketli verilerin mevcut olduğu durumlarda yüksek doğrulukla sonuçlar elde edilmesini sağlar. Bu çalışmada, ses sinyallerindeki anormallikleri tespit etme performanslarını karşılaştırmak için dört farklı gözetimli öğrenme algoritması kullanılmaktadır.

3.4.1.1. Rastgele orman

Breiman tarafından önerilen rastgele orman sınıflandırıcısı [66], makine öğrenimi alanında sıklıkla kullanılan bir topluluk sınıflandırma tekniğidir ve birden fazla karar ağacı sınıflandırıcısından oluşur. Şekil 3.15'te gösterildiğı üzere, bu yöntem, farklı veri kümesi alt örnekleri üzerinde paralel olarak birden fazla karar ağacı sınıflandırıcısını eğiten ve sonuçları çoğunluk oyu veya ortalama yöntemiyle birleştiren bir paralel topluluklama (parallel ensembling) yaklaşımı benimser. Bu sayede, aşırı uyum (overfitting) sorunu en aza indirilirken, modelin tahmin doğruluğı ve genelleme yeteneğı artırılır. Bu nedenle, birden fazla karar ağacından oluşan bir Rastgele Orman (RF) modeli, genellikle tek bir karar ağacı tabanlı modelden daha yüksek doğruluk sağlamaktadır. Hem sınıflandırma hem de regresyon sorunlarına uyarlanabilen bu model, aynı zamanda özellik seçimi ve değışken önem sıralaması gibi görevlerde de etkilidir [67].



Şekil 3.15. Rastgele orman yapısı örneği [67].

3.4.1.2. XGBoost

XGBoost, Chen ve Guestrin (2016) tarafından geliştirilmiş, yüksek performanslı ve esnek bir gradient boosting algoritmasıdır. Bu algoritma, hem sınıflandırma hem de regresyon problemleri için kullanılmaktadır. Hızlı ve esnek yapısı sayesinde, büyük veri setleri ve karmaşık problemler için özellikle uygundur.

Algoritma, karar ağaçlarını ardışık olarak inşa eder; her bir ağaç, önceki ağaçların hatalarını düzeltmeye odaklanarak genel model doğruluğunu artırır. XGBoost, aşırı öğrenmeyi (overfitting) engellemek için düzenleme (regularization) tekniklerini içeren bir yapıya sahiptir, bu da onu geleneksel gradyan boosting yöntemlerine kıyasla daha genelleştirilebilir hale getirir [68].

3.4.1.3. Açıklanabilir güçlendirme makinesi


Açıklanabilir Güçlendirme Makinesi (Explainable Boosting Machine - EBM), Nori ve arkadaşları tarafından açıklanabilirlik odaklı geliştirilmiş, gradient boosting algoritmasının bir varyasyonudur. Geleneksel kara kutu boosting modellerinin aksine, EBM bir cam kutu (glass-box) modeli olarak çalışır ve model tahminlerini etkileyen faktörlerin anlaşılmasında şeffaflık ve netlik sağlar. Model, düşük öğrenme hızlarıyla iteratif olarak inşa edilir ve bu süreçte özellik etkileşimlerinin otomatik olarak tespit edilmesini ve doğru bir şekilde temsil edilmesini garanti eder [69].

Bu tezde, EBM algoritması hem ses sinyallerindeki anomalilerin tespiti hem de bu anomalilerin ardındaki önemli özelliklerin açıklanması için kullanılmıştır.

3.4.1.4. Derin sinir ağı

Derin Sinir Ağı (DNN), üç veya daha fazla gizli katmana sahip çok katmanlı algılayıcılar olarak modellenen ve manuel özellik çıkarımı yapmadan, veri kümelerindeki desenleri ve önemli bilgileri doğrudan öğrenebilen bir algoritma sınıfıdır. DNN'lerdeki öğrenme algoritması, derin öğrenmenin temelini oluşturur. Her bir katmanı, düşük seviyeli özelliklerden başlayarak, giderek daha karmaşık özellikleri tanıyacak şekilde özelleştirebilmek mümkündür. Bu yapı, ağın veriye dayalı olarak kendiliğinden öğrenmesini sağlar ve her katman, daha önceki katmanlardan gelen bilgileri daha yüksek bir soyutlama düzeyinde işleyerek anlamlı sonuçlara ulaşır [70].

Bu öğrenme süreci, geri yayılım (backpropagation) algoritması ile gerçekleştirilir. Geri yayılım, ağın çıktısındaki hatayı hesaplar ve bu hatayı her katmanda geriye doğru yayarak, ağırlıkların optimize edilmesini sağlar. Böylece ağ, öğrenme süreci boyunca daha doğru sonuçlar üretmek için ağırlıklarını günceller. Şekil 3.16'da, ikili sınıflandırma için kullanılan örnek bir derin sinir ağı mimarisi gösterilmektedir.



Şekil 3.16. İkili sınıflandırma için örnek derin sinir ağı mimarisi [71].

3.4.2. Gözetimsiz öğrenme yöntemleri


Gözetimsiz öğrenme, etiketli veriye ihtiyaç duymadan veriden desenler ve yapılar öğrenmeye dayanan bir makine öğrenme yaklaşımıdır. Bu yöntem, etiketli verilerin elde edilmesinin zor olduğu durumlarda önemli avantajlar sunar. Endüstriyel ortamda

etiketli veri seti elde etmek zor olduğu için gözetimli öğrenme yöntemlerinin yanı sıra, anomali tespiti için iki farklı gözetimsiz öğrenme yöntemi de kullanılmaktadır.

3.4.2.1. Autoencoder

Autoencoder (AE), giriş veri setindeki yapıları öğrenerek boyut azaltma ve orijinal veri setini yeniden oluşturma işlemleri için kullanılan bir sinir ağı mimarisidir. Öğrenme algoritması, geri yayılımın uygulanmasına dayanmaktadır [70].

Kodlayıcı-Kod Çözücü kavramlarından oluşan mimarisi, Şekil 3.17’de gösterilmektedir. Bu mimari, görevi yalnızca girdide verilen verilerin aynısını çıktıda yeniden üretmek olan Yapay Sinir Ağı'nın (YSA) özel bir tipolojisidir. Genellikle, yalnızca eğitim verilerine benzeyen girdilerin yaklaşık kopyalarını üretmelerine izin verecek şekilde kısıtlanırlar. Model, girdi verisini yeniden yapılandırırken, hangi özelliklerin kopyalanması gerektiğine öncelik vermek zorunda kaldığı için, bu süreçte verilerin yararlı özelliklerini öğrenme eğilimindedir [72].



Şekil 3.17. Autoencoder mimarisi [72].


AE, hedef değışkene ihtiyaç duymadığı için gözetimsiz öğrenme yöntemleri arasında sınıflandırılmaktadır. Anomali tespiti bağlamında bu mimarinin kullanılma mantığı, modelin yalnızca normal ses sinyalleri üzerinde eğitilmesi ve bu süreçte ortaya çıkan yeniden yapılandırma hatasının analiz edilmesidir. Eğitim sürecinde, model normal veri dağılımını öğrenerek bu verilere yakın örnekleri yeniden yapılandırma konusunda yüksek bir başarı elde eder. Ancak, eğitim sırasında norm dışı verilere maruz

kalmadığından, anormal veriyle karşılaştığında bu örnekleri doğru şekilde yeniden yapılandıramaz ve bu durum yeniden yapılandırma hatasının (MSE) belirgin şekilde artmasına yol açar [73]. Dolayısıyla, AE modelinin anomali tespiti probleminde etkin bir şekilde kullanılabilmesi için, eğitim veri setinin yalnızca normal örneklerden oluşması gereklidir. Bu nedenle, AE genellikle gözetimsiz öğrenme teknikleri arasında sayılmakla birlikte, anomali tespiti uygulamaları açısından yarı gözetimli (semi-supervised) teknikler arasında değerlendirilmektedir.

3.4.2.2. İzolasyon ormanı

İzolasyon Ormanı (IF) algoritması, gözetimsiz makine öğrenmesi yöntemlerinden biridir ve özellikle anomali tespiti için kullanılmaktadır. Bu algoritma, veriyi izole eden karar ağaçları oluşturarak, verinin ne kadar hızlı izole edilebileceğini değerlendirir ve bu sayede normal verilerden sapmalar gösteren, olağan dışı gözlemleri tespit eder.

Oluşturulan her karar ağacı, veri noktalarını daha küçük parçalara böler. Anormal noktalar, normal verilere kıyasla daha hızlı bir şekilde izole edilir, çünkü çoğu zaman normal verilere göre daha uzak konumda bulunurlar. Diğer yandan, normal veriler daha fazla adımda izole edilmektedir. Algoritma, bir örneği izole etmek için gereken bölünme sayısını anomali skorunun bir ölçüsü olarak kullanır [73]. Şekil 3.18’de görüldüğü üzere daha az sayıda bölme gerektiren örnekler anomali, daha fazla bölme yapılan örnekler normal olarak belirlenmektedir.



Şekil 3.18. Isolation forest mekanizması [73].

IF algoritmasında bulunan contamination parametresi bir veri setinde bulunan anomalilerin oranını ifade eder. Bu oran, algoritmanın hangi gözlemleri anomali olarak sınıflandıracakını yönlendirir. Örneğin, %10'luk bir contamination oranı, algoritmanın verilerin %10'unu anomali olarak etiketlemesini sağlar. Bu oran doğru seçildiğinde, modelin doğruluğu artarken; yanlış belirlendiğinde, modelin gereksiz yere fazla normal veri ya da anomali etiketlemesine neden olmaktadır. Bu çalışmada, veri setlerindeki anomali sayısını bildiğimiz için, bu parametre anomali oranına göre optimize edilmektedir. Anomali oranının bilinmediği çalışmalarda, bu parametrenin deneysel olarak belirlenmesi gerekmektedir.

3.5. Deneysel Sonuçların Analizi İçin Kullanılan Performans Ölçütleri

Bu çalışmada, deneysel sonuçların analizi için, modellerin performansını kapsamlı bir şekilde değerlendirebilmek amacıyla çeşitli sınıflandırma ölçütleri kullanılmaktadır. Kullanılan performans ölçütleri şunlardır:

- **Doğruluk (Accuracy):** Modelin doğru tahminlerde bulunma oranını ifade eder. Yani, modelin yaptığı doğru tahminlerin, toplam tahminlere oranıdır.
- **Kesinlik (Precision):** Modelin tahmin ettiği anomalilerin ne kadarının gerçekten anomali olduğunu gösteren bir ölçüttür. Yüksek kesinlik, yanlış pozitiflerin (FP) düşük olduğunu gösterir.
- **Duyarlılık (Recall):** Gerçek anomalilerin ne kadarının model tarafından doğru şekilde tespit edildiğini yansıtan bir ölçüttür. Yüksek duyarlılık, yanlış negatiflerin (FN) düşük olduğunu ifade eder.
- **F1-Skor (F1-Score):** Kesinlik ve duyarlılık metriklerinin harmonik ortalamasını alarak tek bir performans metriği sağlar. Bu metrik, modelin her iki ölçütü de dengeli bir şekilde optimize etmesini gerektirir.
- **AUC (Area Under the Curve):** Modelin, anormal (1) ve normal (0) sınıflarını ayırt etme yeteneğini ölçen bir metrik olup, ROC eğrisinin altındaki alandır. Yüksek AUC değeri, modelin bu iki sınıfı ayırt etme yeteneğinin güçlü olduğunu gösterir.
- **MCC (Matthews Correlation Coefficient):** Genel doğruluğu ve güvenilirliği değerlendiren bir ölçüttür. Hem doğru pozitif (TP) hem de doğru negatif (TN) sonuçları dikkate alarak, dengesiz veri setlerinde bile modelin başarısını ölçer.

3.6. Açıklanabilir Yapay Zeka Modelleri İle Ses Özelliklerinin Analizi

Açıklanabilir Yapay Zeka (XAI), yapay zeka sistemlerinin ve makine öğrenimi modellerinin karar verme süreçlerinin, tahminlerinin ve sonuçlarının anlaşılabilirliğini artırmayı amaçlamaktadır. Günümüzde yaygın olarak kullanılan karmaşık makine öğrenimi modelleri, özellikle derin öğrenme ve ensemble yöntemleri, genellikle "kara kutu" olarak adlandırılmaktadır. Bu durum, modellerin iç işleyişinin ve karar alma mekanizmalarının kullanıcılar ve uzmanlar tarafından anlaşılmasını güçleştirmektedir. Kara kutunun içini aydınlatan XAI, kullanıcıların bir makine öğrenimi modeli tarafından oluşturulan sonuçları anlamalarını ve güvenmelerini sağlayan bir dizi süreç ve yöntemdir [69].

Ses sinyallerinden çıkardığımız özelliklerin, modelin başarılı tahminlerine katkı sağlama düzeyinin ve bazı özelliklerin model performansını olumsuz etkileyip etkilemediğinin belirlenmesi amaçlanmaktadır. Bu bağlamda, özelliklerin önem derecelerinin analiz edilmesi büyük bir öneme sahiptir. Bu bölümde, özellik analizi sürecinde kullanılacak XAI yöntemleri ele alınacaktır. Bu yöntemler, hangi özelliklerin daha etkili olduğunu belirlememize yardımcı olacaktır.

3.6.1. Kullanılan yöntemler

Bu çalışmada, aşağıdaki açıklanabilir yapay zeka yöntemleri kullanılacaktır:

3.6.1.1. RF

Yüksek doğruluk sağlaması nedeniyle anomali tespiti modeli olarak kullanacağımız Random Forest (RF), birçok karar ağacının birleşiminden oluşan bir ensemble öğrenme modelidir. Bu model, doğası gereği açıklanabilir bir yapıya sahiptir çünkü her bir karar ağacı, belirli özellikler üzerinde karar verirken kullanılan kuralları açıkça gösterir. Kullanıcılar, bu kuralları inceleyerek modelin neden belirli bir tahminde bulunduğunu anlayabilirler. Ayrıca, özelliklerin önem derecelerini belirleyip sıralanmasını sağlayarak, hangi faktörlerin tahmin üzerinde daha etkili olduğunu açık bir şekilde ortaya koyar. Bu sayede, anomali tespiti sürecinde önemli özelliklerin etkisini anlamak ve değerlendirmek mümkün hale gelmektedir.

3.6.1.2. IG

Integrated Gradients (IG), derin öğrenme modellerinin açıklanabilirliğini artırmak için kullanılan bir tekniktir. Bu yöntem, bir modelin çıkışının belirli bir özelliğe olan duyarlılığını ölçerek, her bir özelliğin tahmin üzerindeki katkısını hesaplar. Giriş

verisini bir temel deęerle (genellikle sıfır) karşılařtırarak, özellik deęerleri boyunca bir integral hesaplar. Bu integral, giriş özelliklerinin temel deęerinden tahmine kadar olan etkisini ölçer ve her bir özelliğin modelin kararına katkısını sayısal olarak ifade eder [74]. Özellikle karmaşık model yapılarında önemli bir açıklama aracı olarak deęerlendirilen IG, anomali tespitinde kullanacağımız DNN modelinin hangi özellikler tarafından nasıl etkilendiğini anlamamıza yardımcı olacaktır.

3.6.1.3. SHAP

Lundberg & Lee [10] tarafından geliştirilen SHAP, yerel tahminleri açıklamak için kullanılan bir yöntemdir. Adını işbirlikçi oyun teorisinden alan bu yöntem, özelliklerin model sonuçlarına olan katkısını ölçmek için oyun teorisinden esinlenmektedir. Burada Shapley deęerleri, katılımcılar arasında ödüllerin adil bir şekilde dağıtılmasını sağlamak amacıyla kullanılmaktadır. Makine öğrenimi alanında SHAP, her bir özelliğin model tahminlerine katkısını anlamanın sistematik bir yolunu sunar. Bu, her özellik için Shapley deęerlerini hesaplayarak ve tahminler üzerindeki etkilerini nicelendirerek gerçekleştirilir.

SHAP'ın en önemli gücü, hem yerel hem de küresel yorumlanabilirlik sunma yeteneğidir. Yerel düzeyde, belirli bir veri noktası için neden o tahminin yapıldığını, bireysel özelliklerin katkılarını inceleyerek açıklar. Küresel düzeyde ise, tüm veri seti boyunca özelliklerin önemine dair genel bir bakış sunar; böylece hangi özelliklerin model tahminlerini sürekli olarak yönlendirdiğini belirlemeye yardımcı olur. Ancak bununla birlikte, hesaplama yükü ve karmaşıklığı gibi potansiyel sınırlamaları da bulunmaktadır [76].

3.6.1.4. LIME

Kara kutu makine öğrenimi modellerinin yerel tahminlerini açıklamak için kullanılan LIME, belirli veri noktalarının etrafında bir modelin neden belirli bir tahmin yaptığını anlamak için önemli bir araçtır. LIME, açıklama amacıyla seçilen veri noktasının özelliklerini deęiřtirerek benzer örneklerden oluşan bir veri kümesi üretir. Bu deęiřtirilmiş örnekler üzerinde orijinal modelden tahminler talep edilir ve bu veriye basit bir lineer model uydurularak özellik deęiřiklikleri ve karşılık gelen tahminler dikkate alınır. Ortaya çıkan lineer model, her bir özelliğin o belirli örnek için tahmine nasıl katkıda bulunduğunu ve etkili olduğunu açığa çıkarmaya yardımcı olur [77].

LIME'in en büyük avantajlarından biri, model bağımsız doğasıdır; yani, modelin iç mimarisine dair bilgiye ihtiyaç duymadan herhangi bir makine öğrenimi modeline uygulanabilir. Yerel ve örnek bazında açıklamalar sağlayarak, sağlık ve finans gibi çeşitli uygulamalarda bireysel tahminlerin arkasındaki mantığı anlamak için değerli bir araç haline gelir. Bu yöntem, karmaşık modellerin yerel olarak açıklanmasını sağlayarak, belirli bir tahminin arkasındaki özelliğin etkisini analiz eder. Sonuç olarak, her bir örnek için açıklamalar üreterek, modelin karar verme sürecini daha anlaşılır hale getirir [76].

3.6.1.5. EBM

EBM, otomatik etkileşim algılama özelliğine sahip ağaç tabanlı, dögüsel gradyan güçlendirmeli (gradient boosting), hem son teknoloji kara kutu modelleri kadar yüksek performans sunan hem de açıklanabilir olan bir cam kutu modeldir. Özelliklerin etkilerini net bir şekilde ortaya koyarak, kullanıcıların modelin çıktısını anlamasını kolaylaştırır [78].

EBM, bagging ve gradient boosting gibi modern makine öğrenme tekniklerini kullanarak her bir özellik fonksiyonu f_j 'yi öğrenir. Bu güçlendirme prosedürü, çok düşük bir öğrenme oranı kullanılarak, özellik sırasının önemli olmaması için, her seferinde yalnızca bir özellik üzerinde round-robin tarzında eğitim vermek üzere dikkatlice sınırlandırılmıştır. Eş doğrusallığın etkilerini azaltmak ve her bir özellik için en iyi özellik fonksiyonu f_j 'yi öğrenmek için özellikler arasında round-robin döngüleri gerçekleştirir ve her bir özelliğin modelin probleme ilişkin tahminine nasıl katkıda bulunduğunu gösterir.

EBM, özellikler arasındaki karmaşık etkileşimleri keşfetme yeteneğiyle de dikkat çeker. Geleneksel modellerde, kullanıcıların çiftler arası etkileşimleri önceden tanımlaması gerekirken, EBM bu süreci otomatikleştirir. İki özelliğin bir araya gelerek nasıl etkileşimde bulunduğunu keşfetmek için istatistiksel yöntemler kullanır. Örneğin, iki özellik arasında belirli bir eşik değeri aşıldığında modelin tahminleri değişebilir. EBM, bu tür etkileşimleri otomatik olarak tespit edip görselleştirerek daha doğru ve anlamlı tahminler yapabilmektedir [69].

3.6.1.6. LASSO

LASSO, hem özellik seçimi hem de regresyon analizi için kullanılan bir yöntemdir. Bu yöntem, modeldeki gereksiz özellikleri azaltarak açıklanabilirlik sağlar ve modelin

genel performansını artırır. Tahmin ediciler grubunda yüksek korelasyon varsa, LASSO bunlardan yalnızca birini seçer ve diğerlerini sıfıra indirir. Bazı katsayıları tam olarak sıfıra indirip tahminlerin değişkenliğini azaltarak daha basit ve kolayca yorumlanabilir modeller oluşturulmasına yardımcı olur [79].

LASSO, regresyon analizi sırasında kullanılan bir ceza terimi ekleyerek çalışır. Matematiksel olarak, LASSO, aşağıdaki optimizasyon problemine dayanır:

$$\min \frac{1}{2n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{j=1}^p |\beta_j| \quad (3.13)$$

Burada y_i hedef değişken, $\hat{y}_i$ tahmin edilen değer, n gözlem sayısı, p özellik sayısı ve λ ceza parametresidir. Ceza parametresi, modelin karmaşıklığını kontrol eder. λ değeri arttıkça, daha fazla özellik sıfıra çekilir ve modelin basitliği artar.

3.6.2. Analiz süreci

Ses sinyali özelliklerinin anomali tespiti amacıyla oluşturulan modeller üzerindeki etkileri, XAI yöntemleri kullanılarak analiz edilecektir. Anomali tespiti modellerinde farklı XAI yöntemleri (RF, IG, SHAP, LIME, EBM, LASSO) kullanıldığından, her bir yöntemin özellik önemini belirleme mantığı farklılık göstermektedir. Bu nedenle, her model için öne çıkan özellikler tamamen aynı olmayabilir. Ancak, ortak önemli özelliklerin tespiti, genel bir çıkarım yapabilmek açısından önem taşımaktadır.

Bu amaçla, her XAI yöntemi için en önemli olarak sıralanan ilk 25 özellik arasından, en az iki modelde önemli bulunan özellikler belirlenerek; bu özellikler arasındaki örtüşmeleri göstermek ve her bir özelliğe, kaç farklı modelde önemli bulunduğu göre bir skor atamak için tablolar oluşturulacaktır. Bu tablolar, her makine türü (pompa, valf, fan vb.) için ayrı ayrı hazırlanacak ve makineye özgü anomali ayırtmasında öne çıkan özelliklerin analizine olanak tanıyacaktır.

Her makine türüne özgü analiz yapılması, her bir makinenin ürettiği ses sinyallerinin doğasındaki farklılıklar nedeniyle gereklidir. Örneğin, fanlar daha motorumsu ve hışırtılı bir ses üretirken, pompalar su akışına benzer bir ses profiline sahiptir. Bu akustik farklılıklar, anomali tespitinde ayırt edici özelliklerin de makineye göre değişiklik göstermesine yol açar. Bu nedenle, her makine türü için öne çıkan

özelliklerin belirlenmesi, daha hassas ve doğru anomali tespiti sağlamak açısından önemlidir.

3.6.3. Özellik analizi sonuçlarının model optimizasyonuna etkisi

Modellerde önemli olarak tespit edilen özelliklerin anomali tespiti üzerindeki etkisini daha iyi anlamak amacıyla, görselleştirme tekniklerinden yararlanılacaktır. Bu görselleştirme, her bir özelliğin anomali tespiti modeline katkısını daha somut bir biçimde analiz etme olanağı sağlayacaktır.


Ayrıca, anomali tespit modellerinin performansını optimize etmek için, önemi düşük olarak belirlenen özelliklerin modelden çıkarılmasıyla (özellik azaltma) elde edilen sonuçlar incelenecektir. Bu özellik azaltma süreci, modelin yalnızca en belirleyici özellikleri kullanarak doğruluğunu koruyup koruyamadığını veya iyileştirip iyileştiremediğini değerlendirmek açısından önemlidir.

Bu analiz, model performansının yüksek tutulmasıyla birlikte, özelliklerin modeldeki gereksiz yükünü azaltma ve daha açıklanabilir bir model yapısı elde etme amacı taşımaktadır. Sonuç olarak, özellik azaltmanın model doğruluğu üzerindeki etkisi değerlendirilerek, seçilen önemli özelliklerin doğruluktaki payı ortaya konacaktır. Bu, XAI yöntemlerinin sunduğu açıklanabilirliğin, model performansının iyileştirilmesi açısından nasıl kullanılabileceğine dair bir bakış açısı sunacaktır.



4. UYGULAMA VE DENEYSEL SONUÇLAR

Bu bölümde, çalışmada kullanılan deney düzeni, modelleme süreci ve elde edilen sonuçlar detaylı bir şekilde sunulacaktır. Şekil 4.1, çalışmada kullanılan deneysel düzenek ile gözetimli ve gözetimsiz modelleme sürecinin adımlarını özetlemektedir.



Şekil 4.1. Deney düzeni akış şeması.

4.1. Deney 1: MIMII Veri Seti

MIMII veri setinde bulunan her makine tipi, 4 farklı makine kimliğinden (ID) oluşmaktadır. Bu çalışmada, her makine tipi ve kimliği için ayrı model oluşturulmuştur.

4.1.1. Pompa verileri

4.1.1.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme

Bu çalışmada, dört farklı gözetimli öğrenme modelinin (RF, XGBoost, EBM, DNN) performansı 10 katlı çapraz doğrulama (10-fold cross-validation) yöntemiyle kapsamlı bir şekilde değerlendirilmiştir. Bu yöntem, veri setini 10 alt küme olarak bölerek, sağlam ve genellenebilir performans ölçütleri sağlar. Model, her seferinde 9 alt küme üzerinde eğitilir ve geriye kalan bir alt küme üzerinde test edilir. Bu işlem, her alt küme bir kez test kümesi olarak kullanılarak 10 kez tekrarlanır. Tüm veriler hem eğitim hem de test verisi olarak kullanıldığı için modelin genellenebilirliğini test etmek ve aşırı öğrenme etkisini azaltmak için test aşamasında kullanılması gereken önemli bir tekniktir.

Tablo 4.1, her bir makine kimliği için dört algoritmanın performansını detaylı bir şekilde sunmaktadır. Tabloda görüldüğü gibi, gözetimli modeller çoğu durumda başarılı performans sergilemiştir. Tabloyu daha ayrıntılı bir şekilde incelediğimizde:

- DNN ve XGBoost, genel olarak anomalilerin tespitinde en yüksek performansı sergilemiştir. XGBoost ve EBM'in özellikle Precision metriği için en başarılı sonuçları verdiği, ancak DNN'in daha dengeli performanslar sergileyerek F1 skor ve Recall gibi önemli metriklerde öne çıktığı görülmektedir. Bu, DNN modelinin anomali durumlarını daha iyi yakaladığını, anomali olan seslerin gözden kaçırma oranının düşük olduğunu göstermektedir.
- XGBoost'un yüksek Precision değerleri, normal durumları yanlışlıkla anomali olarak sınıflandırma ihtimalinin az olduğunu göstermektedir. Bu durum, özellikle anomali yanlış alarmlarının maliyetinin yüksek olduğu veya direkt müdahale gerektirdiği sistemlerde önemli bir avantajdır.
- Pompa 04'te, DNN modeli tüm metriklerde %100 başarı göstermiştir. Ancak, Pompa 00'da performans metriklerinin diğer üç modelden daha düşük olduğu görülmektedir. Bu durum, DNN modelinin hiperparametrelerinde tutarlı sonuçlar için daha fazla ince ayar yapılması gerektiğine işaret etmektedir.

- Pompa 00’da RF ve XGBoost, Pompa 02 ve 06’da DNN, yüksek doğruluk ve F1 skor değerleri ile öne çıkmaktadır.


Tablo 4.1. Pompa sinyallerinde anomali sınıflandırması için performans ölçümleri.

ID	Metotlar	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)	AUC (%)	MCC (%)
00	RF	99.65	98.45	100.0	97.22	100.0	98.35
	XGBoost	99.65	98.58	100.0	97.20	99.97	98.40
	EBM	98.43	92.25	100.0	87.52	99.88	92.31
	DNN	98.37	93.01	98.17	88.64	98.81	92.34
02	RF	97.67	87.47	94.25	85.28	99.53	87.55
	XGBoost	99.01	94.88	98.08	91.89	99.91	94.40
	EBM	98.21	90.68	93.97	90.91	99.97	90.75
	DNN	99.40	97.04	96.78	97.64	99.85	96.81
04	RF	99.88	99.44	100.0	98.96	100.0	99.40
	XGBoost	99.88	99.50	99.01	100.0	100.0	99.43
	EBM	98.51	90.83	100.0	88.0	100.0	91.77
	DNN	100.0	100.0	100.0	100.0	100.0	100.0
06	RF	98.33	89.14	97.14	85.64	97.63	89.54
	XGBoost	99.21	99.22	99.23	99.24	99.25	95.07
	EBM	99.30	95.50	100.0	92.27	97.70	95.49
	DNN	99.30	95.55	98.89	93.21	99.32	95.46

4.1.1.2. XAI yöntemleri ile özellik analizi ve öznitelik seçimi

Şekil 4.2, pompa seslerinden elde edilen özelliklerin anomali tespiti üzerindeki etkilerini SHAP değerleri üzerinden göstermektedir. “Pompa 02” verileri için

izdirilen bu grafik, modelin hangi zelliklere odaklandığını ve bu zelliklerin yüksek ya da düşük deęerlerdeyken model kararını nasıl etkilediğini açıklamaktadır.



Şekil 4.2. SHAP deęerlerini ieren zet grafik.

Ses sinyalinin yüksek frekans bileşenlerinin zaman içinde ne kadar deęişkenlik gösterdiğini ölçen en önemli zellik *spectralRollofStd* deęeri arttıka, modelin anomali olma olasılıęının azaldığı grlmektedir. Benzer şekilde, *magnitudesStd* zellięi, byklk deęişkenliğini ifade eder ve grafikte ikinci en önemli zellik olarak ne çıkmaktadır. Yüksek deęerler (kırmızı) genlik dalgalanmalarındaki artışların model tarafından anomali gstergesi olarak deęerlendirildiğini iřaret etmektedir.

Bu şekilde, altı farklı XAI yntemi tarafından belirlenen en önemli 25 zellik analiz edilerek, en az iki modelde önemli olarak ne çıkan zelliklerin dahil edildięi bir tablo oluřturulmuřtur. Pompa seslerinde anomali sınıflandırması iin kullanılan modellerde ne çıkan zellikler Tablo 4.2’de sunulmaktadır.

Tablo 4.2. Pompa sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
spectralBandwithMax	✓	✓	✓	✓	✓	✓	6
spectralRollofMax	✓	✓	✓	✓	✓	✓	6
spectralBandwithMin	✓	✓	✓		✓	✓	5
chromaPitch0Max	✓	✓	✓	✓	✓		5
rmsTotal	✓	✓	✓	✓	✓		5
autocorrCoeffSB3	✓	✓	✓	✓	✓		5
magnitudesSum	✓	✓	✓	✓		✓	5
amplitudeEnvelopeMedian	✓	✓	✓	✓	✓		5
magnitudesStd	✓	✓	✓		✓		4
powerSpectralDensityMean	✓		✓	✓	✓		4
spectralBandwithMean	✓	✓		✓		✓	4
instantaneousAmplitudeMean	✓	✓	✓		✓		4
instantaneousAmplitudeStd	✓	✓		✓	✓		4
rmsStd	✓	✓	✓	✓			4
spectralRollofMin		✓	✓	✓		✓	4
spectralRollofMAD	✓		✓	✓		✓	4
chromaPitch1Max	✓	✓	✓	✓			4
chromaPitch11	✓	✓	✓		✓		4
chromaPitch6		✓	✓	✓	✓		4


Tablo 4.2. (Devamı) Pompa sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
chromaPitch5		✓	✓	✓	✓		4
chromaPitch9Max		✓		✓	✓		3
chromaPitch10		✓		✓	✓		3
cqtSum	✓			✓		✓	3
amplitudeEnvelopeSum	✓	✓			✓		3
bandEnergyRatioStd	✓		✓		✓		3
chromaSum		✓	✓			✓	3
spectralSpread		✓		✓		✓	3
amplitudeEnvelopeMin	✓	✓	✓				3
spectralRollofStd	✓		✓			✓	3
spectralCentroidsStd	✓		✓			✓	3
powerSpectralDensityStd	✓				✓		2
instantaneousFrequencyStd			✓			✓	2
spectralCentroidsMAD			✓			✓	2
spectralCentroidsMax				✓		✓	2
spectralRollofSkew			✓		✓		2
signalSkew				✓	✓		2
bandEnergyRatioMean	✓				✓		2

spectralBandwidthMax ve *spectralRolloffMax*, altı XAI yönteminin tamamında önemli olarak işaretlenmiştir. Frekans spektrumundaki genişlik ve sınırları tanımlamada önemli olan bu iki özellik, pompa seslerinin dar bantlı ve ritmik doğası nedeniyle pompa operasyonlarında normal ve anormal akustik desenleri ayırt etmek için özellikle etkili olmaktadır.

spectralBandwidthMin, *chromaPitch0Max*, *rmsTotal*, *autocorrCoeffSB3*, *amplitudeEnvelopeMedian* ve *magnitudesSum*, beş yöntem tarafından önemli bulunmuş ve sıklıkla vurgulanmıştır. Bu özellikler, anomalilerin perde, frekans, genlik boyutlarında tespit edilmesine katkı sağlamaktadır.

Şekil 4.3, "Pompa 00" verilerinde tespit edilen önemli özelliklerin normal ve anormal örnekler için dağılımlarını göstermektedir. Her iki grafikte de bazı örtüşmeler olmasına rağmen, bu özelliklerin normal ve anormal örnekleri ayırtırmada etkili olduğu gözlemlenmektedir.



Şekil 4.3. Pompa 00 verilerinde önemli özelliklerin normal ve anormal dağılımı.

4.1.1.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme

Bu çalışmada, gözetimsiz öğrenme algoritmaları ile anomali tespiti gerçekleştirilirken, özellik azaltımı yapılarak yalnızca önemli özelliklerin bulunduğu bir veri setiyle eğitim yapılmıştır. Bu yaklaşımın temel nedeni, gözetimsiz öğrenme modellerinin etiketli verilere sahip olmaması nedeniyle hangi özelliklerin ayırt edici olduğunu doğrudan belirleyememesi ve tüm özelliklerin dahil edilmesinin model performansını olumsuz etkileyebilme potansiyelidir. Özellikle ayırt edicilik düzeyi düşük olan veya veri setine gürültü ekleyen özellikler, modelin anomali tespitindeki doğruluk oranını ve hassasiyetini düşürebilmektedir.

Nitekim yapılan deneyler sonucunda, 110 özniteliğin tamamını içeren veri setiyle eğitilen gözetimsiz öğrenme modellerinin anomali tespit performansının, yalnızca ayırt ediciliği yüksek önemli özellikleri içeren bir veri setiyle eğitilen modellere kıyasla daha düşük olduğu görülmüştür. Bu deney, tüm özniteliklerin modele dahil edilmesinin, modelin ayırt edici desenleri öğrenme kabiliyetini azalttığını ortaya koymaktadır.

Özellik azaltımı sürecinde en düşük öneme sahip özelliklerin belirli yüzde oranlarıyla azaltılması stratejisi benimsenmiştir. Bu strateji, her bir pompa makinesi modeli için farklı özellik sayıları elde edilmesine neden olmuştur. Örneğin, “Pompa 06” için en düşük öneme sahip özelliklerin %45 oranında azaltılması sonucunda 61 özellik içeren model en iyi performansı göstermiştir. Benzer şekilde, “Pompa 04” için en düşük öneme sahip özelliklerin %60 oranında azaltılması ile 44 özellikli bir model elde edilmiş ve bu model en yüksek performansı sergilemiştir. “Pompa 02” için en düşük öneme sahip özelliklerin %65 oranında azaltılması ile 39 özellikli; “Pompa 00” için ise en düşük öneme sahip özelliklerin %70 oranında azaltılması ile 33 özellikli bir model geliştirilmiş ve bu model en yüksek performansı sağlamıştır.


Özellik azaltımı uygulanarak oluşturulan veri setiyle gerçekleştirilen model eğitimi, algoritmanın yalnızca kritik özniteliklere odaklanmasını sağlayarak, daha etkili desenler öğrenmesine olanak tanımıştır. Sonuç olarak, özellik azaltımı stratejisinin gözetimsiz öğrenme algoritmaları için önemli bir avantaj sunduğu ve anomali tespitinde daha yüksek doğruluk ve ayırt edicilik sağladığı görülmüştür. Bu bulgular, yüksek boyutlu veri setlerinde özellik seçiminin, hem model performansını artırmak hem de daha güvenilir sonuçlar elde etmek için önemli bir adım olduğunu göstermektedir.

İzolasyon ormanı ile anomali tespiti

Gözetimsiz anomali tespiti için kullanılan IF algoritması, 100 karar ağacı ($n_estimators=100$) ile yapılandırılmıştır. Veri setindeki anomalilerin oranı, modelin anomali tanımlama sınırlarını belirlemede önemli bir rol oynayan *contamination* parametresi ile belirtilmiştir.

Modelin performansını daha iyi anlamak ve tahminleri görselleştirmek için, veri setinde Ana Bileşen Analizi (PCA) uygulanarak boyut azaltımı gerçekleştirilmiştir.

Şekil 4.4'te, PCA uygulanarak boyutları indirgenmiş veri üzerinde IF modeli ile yapılan anomali tespiti sonuçları sunulmaktadır. Her bir pompa makinesi ID'si için elde edilen iki boyutlu veriler hem gerçek hem de tahmin edilen etiketlerle görselleştirilmiştir.



Şekil 4.4. Pompa seslerinde PCA ve IF ile anomali tespiti sonuçları.


Autoencoder ile anomali tespiti

Gözetimsiz anomali tespiti için test edilen bir diğer yöntem ise AE modelidir. Modele giriş için, veriler önce *MinMaxScaler* ile ölçeklendirilmiş ve eğitim veri seti için normal verilerin %80'i ayrılmıştır. Eğitimi sırasında *Adam* optimizasyon algoritması ve *mean_squared_error* kayıp fonksiyonu kullanılan model, *ReLU* aktivasyon fonksiyonları ve *Dropout* katmanları içeren bir yapıya sahiptir.

Anomali tespiti için, eğitim veri setinin örnekleri üzerinden hesaplanan yeniden yapılandırma hatalarının (MSE) %99.5 ile %99.9 arasında değişen (modele bağlı olarak değişkenlik göstermektedir) hata yüzdesine karşılık gelen bir eşik değeri (threshold) belirlenmiştir. Bu eşik değeri, modelin normal veriler ile anormal veriler arasındaki farkları doğru şekilde ayırt etmesini sağlamak amacıyla seçilmektedir.

Eğitim sırasında kullanılmayan normal sinyallerin %20'si ve anormal sinyallerin tamamı üzerinden modelin anomalileri doğru tespit etme performansı test edilmiştir. Anomali tespiti sonuçları, yüksek boyutlu verilerin yapısını koruyarak daha anlamlı iki boyutlu görselleştirmeler sağlamak için tercih edilen doğrusal olmayan boyut indirgeme yöntemi t-SNE, kullanılarak görselleştirilmiştir. Pompa makinelerinde AE

ile elde edilen anomali tespiti sonuçlarının gösterildiği t-SNE projeksiyonları, Şekil 4.5’te görülmektedir.



Şekil 4.5. Pompa seslerinde t-SNE ve AE ile anomali tespiti sonuçları.

Sonuçlar ve Değerlendirme

Tablo 4.3’te, IF ve AE modellerinin AUC değerleri karşılaştırılmaktadır. Bu metrik, modellerin doğru sınıflandırma yeteneklerini ölçmektedir.

Tablo 4.3. Pompa sinyallerinde IF ve AE modellerinin AUC değerleri.

Model	Pompa 00	Pompa 02	Pompa 04	Pompa 06	Ortalama
IF	99.72	96.86	99.91	99.42	98.98
AE	99.02	97.11	100.00	99.62	98.94

Ortalama doğrulukları göz önünde bulundurulduğunda, IF modeli %98.98 doğrulukla, AE modelinin %98.94 doğruluğuna kıyasla biraz daha iyi performans gösterdiği görülse de “Pompa 00” haricindeki diğer tüm pompa makineleri için AE modeli daha iyi daha iyi performans göstermektedir. Özellikle “Pompa 04” verisi için AE modelinin 100% AUC değeri ile mükemmel bir performans sergilemesi, modelin belirli durumlarda anomali tespitinde oldukça güçlü olduğunu ortaya koymaktadır.

Bununla birlikte, “Pompa 00” için IF modelinin daha iyi bir AUC değerine sahip olması, modellerin farklı veri setleri üzerinde farklı performanslar gösterebileceğini işaret etmektedir. IF modeli tamamen gözetimsiz olduğu için normal verilerin bile tam olarak bilinmediği durumlarda kullanılabilecek etkili bir model olduğunu göstermiştir.

4.1.2. Fan verileri

4.1.2.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme

Tablo 4.4, fan makinelerinin her bir makine kimliği için, 10 katlı çapraz doğrulama yöntemi kullanılarak test edilen dört farklı modelin performansını göstermektedir.

Tablo 4.4. Fan sinyallerinde anomali sınıflandırması için performans ölçümleri.

ID	Metotlar	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)	AUC (%)	MCC (%)
00	RF	98.45	97.22	98.39	96.32	99.98	96.28
	XGBoost	99.44	99.02	99.02	99.02	99.97	98.62
	EBM	99.01	98.22	99.29	97.30	100.0	97.61
	DNN	98.59	97.50	98.12	97.03	99.92	96.59
02	RF	99.86	99.72	99.73	99.72	100.0	99.63
	XGBoost	99.85	99.72	99.45	100.0	100.0	99.62
	EBM	99.93	99.86	99.73	100.0	100.0	99.82
	DNN	99.71	99.45	99.31	99.63	99.98	99.27
04	RF	99.93	99.85	100.0	99.71	100.0	99.81
	XGBoost	100.0	100.0	100.0	100.0	100.0	100.0
	EBM	100.0	100.0	100.0	100.0	100.0	100.0
	DNN	99.81	99.62	99.63	99.62	99.67	99.49
06	RF	98.84	98.25	97.10	100.0	100.0	97.73
	XGBoost	99.85	99.72	99.72	99.72	100.0	99.62
	EBM	99.35	98.86	98.18	99.73	100.0	98.50
	DNN	100.0	100.0	100.0	100.0	100.0	100.0

Tablo 4.4 verilerine göre boosting modellerinden olan XGBoost ve EBM genellikle diğer modellere daha üstün performans sergilemiştir. EBM, özellikle etkileyici doğruluk ve duyarlılık gösterdiği "Fan 02" ve "Fan 04"te güçlü bir performans göstermiştir. XGBoost modeli ise "Fan 00" için en başarılı sonuçları elde ederek %99.44 doğruluk ve %99.02 F1 skor ile öne çıkmıştır.

DNN modeli, bazı kimliklerde (örneğin ID 06) %100 doğruluk ve F1 skor ile en iyi performansı sergilese de, genel olarak diğer modellere göre biraz daha düşük sonuçlar elde edebilmiştir. RF modeli ise genel olarak diğer modellere göre daha düşük doğruluk değerlerine sahip olmasına rağmen, yine de yüksek AUC değerleri sağlayarak kabul edilebilir bir performans göstermiştir.

4.1.2.2. XAI yöntemleri ile özellik analizi ve önemlilik seçimi

Fan seslerinde anomali tespiti için kullanılan modellerde, önemliliklerin önem dereceleri farklı XAI yöntemleriyle analiz edilerek Tablo 4.5'te sunulmaktadır.

Tablo 4.5. Fan sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
spectralContrastMean	✓	✓	✓	✓	✓	✓	6
cqtSum	✓	✓	✓	✓	✓	✓	6
rmsTotal	✓	✓	✓	✓	✓		5
amplitudeEnvelopeMedian	✓	✓	✓	✓	✓		5
instantaneousAmplitudeStd	✓	✓	✓	✓	✓		5
chromaPitch6	✓	✓	✓	✓	✓		5
chromaPitch2	✓	✓	✓	✓	✓		5
powerSpectralDensityMin	✓	✓	✓	✓			4
powerSpectralDensityMean	✓	✓		✓	✓		4
powerSpectralDensityStd	✓	✓		✓	✓		4

Tablo 4.5. (Devamı) Fan sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
instantaneousAmplitudeMean	✓	✓		✓	✓		4
bandEnergyRatioMean		✓	✓	✓		✓	4
magnitudesSum	✓				✓	✓	3
magnitudesStd	✓	✓			✓		3
chromaPitch11Max			✓	✓	✓		3
chromaPitch9Max		✓		✓	✓		3
chromaPitch8	✓	✓	✓				3
chromaPitch1	✓			✓	✓		3
cqtStd		✓	✓	✓			3
amplitudeEnvelopeMin		✓	✓		✓		3
amplitudeEnvelopeSum	✓	✓			✓		3
powerSpectralDensityMax	✓	✓		✓			3
chromaStd	✓	✓	✓				3
chromaSum	✓			✓		✓	3
cqtMax		✓	✓			✓	3
autocorrCoeffAE2		✓	✓				2
spectralCentroidsStd	✓					✓	2
spectralCentroidsMAD				✓		✓	2
spectralCentroidsMin			✓			✓	2

Tablo 4.5. (Devamı) Fan sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
bandEnergyRatioStd			✓		✓		2
spectralFlatness		✓		✓			2
chromaPitch10Max		✓			✓		2
signalKurtosis			✓		✓		2
chromaPitch7	✓		✓				2

Fan arızaları genellikle aerodinamik düzensizliklerden kaynaklanır ve bu durum, diğer makinelere kıyasla daha karmaşık bir frekans yapısına yol açar. Sonuç olarak, farklı frekans bantlarındaki enerji dağılımını ölçen özellikler, anomali tespiti için özellikle kritik hale gelir. Bunlar arasında, tüm XAI yöntemleri tarafından en önemli özellik olarak vurgulanan, frekans grupları arasındaki enerji farklılıklarını yakalayan *spectralContrastMean*, özelliği öne çıkmaktadır. Yine tüm yöntemlerde öne çıkan, sabit-Q dönüşümünden türetilen *cqtSum* özelliği de fan seslerinde enerji dağılımını ölçerek akustik varyasyonlara duyarlılık sağladığı düşünülmektedir.

rmsTotal ve *amplitudeEnvelopeMedian* özellikleri de enerji tutarlılığı ve değişkenliğini ifade eden ve beş farklı yöntem tarafından önemli bulunan özelliklerdir. *InstantaneousAmplitudeStd* ise zaman içindeki genlik değişimlerini yakalayarak, düzensiz çalışma desenlerini belirlemeye yardımcı olmaktadır. Ayrıca, *bandEnergyRatioMean* özelliği, belirli frekans bantlarındaki enerji dağılımını vurgulayarak değerli bilgiler sunar. Bunların yanı sıra, *ChromaPitch6*, *ChromaPitch2*, *ChromaPitch1* ve *chromaPitch11Max* gibi kroma özellikleri, arızalı fan koşullarında belirginleşen harmonik içerik değişimlerini ifade etmektedir. XAI yöntemleri tarafından önemli olarak belirlenen bu özellikler, fanın çalışma durumu bozulduğunda, frekans spektrumunda oluşan anormal harmonik farklılıkları ortaya koymaktadır.

Şekil 4.6, “Fan 02” verileri üzerinde önemli özelliklerin normal (mavi) ve anormal (kırmızı) örnekler için dağılımlarını göstermektedir. Her iki grafikte de, özelliklerin normal ve anormal örnekler arasında belirgin bir şekilde ayrıştığı gözlemlenmiştir.

Özellikle ilk grafikte *instantaneousAmplitudeMean* özelliğinin, anormal verilerin normal verilerden açık bir şekilde ayrılmasını sağladığı görülmektedir. Sağdaki kroma özelliklerinin kullanıldığı grafikte, anormal veriler üst sınırda (1.0) yoğunlaşırken, normal veriler daha geniş bir dağılım sergilemiştir.




Şekil 4.6. Fan 02 verilerinde önemli özelliklerin normal ve anormal dağılımı.

4.1.2.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme

Pompa verilerinde olduğu gibi fan verilerinde de gözetimsiz öğrenme algoritmaları ile anomali tespiti gerçekleştirilirken, XAI yöntemleri tarafından belirlenen yalnızca önemli özelliklerin bulunduğu veri setleriyle eğitim gerçekleştirilmiştir. Bu yaklaşım, özellik sayısının azaltılmasıyla modellerin ayırt edicilik performansını arttırmaktadır.

İzolasyon ormanı ile anomali tespiti


IF modelinin performansını daha iyi anlamak üzere tahminleri görselleştirmek için PCA yöntemiyle oluşturulan grafikler, Şekil 4.7’de gösterilmektedir.



Şekil 4.7. Fan seslerinde PCA ve IF ile anomali tespiti sonuçları.

Autoencoder ile anormali tespiti

Fan seslerinde AE modeli ile gözetimsiz öğrenme tespiti, Bölüm 4.1.1.3'te açıklanan işlemler ve model doğrultusunda gerçekleştirilmiştir. Eğitim sırasında kullanılmayan normal sinyallerin %20'si ve anormal sinyallerin tamamı üzerinden modelin anormali tespit etme performansı test edilmiştir. Anormali tespiti sonuçları, yüksek boyutlu verilerin yapısını koruyan t-SNE yöntemiyle görselleştirilmiş olup, bu sonuçlar Şekil 4.8'de gösterilmektedir.



Şekil 4.8. Fan seslerinde t-SNE ve AE ile anormali tespiti sonuçları.

Sonuçlar ve Değerlendirme

Tablo 4.6'da, IF ve AE modellerinin AUC değerleri verilmektedir. Modellerin doğru sınıflandırma yeteneklerinin karşılaştırıldığı bu tabloda, ortalama AUC değerine bakıldığında, AE modelinin genel olarak daha yüksek başarı gösterdiği görülmektedir.

Tablo 4.6. Fan sinyallerinde IF ve AE modellerinin AUC değerleri.

Model	Fan 00	Fan 02	Fan 04	Fan 06	Ortalama
IF	97.52	99.51	96.39	98.56	98.00
AE	98.80	99.98	99.36	100.00	99.54

“Fan 06” verisinde AE modelinin %100 AUC değeri ile mükemmel bir performans sergilemesi dikkat çekmektedir. IF modeli, “Fan 02” verisinde %99.51 AUC değeri ile oldukça iyi bir sonuç elde etse de, genel olarak AE modelinin fan verileri gibi karmaşık ses yapıları içeren durumlarda daha iyi performans sergilediği sonucuna varılmaktadır.

4.1.3. Sürgülü ray verileri

4.1.3.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme

Tablo 4.7, sürgülü ray makinelerinin her bir kimliği için, 10 katlı çapraz doğrulama yöntemiyle test edilen modellerin performansını göstermektedir.

Tablo 4.7. S. ray sinyallerinde anomali sınıflandırması için performans ölçümleri.

ID	Metotlar	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)	AUC (%)	MCC (%)
00	RF	99.93	99.86	100.0	99.72	100.0	99.81
	XGBoost	100.0	100.0	100.0	100.0	100.0	100.0
	EBM	100.0	100.0	100.0	100.0	100.0	100.0
	DNN	100.0	100.0	100.0	100.0	100.0	100.0
02	RF	99.92	99.81	99.63	100.0	100.0	99.77
	XGBoost	99.78	99.44	99.62	99.25	99.99	99.30
	EBM	98.72	97.54	96.05	100.0	100.0	97.13
	DNN	99.90	99.76	99.52	100.0	100.0	99.70
04	RF	100.0	100.0	100.0	100.0	100.0	100.0
	XGBoost	99.72	99.44	100.0	98.88	100.0	99.25
	EBM	100.0	100.0	100.0	100.0	100.0	100.0
	DNN	100.0	100.0	100.0	100.0	100.0	100.0
06	RF	99.20	97.21	98.96	95.68	99.98	96.82
	XGBoost	99.36	97.70	100.0	95.51	99.97	97.36
	EBM	100.0	100.0	100.0	100.0	100.0	100.0
	DNN	99.78	99.09	100.0	98.33	100.0	99.02

RF, XGBoost, EBM ve DNN yöntemlerinin tümü genel olarak yüksek performans göstermiştir. Çoğu durumda doğruluk, F1 skoru, kesinlik değerleri %99 veya üzerinde, hatta bazı ID'ler için %100 seviyesindedir. Bu durum, önerilen yöntemin sürgülü ray sinyallerindeki anomalileri sınıflandırmada oldukça etkili olduğunu göstermektedir. “Sürgülü Ray 00” ve “Sürgülü Ray 04” için tüm modeller %100 kesinlik ve AUC değerleriyle mükemmel bir performans sergilemiştir. “Sürgülü Ray 02” için RF ve DNN modelleri yüksek doğruluk ve F1 skoru ile diğer yöntemlerden daha iyi bir performans serilerken; EBM yöntemi, biraz daha düşük performans göstermiştir. Ancak “Sürgülü Ray 06” verilerinde EBM %100 performans göstererek öne çıkmıştır.

4.1.3.2. XAI yöntemleri ile özellik analizi ve önemlilik seçimi

Tablo 4.8, sürgülü ray ses sinyallerindeki anomali tespiti modellerinin XAI yöntemleri ile önemlilik önem derecelerini göstermektedir.

Tablo 4.8. S. ray sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
spectralRollofMax	✓	✓	✓	✓	✓	✓	6
rmsEntropy	✓	✓	✓	✓	✓	✓	6
magnitudesSum	✓	✓	✓	✓	✓	✓	6
spectralBandwidthMax	✓	✓	✓	✓	✓	✓	6
signalKurtosis	✓	✓	✓	✓	✓		5
rmsStd	✓	✓	✓	✓	✓		5
amplitudeEnvelopeStd	✓	✓	✓	✓	✓		5
instantaneousAmplitudeStd	✓	✓	✓	✓	✓		5
instantaneousAmplitudeMax	✓	✓	✓	✓	✓		5
magnitudesMean	✓	✓	✓		✓		4
powerSpectralDensityMean	✓	✓	✓	✓			4

Tablo 4.8. (Devamı) S. ray sesi XAI yöntemlerine göre özelliklerin önem dereceleri.


Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
instantaneousFrequencyMean		✓	✓	✓		✓	4
spectralBandwithMin	✓	✓	✓			✓	4
chromaPitch1Min	✓		✓	✓	✓		4
chromaPitch6		✓	✓	✓	✓		4
chromaPitch11Max	✓	✓	✓		✓		4
chromaPitch4Max	✓	✓	✓		✓		4
chromaPitch4	✓		✓	✓	✓		4
chromaPitch7Min	✓	✓			✓		3
chromaPitch5Min	✓	✓	✓				3
magnitudesStd	✓			✓	✓		3
cqtStd	✓		✓	✓			3
powerSpectralDensityStd	✓			✓	✓		3
spectralCentroidsMax	✓				✓	✓	3
instantaneousPhaseEntropy		✓	✓	✓			3
spectralCentroidsPvariance		✓	✓	✓			3
amplitudeEnvelopeMin			✓	✓			2
amplitudeEnvelopeMax	✓				✓		2
chromaPitch6Min				✓	✓		2
spectralCentroidsStd		✓				✓	2

Verilen tabloda her XAI yöntemi için en önemli olarak sıralanan 25 özellik arasından, en az iki modelde önemli bulunan özellikler belirlenerek; her bir özelliğin farklı yöntemlerle ne kadar sık vurgulandığını göstermek amacıyla skor atanmıştır.

Pompa sesleri içinde tüm XAI modelleri tarafından en önemli özellikler olarak seçilen *spectralRollofMax* ve *spectralBandwithMax* sürgülü yay sesleri için de tüm XAI yöntemleri tarafından seçilmiştir. Bunun yanı sıra, *rmsEntropy* ve *magnitudesSum* özellikleri de tüm yöntemler tarafından önemli olarak seçilmiştir. Bu özellikler, sinyalin enerji yoğunluğunu ve zamanla değişkenliğini ifade eder. Anormal durumlarda, sürgülü raylarda meydana gelen yağsızlık sonucu sürtünme, titreşim ya da mekanik çarpımlar enerji seviyesinde belirgin değişiklikler yaratabilir.

signalKurtosis, *rmsStd*, *amplitudeEnvelopeStd*, *instantaneousAmplitudeStd* ve *instantaneousAmplitudeMax* gibi özellikler ise toplamda beş yöntem tarafından önemli bulunmuş, yalnızca LASSO yöntemi tarafından öne çıkarılmamıştır. Bu özellikler, sinyaldeki lokal genlik dalgalanmalarını ve değişimlerin büyüklüğünü yansıtır. Anormal sürgülü ray hareketleri, sinyalin genlik zarfında düzensizliklere ve daha belirgin genlik değişikliklerine yol açabilir.

Şekil 4.9, “Sürgülü Ray 06” verileri üzerinde önemli özelliklerin normal ve anormal örnekler için dağılımlarını göstermektedir. Her iki grafikte de özelliklerin normal ve anormal örnekleri ayırtmada etkili olduğu görülmektedir.




Şekil 4.9. S. ray 06 verilerinde önemli özelliklerin normal ve anormal dağılımı.

4.1.3.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme

Gözetimsiz öğrenme algoritmaları ile anomali tespiti gerçekleştirilirken, yalnızca XAI yöntemleri aracılığıyla belirlenmiş önemli özelliklere dayalı veri setleriyle eğitim yapılmıştır.

İzolasyon ormanı ile anormali tespiti

Gözetimsiz anormali tespiti için kullanılan IF modelinin performansını daha iyi değerlendirebilmek amacıyla, tahmin sonuçlarının görselleştirilmesi için PCA uygulanmıştır. Bu süreç, verinin boyutunu küçültürken, önemli bilgilerin kaybolmamasını sağlamaktadır. Boyut azaltma sonrası elde edilen verilerle oluşturulan grafikler, Şekil 4.10'da sunulmaktadır. Bu görselleştirmeler sayesinde modelin anormali tespiti performansı daha net bir şekilde görülmektedir.




Şekil 4.10. Sürgülü ray seslerinde PCA ve IF ile anormali tespiti sonuçları.

Autoencoder ile anormali tespiti

Sürgülü ray seslerinde AE modeli ile gözetimsiz öğrenme tespiti, Bölüm 4.1.1.3'te açıklanan işlemler ve model doğrultusunda gerçekleştirilmiştir.

Eğitim sırasında kullanılmayan normal sinyallerin %20'si ve anormal sinyallerin tamamı, anormali tespiti performansını değerlendirmek için test verisi olarak kullanılmıştır. Anormali tespiti sonuçları, yüksek boyutlu verilerin yapısını koruyan t-SNE yöntemiyle görselleştirilmiş olup, bu sonuçlar Şekil 4.11'de gösterilmektedir.

Gerçek etiketleri gösteren t-SNE projeksiyonları incelendiğinde, anormal sinyallerin normal sinyallerden belirgin bir şekilde ayrıldığını görmek mümkündür. Etkili özelliklerin kullanılması anomalileri, verinin genel dağılımından net bir şekilde ayırılmasına olanak sağlamıştır.



Şekil 4.11. Sürgülü ray seslerinde t-SNE ve AE ile anomali tespiti sonuçları.

Sonuçlar ve Değerlendirme

Tablo 4.9'da, sürgülü ray sinyallerinde kullanılan IF ve AE modellerinin test veri setleri üzerinden hesaplanan AUC değerleri karşılaştırılmaktadır. Bu metrik, modelin anomalileri ayırt etme gücünü gösterdiği için literatürde gözetimsiz öğrenme modellerinin performansını değerlendirmek için en çok tercih edilen metriktir. Etiketlenmemiş veriler üzerinde modelin doğruluğunu etkili bir şekilde ölçmektedir.

Tablo 4.9. Sürgülü ray sinyallerinde IF ve AE modellerinin AUC değerleri.

Model	Ray 00	Ray 02	Ray 04	Ray 06	Ortalama
IF	99.29	99.33	98.96	87.24	96.21
AE	100.00	100.00	100.00	95.40	98.85

Tablodan elde edilen verilere göre, AE modeli, tüm sürgülü ray sinyallerinde (Ray 00, Ray 02, Ray 04) %100 AUC değeriyle en yüksek başarıyı göstermektedir. Ray 06 verisinde ise AE modeli, %95.40 AUC değeriyle biraz daha düşük bir performans sergilese de tüm ray sinyallerinde IF modelinden daha yüksek AUC değeri sunmuştur.

Tüm sürgülü ray sinyallerinde %99'un üstünde AUC elde edilirken, Ray 06'da iki modelde de önemli düşüş görülmesi bu makine kimliğinin daha karmaşık veya sınırda kalan anomalilere sahip olabileceğini düşündürmektedir. Sonuç olarak, her iki modelin de anomali tespiti konusunda yüksek başarılar elde ettiği, ancak AE modelinin genel olarak daha üstün bir performans sergilediğini söylemek mümkündür.

4.1.4. Valf verileri

4.1.4.1. Gözetimli öğrenme algoritmaları ile eğitim ve değerlendirme

Tablo 4.10, valf sinyalleri üzerinde gerçekleştirilen anomali sınıflandırması için kullanılan dört farklı gözetimli öğrenme modelinin başarısının karşılaştırılmasına olanak tanıyan performans ölçütlerini göstermektedir.

Tablo 4.10. Valf sinyallerinde anomali sınıflandırması için performans ölçümleri.

ID	Metotlar	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)	AUC (%)	MCC (%)
00	RF	100.0	100.0	100.0	100.0	100.0	100.0
	XGBoost	100.0	100.0	100.0	100.0	100.0	100.0
	EBM	100.0	100.0	100.0	100.0	100.0	100.0
	DNN	100.0	100.0	100.0	100.0	100.0	100.0
02	RF	100.0	100.0	100.0	100.0	100.0	100.0
	XGBoost	100.0	100.0	100.0	100.0	100.0	100.0
	EBM	100.0	100.0	100.0	100.0	100.0	100.0
	DNN	100.0	100.0	100.0	100.0	100.0	100.0
04	RF	99.02	94.92	98.08	93.33	100.0	94.86
	XGBoost	99.73	98.73	100.0	97.50	99.97	98.59
	EBM	99.55	97.75	100.0	95.83	100.0	97.60
	DNN	99.64	98.16	100.0	96.67	100.0	98.07
06	RF	96.22	75.34	84.68	69.17	97.18	74.82
	XGBoost	98.29	91.56	98.10	85.83	99.72	90.86
	EBM	96.67	76.31	86.56	73.33	97.64	77.00
	DNN	99.16	95.94	99.00	93.33	99.57	95.62

4.1.4.2. XAI yöntemleri ile özellik analizi ve öznelik seçimi

Tablo 4.11, valf ses sinyallerinde anomali tespiti için öne çıkan özelliklerin, hangi XAI yöntemlerinde vurgulandığını göstermektedir.

Tablo 4.11. Valf sesi XAI yöntemlerine göre özelliklerin önem dereceleri.

Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
spectralRollofMax	✓	✓	✓	✓	✓	✓	6
rmsEntropy	✓	✓	✓	✓	✓	✓	6
signalKurtosis	✓	✓	✓	✓	✓	✓	6
spectralCentroidsMax	✓	✓	✓	✓	✓	✓	6
autocorrCoeffAE2	✓	✓	✓	✓	✓		5
autocorrCoeffSB3	✓	✓	✓	✓	✓		5
signalSkew	✓	✓	✓	✓	✓		5
magnitudesStd	✓	✓	✓	✓	✓		5
chromaPitch1Min	✓	✓	✓	✓	✓		5
chromaPitch10Min	✓	✓	✓		✓		4
chromaPitch11Min	✓	✓	✓	✓			4
instantaneousAmplitudeMax	✓	✓	✓		✓		4
amplitudeEnvelopeMax	✓	✓		✓	✓		4
amplitudeEnvelopeStd	✓	✓	✓		✓		4
cqtSum		✓	✓	✓		✓	4
spectralBandwithMean		✓		✓		✓	3

Tablo 4.11. (Devamı) Valf sesi XAI yöntemlerine göre özelliklerin önem dereceleri.


Önemli Özellikler	RF	IG	SHAP	LIME	EBM	LASSO	Skor
spectralBandwidthMax			✓	✓		✓	3
magnitudesMax	✓			✓	✓		3
rmsTotal	✓			✓	✓		3
rmsStd	✓	✓		✓			3
powerSpectralDensityMean	✓		✓		✓		3
spectralCentroidsAnderson			✓	✓		✓	3
autocorrCoeffSB2		✓	✓	✓			3
autocorrCoeffAE3			✓	✓	✓		3
instantaneousAmplitudeStd	✓	✓			✓		3
instantaneousFrequencyStd			✓			✓	2
spectralBandwidthMin		✓				✓	2
spectralRollofSkew		✓			✓		2
instantaneousAmplitudeMean	✓				✓		2
magnitudesMean		✓		✓			2
cqtMax				✓	✓		2
SpectralCentroidsKurtosisTestPvalue			✓	✓			2

spectralRollofMax, *rmsEntropy*, *signalKurtosis* ve *spectralCentroidsMax* özellikleri tüm yöntemler tarafından vurgulanmaktadır. *spectralRollofMax* ve *spectralCentroidsMax* gibi spektral özellikler genellikle anomali sırasında oluşan

yüksek frekanslı bileşenlerin belirlenmesini sağlarken; *rmsEntropy* ve *signalKurtosis* gibi özellikler bir sinyalin enerji seviyelerindeki düzensizliği ve karmaşıklığı ölçer.

XAI yöntemleri ile yapılan analizlerde öne çıkan diğer özellikler arasında, sinyalin genlik zarfındaki düzenlilik derecesini ölçen *autocorrCoeffAE2* özelliği, düşük değerler aldığı anda bir zaman dilimindeki sinyal deseninin sonraki zaman dilimiyle uyumsuz olduğunu göstermektedir. Bunun yanı sıra, spektral bant genişliğinin otokorelasyon katsayısını ifade eden *autocorrCoeffSB3* özelliği, sinyalin frekans bileşenlerinin zaman içinde nasıl tekrarladığına dair bilgi sunmaktadır. Her iki özellik için düşük otokorelasyon katsayısı, valf mekanizmasında süreklilik eksikliğini, beklenmedik davranışları ve frekans kaymalarını işaret edebilir.

Bu özelliklerin valf ses sinyallerindeki anomalilerin ayırt edilmesinde ne derece etkili olduğunu daha iyi anlamak amacıyla, “Valf 02” makinesine ait veriler üzerinde yapılan analizlerde, önemli özelliklerin normal ve anormal örnekler için dağılımı incelenmiştir. Şekil 4.12’de, bu özelliklerin her iki durumun ayrıştırılmasında ne kadar etkili olduğu görülmektedir. *amplitudeEnvelopeMax* ve *rmsEntropy* gibi özellikler, “Valf 02” seslerinin normal ve anormal örnek kümeleri arasında net bir ayrışma sağlamaktadır.




Şekil 4.12. Valf 02 verilerinde önemli özelliklerin normal ve anormal dağılımı.

4.1.4.3. Gözetimsiz öğrenme algoritmaları ile eğitim ve değerlendirme

İzolasyon ormanı ile anomali tespiti

Gözetimsiz anomali tespiti amacıyla kullanılan IF modelinin valf ses sinyalleri üzerindeki performansını daha iyi değerlendirebilmek için, tahmin sonuçları PCA kullanılarak görselleştirilmiştir. Boyut azaltma sonrası elde edilen verilerle oluşturulan grafikler, Şekil 4.13’te sunulmuştur. Sadece etkili özellikleri içeren veri seti


kullanıldığı için, PCA görsellerinde çoğu normal ve anormal veri noktalarının net bir şekilde ayrıştığı gözlemlenmektedir.



Şekil 4.13. Valf seslerinde PCA ve IF ile anomali tespiti sonuçları.

Autoencoder ile anomali tespiti

Valf ses sinyalleri üzerinde AE modeli kullanılarak gözetimsiz öğrenme tabanlı anomali tespiti gerçekleştirilmiştir. Bu işlem, Bölüm 4.1.1.3'te açıklanan metodoloji ve model yapılandırması doğrultusunda yürütülmüştür. Elde edilen anomali tespiti sonuçları, yüksek boyutlu verilerin yapısını koruyan t-SNE yöntemi ile görselleştirilmiş ve bu sonuçlar Şekil 4.14’te sunulmuştur.



Şekil 4.14. Valf seslerinde t-SNE ve AE ile anomali tespiti sonuçları.

t-SNE projeksiyonları üzerinde inceleme yapıldığında, özellikle “Valf 00” ve “Valf 02” makinelerinde anormal sinyallerin normal sinyallerden belirgin bir şekilde ayrışması, anomali tespitinde kullanılan özelliklerin oldukça güçlü olduğunu ve bu

makinelerdeki anormal durumları açık bir şekilde ayırt edilebildiğini gösterir. Nitekim, AE modelinin de bu makine kimliklerinin test veri setleri üzerindeki değerlendirmesinde %100 AUC elde edilmiştir.

Sonuçlar ve Değerlendirme

Tablo 4.12'de, valf sinyallerinin anomali tespitinde kullanılan IF ve AE modellerinin AUC değerleri verilmektedir. Bu değerler, modellerin doğru sınıflandırma yeteneklerini ölçmek amacıyla karşılaştırılmaktadır.

Tablo 4.12. Valf sinyallerinde IF ve AE modellerinin AUC değerleri.

Model	00	02	04	06	Ortalama
IF	99.69	99.86	98.17	92.48	97.55
AE	100.00	100.00	99.41	93.08	98.12

Her iki model de valf sinyallerinde anomali tespitinde başarılı sonuçlar elde etmiş olsa da, AE modelinin bütün makine kimlikleri için daha iyi performans göstermesi onu öne çıkarmaktadır.

4.2. Deney 2: ToyADAMOS Veri Seti

ToyADAMOS veri setinde bulunan oyuncak araba verileri için dört farklı gözetimli öğrenme modelinin performansı çapraz doğrulama yöntemiyle kapsamlı bir şekilde değerlendirilmiş, elde edilen sonuçlar Tablo 4.13'te sunulmuştur.


Tablo 4.13. Oyuncak araba anomali sınıflandırması için performans ölçümleri.

Metotlar	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)	AUC (%)	MCC (%)
RF	83.42	76.79	88.85	71.54	93.95	67.54
XGBoost	88.86	85.43	90.23	81.11	95.42	76.73
EBM	87.64	84.03	88.42	81.50	95.2	75.06
DNN	89.5	86.59	89.19	84.38	95.62	78.21

DNN modeli, tüm metriklerde diğer modellerin üzerinde, dengeli bir performans sergileyerek en iyi sonucu elde etmiştir. Bu model, hem anomaliyi doğru tespit etmede

(recall) hem de yanlış pozitif oranını düşük tutmada (precision) başarılı olmuştur. DNN'in ardından en yüksek performansa sahip olan XGBoost modeli, özellikle yüksek Precision değeri ile öne çıkmaktadır.

En başarılı sonuçlar DNN modeli ile elde edildiği için, DNN modelinin hangi özellikler tarafından nasıl etkilendiğini anlamamıza yardımcı olan XAI yöntemlerinden IG (Integrated Gradients) ile en önemli özellikler incelenmiştir. Şekil 4.15'te DNN modeli için IG yöntemi tarafından belirlenen en önemli 20 özellik görülmektedir.



Şekil 4.15. Oyuncak araba seslerinde IG ile belirlenen en önemli özellikler.


spectralRollofMedian, *instantaneousFrequencyStd*, *instantaneousPhaseEntropy* ve *zeroCrossingRate* özellikleri, pozitif yönde en güçlü etkiye sahip olan özelliklerdir. Modelin anomali tespit kabiliyetini arttıran bu özellikler, sırasıyla sinyalin frekans spektrumunun üst sınırındaki enerjiyi, frekans içeriğindeki değişkenliği, faz bilgisinin karmaşıklığını, sıfır geçiş oranını ifade etmektedir.

spectralSpread ve *autocorrCoeffB52* özellikleri de negatif yönde (normal sınıfa yönlendirici) en güçlü etkiye sahip olan özelliklerdir. Bu özellikler, normal sinyallerin zamansal tutarlılık ve spektral dağılım gibi ayırt edici özelliklerini temsil ederek, modelin normal durumları doğru bir şekilde sınıflandırmasına katkı sağlamaktadır.

4.3. Gerçek Vaka Çalışması: Elektrik Motorları Veri Seti

Testi geçen 41 ve testi geçemeyen 164 motora ait ses sinyali ölçümlerini içeren veri seti ile gözetimli öğrenme modelleri test edilmiştir. Yaklaşık 13 saniyeden oluşan her sinyal ölçümünün ortasından alınan 3 ve 5 saniyelik kayıtlar için ayrı model oluşturulmuştur. 5 saniyelik ölçümlerle oluşturulan model ile 3 saniyelik ölçümler için eğitilen modeller aynı başarılı sonuçları vermiştir.

Veri setinin %75'lik kısmı eğitim, %25'lik kısmı ise test için kullanılarak oluşturulan modelin değerlendirmesi, modelin bu veri seti üzerinde %100 doğrulukla performans sergilediğini göstermiştir. Şekil 4.16'da verilen karışıklık matrislerinde görüldüğü gibi eğitim ve test setleri için sonuçların tamamen doğru olması, önerilen yöntemin ve modelin bu veri seti üzerinde oldukça başarılı ve etkili bir şekilde çalıştığını göstermektedir.



Şekil 4.16. Eğitim ve test veri setleri için karışıklık matrisleri.


Karışıklık matrisinde sunulan bu sonuçlar, veri setinin belirli bir bölümü üzerinde modelin performansını değerlendirdiği için genelleme yeteneği hakkında kesin bir fikir vermemektedir. Nitekim, diğer modellerde olduğu gibi daha güvenilir bir değerlendirme için çapraz doğrulama yöntemi uygulandığında model doğruluğunun ancak %96 seviyelerine ulaştığı görülmüştür.

Tablo 4.14'te gösterilen, çapraz doğrulama sonucunda elde edilen ölçümler, modelin genelleme yeteneğini ve farklı yöntemler arasındaki karşılaştırmaları daha doğru bir şekilde yansıtmaktadır.

Tablo 4.14. Elektrik motorları anomali sınıflandırması için performans ölçümleri.

Metotlar	Accuracy (%)	F1-Score (%)	Precision (%)	Recall (%)	AUC (%)	MCC (%)
RF	94.83	95.21	99.43	94.38	97.81	92.21
XGBoost	96.10	97.56	97.56	97.56	99.26	87.80
EBM	95.31	95.54	99.43	95.00	99.38	92.96
DNN	96.16	97.34	99.29	95.83	98.75	91.41


Oluşturulan ilk modellerin kara kutu olarak kalmaması için sınıflandırmada kullandığı özneteliklerin önemleri irdelenmiş, gereksiz özelliklerin azaltımı yapılarak modeller tekrar eğitilmiştir. Modeller, 110 özellik yerine sadece 21 özellik ile eğitildiğinde de model performansı düşmemiş hatta iyileşmeler görülmüştür. % 97.56 ile en iyi F1 skor değerini veren XGBoost modeli için kullanılan en önemli özellikler Şekil 4.17’de gösterilmektedir.



Şekil 4.17. XGBoost modeline göre belirlenen en önemli özellikler.

En yüksek AUC ve MCC değerlerini veren EBM modelindeki öne çıkan özellikleri gösteren Şekil 4.18’i incelediğimizde; *magnitudesStd*, *magnitudesMax*, *spectralFlatness* özelliklerinin XGBoost modelinde olduğu gibi ilk sıralara yerleştiği görülmektedir.


Global Term/Feature Importances




Şekil 4.18. EBM ile belirlenen en önemli özellikler.

magnitudesStd ve *magnitudesMax* gibi spektral genlik tabanlı özelliklerin ön planda olması, sinyallerin enerji yoğunluğu ve genlik varyasyonlarının anomalilerin ayrıştırılmasında kritik bir etken olduğunu göstermektedir. Ayrıca, *spectralFlatness* özelliğinin iki modelde de öne çıkması, spektral dağılımın düzlüğünün anomali tespitinde genel bir gösterge olarak kabul edilebileceğini desteklemektedir.

Şekil 4.19 ve Şekil 4.20’de elektrik motorlarına ait ses sinyallerinden elde edilen önemli özelliklerin görselleştirilmiş dağılımları incelendiğinde, bazı örtüşme alanları bulunsa da sağlıklı (mavi) ve hatalı (kırmızı) motorlar arasında büyük ölçüde ayrışma olduğu gözlemlenmiştir. Bu durum, çıkarılan ses sinyali özelliklerinin motorların durumunu ayırt etme konusundaki genel başarısını göstermektedir.



Şekil 4.19. Elektrik motorları önemli özelliklerin normal ve anormal dağılımı 1.



Şekil 4.20. Elektrik motorları önemli özelliklerin normal ve anormal dağılımı 2.

4.4. Karşılaştırmalı Değerlendirme

Literatürdeki gözetimli yöntemlerin sonuçlarıyla karşılaştırıldığında, geliştirdiğimiz yöntem önemli bir iyileştirme sağlamaktadır. Literatür taramasında, endüstriyel makinelere ait sesleri içeren MIMII veri seti üzerinde ses sınıflandırması gerçekleştiren ve 9 farklı gözetimli yöntem öneren çalışma incelenmiştir. Önerdiğimiz yöntem, bu çalışmaların tümünde elde edilen sonuçlardan daha iyi performans göstermiştir. Literatürdeki çalışmalardan en iyi sonuçları elde eden iki gözetimli modelin AUC değerleri ile önerdiğimiz yöntemin sonuçları Tablo 4.15’te gösterilmektedir.

Tablo 4.15. Literatürdeki gözetimli yöntemlerle önerilen karşılaştırması.

Makine / Model	MLP	HM-Net + SVM	Önerilen
Fan	99.7	100.0	100.0
Pompa	98.3	90.0	99.87
Sürgülü Ray	98.5	94.0	100.0
Valf	92.9	84.0	99.93
Ortalama	97.35	92.0	100.0

Tablodan da görüleceği üzere, önerdiğimiz yöntem fan makinesi hariç diğer üç makine türüne ait gözetimli modellerin tamamı için literatürdeki en iyi sonuçlara kıyasla ortalama %3.56 daha iyi performans elde edilmiştir.

Literatürde bulunan 12 farklı gözetimsiz çalışmanın sonuçları ile karşılaştırıldığında, önerilen yöntemin, endüstriyel makinelere gözetimsiz anomali tespitinde de çok iyi sonuçlar elde ettiği görülmüştür. 6 dB SNR seviyesinde verilerle eğitilip test edilmiş gözetimsiz modellerle karşılaştırılmasının sunulduğu Tablo 4.16 incelendiğinde, önerilen yöntemin farklı makine kimlikleri arasında tutarlı bir şekilde yüksek AUC değerleri elde ettiği ve diğer yöntemlere kıyasla daha ön plana çıktığı görülmektedir.

Tablo 4.16. Literatürdeki gözetimsiz yöntemlerle önerilen karşılaştırması.

Makine	Model	00	02	04	06	Ortalama
Fan	AE [19]	75.00	99.00	92.00	99.00	91.25
	VAE [28]	82.85	99.49	96.71	100.00	94.76
	CVAE [28]	73.13	98.44	89.49	99.94	90.25
	GAN [25]	81.47	98.69	96.15	99.43	93.94
	GRLNet [25]	83.59	99.96	97.81	100.00	95.34
	GRLNet [24]	85.34	98.90	96.93	99.34	95.13
	EDGAN [24]	98.15	100.00	99.68	99.51	99.34
	Önerilen	98.80	99.98	99.36	100.00	99.54
Pompa	AE [19]	84.00	45.00	99.00	94.00	80.50
	VAE [28]	92.27	59.91	100.00	98.56	87.69
	CVAE [28]	99.83	55.78	100.00	99.26	88.72
	GAN [25]	96.37	60.97	98.47	97.86	88.42
	GRLNet [25]	98.87	62.16	100.00	99.46	90.12
	GRLNet [24]	90.88	98.63	99.26	96.57	96.34
	EDGAN [24]	99.50	99.27	100.00	99.87	99.66
	Önerilen	99.72	97.11	100.00	99.62	99.11

Tablo 4.16. (Devamı) Literatürdeki gözetimsiz yöntemlerle önerilen karşılaştırması.

Makine	Model	00	02	04	06	Ortalama
Sürgülü Ray	AE [19]	99.00	93.00	88.00	71.00	87.75
	VAE [28]	99.45	90.84	91.63	77.02	89.74
	CVAE [28]	99.96	91.66	85.93	80.21	89.44
	GAN [25]	99.43	90.48	84.93	81.82	89.17
	GRLNet [25]	99.96	92.08	88.73	83.62	91.10
	GRLNet [24]	100.00	99.22	86.54	91.04	94.20
	EDGAN [24]	100.00	99.54	100.00	99.46	99.75
	Önerilen	100.00	100.00	100.00	95.40	98.85
Valf	AE [19]	68.00	66.00	64.00	70.00	67.00
	VAE [28]	50.87	64.40	54.24	59.82	57.33
	CVAE [28]	65.84	73.94	58.75	63.42	65.49
	GAN [25]	52.97	71.28	55.01	59.64	59.73
	GRLNet [25]	61.37	74.26	59.24	60.84	63.93
	GRLNet [24]	81.18	96.13	93.83	64.51	83.91
	EDGAN [24]	99.98	97.95	98.65	96.97	98.39
	Önerilen	100.00	100.00	99.41	93.08	98.12

Özellikle Fan makinesi için önerilen yöntem, %99.54 ortalama AUC değeriyle en yakın sonucu elde eden EDGAN'ın %99.34 oranını geride bırakmıştır. Önerilen yöntem, fan makine sesleri için gözetimsiz anomali tespitinde literatürdeki en yüksek performansı göstermiştir.

Bunun yanı sıra, literatürdeki çoğu gözetimli ve gözetimsiz algoritmanın anomali tespitinde düşük performans elde ettiği valf seslerinde iki makine kimliği için %100 performans elde edilmiştir.

Diğer makine türleri için, literatürdeki sadece bir çalışmada ortalama %0.37 farkla daha yüksek sonuç elde edilmiştir. Ancak, EDGAN yöntemi, yüksek doğruluğunu oldukça ağır bir model ile sunmaktadır. Parametre boyutu 81.18 MB olan EDGAN modeline kıyasla, önerilen yöntemdeki AE modelinin parametre boyutu kullanılan öznitelik sayısına göre 0.03 ile 0.06 MB arasında değişirken, IF modelinin parametre boyutu yalnızca 0.4 ile 1 MB arasında değişmektedir. Bu fark, önerilen yöntemin çok daha hafif ve verimli bir yapı sunduğunu, aynı zamanda çok daha düşük hesaplama gücü gereksinimi ile yüksek performans sağladığını ortaya koymaktadır.

Bu özellikleri sayesinde, özellikle Endüstri 4.0 kapsamında düşük kaynak gereksinimleriyle çalışan ve gerçek zamanlı veri işleme gerektiren uygulamalarda etkin bir şekilde kullanıma daha uygun olduğu düşünülmektedir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada, akustik ses sinyalleri kullanılarak endüstriyel makinelerde anomali tespiti için hafif ve etkili bir makine öğrenimi yöntemi önerilmiştir. Önerilen yöntemle literatürdeki mevcut tekniklerin önemli ölçüde önüne geçilmiştir.

5.1. Elde Edilen Sonuçların Analizi

Gözetimli modellerde MIMII veri setinde bulunan her makine kimliği için ortalama olarak aşağıdaki performans ölçütleri elde edilmiştir:

- Pompalar için %99.59 doğruluk ve %99.87 AUC
- Fanlar için %99.84 doğruluk ve %100 AUC
- Sürgülü raylar için %99.98 doğruluk ve %100 AUC
- Valfler için %99.72 doğruluk ve %99.92 AUC

Çalışmada kullanılan dört farklı gözetimli öğrenme modellerinde tek bir modelin üstünlük kurduğunu söylemek mümkün değildir çünkü zaman zaman farklı makine tipi ve makine kimlikleri için performans üstünlüğü sağlayan model değişmiştir. Ancak genellikle DNN ve XGBoost modellerinin öne çıktığını söylemek mümkündür.

Gözetimsiz modellerde ise her makine kimliği için elde edilen ortalama AUC değerleri; pompalar için %99.11, fanlar için %99.54, sürgülü raylar için %98.85, valfler için %98.12 olmuştur.

Test edilen iki gözetimsiz öğrenme modeli arasından, AE modelinin daha yüksek AUC değerleri elde ederek IF modelinden daha iyi sonuçlar verdiği görülmüştür. Yalnızca “Pompa 00” makinesi için IF modeli, AE modeline göre daha iyi performans göstermiştir. Buna rağmen diğer makinelerde de IF modelinin AE modeline çok yakın değerler elde ederek oldukça iyi bir performans gösterdiğini söylemek mümkündür.

Önerilen yöntem, ToyADMOS veri setindeki oyuncak arabalarının anomali tespiti için de test edilmiş, %95.62 AUC ile literatürdeki çoğu çalışmadan daha iyi bir başarı elde edilmiştir.

Önerilen yöntemin, gerçek vaka çalışması ile beyaz eşya elektrik motorlarından toplanan ses sinyalleri üzerinde test edilerek, %99.38 AUC ile sağlıklı ve hatalı elektrik motorlarını ayırmada başarılı performans göstermesi gerçek dünya problemlerinde de başarılı sonuçlar verdiğini ortaya koymuştur.

Çalışma sırasında, çeşitli XAI yöntemleri ile farklı makineler için kritik özelliklerin belirlenmesinin, gerçek zamanlı akustik izleme ve kestirimci bakım sistemleri için değerli bilgiler sağlayacağı düşünülmektedir. Çalışmada, önerilen yöntemin ve modellerin şeffaflığını artıran açıklanabilir ve etkili özelliklere odaklanması, gelecekteki uygulanabilir endüstriyel bakım çalışmalarını da destekleyecektir.

Önerilen yöntemin yüksek performansının yanı sıra en önemli katkısı, hafif bir model olmasıdır. Endüstride özellikle uç cihazlarda (edge devices) kullanılabilecek hafif modellerin geliştirilmesi, güncel ve endüstriyel uygulamalardaki enerji ile hesaplama maliyetlerini düşürmesi açısından önemli bir araştırma konusudur.

Önerilen yöntem, literatürdeki iyi sonuçlar elde edilmiş çoğu çalışmaya göre oldukça düşük hesaplama maliyeti ve boyut avantajı sağlamaktadır. Literatürde önerilen iyi performans göstermiş yöntemler, genellikle yüksek boyutlu veriler (örneğin, görüntü verileri) ve birden fazla derin öğrenme ağından oluşan karmaşık yapılar gerektirmektedir. Bu tez çalışması kapsamında önerilen yöntemde başlangıçta 110 öznitelik (1×110 boyutlu veri) çıkarılsa da, özellik seçimi ve azaltımı süreçleri sonucunda çoğu durumda yalnızca 20-50 öznitelikten oluşan veriyle daha iyi sonuçlar elde edilmiştir. Ayrıca RF ve XGBoost gibi ağaç tabanlı basit makine öğrenmesi modellerinin yanı sıra, yalnızca 3-4 gizli katmandan oluşan DNN ve AE gibi hafif yapıları derin öğrenme modelleri kullanılmıştır. Bu sayede, önerilen yöntem karmaşık ve hesaplama açısından maliyetli yapılardan kaçınarak daha basit, ancak bir o kadar da etkili ses sinyalleri ile anomali ve arıza tespiti çözümü üretmiştir.

5.2. Gelecek Çalışmalar İçin Öneriler

Bu çalışmada önerilen ses sinyalleri işleme ve özellik çıkarma tekniklerinin hem gözetimli hem de gözetimsiz modellerde etkili sonuçlar ürettiği görülmüştür. Ancak, yöntemimizin geliştirilmesi ve daha geniş bir alanda uygulanabilmesi için gelecekte farklı sinyal türlerinin entegrasyonu, veri çeşitliliğinin artırılması, gerçek zamanlı anomali tespiti gibi konulara odaklanılabilir.

Akustik sinyallerin yanı sıra, önerilen yöntemde çıkarılan birçok sinyal özelliği; titreşim, akım, basınç, sıcaklık gibi farklı sensör verilerinden toplanan sinyallerin özellik çıkarımı için de kullanılabilir. Çeşitli sinyallerin birleştirilmesiyle hibrit bir model geliştirilebilir. Bu tür bir çalışma, yöntemin doğruluğunu ve genelleme yeteneğini daha da artırabilir.

Daha karmaşık ve gürültülü endüstriyel ortamların temsil edildiği, gürültü seviyesinin daha yüksek olduğu verilerle yöntemin sonuçları test edilerek, farklı ve gürültülü ortamlardaki durumlarda da başarılı sonuç verip vermediği test edilebilir. Daha gürültülü seslerde hangi ses sinyali özelliklerinin daha ayırtıcı olduğu tespit edilebilir.

Önerilen yöntemde çıkarılan ve önemli olduğu tespit edilen özelliklerin gerçek zamanlı akustik durum izleme sistemleri ile entegrasyonu, akustik anomali tespitinde performans ve hız açısından değerlendirilebilir. Hafif bir yöntem olduğundan özellikle düşük gecikme süresi gerektiren uygulamalar için önemli olabilir.

Gözetimsiz modellerin doğruluğunun, gözetimli modellere kıyasla bir miktar daha düşük olduğu görülmüştür. PCA ve t-SNE gibi özellik azaltma yöntemleri uygulandığında dahi, belirli veri noktalarının ayırt edilebildiği görülmüne rağmen, modelin bu noktaları hatasız bir şekilde sınıflandıramadığı tespit edilmiştir. Bu durum, modelin genel ayırt ediciliğinin iyi olduğunu ancak kesin sınıflandırma yapma konusunda bazı zorluklar yaşadığını göstermektedir. Bu nedenle, daha farklı ve etkili gözetimsiz veya yarı-gözetimli öğrenme teknikleri de test edilebilir. Ayrıca, dinamik çalışma koşullarına uyarlanabilirliği değerlendirmek ve modelin performansını artırmak amacıyla transfer öğrenme ya da sürekli öğrenme yöntemlerinin uygulanması göz önünde bulundurulabilir.



KAYNAKLAR

- [1] “Home - iRel40”. [Çevrimiçi]. Erişim adresi: <https://www.irel40.eu/>
- [2] A. Bala vd., “Artificial intelligence and edge computing for machine maintenance-review”, *Artificial Intelligence Review 2024* 57:5, c. 57, sy 5, ss. 1-33, Nis. 2024, doi: 10.1007/S10462-024-10748-9.
- [3] S. Y. Wong, X. Ye, F. Guo, ve H. H. Goh, “Computational intelligence for preventive maintenance of power transformers”, *Appl Soft Comput*, c. 114, s. 108129, Oca. 2022, doi: 10.1016/J.ASOC.2021.108129.
- [4] Y. Huang vd., “A Lightweight Collaborative Deep Neural Network for the Mobile Web in Edge Cloud”, *IEEE Trans Mob Comput*, c. 21, sy 7, ss. 2289-2305, Tem. 2022, doi: 10.1109/TMC.2020.3043051.
- [5] P. Henriquez, J. B. Alonso, M. A. Ferrer, ve C. M. Travieso, “Review of automatic fault diagnosis systems using audio and vibration signals”, *IEEE Trans Syst Man Cybern Syst*, c. 44, sy 5, ss. 642-652, 2014, doi: 10.1109/TSMCC.2013.2257752.
- [6] Y. Wei, D. Wu, ve J. Terpenney, “Robust Incipient Fault Detection of Complex Systems Using Data Fusion”, *IEEE Trans Instrum Meas*, c. 69, sy 12, ss. 9526-9534, Ara. 2020, doi: 10.1109/TIM.2020.3003359.
- [7] B. S. Caglar, H. B. Ketmen, ve B. Bulut, “Condition Monitoring on Renewable Energy Production with Application to Wind Generation”, *IECON Proceedings (Industrial Electronics Conference)*, c. 2022-October, 2022, doi: 10.1109/IECON49645.2022.9968833.
- [8] J. Gama, R. P. Ribeiro, S. Mastelini, N. Davari, ve B. Veloso, “From fault detection to anomaly explanation: A case study on predictive maintenance”, *Journal of Web Semantics*, c. 81, s. 100821, Tem. 2024, doi: 10.1016/J.WEBSEM.2024.100821.
- [9] Y. S. Afridi, K. Ahmad, ve L. Hassan, “Artificial intelligence based prognostic maintenance of renewable energy systems: A review of techniques, challenges, and future research directions”, *Int J Energy Res*, c. 46, sy 15, ss. 21619-21642, Ara. 2022, doi: 10.1002/ER.7100.
- [10] M. Acar, H. B. Ketmen, ve B. Bulut, “Prediction of failures in wind turbines”, *SIU 2021 - 29th IEEE Conference on Signal Processing and Communications Applications, Proceedings*, Haz. 2021, doi: 10.1109/SIU53274.2021.9477858.
- [11] W. Ahmad, S. A. Khan, M. M. M. Islam, ve J. M. Kim, “A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models”, *Reliab Eng Syst Saf*, c. 184, ss. 67-76, Nis. 2019, doi: 10.1016/J.RESS.2018.02.003.

- [12] S. Pashami vd., “Explainable Predictive Maintenance”, Haz. 2023.
- [13] E. Rushe ve B. Mac Namee, “Anomaly Detection in Raw Audio Using Deep Autoregressive Networks”, *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, c. 2019-May, ss. 3597-3601, May. 2019, doi: 10.1109/ICASSP.2019.8683414.
- [14] L. Tang, H. Tian, H. Huang, S. Shi, ve Q. Ji, “A survey of mechanical fault diagnosis based on audio signal analysis”, *Measurement*, c. 220, s. 113294, Eki. 2023, doi: 10.1016/J.MEASUREMENT.2023.113294.
- [15] H. Zhang, S. Zhang, Q. He, ve F. Kong, “The Doppler Effect based acoustic source separation for a wayside train bearing monitoring system”, *J Sound Vib*, c. 361, ss. 307-329, Oca. 2016, doi: 10.1016/J.JSV.2015.09.038.
- [16] H. J. Liu vd., “Mechanical Fault Diagnosis Based on Acoustic Features in Transformers”, *Annual Report - Conference on Electrical Insulation and Dielectric Phenomena, CEIDP*, c. 2020-October, ss. 563-566, Eki. 2020, doi: 10.1109/CEIDP49254.2020.9437518.
- [17] L. Si, Z. Wang, G. J.-I. Access, ve undefined 2019, “Fusion recognition of shearer coal-rock cutting state based on improved RBF neural network and DS evidence theory”, *ieeexplore.ieee.org* L Si, ZB Wang, G Jiang *IEEE Access*, 2019•*ieeexplore.ieee.org*, Erişim: 09 Kasım 2024. [Çevrimiçi]. Erişim adresi: <https://ieeexplore.ieee.org/abstract/document/8815761/>
- [18] B. S. Soares, J. S. Luz, V. F. de Macêdo, R. R. V. e. Silva, F. H. D. de Araújo, ve D. M. V. Magalhães, “MFCC-based descriptor for bee queen presence detection”, *Expert Syst Appl*, c. 201, s. 117104, Eyl. 2022, doi: 10.1016/J.ESWA.2022.117104.
- [19] H. Purohit vd., “MIMII Dataset: Sound Dataset for Malfunctioning Industrial Machine Investigation and Inspection”, Eyl. 2019.
- [20] J. Wu, F. Yang, ve W. Hu, “Unsupervised anomalous sound detection for industrial monitoring based on ArcFace classifier and gaussian mixture model”, *Applied Acoustics*, c. 203, s. 109188, Şub. 2023, doi: 10.1016/J.APACOUST.2022.109188.
- [21] B. Geng, Y. Liao, L. Guo, X. Feng, ve K. Cui, “Anomaly Detection in Rotating Machinery Sound Based on Time and Spectral Information Fusion”, *Proceedings of 2024 IEEE 13th Data Driven Control and Learning Systems Conference, DDCLS 2024*, ss. 1434-1438, 2024, doi: 10.1109/DDCLS61622.2024.10606600.
- [22] M. D. Chinnasamy, M. Sumbwanyambe, ve T. S. Hlalele, “Acoustic Anomaly Detection of Machinery using Autoencoder based Deep Learning”, *Proceedings of the 32nd Southern African Universities Power Engineering Conference, SAUPEC 2024*, 2024, doi: 10.1109/SAUPEC60914.2024.10445053.
- [23] Z. Liu, H. Tang, S. Michiels, W. Joosen, ve D. Hughes, “Unsupervised Acoustic Anomaly Detection Systems Based on Gaussian Mixture Density Neural Network”, *European Signal Processing Conference*, c. 2022-August, ss. 259-263, 2022, doi: 10.23919/EUSIPCO55093.2022.9909741.

- [24] S. Liu, J. Li, W. Ke, ve H. Yin, “Multi-Attention Enhanced Discriminator for GAN-Based Anomalous Sound Detection”, ss. 6715-6719, Mar. 2024, doi: 10.1109/ICASSP48485.2024.10447924.
- [25] Y. Sha vd., “Regional-Local Adversarially Learned One-Class Classifier Anomalous Sound Detection in Global Long-Term Space”, Şub. 2022, doi: 10.1145/3534678.3539133.
- [26] P. Daniluk, M. Gozdziwski, K. Sławomir, ve M. Kosmider, “Ensemble of Auto-Encoder Based and Wavenet Like Systems For Unsupervised Anomaly Detection”, Warsaw, 2020. [Çevrimiçi]. Erişim adresi: https://dcase.community/documents/challenge2020/technical_reports/DCASE_2020_Daniluk_140_t2.pdf
- [27] E. Di Fiore, A. Ferraro, A. Galli, V. Moscato, ve G. Sperli, “An anomalous sound detection methodology for predictive maintenance”, *Expert Syst Appl*, c. 209, s. 118324, Ara. 2022, doi: 10.1016/J.ESWA.2022.118324.
- [28] M. H. Nguyen, D. Q. Nguyen, D. Q. Nguyen, C. N. Pham, D. Bui, ve H. D. Han, “Deep Convolutional Variational Autoencoder for Anomalous Sound Detection”, *ICCE 2020 - 2020 IEEE 8th International Conference on Communications and Electronics*, ss. 313-318, Oca. 2021, doi: 10.1109/ICCE48956.2021.9352085.
- [29] S. Abbasi, M. Famouri, M. J. Shafiee, ve A. Wong, “OutlierNets: Highly Compact Deep Autoencoder Network Architectures for On-Device Acoustic Anomaly Detection”, *Sensors 2021, Vol. 21, Page 4805*, c. 21, sy 14, s. 4805, Tem. 2021, doi: 10.3390/S21144805.
- [30] Y. Shul, W. Yi, J. Choi, D. S. Kang, ve J. W. Choi, “Noise-based self-supervised anomaly detection in washing machines using a deep neural network with operational information”, *Mech Syst Signal Process*, c. 189, s. 110102, Nis. 2023, doi: 10.1016/J.YMSSP.2023.110102.
- [31] M. Zabin, A. N. Binte Kabir, M. K. Kabir, H. J. Choi, ve J. Uddin, “Machine Fault Diagnosis Using EMD-Gammatone Texture Representation and A Lightweight Self-Attention SqueezeNet”, *Proceedings - 2024 IEEE International Conference on Big Data and Smart Computing, BigComp 2024*, ss. 32-39, 2024, doi: 10.1109/BIGCOMP60711.2024.00015.
- [32] B. S. Çağlar, H. B. Ketmen, ve B. Bulut, “Anomaly Detection using Audio Signals”, içinde *International Aegean Scientific Research Symposium 2021 (IASRS'21)*, Ara. 2021, ss. 321-330.
- [33] Y. Ota ve M. Unoki, “Anomalous Sound Detection for Industrial Machines Using Acoustical Features Related to Timbral Metrics”, *IEEE Access*, c. 11, ss. 70884-70897, 2023, doi: 10.1109/ACCESS.2023.3294334.
- [34] M. Zabin, H. J. Choi, ve J. Uddin, “Hybrid deep transfer learning architecture for industrial fault diagnosis using Hilbert transform and DCNN–LSTM”, *Journal of Supercomputing*, c. 79, sy 5, ss. 5181-5200, Mar. 2023, doi: 10.1007/S11227-022-04830-8/TABLES/6.

- [35] S. Singhal vd., “Audio Based Machine Fault Diagnosis using Hybrid Feature Extraction and Ensemble Learning”, *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, ss. 1-7, Haz. 2024, doi: 10.1109/ICCCNT61001.2024.10724147.
- [36] L. Gantert, M. Sammarco, M. Detyniecki, ve M. E. M. Campista, “A Supervised Approach for Corrective Maintenance Using Spectral Features from Industrial Sounds”, *7th IEEE World Forum on Internet of Things, WF-IoT 2021*, ss. 723-728, Haz. 2021, doi: 10.1109/WF-IOT51360.2021.9594966.
- [37] A. Singh ve R. Arvind, “A Lightweight Machine Learning Framework For Acoustic Health Monitoring of Industrial Machines”, 2023, doi: 10.2139/SSRN.4507707.
- [38] L. Wang, G. Sun, Y. Wang, J. Ma, X. Zhao, ve R. Liang, “AFExplorer: Visual analysis and interactive selection of audio features”, *Visual Informatics*, c. 6, sy 1, ss. 47-55, Mar. 2022, doi: 10.1016/J.VISINF.2022.02.003.
- [39] L. Gantert, T. Zeffiro, M. Sammarco, ve M. E. M. Campista, “Multiclass classification of faulty industrial machinery using sound samples”, *Eng Appl Artif Intell*, c. 136, s. 108943, Eki. 2024, doi: 10.1016/J.ENGAPPAL.2024.108943.
- [40] Y. Koizumi, S. Saito, H. Uematsu, N. Harada, ve K. Imoto, “ToyADMOS: A Dataset of Miniature-Machine Operating Sounds for Anomalous Sound Detection”, Ağu. 2019.
- [41] “Arçelik A.Ş. - iRel40”. [Çevrimiçi]. Erişim adresi: <https://www.irel40.eu/consortium/turkey/arcelik-a-s>
- [42] B. McFee vd., “librosa/librosa: 0.10.1”, Ağustos 2023, *Zenodo*. doi: 10.5281/zenodo.8252662.
- [43] P. Virtanen vd., “SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python”, *Nat Methods*, c. 17, ss. 261-272, 2020, doi: 10.1038/s41592-019-0686-2.
- [44] S. Seabold ve J. Perktold, “statsmodels: Econometric and statistical modeling with python”, içinde *9th Python in Science Conference*, 2010.
- [45] T. Giannakopoulos ve A. Pikrakis, “Audio Features”, *Introduction to Audio Analysis*, ss. 59-103, Oca. 2014, doi: 10.1016/B978-0-08-099388-1.00004-2.
- [46] N. Kulkarni ve V. Bairagi, “Use of Complexity Features for Diagnosis of Alzheimer Disease”, *EEG-Based Diagnosis of Alzheimer Disease*, ss. 47-59, Oca. 2018, doi: 10.1016/B978-0-12-815392-5.00004-6.
- [47] “librosa.feature.spectral_bandwidth”. [Çevrimiçi]. Erişim adresi: https://librosa.org/doc/main/generated/librosa.feature.spectral_bandwidth.html#idl
- [48] J. P. Ugarte ve J. Arias-Arias, “Unveiling relevant acoustic features for bird species automatic classification”, *Expert Syst Appl*, c. 257, s. 125046, Ara. 2024, doi: 10.1016/J.ESWA.2024.125046.
- [49] Y. Soeta ve A. Ariki, “Subjective salience and the effects of familiarity with birdsongs and insect songs in noise environments”, *Applied Acoustics*, c. 213, s. 109666, Eki. 2023, doi: 10.1016/J.APACOUST.2023.109666.

- [50] D. N. Jiang, L. Lu, H. J. Zhang, J. H. Tao, ve L. H. Cai, “Music type classification by spectral contrast feature”, *Proceedings - 2002 IEEE International Conference on Multimedia and Expo, ICME 2002*, c. 1, ss. 113-116, 2002, doi: 10.1109/ICME.2002.1035731.
- [51] R. Panda, R. Malheiro, ve R. P. Paiva, “Audio Features for Music Emotion Recognition: A Survey”, *IEEE Trans Affect Comput*, c. 14, sy 1, ss. 68-88, Oca. 2023, doi: 10.1109/TAFFC.2020.3032373.
- [52] S. Dubnov, “Generalization of spectral flatness measure for non-Gaussian linear processes”, *IEEE Signal Process Lett*, c. 11, sy 8, ss. 698-701, Ağu. 2004, doi: 10.1109/LSP.2004.831663.
- [53] G. Sharma, K. Umapathy, ve S. Krishnan, “Trends in audio signal feature extraction methods”, *Applied Acoustics*, c. 158, s. 107020, Oca. 2020, doi: 10.1016/J.APACOUST.2019.107020.
- [54] “welch — SciPy v1.14.1 Manual”. Erişim: 11 Kasım 2024. [Çevrimiçi]. Erişim adresi: <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.welch.html#r34b375daf612-1>
- [55] “Audio Feature Extraction”. [Çevrimiçi]. Erişim adresi: <https://devopedia.org/audio-feature-extraction#Schutz-and-Vaisberg-2012>
- [56] “(480) Extracting the amplitude envelope feature from scratch in Python - YouTube”. Erişim: 11 Kasım 2024. [Çevrimiçi]. Erişim adresi: <https://www.youtube.com/watch?v=rlypsap6Wow>
- [57] T. Maka, “Audio content analysis based on density of peaks in amplitude envelope”, *2016 39th International Conference on Telecommunications and Signal Processing, TSP 2016*, ss. 331-334, Kas. 2016, doi: 10.1109/TSP.2016.7760891.
- [58] N. Agrawal, “Decoding the Symphony of Sound: Audio Signal Processing for Musical Engineering”, *Towards Data Science*. [Çevrimiçi]. Erişim adresi: <https://towardsdatascience.com/decoding-the-symphony-of-sound-audio-signal-processing-for-musical-engineering-c66f09a4d0f5>
- [59] “librosa.feature.chroma_stft — librosa 0.10.2.post1 documentation”. Erişim: 12 Kasım 2024. [Çevrimiçi]. Erişim adresi: https://librosa.org/doc/main/generated/librosa.feature.chroma_stft.html
- [60] R. Kumar, “Audio Features — The GenAI Guidebook”. [Çevrimiçi]. Erişim adresi: https://ravinkumar.com/GenAiGuidebook/audio/audio_feature_extraction.html
- [61] D. Ellis, “Chroma Feature Analysis and Synthesis”. [Çevrimiçi]. Erişim adresi: <https://www.ee.columbia.edu/~dpwe/LabROSA/matlab/chroma-ansyn/>
- [62] C. Schörkhuber, “Constant-Q Transform Toolbox for Music Processing”, doi: 10.5281/ZENODO.849741.
- [63] A. Medoued, A. Lebaroud, ve D. Sayad, “Application of Hilbert transform to fault detection in electric machines”, *Adv Differ Equ*, c. 2013, sy 1, ss. 1-7, Oca. 2013, doi: 10.1186/1687-1847-2013-2/FIGURES/4.

- [64] A. Bates, “Decibels Via Loudness — Distance Properties of a Loudspeaker”, *Phys Teach*, c. 52, sy 5, ss. 302-303, May. 2014, doi: 10.1119/1.4872415.
- [65] “Introduction to Audio - Fastaudio”, github.io. [Çevrimiçi]. Erişim adresi: <https://fastaudio.github.io/Introduction%20to%20Audio/>
- [66] L. Breiman, “Random forests”, *Mach Learn*, c. 45, sy 1, ss. 5-32, Eki. 2001, doi: 10.1023/A:1010933404324/METRICS.
- [67] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions”, *SN Comput Sci*, c. 2, sy 3, ss. 1-21, May. 2021, doi: 10.1007/S42979-021-00592-X/FIGURES/11.
- [68] T. Chen ve C. Guestrin, “XGBoost: A scalable tree boosting system”, *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, c. 13-17-August-2016, ss. 785-794, Ağu. 2016, doi: 10.1145/2939672.2939785/SUPPL_FILE/KDD2016_CHEN_BOOSTING_SYSTEM_01-ACM.MP4.
- [69] C. K. Kasaraneni, “Understanding XAI and EBM”, medium.com. [Çevrimiçi]. Erişim adresi: <https://medium.com/predmatic/understanding-xai-and-ebm-112bcc7babc3>
- [70] A. Shrestha ve A. Mahmood, “Review of deep learning algorithms and architectures”, *IEEE Access*, c. 7, ss. 53040-53065, 2019, doi: 10.1109/ACCESS.2019.2912200.
- [71] M. Gao, L. Ma, H. Liu, Z. Zhang, Z. Ning, ve J. Xu, “Malicious Network Traffic Detection Based on Deep Neural Networks and Association Analysis”, *Sensors* 2020, Vol. 20, Page 1452, c. 20, sy 5, s. 1452, Mar. 2020, doi: 10.3390/S20051452.
- [72] M. Sakwa vd., “Electric vehicle supply equipment monitoring and early fault detection through autoencoders”, *Sustainable Energy, Grids and Networks*, c. 40, s. 101497, Ara. 2024, doi: 10.1016/J.SEGAN.2024.101497.
- [73] H. Liu, B. Zhao, J. Guo, K. Zhang, ve P. Liu, “A lightweight unsupervised adversarial detector based on autoencoder and isolation forest”, *Pattern Recognit*, c. 147, s. 110127, Mar. 2024, doi: 10.1016/J.PATCOG.2023.110127.
- [74] M. Sundararajan, A. Taly, ... Q. Y. on machine, ve undefined 2017, “Axiomatic attribution for deep networks”, *proceedings.mlr.pressM Sundararajan, A Taly, Q YanInternational conference on machine learning, 2017•proceedings.mlr.press*, 2017, Erişim: 30 Ekim 2024. [Çevrimiçi]. Erişim adresi: <http://proceedings.mlr.press/v70/sundararajan17a.html>
- [75] S. M. Lundberg ve S. I. Lee, “A unified approach to interpreting model predictions”, *Adv Neural Inf Process Syst*, c. 2017-December, ss. 4766-4775, 2017.
- [76] A. S. Shaikh, R. M. Samant, K. S. Patil, N. R. Patil, ve A. R. Mirkale, “Review on Explainable AI by using LIME and SHAP Models for Healthcare Domain”, *Int J Comput Appl*, c. 125, sy 45, Kas. 2023, [Çevrimiçi]. Erişim adresi: <https://www.ijcaonline.org/archives/volume185/number45/shaikh-2023-ijca-923263.pdf>

- [77] M. Ribeiro, S. Singh, C. G.-P. of the 22nd ACM, ve undefined 2016, ““ Why should i trust you?’ Explaining the predictions of any classifier”, *dl.acm.orgMT Ribeiro, S Singh, C GuestrinProceedings of the 22nd ACM SIGKDD international conference on knowledge, 2016•dl.acm.org*, c. 13-17-August-2016, ss. 1135-1144, Ağu. 2016, doi: 10.1145/2939672.2939778.
- [78] “Explainable Boosting Machine — InterpretML”. [Çevrimiçi]. Erişim adresi: <https://interpret.ml/docs/ebm.html>
- [79] R. Muthukrishnan ve R. Rohini, “LASSO: A feature selection technique in predictive modeling for machine learning”, *2016 IEEE International Conference on Advances in Computer Applications, ICACA 2016*, ss. 18-20, Mar. 2017, doi: 10.1109/ICACA.2016.7887916.





ÖZGEÇMİŞ

Ad-Soyad: Betül Sena Çağlar

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Sakarya Üniversitesi, Bilgisayar ve Bilişim Bilimleri Fakültesi, Bilişim Sistemleri Mühendisliği
- **Lisans** : 2025, Anadolu Üniversitesi, İktisat Fakültesi, Siyaset Bilimi Ve Kamu Yönetimi
- **Yüksek Lisans** : 2025, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği

MESLEKİ DENEYİM:

- 2021-2024 yılları arasında Enforma Bilişim A.Ş.'de Veri Mühendisi olarak çalıştı.

TEZDEN TÜRETİLEN ESERLER:

- B. S. Çağlar ve D. Akgün, "Anomaly Detection in Industrial Machines Using Explainable AI and Acoustic Signals", içinde 4. International World Energy Conference, Kayseri, Ara. 2024.

DİĞER ESERLER:

- B. S. Çağlar, H. B. Ketmen, ve B. Bulut, "Anomaly Detection using Audio Signals", içinde *International Aegean Scientific Research Symposium 2021 (IASRS'21)*, Ara. 2021, ss. 321-330.
- B. S. Çağlar, H. B. Ketmen, ve B. Bulut, "End-to-End Integration of an Arduino Based Edge Device with Healthcare Analytics Platform", içinde *International Aegean Scientific Research Symposium 2021 (IASRS'21)*, Ara. 2021, ss. 332-341.
- B. S. Çağlar, H. B. Ketmen, ve B. Bulut, "Condition Monitoring on Renewable Energy Production with Application to Wind Generation", IECON Proceedings (Industrial Electronics Conference), c. 2022-Ekim, doi: 10.1109/IECON49645.2022.9968833.
- B. S. Çağlar, H. B. Ketmen, ve B. Bulut, "Wind Turbine Condition Monitoring Using Failure Analysis", ss. 391-399, 2023, doi: 10.1007/978-3-031-30171-1_42.
- M. Çom, B. Ketmen, S. Çağlar, S. Sultanoğlu, ve B. Bulut, "Container Based Distributed Simulation for Temperature Control in Textile Dyeing Processes", 9th 2023 International Conference on Control, Decision and Information Technologies, CoDIT 2023, ss. 439-444, 2023, doi: 10.1109/CODIT58514.2023.10284225.