



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA PROGRAMI

**HAFİF ELEKTRİKLİ ARAÇ MOTORLARINDA DERİN
ÖĞRENME TABANLI ARIZA TESPİTİ VE SINIFLANDIRILMASI**

DOKTORA TEZİ

Hadi ESMERAY

Birinci Danışman: Doç. Dr. Zafer DOĞAN

İkinci Danışman: Doç. Dr. İsmail İŞERİ

TOKAT- 2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Zafer DOĞAN danışmanlığında hazırlamış olduğum “Hafif Elektrikli Araç Motorlarında Derin Öğrenme Tabanlı Arıza Tespiti ve Sınıflandırılması” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../...

Hadi ESMERAY

JÜRİ KABUL VE ONAY

Hadi ESMERAY tarafından hazırlanan “**Hafif Elektrikli Araç Motorlarında Derin Öğrenme Tabanlı Arıza Tespiti ve Sınıflandırılması**” adlı tez çalışmasının savunma sınavı 19.12.2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı) İmzası

Üye (Danışman): Doç. Dr. Zafer DOĞAN

Üye (Başkan): Prof. Dr. Mahmut HEKİM

Üye : Prof. Dr. Ünal KURT

Üye : Doç. Dr. Bülent TURAN

Üye : Doç. Dr. Levent GÖKREM

ONAY

...../...../.....

Prof. Dr. Ercan ÇAÇAN
Lisansüstü Eğitim Enstitüsü Müdürü

ÖNSÖZ

Bu tez çalışmasının hazırlanmasında bilgi, deneyim ve yönlendirmeleriyle her aşamada bana rehberlik eden danışmanım Doç. Dr. Zafer DOĞAN'a ve ikinci danışmanım Doç. Dr. İsmail İŞERİ'ye en içten teşekkürlerimi sunarım.

Tez izleme sürecinde bilgi ve birikimleriyle destek olan Prof. Dr. Mahmut HEKİM ve Doç. Dr. Bülent TURAN'a teşekkür ederim.

Tez yazımı boyunca verdiği katkılardan dolayı Öğr. Gör. İlker GÜNAY'a teşekkür ederim.

Her zaman yanımda olan, arkadaşlıkları ve destekleriyle motivasyonuma güç katan Cihan ÇELİK ve Alperen DÜN'e teşekkür ederim.

Bugünlere gelmemde emeklerini esirgemeyen, destekleriyle her zaman yanımda olan anneme ve babama minnettarlığımı sunarım.

Maddi ve manevi destekleriyle her zaman yanımda olan abim ve kardeşime minnettarım.

Ve moral ve motivasyonu her daim yanımda olan kıymetli eşim Meltem ESMERAY'a, enerji ve neşe kaynaklarım canım kızlarım Meryem Rana ve Elif Nil'e sevgilerimi sunarım, iyi ki varsınız.

ÖZET

HAFİF ELEKTRİKLİ ARAÇ MOTORLARINDA DERİN ÖĞRENME TABANLI ARIZA TESPİTİ VE SINIFLANDIRILMASI

Esmeray, Hadi

Doktora, Elektrik Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Zafer DOĞAN

İkinci Danışman: Doç. Dr. İsmail İŞERİ

Aralık 2025, xvii + 163 sayfa

Son yıllarda, çevre dostu özellikleri ve ekonomik avantajları sayesinde Hafif Elektrikli Araçlar (HEA), ulaşım alanında önemli bir popülerlik kazanmıştır. Özellikle şehir içi kısa mesafeli ulaşımında elektrikli scooter'ların yaygınlaşması HEA motorlarının yüksek performansla ve güvenilir biçimde çalışmasını zorunlu hale getirmiştir. HEA'larda yaygın olarak Fırçasız Doğru Akım Motorları kullanılmaktadır. Dış ortamlarda kullanılan bu motorlar, çevresel koşulların yanı sıra termal, manyetik ve mekanik zorlanmalar sonucunda zamanla arızalanmaktadır. Bu durum, erken ve güvenilir arıza tespiti ihtiyacını ön plana çıkarmaktadır.

Bu tez çalışmasında, elektrikli scooter üzerinde gerçekleştirilen deneylerle elde edilen çok boyutlu ve hiyerarşik bir veri seti kullanılarak, motor arızalarının sınırlı veri koşullarında yüksek doğrulukla tespiti amacıyla iki farklı derin öğrenme yaklaşımı değerlendirilmiştir. Çalışmada; sağlam, rulman arızalı, mıknatıs arızalı ve çoklu (rulman-mıknatıs) arızalı motor durumları incelenmiştir. Her bir motor durumuna ait sinyaller, akı, akım, akustik, gerilim ve titreşim olmak üzere beş sensör ile kaydedilmiştir. Veri setinin hiyerarşik yapısı, arıza tipi ve sensör bilgisini içeren iki katmanlı klasör yapısıyla oluşturulmuş, böylece hem arıza türünün tespiti hem de her arıza için en ayırt edici sensör tipinin belirlenmesi sağlanmıştır.

Toplanan bu veri setinin derin öğrenme modelleri için kullanılabilmesi amacıyla çok aşamalı bir sinyal işleme süreci uygulanmıştır. Tek boyutlu zaman serisi sinyalleri Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması yöntemiyle İçsel

Mod Fonksiyonlarına (IMF) bileşenlerine ayrıştırılmış, daha sonra her IMF satırı Kısa Zamanlı Fourier Dönüşümü kullanılarak iki boyutlu spektrogramlara dönüştürülmüş ve veri artırma teknikleriyle çoğaltılmıştır.

Üretilen bu veri seti üzerinde iki farklı derin öğrenme yaklaşımı uygulanmıştır. İlk yaklaşımda, Parçacık Sürü Optimizasyonu (PSO) algoritması kullanılarak Evrişimli Sinir Ağının (CNN) mimari yapısı sıfırdan tasarlanmıştır. Bu süreçte katman sayısı, katman tipleri, katman sıralaması, filtre boyutları ve eğitim hiperparametreleri PSO tarafından optimize edilmiş, elde edilen mimari eğitilmiştir. İkinci yaklaşımda ise, önceden büyük ölçekli veri setlerinde eğitilmiş GoogLeNet, MobileNet-v2 ve ResNet-50 gibi derin ağ mimarileri Transfer Öğrenme (TL) yöntemlerinden fine-tuning (ince ayar) ile hedef veri setine uyarlanmıştır. Modellerin performansı, beş katlı çapraz doğrulama ile test edilmiş; doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru (F1 Score) metrikleri kullanılarak değerlendirilmiştir.

DeneySEL bulgular, hem PSO ile optimize edilen CNN mimarisinin hem de TL uygulanan ön eğitimli modellerin, çoklu motor arıza türlerinin sınıflandırılmasında yüksek başarı sağladığını ortaya koymuştur. Bu çalışma, sinyal işleme, optimizasyon ve TL yöntemlerinin bütüncül biçimde ele alınmasıyla, sınırlı veri koşullarında dahi güvenilir bir sınıflandırma performansı ortaya koyarak HEA motor arızalarını tespit etmede özgün bir çözüm sunmaktadır.

Anahtar Kelimeler: Arıza Tespiti, Derin Öğrenme, CNN, Transfer Öğrenme

ABSTRACT

DEEP LEARNING-BASED FAULT DETECTION AND CLASSIFICATION IN LIGHT ELECTRIC VEHICLE MOTORS

Esmeray, Hadi

PhD, Department of Electrical and Electronics Engineering

Advisor: Assoc. Prof. Dr. Zafer DOĞAN

Second Advisor: Assoc. Prof. Dr. İsmail İŞERİ

December 2025, xvii + 163 Pages

In recent years, Light Electric Vehicles (LEVs) have gained increasing popularity in the transportation industry due to their eco-friendly features and cost benefits. The widespread use of electric scooters, particularly for short-distance urban travel, has necessitated that LEV motors operate reliably and with high performance. Brushless Direct Current Motors are commonly used in LEVs. These motors, used in outdoor environments, fail over time due to environmental conditions as well as thermal, magnetic, and mechanical forces. This situation underscores the importance of early and reliable fault detection.

In this thesis study, two different deep learning approaches were evaluated to detect motor faults with high accuracy under limited data conditions, using a multidimensional and hierarchical dataset obtained from experiments conducted on an electric scooter. The study examined healthy motor conditions, bearing failures, magnet failures, and multiple (bearing-magnet) failures. Signals for each motor condition were recorded using five sensors: flux, current, acoustic, voltage, and vibration. The hierarchical structure of the dataset was created using a two-layer folder structure, which contains fault type and sensor information, thereby enabling both the detection of fault type and the determination of the most distinctive data type for each fault.

A multi-stage signal processing procedure was applied to enable the use of this collected dataset for deep learning models. One-dimensional time series signals were decomposed into Intrinsic Mode Function (IMF) components using the Complete Ensemble Empirical

Mode Decomposition with Adaptive Noise method. Subsequently, each IMF row was converted into two-dimensional spectrograms using the Short-Time Fourier Transform and replicated using data augmentation techniques.

Two different deep learning approaches were applied to this generated dataset. In the first approach, the architecture of the Convolutional Neural Network (CNN) was designed from scratch using the Particle Swarm Optimization (PSO) algorithm. During this process, the number of layers, layer types, layer order, filter sizes, and training hyperparameters were optimized by PSO, and the resulting architecture was trained. In the second approach, deep network architectures such as GoogLeNet, MobileNet-v2, and ResNet-50, which were previously trained on large-scale datasets, were adapted to the target dataset using fine-tuning methods from Transfer Learning (TL). The performance of the models was evaluated using five-fold cross-validation, with metrics including accuracy, precision, recall, and F1 score.

Experimental findings reveal that both the CNN architecture optimized with PSO and the pre-trained models with TL achieve high success in classifying multiple motor failure types. This study offers a unique solution for detecting LEV motor failures by comprehensively addressing signal processing, optimization, and TL methods, delivering reliable classification performance even under limited data conditions.

Keywords: Fault Detection, Deep Learning, CNN, Transfer Learning

İÇİNDEKİLER

ETİK SÖZLEŞME	ii
JÜRİ KABUL VE ONAY	iii
ÖNSÖZ.....	iv
ÖZET	v
ABSTRACT	vii
İÇİNDEKİLER.....	ix
TABLolar LİSTESİ	xii
ŞEKİL LİSTESİ	xiii
SİMGE VE KISALTMALAR.....	xvi
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETLERİ / KURAMSAL TEMELLER	8
2.1. Literatür Özetleri.....	8
2.2. Hafif Elektrikli Araçlar (HEA)	27
2.3. Elektrikli Araçlarda Kullanılan Motor Türleri.....	28
2.4. Fırçasız Doğru Akım Motorları (BLDC)	29
2.4.1. BLDC motorun yapısı	30
2.4.2. BLDC motorun matematiksel modeli	34
2.4.3. BLDC motorun çalışma prensibi.....	37
2.4.4. BLDC motor arızaları.....	38
2.5. Arıza Tespit Yöntemi.....	43
2.6. Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması (CEEMDAN)	44
2.7. Kısa Zamanlı Fourier Dönüşümü (STFT).....	46
2.8. Görüntü Verilerinin Çoğaltılması	48
2.9. Evrişimli Sinir Ağı (CNN).....	51
2.10. Parçacık Sürü Optimizasyonu (PSO).....	56
2.10.1. Temel kavramlar ve yapı.....	56
2.10.2. Matematiksel model	57
2.10.3. PSO özellikleri.....	58
2.11. Transfer Öğrenme (TL).....	59

3. MATERYAL VE YÖNTEM.....	61
3.1. Deney Düzenegi ve Veri Toplama.....	62
3.2. Arıza Durumlarının Oluşturulması	70
3.2.1. Rulman arızası.....	70
3.2.2. Mıknatıs arızası	71
3.2.3. Çoklu arıza (Mıknatıs-Rulman).....	72
3.3. Veri Seti Önışleme ve Dosya Yapısı.....	72
3.4. CNN Modeli Optimizasyonu	75
3.5. Parametre Kullanımı	80
3.6. İki Aşamalı Hiyerarşik Sınıflandırma Yöntemi	82
3.7. Transfer Öğrenme Uygulaması.....	84
4. BULGULAR VE TARTIŞMA.....	87
4.1. Çoklu Arıza Durum Tespiti.....	87
4.1.1. Eğitim performansının incelenmesi.....	87
4.1.2. Sınıflandırma performansının değeri.....	89
4.1.3. ROC eğrisi ve AUC değeri.....	91
4.1.4. Performans metrikleri.....	93
4.1.5. Sensör türüne göre sınıflandırma.....	95
4.2. Mıknatıs Arızası Durum Tespiti.....	98
4.2.1. Eğitim performansının incelenmesi.....	98
4.2.2. Sınıflandırma performansının değeri.....	100
4.2.3. ROC eğrisi ve AUC değeri.....	101
4.2.4. Performans metrikleri.....	103
4.2.5. Sensör türüne göre sınıflandırma.....	105
4.3. Rulman Arızası Durum Tespiti	109
4.3.1. Eğitim performansının incelenmesi.....	109
4.3.2. Sınıflandırma performansının değeri.....	111
4.2.3. ROC eğrisi ve AUC değeri.....	112
4.2.4. Performans metrikleri.....	114
4.2.5. Sensör türüne göre sınıflandırma.....	115
4.4. Arıza Sınıflandırması	119
4.4.1. Eğitim performansının incelenmesi.....	120

4.4.2. Sınıflandırma performansının değerlendirilmesi.....	122
4.4.3. ROC eğrisi ve AUC değeri.....	124
4.4.4. Performans metrikleri.....	125
4.4.5. Sensör türüne göre sınıflandırma.....	128
5. SONUÇ VE ÖNERİLER.....	133
KAYNAKLAR.....	136
ÖZGEÇMİŞ.....	163



TABLÖLER LİSTESİ

Çizelge 2.1. Elektrikli araçlarda kullanılan motor türlerinin temel özellikleri	29
Çizelge 2.2. BLDC motorun matematiksel modelinde kullanılan parametreler.....	37
Çizelge 2.3. Çalışmada kullanılan ön eğitilmiş modeller ve özellikleri.....	55
Çizelge 3.1. BLDC motorun özellikleri.....	64
Çizelge 3.2. Toplanan ham verilerin özellikleri	66
Çizelge 3.3. Deneysel veri setinde çalışma durumları, arıza tipleri ve toplanan sinyal türleri.....	69
Çizelge 3.4. Spektrogramların veri artırma işleminden önceki ve sonraki sayıları	73
Çizelge 3.5. PSO algoritması başlatma değerleri	76
Çizelge 3.6. Model optimizasyonu için başlangıç referans aralıkları.....	77
Çizelge 3.7. Referans aralıkları.....	80
Çizelge 3.8. PSO mimarisinin katman sayıları	81
Çizelge 3.9. Eğitim için kullanılan hiperparametreler.....	81
Çizelge 3.10. Kullanılan modeller için TL eğitim parametreleri.....	86
Çizelge 4.1. Çoklu arıza durum tespitinde AUC test değerleri	92
Çizelge 4.2. Çoklu arıza durum tespiti için modellere ait performans metrikleri	93
Çizelge 4.3. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları.....	95
Çizelge 4.4. Mıknatıs arızası durum tespitinde AUC test değerleri	102
Çizelge 4.5. Mıknatıs arızası durum tespiti için modellere ait performans metrikleri .	103
Çizelge 4.6. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları.....	105
Çizelge 4.7. Rulman arızası durum tespitinde AUC test değerleri.....	113
Çizelge 4.8. Rulman arızası durum tespiti için modellere ait performans metrikleri ...	114
Çizelge 4.9. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları.....	116
Çizelge 4.10. Arıza sınıflandırmada AUC test değerleri	124
Çizelge 4.11. Arıza sınıflandırmada modellere ait performans metrikleri	125
Çizelge 4.11. (Devam) Arıza sınıflandırmada modellere ait performans metrikleri	126
Çizelge 4.12. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları.....	128

ŞEKİL LİSTESİ

Şekil 2.1. Elektrikli scooter.....	27
Şekil 2.2. BLDC motor	30
Şekil 2.3. BLDC motor bileşenleri	31
Şekil 2.4. Stator yapısı	32
Şekil 2.5. HEA BLDC'nin Hub rotor yapısı.....	33
Şekil 2.6. BLDC motorun sargı bağlantısı.....	34
Şekil 2.7. BLDC motor modelinin koordinat sisteminde gösterimi	35
Şekil 2.8. BLDC Motor Arıza Dağılımları	38
Şekil 2.9. Arıza sınıflandırma yöntemi	43
Şekil 2.10. Ham titreşim sinyalleri	45
Şekil 2.11. Titreşim arızalı ham sinyalin IMF bileşenlerine ayrıştırılmış gösterimi	46
Şekil 2.12. IMF bileşenlerine STFT uygulanmasıyla elde edilen spektrogramlar	48
Şekil 2.13. Orijinal ve döndürme işlemi uygulanmış örnek görüntü.....	49
Şekil 2.14. Orijinal ve öteleme işlemi uygulanmış örnek görüntü	49
Şekil 2.15. Orijinal ve yakınlaştırma işlemi uygulanmış örnek görüntü	49
Şekil 2.16. Orijinal ve renk değiştirme işlemi uygulanmış örnek görüntü	50
Şekil 2.17. Orijinal ve çevirme işlemi uygulanmış örnek görüntü	50
Şekil 2.18. Orijinal ve gürültü işlemi uygulanmış örnek görüntü	51
Şekil 2.19. Çoğaltma işlemi sonrası veri setinden rastgele seçilmiş örnek görüntüler... 51	
Şekil 2.20. CNN yapısı	52
Şekil 2.21. Ön eğitilmiş CNN Mimarileri	55
Şekil 2.22. PSO algoritması akış diyagramı	58
Şekil 3.1. Önerilen yöntemin blog diyagramı.....	61
Şekil 3.2. Deney düzeneği	63
Şekil 3.3. Veri toplama blok	63
Şekil 3.4. Deney aşamasında elektrikli scooter'a ait hız-zaman grafiği.....	65
Şekil 3.5. Sağlam durumda boşta çalışma koşulu için toplanan sinyaller	67
Şekil 3.6. Sağlam durumda yüksüz bant koşulu için toplanan sinyaller.....	67
Şekil 3.7. Sağlam durumda yüklü bant koşulu için toplanan sinyaller.....	68
Şekil 3.8. Sağlam ve arızalı rulmanların üstten görüntüsü	70

Şekil 3.9. Mıknatıs arızası oluşturulduktan sonra yapılan ölçüm	71
Şekil 3.10. Sağlam mıknatıs ölçüm değeri	71
Şekil 3.11. Oluşturulan veri seti için klasör yapısı	74
Şekil 3.12. Parçacıkların CNN mimarisini temsil eden gösterimi	77
Şekil 3.13. <i>Pbest</i> ve <i>Gbest</i> 'in hesaplanması	78
Şekil 3.14. <i>Pbest</i> ve <i>Gbest</i> referans değere göre hesaplanması	79
Şekil 3.15. PSO tarafından güncellenmiş katman yapısı	79
Şekil 3.16. Hiyerarşik klasör yapısı	83
Şekil 3.18. Hiyerarşik sınıflandırma yapısının akış diyagramı	84
Şekil 4.1. Çoklu arıza durum tespiti PSO-CNN eğitim ve doğrulama grafiği	88
Şekil 4.2. Çoklu durum arıza tespiti GoogLeNet eğitim ve doğrulama grafiği	89
Şekil 4.3. Çoklu arıza durum tespiti için PSO-CNN'e ait karışıklık matrisi	90
Şekil 4.4. Çoklu arıza durum tespiti için GoogLeNet'e ait karışıklık matrisi	90
Şekil 4.5. Çoklu arıza durum tespiti için PSO-CNN'e ait ROC eğrisi	91
Şekil 4.6. Çoklu arıza durum tespitinde modellerin genel başarı düzeyleri	94
Şekil 4.7. Mıknatıs arızası durum tespiti PSO-CNN eğitim ve doğrulama grafiği	98
Şekil 4.8. Mıknatıs arızası durum tespiti GoogLeNet eğitim ve doğrulama grafiği	99
Şekil 4.9. Mıknatıs arızası durum tespiti için PSO-CNN'e ait karışıklık matrisi	100
Şekil 4.10 Mıknatıs arızası durum tespiti için GoogLeNet'e ait karışıklık matrisi	101
Şekil 4.11. Mıknatıs arızası durum tespiti için PSO-CNN'e ait ROC eğrisi	102
Şekil 4.12. Mıknatıs arızası durum tespitinde modellerin başarı grafiği	104
Şekil 4.13. Rulman arızası durum tespiti PSO-CNN eğitim ve doğrulama grafiği	109
Şekil 4.14. Rulman arızası durum tespiti GoogLeNet eğitim ve doğrulama grafiği	110
Şekil 4.15. Rulman arızası durum tespiti için PSO-CNN'e ait karışıklık matrisi	111
Şekil 4.16. Rulman arızası durum tespiti için GoogLeNet'e ait karışıklık matrisi	111
Şekil 4.17. Rulman arızası durum tespiti için PSO-CNN'e ait ROC eğrisi	112
Şekil. 4.18. Rulman arızası durum tespitinde modellerin başarı grafiği	115
Şekil 4.19. Arıza sınıflandırmasında PSO-CNN'e ait eğitim ve doğrulama grafiği	120
Şekil 4.20. Arıza sınıflandırmasında GoogLeNet'e ait eğitim ve doğrulama grafiği ...	121
Şekil 4.21. Arıza sınıflandırmasında PSO-CNN modeli için karışıklık matrisi	122
Şekil 4.22. Arıza sınıflandırmasında GoogLeNet mimarisinin karışıklık matrisi	123
Şekil 4.23. Arıza sınıflandırmasında kullanılan PSO-CNN modeline ait ROC eğrisi .	124

Şekil 4.24. Arıza sınıflandırmada modellere ait başarı grafiği 127



SİMGE VE KISALTMALAR

Kısaltma	Açıklama
.m4a	MPEG-4 Audio File
.mat	MATLAB data file
.tdms	Test Data Management Streaming (NI veri formatı)
1D	One-Dimensional (Tek boyutlu)
2D	Two-Dimensional (İki boyutlu)
ABC	Artificial Bee Colony (Yapay Arı Kolonisi)
ANN	Artificial Neural Network (Yapay Sinir Ağı)
AUC	Area Under Curve (Eğri Altı Alan)
BLDC	Brushless Direct Current (Fırçasız Doğru Akım Motoru)
BO	Bayesian Optimization (Bayesyen Optimizasyon)
BPFO	Ball Pass Frequency Outer (Dış Bilezik Arıza Frekansı)
CEEMDAN	Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması)
CNN	Convolutional Neural Network (Evrişimli Sinir Ağı)
CWRU	Case Western Reserve University
CWT	Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
DT	Decision Tree (Karar Ağacı)
DWT	Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
EA	Elektrikli Araç
EEMD	Ensemble Empirical Mode Decomposition (Toplu Empirik Mod Ayırıştırma)
EMD	Empirical Mode Decomposition (Empirik Mod Ayırıştırma)
FFT	Fast Fourier Transform (Hızlı Fourier Dönüşümü)
FT	Fourier Transform (Fourier Dönüşümü)
GA	Genetic Algorithm (Genetik Algoritma)
GAN	Generative Adversarial Network (Üretken Çekişmeli Ağlar)
Gbest	Global Best (PSO küresel en iyi)
GRU	Gated Recurrent Unit (Geçitli Tekrarlayan Birim)

GWO	Grey Wolf Optimization (Gri Kurt Optimizasyonu)
HEA	Hafif Elektrikli Araç
Hz	Hertz (Frekans birimi)
IM	Induction Motor (İndüksiyon Motoru)
IMF	Intrinsic Mode Function (İçsel Mod Fonksiyonu)
k-NN	k-Nearest Neighbors (En Yakın Komşu Algoritması)
LEV	Light Electric Vehicle (Hafif Elektrikli Araç)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MCSA	Motor Current Signature Analysis (Motor Akımı İmza Analizi)
MLP	Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
NB	Naive Bayes
Pbest	Personal Best (PSO kişisel en iyi)
PMSM	Permanent Magnet Synchronous Motor (Daimi Mıknatıslı Senkron Motor)
PSO	Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)
PV	Parking Vector (Park Vektörü)
ReLU	Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RNN	Recurrent Neural Networks (Tekrarlayan Sinir Ağları)
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SGDM	Stochastic Gradient Descent with Momentum
SRM	Switched Reluctance Motor (Anahtarlama Relüktans Motor)
STFT	Short-Time Fourier Transform (Kısa Zamanlı Fourier Dönüşümü)
SVM	Support Vector Machine (Destek Vektör Makineleri)
TL	Transfer Learning (Transfer Öğrenme)
WT	Wavelet Transform (Dalgacık Dönüşümü)
VMD	Variational Mode Decomposition
WVD	Wigner-Ville Distribution (Wigner-Ville Dağılımı)

1. GİRİŞ

Son yıllarda teknolojinin hızlı gelişmesi ve buna paralel olarak artan dünya nüfusu, fosil yakıtların sınırlılığı ve bu yakıtların çevreye olan olumsuz etkileri, elektrikli araçlara duyulan ilgiyi önemli ölçüde artırmıştır (Muratori ve ark., 2021; Sanguesa ve ark., 2021). Özellikle kısa mesafeli ulaşımında ekonomik ve çevreci bir alternatif sunan Hafif Elektrikli Araçlar (HEA), elektrikli bisikletlerden elektrikli scooter'lara kadar uzanan farklı yapılarıyla günlük yaşamda kendilerine giderek daha fazla yer bulmaktadır (Sanguesa ve ark., 2021). HEA'larda tahrik için, içten yanmalı motorlar yerine elektrik motorları kullanılır. Bu araçlar, enerji kaynağı olarak görev yapan batarya seti, tahrik gücünü sağlayan bir veya birden fazla elektrik motoru ve bu motorların kontrolünü gerçekleştiren motor sürücülerinden meydana gelir (Aloeyi ve ark., 2022).

HEA'ların yaygınlaşmasıyla birlikte, bu araçlarda kullanılan bileşenlerin güvenilirliği ve performansı giderek daha önemli bir hale gelmiştir. Bu araçlarda Daimi Mıknatıslı Senkron Motorlar (PMSM), İndüksiyon Motorları (IM), Anahtarlama Relüktans Motor (SRM) ve Fırçasız Doğru Akım Motorları (BLDC) kullanılmaktadır. Son yıllarda ise performans, düşük ses seviyesi, motor verimi, bakım gerektirmeyen uzun ömürleri ve düşük arıza oranları sayesinde BLDC motorlar daha çok tercih edilmektedir (Krishnamoorthy & Panikkar, 2024; Rimpas ve ark., 2023). Bu motorlarda zaman içerisinde çevresel faktörler, elektriksel zorlanmalar, mekanik temelli arızalar, termal ve manyetik etkiler nedeniyle çeşitli arızalar ortaya çıkmaktadır. Bu arızaların başında, sargı arızaları, rulman arızaları ve manyetik arızalar yer almaktadır. Bu arızalardan birinin oluşması, çoğu zaman diğer arızaların da meydana gelmesini tetikleyebilmektedir (Faiz & Mazaheri-Tehrani, 2017; Usman & Rajpurohit, 2019). Bu arızaların erken tespiti, sistemin devamlılığı, bakım maliyetlerinin azaltılması, zamansal ve ekonomik kayıpların önlenmesi açısından büyük önem taşımaktadır (Usman & Rajpurohit, 2019).

Günümüzde şehirlerde, belediye hizmetleri olarak bisiklet veya scooter gibi HEA'lar kısa süreli kiralama yoluyla insanlara ulaşım aracı olarak sunulmaktadır. Kullanıcılar, bu araçları bir istasyondan kiralayıp diledikleri başka bir istasyona bırakabilmektedir. İstasyonda park edilen HEA'ların sensörleri aracılığıyla farklı veri türleri toplanmaktadır.

Daha sonra bu veriler merkezi bir bakım-onarım istasyonuna iletilmektedir (Ewert ve ark., 2020). Bir merkezden izlenen HEA'lardan, internet veri transferinin zorluğu nedeniyle sınırlı sayıda veri toplanabilmektedir. HEA arızalarının tespitinde sınırlı veriyle yüksek doğruluklu sınıflandırma istenen bir durumdur. Ayrıca, HEA verileri, arıza bileşenlerinin yanı sıra birçok harmonik bileşeni de içermektedir. Bu durum arıza tespitini zorlaştırmaktadır (Khan ve ark., 2023).

Arıza sınıflandırmaları için kaçak akı, akım, akustik, gerilim ve titreşim sinyalleri gibi farklı veri türlerinden yararlanılmaktadır. Bu sinyaller, motor bileşenlerinin davranışları hakkında zengin bilgiler içermekle birlikte doğrusal olmayan yapıda bulunmaktadır. Bu nedenle bu verilerden anlamlı bilgiler çıkarabilmek için gelişmiş sinyal işleme yöntemleri ve makine öğrenmesi tabanlı yaklaşımların bir arada kullanılması gerekmektedir (Xu ve ark., 2024).

Elektrik motorlarında arıza sınıflandırmalarında; zaman veya frekans boyutundaki istatistiksel yöntemler, model tabanlı yöntemler ve veri odaklı makine öğrenmesi yöntemleri kullanılmaktadır (Anbalagan ve ark., 2023; Jiang ve ark., 2024). Makine öğrenmesi yöntemleri ise genel olarak iki başlıkta incelenir. İlki, uzman bilgisine dayalı geleneksel yöntemler; ikincisi arızaların oluşturduğu karakteristik özellikleri veri üzerinden belirleyen yeni nesil yöntemlerdir (Huang ve ark., 2022). İlki olan geleneksel yöntemlerin başında Bulanık Mantık (FL), Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (SVM) gibi uzman bilgisine dayanan sınıflandırma yaklaşımları yer almaktadır (Zhang ve ark., 2020). Bu yöntemler çoğunlukla manuel özellik çıkarımına bağlı olduğu için hem zaman alıcıdır hem de özelliğin seçimine bağlı olarak hata yapma riskini artırmaktadır (Samanta & Al-Balushi, 2003; Saufi ve ark., 2019). Ayrıca yüksek boyutlu, gürültülü ve karmaşık sinyal yapılarında manuel çıkarılan özelliklerin ayırt ediciliği azaldığından bu yöntemlerin etkinliği sınırlı kalmaktadır (Huang ve ark., 2022). İkincisi ise uzman bilgisi gereksinimini azaltan, yüksek boyutlu verilerden karakteristik özellikleri otomatik olarak çıkarabilen Derin Öğrenme (DL) tabanlı yaklaşımlardır. DL yöntemleri arasında Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Süreli Bellek (LSTM), Geçitli Tekrarlayan Birim (GRU), Üretken Çekişmeli Ağlar (GAN) ve Evrişimli Sinir Ağları (CNN) gibi yapılar yer almaktadır (Hussain, 2024).

CNN'ler 1D sinyal ve 2D görüntü verilerinde bulunan örüntüleri otomatik olarak öğrenebilen güçlü DL modelleridir. Aynı zamanda, manuel özellik çıkarımına ihtiyaç duymamaları ve karmaşık yapıları doğrudan veriden öğrenebilmeleri sayesinde son yıllarda arıza sınıflandırmalarında yaygın olarak kullanılmaktadır (Hussain, 2024; Zhang ve ark., 2020). HEA'lardan toplanan verilerin doğrusal olmayan bir yapıda olması ve bu tür verilerden ayırt edici özelliklerin çıkarılmasında CNN tabanlı yaklaşımlar öne çıkmaktadır. Bununla birlikte, CNN tabanlı modeller güvenilir sonuçlar üretebilmek için geniş ve dengeli veri setlerine ihtiyaç duymaktadır. HEA uygulamalarında ise verinin sınırlı olması, CNN modellerinde aşırı öğrenme (overfitting) riskini artırarak sınıflandırma performansını olumsuz etkileyebilmektedir. Bu sorunu azaltmak için literatürde yaygın olarak veri artırma yöntemlerine başvurulmaktadır (Maharana ve ark., 2022).

Sınırlı veri ile çalışan sistemlerde modelin genelleme başarısını artırmak amacıyla gelişmiş sinyal işleme teknikleri ve veri artırma yöntemlerinin birlikte kullanılması gerekmektedir (Li ve ark., 2021). Bu noktada, sinyal işleme tabanlı veri artırma yaklaşımlarının önemli bir kısmı, doğrudan zaman boyutundaki sinyallerin daha ayrıntılı bileşenlerine ayrıştırılmasına dayanmakta olup, bu amaçla kullanılan en etkili yöntemler sinyal ayrıştırma teknikleridir. Bu yöntemlerin başında, Deneysel Mod Ayrıştırma (EMD) yer almaktadır. EMD, sinyallerin daha ayrıntılı ve anlamlı özelliklerinin ortaya çıkarılması ve sınırlı sayıdaki verinin artırımı ve filtrelenmesi amacıyla, kullanılan temel yaklaşımlardan biridir. Bu yöntem, sinyalin farklı frekans bileşenlerine ayrılmasını sağlayarak arıza tespitinde kullanılan temel öznitelikleri belirlemiştir (Lei ve ark., 2013). EMD, bir sinyali İçsel Mod Fonksiyonlarına (IMF) ayırır. Her IMF, sinyalin temel frekans bileşenlerinden birini temsil etmektedir. Ancak, EMD'nin mode kaydırma adı verilen iki veya daha fazla frekans bileşenini tek bir IMF'de tutması, veriye duyarlılığı ve ayrıştırma sayısı gibi bazı sınırlamaları, özellikle mod karışımı (mode mixing) sorununu ortaya çıkarmış ve bu sorunun üstesinden gelebilmek için Toplu Empirik Mod Ayrıştırma (EEMD) geliştirilmiştir (Jin & Vai, 2014; Torres ve ark., 2011). EEMD, gürültüye dayanıklı ayrıştırma yaparak EMD'nin dezavantajlarını önemli ölçüde azaltmış ve daha güvenilir modlar üretmiştir. Bununla birlikte, EEMD'nin yine de bazı durumlarda yeterli ayrıştırmayı yapamaması, sinyallerde daha yüksek doğrulukla bileşenlerin elde

edilmesini sağlayan Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması (CEEMDAN) yönteminin geliştirilmesine yol açmıştır (Lei ve ark., 2015). CEEMDAN, sinyalleri gürültü uyarlamalı olarak ayırıştırarak, arıza tespitinde daha hassas frekans ve zaman bilgileri sunmuş ve elde edilen modların daha anlamlı bilgiler içerdiğini göstermiştir (Wu & Huang, 2009). Torres ve ark. (Torres ve ark., 2011) tarafından önerilen CEEMDAN, her aşamada rastgele beyaz gürültü örnekleri ekleyerek sinyali ayırıştırır ve her bir IMF çıkarımından sonra sinyalde benzersiz bir kalıntı bırakır. IMF sayıları, sinyalin karmaşıklığı ve seçilen analiz yöntemine göre değişmektedir (Li & Wang, 2020). CEEMDAN uygulaması sonucunda artık (residual) sinyalin ana sinyalden uzaklaştırılması, sinyalin daha temiz ve filtrelenmiş bir hale gelmesini sağlamaktadır. Ayrıca CEEMDAN ile elde edilen IMF bileşenleri, veri artırma süreçlerinde kullanılabilen zengin ve anlamlı sinyal yapıları sunmaktadır (Huang ve ark., 2021; Singh & Harsha, 2019).

1D sinyallerin CNN tabanlı olarak işlenebilmesi için, bu sinyallerin 1D formdan 2D bir zaman-frekans domenine dönüştürülmesi gerekmektedir. Bu amaçla, Kısa Zamanlı Fourier Dönüşümü (STFT), Dalgacık Dönüşümü (WT), Hilbert-Huang Dönüşümü (HHT), Wigner-Ville Dağılımı (WVD) ve bunun gibi zaman-frekans dönüşümleri kullanılmaktadır (Nagarajaiah & Basu, 2009; Randall, 1987). Bu yöntemler, sinyaldeki ani değişimleri, süresiz davranışları veya frekans içeriğini zaman eksenine bağlı olarak ortaya çıkarmakta ve böylece CNN modelleri için anlamlı 2D görseller elde edilmesini sağlamaktadır. Her yöntemin incelenen sinyalin yapısına bağlı olarak kendine özgü avantajları ve sınırlılıkları bulunmaktadır. Örneğin, WT çok ölçekli analiz yeteneği sağlar, HHT adaptiftir ve doğrusal olmayan sinyallerde güçlüdür, WVD ise yüksek zaman-frekans çözünürlüğü sunmakla birlikte çapraz terim problemi oluşturmaktadır (Rastegaeva ve ark., 2022; Scholl, 2021). Bu dönüşümler arasında STFT, ani frekans değişimlerini ve geçici sinyal davranışlarını güçlü bir şekilde yansıtarak uygulamada kolaylık sağlaması nedeniyle arıza sınıflandırma çalışmalarında en yaygın tercih edilen yöntemlerden biri olmuştur (Liu ve ark., 2016; Mehala & Dahiya, 2008).

CNN'in ihtiyaç duyduğu veri miktarına 1D sinyal tabanlı veri çoğaltma ile ulaşmak mümkün değildir. Bu sorun, sinyallerden elde edilen 2D görüntüler kullanılarak ve bu

görüntüler üzerinde uygulanan veri artırma teknikleriyle aşılmaktadır. Bu nedenle kısıtlı miktardaki veri setlerinin farklı tekniklerle çoğaltılması (augmentation) yaygın bir çözüm olarak kullanılmaktadır (Chlap ve ark., 2021; Maharana ve ark., 2022). Bu sürecin temel amacı, verinin yapısal özelliklerini korurken, modele ek çeşitlilik kazandırmaktır. Bu nedenle görüntüler üzerinde uygulanan dönüşümlerin bozulma miktarı ne çok düşük ne de aşırı yüksek olmalıdır. Bozulmanın yetersiz olması modelin veri setine aşırı öğrenme yapmasına, aşırı bozulma ise veri bütünlüğünün kaybolmasına ve sınıflandırma performansının düşmesine neden olabilmektedir (Maharana ve ark., 2022; Srivastava ve ark., 2014). Bu durumun üstesinden gelmek için 2D görüntüler, uygun veri artırma teknikleriyle çeşitlendirilmekte ve böylece sınırlı veri probleminin olumsuz etkileri önemli ölçüde azaltılmaktadır (Li ve ark., 2021).

Son yıllarda farklı derin öğrenme mimarilerinin karmaşık problem çözme algoritmalarıyla birleştirilmesiyle geliştirilen hibrit modeller; doğruluk oranlarını artırmaları, yüksek genelleme yetenekleri ve farklı veri türlerinde gösterdikleri üstün performanslar sayesinde mühendislik ve birçok bilim alanında önemli katkılar sağlamıştır (Jena ve ark., 2021). Bu yapılar, sadece teorik prensiplere değil aynı zamanda gerçek dünya senaryolarında karşılaşılan belirsizlikler ve kısıtlamaları da referans alarak, pratik uygulamalara uygun esnek ve uyarlanabilir çözümler üretmektedir (Ahmed ve ark., 2023).

Optimizasyon temelli çalışan bu algoritmalar, matematiksel ve sezgisel yöntemler kullanmaktadır. Matematiksel yöntemler çözüm uzayını kapsamlı olarak taradığı için hesaplama maliyetlerini artırırken, sezgisel yöntemler problemin çözümüne daha hızlı ve daha düşük maliyetle ulaşmayı mümkün kılmaktadır (Tomar ve ark., 2024; Zou, 2025). Bu nedenle son yıllarda yapılan çalışmalar, sezgisel optimizasyon algoritmalarının özellikle derin öğrenme tabanlı modellerde daha yüksek başarı ve daha iyi arama performansı sunduğunu göstermektedir (Çelik ve ark., 2019).

Derin öğrenme modellerinde kullanılan hibrit mimariler, çok sayıda parametrenin doğru ve dengeli şekilde ayarlanmasını gerektirmektedir. Bu parametreler, optimizasyon ve model tasarımı parametreleri olarak ikiye ayrılmaktadır. Literatürde, birçok farklı

optimizasyon tekniklerinin bulunması araştırmacılara geniş bir esneklik sağlarken, aynı zamanda belirli bir problem için en uygun yöntemin seçilmesini zorlaştırmaktadır. Bu nedenle, CNN modelinin belirsizliğini azaltmak ve performansını artırmak amacıyla optimizasyon süreçlerinde en çok doğadan ilham alınan popülasyon temelli metasezgisel algoritmalar tercih edilmektedir (Tomar ve ark., 2024). Bu algoritmaların başında, Yapay Arı Kolonisi (ABC), Parçacık Sürü Optimizasyonu (PSO), Gri Kurt Optimizasyonu (GWO) ve Genetik Algoritma (GA) gelmektedir. Bu yöntemler arasında PSO, basit yapısı ve hızlı yakınsama özelliği sayesinde arama uzayında yüksek performans göstermesi nedeniyle optimizasyon için en sık tercih edilen algoritmalarından biri haline gelmiştir (Baçanin ve ark., 2021; Oyelade ve ark., 2025; Saifullah ve ark., 2025).

Görüntü tabanlı analizlerde kullanılan derin öğrenme yöntemleri geniş veri kümelerinde yüksek başarı elde edebilmekte; ancak bu yöntemler uzun eğitim süreleri ve yüksek hesaplama maliyetleri gerektirmektedir. Bu süreyi azaltmak ve sınırlı veri problemini aşmak için Transfer Öğrenme (TL) yaklaşımı kullanılmaktadır. TL, geniş ölçekli veri setleri üzerinde önceden eğitilmiş modellerin, farklı veri setleri üzerinde yeniden kullanılmasıyla eğitim süresini kısaltarak performansı artırmayı amaçlamaktadır. TL'nin önemli bir aşaması olan fine-tuning, önceden eğitilmiş bir modelin ağırlıklarının düşük öğrenme oranlarıyla yeniden eğitilmesi yoluyla modelin yeni göreve uyum sağlamasını mümkün kılar; böylece model hem önceki bilgi birikimini korur hem de hedef veri setine özgü özellikleri öğrenebilir (Shinde ve ark., 2021; Vrbancic & Podgorelec, 2020).

Bu tez çalışmasının amacı, HEA'larda sınırlı veri koşullarında çok sensörlü bir yaklaşım kullanarak arızaların yüksek doğrulukla tespit ve sınıflandırılmasını sağlamaktır. Bu amacı gerçekleştirmek için HEA motor arızalarının erken ve güvenilir biçimde sınıflandırılmasında özgün bir yöntem önerilmiştir. Bu yöntem; veri ön işleme, model optimizasyonu ve TL, eğitim ve test işlemleri ile değerlendirme ve sınıflandırma bloğu olmak üzere dört aşamada gerçekleştirilmiştir. Çalışmada, scooter üzerinde gerçekleştirilen deneylerle üç farklı çalışma koşulu altında (motor boşta, bant üzerinde yüksüz ve bant üzerinde yüklü) motor sinyalleri toplanmış; sağlam, rulman arızalı, mıknaatıs arızalı ve çoklu (rulman-mıknaatıs) arızalı durumları kaydedilmiştir. Her bir motor durumu için akı, akım, akustik, gerilim ve titreşim olmak üzere beş farklı sensörden

veriler toplanmıştır. Bu veriler dört adımda işlenmiştir. Birinci adımda, toplanan bu ham sinyaller, CEEMDAN yöntemiyle IMF bileşenlerine ayrıştırılmıştır. Böylece hem filtreleme hem de sinyal tabanlı veri artırma işlemi gerçekleştirilmiştir. Her bir IMF matrisi, STFT ile spektral görüntülere dönüştürülmüş ve elde edilen görüntüler veri artırma teknikleriyle çoğaltılmıştır. Devamında, yeniden boyutlandırma işlemi yapılarak veri seti hazır hale getirilmiştir. İkinci adımda, iki farklı yöntem değerlendirilmiştir: PSO algoritması ile sıfırdan optimize edilen özel CNN mimarisi ve TL yaklaşımıyla uyarlanmış ön eğitilmiş mimariler. Elde edilen veri seti, PSO algoritması ile optimize edilerek en başarılı CNN modeli oluşturulmuştur. Üçüncü adımda, elde edilen parametre değerleri ile veri seti hem PSO-CNN modelinde hem de TL bloğunda kullanılarak eğitim ve test işlemleri gerçekleştirilmiştir. TL işlemleri için, bu kapsamda yaygın olarak kullanılan GoogLeNet, MobileNet-v2 ve ResNet-50 mimarileri tercih edilmiştir. Son adımda, PSO-CNN modeliyle birlikte TL’de kullanılan modellerin performans metrikleri, ROC ve AUC değerleri, karışıklık matrisleri ve başarı-kayıp grafikleri elde edilmiştir.

Tezin ikinci bölümünde, literatürde yer alan çalışmalar ayrıntılı biçimde sunulmuş devamında kuramsal bilgiler verilmiştir. Üçüncü bölümde, çalışmada kullanılan yöntemler, ön işleme adımları, deney düzeneğinin kurulumu, veri setinin oluşturulma süreci ve geliştirilen yaklaşım detaylı olarak açıklanmıştır. Dördüncü bölümde, elde edilen verilerin önerilen yöntemlerle deneysel olarak uygulanması, bu uygulamalardan elde edilen sonuçların analizi ve deneysel bulgular anlatılmıştır. Beşinci ve son bölümde ise çalışmanın sonuçları özetlenerek gelecekte gerçekleştirilebilecek araştırmalara yönelik öneriler sunulmuştur.

2. LİTERATÜR ÖZETLERİ / KURAMSAL TEMELLER

2.1. Literatür Özetleri

Bu bölümde sunulan literatür özetleri, giriş bölümündeki akış düzeninde yapılmıştır. Literatür incelemesi sırasıyla, HEA'lar ve önemi, HEA'larda karşılaşılan arızalar, HEA motor sistemleri ve arızaları, motor arızası sınıflandırmalarında kullanılan sensör türleri, geleneksel arıza teşhis yöntemleri, makine öğrenmesi tabanlı arıza teşhis yöntemleri, meta-sezgisel optimizasyon tekniklerinin arıza teşhisinde kullanımı, zaman-frekans analizi tabanlı sinyal işleme yöntemleri, veri artırma teknikleri, derin öğrenme tabanlı arıza teşhis yöntemleri ve TL yaklaşımları şeklinde sunulmuştur.

Hafif Elektrikli Araçlar (HEA), çevre dostu ve ekonomik olmaları nedeniyle kısa mesafeli ulaşımda kullanımları giderek daha yaygın hale gelmiştir (Dreßler ve ark., 2024). HEA kapsamında, elektrikli scooter, elektrikli bisiklet, elektrikli moped gibi çeşitli araç türleri yer almaktadır (Bretones ve ark., 2023). Bu yaygınlaşmaya paralel olarak, HEA'larda kullanılan batarya, sensörler, sürücü kartları ve tahrik motorları gibi temel bileşenlerin güvenilirliği büyük bir önem kazanmıştır. Şehir içi kullanım koşullarında yoğun titreşim, ani yük değişimleri, çevresel etkiler (yağmur, toz, sıcaklık dalgalanmaları) ve uzun süreli kesintisiz kullanım bu araçlarda çeşitli arızaların ortaya çıkmasına neden olabilmektedir (Tang ve ark., 2021). Bu çalışma koşulları nedeniyle, HEA'larda kullanılan bileşenlerin erken arıza teşhisi ve kestirimci bakım stratejilerinin geliştirilmesi, araç kullanılabilirliğini artırmak ve beklenmedik arızaları önlemek oldukça önemlidir. Bu nedenle literatürde HEA arızaları; batarya kaynaklı problemler, güç elektroniği ve sürücü devresi hataları, sensör arızaları ile mekanik bileşenlerde ortaya çıkan arızalar ve motor arızaları olarak incelenmektedir (Ali ve ark., 2023; Khan ve ark., 2024; Omakor ve ark., 2024).

Literatürde en yaygın HEA arızalarının başında batarya arızaları gelmektedir; kapasite düşümü, hücre dengesizliği, aşırı ısınma ve voltaj saptmaları sürüş menzilini ciddi ölçüde azaltmaktadır. Bu arıza türlerinin tespitinde genellikle voltaj, sıcaklık ve akım ölçümleri kullanılmaktadır. Martyushev ve ark. (2025) elektrikli araçların şehir içi kullanım

senaryolarında batarya sıcaklığının 30°C'nin üzerine çıkmasının yaşanma hızını ciddi ölçüde artırdığını göstermiştir (Martyushev ve ark., 2025). Zhang ve ark. (2023), elektrikli araçlarda lityum-iyon bataryaların güvenliğini değerlendirmek amacıyla hücre içi kısa devre oluşumunu modelleyen bir yöntem geliştirmiş ve titreşime bağlı güvenlik risklerini ortaya koymuştur (Zhang ve ark., 2023). Batarya arızalarının tespitinde model tabanlı yaklaşımların yanı sıra, son yıllarda makine öğrenmesi ve derin öğrenme tabanlı yöntemler de kullanılmaya başlanmıştır. Lin & Silfvenius (2025), sensör tabanlı performans izleme sayesinde batarya zayıflamasının daha doğru modellenebileceğini ve bunun hem yeniden kullanım hem de geri dönüşüm süreçlerinin sürdürülebilirliğini artırdığını göstermektedir (Lin & Silfvenius, 2025).

Güç elektroniği arızalarının tespitinde gerilim, akım ve termal görüntüleme verileri yaygın olarak kullanılmaktadır. Güç elektroniği ve sürücü devresi arızaları ile ilgili yapılan çalışmalarda; Sampath ve ark. (2023), elektrikli araçlardaki güç elektronik bileşenlerinin yol kaynaklı rastgele titreşimler altındaki yorulma ömrünü tahmin etmek için PSD tabanlı titreşim yükleri ve sonlu eleman analizini birleştiren bir yöntem geliştirmiştir (Sampath ve ark., 2023). Bu çalışmada titreşim verileri kullanılarak güç elektroniği bileşenlerinin güvenilirlik analizi gerçekleştirilmiştir. Yapılan diğer bir çalışmada, Gediya (2025) elektrikli ve hibrit araçlarda kullanılan yarı iletken bileşenlerin mekanik şok ve titreşim altında güvenilirliğini değerlendirmek amacıyla MCUs, MOSFET'ler ve MEMS sensörleri test ederek arıza modlarını belirlemiştir (Gediya, 2025).

Sensör arızaları doğrudan ölçülemediğinden, tespit işlemi genellikle sinyal özelliklerindeki sapmaların analizi ve model tabanlı hesaplamalar üzerinden yapılmaktadır. Sensör arızaları ile ilgili yapılan çalışmalarda, Khaneghah ve ark. (2023), elektrikli araçlarda sensörlerde görülen sinyal sürüklenmesi ile titreşim ve sıcaklık kaynaklı hata oluşumlarını inceleyerek bu arızaların tespiti için kullanılan model tabanlı, sinyal tabanlı ve veri odaklı yöntemleri kapsamlı olarak incelemiştir (Khaneghah ve ark., 2023). Lan ve ark. (2023), elektrikli araçlarda kullanılan lityum-iyon bataryaların güvenilirliğinde sensör hatalarının kritik rol oynadığını vurgulayarak; akım, gerilim ve sıcaklık sensörlerindeki hataların model tabanlı gözlemciler kullanılarak erken dönemde

tahmin edilebileceğini göstermiş ve farklı sensör arıza türleri için hata kestirim yöntemi önermiştir (Lan ve ark., 2023).

Elektrikli araç tahrik sistemi; batarya yönetim birimi, güç elektroniği ve kontrol modülleri ile birlikte çalışan elektrik motorunu, elektriksel ve mekanik bileşenlerin merkezine yerleştirir. Roy ve Kumar (2024), elektrikli araç motor sistemlerinin güvenilirliğini değerlendirmek için sürücü motoru ve motor kontrol ünitesini bütünleşik bir sistem olarak ele alarak alt bileşenlere dayalı arıza oranı tahmini ve kapsamlı bir güvenilirlik analizi gerçekleştirmiştir (Roy & Kumar, 2024). HEA’larda motor arızaları, sistem güvenilirliği açısından en kritik arıza türlerinden biridir ve doğrudan araç performansını etkilemektedir. Khaneghah ve ark. (2023), PMSM’lerde eksantriklik kaynaklı arıza modelleri, stator akımında yan bant bileşenleri, tork salınımları ve hava aralığı manyetik akısındaki asimetrisi gibi karakteristik imzalar ürettiğini ortaya koymuştur (Khaneghah ve ark., 2023). Tao ve ark. (2025) ise tekerlek içi motorlarda karşılaşılan tipik motor arızalarını sistematik biçimde sınıflandırmış ve bu motorların zorlu çalışma koşullarının erken arıza teşhisini güçleştirdiğini, bu nedenle gelişmiş sinyal işleme ve yapay zeka tabanlı teşhis yöntemlerine ihtiyaç duyulduğunu belirtmiştir (Tao ve ark., 2025).

HEA’larda uzun ömürleri ve verimli çalışmaları nedeniyle BLDC motorlar tercih edilmektedir (Saha ve ark., 2023). Ancak bu motorlarda zamanla sargı, rulman ve manyetik bileşenlere bağlı arızalar meydana gelmektedir. Bu durum motorda, enerji verimliliğinin azalmasına, üretim kayıplarına ve ek bakım maliyetlerine neden olmaktadır (Usman & Rajpurohit, 2019). Bu nedenle, motor arızalarının erken teşhisi, bakım maliyetlerini azaltmak, motor bileşenlerinde ikincil veya daha fazla hasar oluşumunu önlemek ve sistemin kullanım ömrünü uzatmak için önemli bir gerekliliktir (Garcia-Calva ve ark., 2022).

Motor arızaları literatürde genel olarak dört ana kategoride incelenmektedir. Stator arızaları; sargı kısa devreleri, faz-toprak hataları ve izolasyon bozulmaları gibi sarım kaynaklı problemlerin ortaya çıkmasıyla ilişkilidir. Rotor arızaları ise BLDC motorlarda kırık rotor çubuğu görülmemekle birlikte; statik veya dinamik eksantriklik, rotor dengesizliği ve rotor-mıknatıs hizasızlığı gibi geometrik ve mekanik kusurlardan

oluşmaktadır. Rulman arızaları ise iç ve dış bilezik hasarları, bilya yüzeyi bozulmaları, kafes kırıkları ve aşınma gibi yaygın rulman kusurlarını kapsamaktadır. Manyetik arızalar ise kalıcı mıknatıslı yapıdan dolayı kritik olup; kısmi veya tam demanyetizasyon, mıknatıs çatlaması, kopması ya da yapışma yüzeyinin bozulması gibi manyetik bütünlüğü etkileyen çeşitli kusurları içermektedir (Chen ve ark., 2019; Mohanraj ve ark., 2022) .

Motor arızalarının teşhisinde kaçak akı, akım, akustik, gerilim, titreşim ve termal sinyaller yaygın olarak kullanılmaktadır. Kaçak akı sinyalleri stator arızalarının erken tespitinde etkin olurken, akustik sinyaller özellikle mekanik arızaların belirlenmesinde tercih edilmektedir. Akım sinyalleri; stator, rotor ve manyetik arızaların tanınmasında düşük maliyetli ve yaygın bir yöntem olarak öne çıkarken, rulman ve mekanik arızaların tespitinde titreşim sinyalleri yüksek hassasiyet sağlamaktadır. Maliyeti nedeniyle termal görüntüleme sınırlı uygulama alanına sahipken, gerilim sinyalleri genellikle diğer sinyal türleriyle birlikte hibrit yaklaşımlarda tamamlayıcı veri olarak kullanılmaktadır (Gherghina ve ark., 2025; Usman & Rajpurohit, 2024).

Motor arızalarının teşhisinde uzun yıllar boyunca geleneksel yöntemler yaygın olarak kullanılmıştır. Bu yöntemler, uzman bilgisine dayalı olup akı, akım, akustik, gerilim ve titreşim gibi sinyallerden belirli özniteliklerin çıkarılmasına ve bu özniteliklerin arıza imzalarının belirlenmesine odaklanılmaktadır. Park Vektörü (PV), Motor Current Signature Analysis (MCSA), Fourier Dönüşümü (FFT), Dalgacık Dönüşümü (WT) ve Kısa Zamanlı Fourier Dönüşümü (STFT) bu kapsamda en sık kullanılan tekniklerdir.

Literatürde özellikle stator tabanlı elektriksel arızaların tespiti için akı, gerilim ve akım temelli yöntemlerin yaygın biçimde kullanıldığı görülmektedir. Hu ve ark. (2021), PMSM’lerde erken stator sargı arızalarının tespiti için negatif-sekans akım bileşenleri ve akım kalıntısına dayalı bir yöntem önermiştir. Yöntem, hatalı ve sağlıklı durum farkından elde edilen DC bileşenlerini arıza göstergesi olarak kullanmış ve hem kararlı hem de geçici çalışma koşullarında yüksek doğruluk sağlamıştır (Hu ve ark., 2021). Benzer şekilde, Im ve Gu (2022), endüksiyon motorlarında negatif-sekans akımına dayalı yöntemle düşük şiddetli stator arızalarını tespit etmiş ve geleneksel tekniklere göre daha hassas sonuçlar raporlamıştır (Im & Gu, 2022). Usman ve Rajpurohit (2020), BLDC

motorlarda stator kısa devresi ve demanyetizasyonu hibrit bir yöntemle modellemiş ve yöntemin hem analitik hem de deneysel olarak güvenilir sonuçlar verdiğini göstermiştir (Usman & Rajpurohit, 2020). Pires ve ark. (2009), inverter beslemeli indüksiyon motorlarında akım ve sanal akı tabanlı yöntemle rotor kafesi arızalarını tespit etmiş ve düşük yüklerde dahi başarılı sonuçlar elde etmiştir (Pires ve ark., 2009). Moseler ve Isermann (2000), BLDC motorlarda akım, gerilim ve hız verilerini kullanan model tabanlı yöntemle elektriksel ve mekanik arızaların erken tespit edilebildiğini göstermiştir (Moseler & Isermann, 2000).

Literatürde rotor arızalarına odaklanan çalışmalarla da sıkça karşılaşılır. Acosta ve ark. (2006), çevrim içi akım izleme sistemiyle rotor ve stator arızalarını erken aşamada yüksek doğrulukla tespit etmiş ve aynı zamanda motor kayma ve yük yüzdesini tahmin etmiştir (Acosta ve ark., 2006). Dias ve Chabu (2014), Hall etkisi sensöründen elde edilen manyetik akı yoğunluğu ve FFT analiziyle büyük endüksiyon motorlarında kırık rotor çubuklarını erken aşamada başarılı biçimde tespit etmiştir (Dias & Chabu, 2014). Kim ve Lieu (2005), analitik ve FEM tabanlı yöntemle rotor eksantrikliğinin titreşim kuvvetleri ve cogging torkunu artırdığını, harmonik içeriği değiştirdiğini göstermiştir (Kim & Lieu, 2005).

Titreşim tabanlı çalışmalar özellikle rulman arızalarının tespiti için etkili olmuştur. Kudelina ve ark. (2021), BLDC motorlarda rulman arızalarının titreşim seviyesine etkisini deneysel olarak incelemiştir. Hasarlı rulmanlarla elde edilen titreşim verileri FFT ile analiz edilmiş ve arızaların temel frekans genliğini artırarak teşhis için kullanılabilecek bir gösterge sunduğu belirlenmiştir (Kudelina ve ark., 2021). Ramesh Balaji ve ark. (2015), WT tabanlı yöntemle BLDC motorlarda tek faz açık devre arızasını titreşim sinyallerinden başarıyla ayırt etmiştir (Ramesh Balaji & Chinnusamy, 2015).

Bunun yanı sıra, farklı iki sinyali birleştiren hibrit yaklaşımlar da önerilmiştir. Pindoriya ve ark. (2018), BLDC motor sürücülerinde titreşim ve akustik gürültünün temel nedeninin elektromanyetik kuvvetler olduğunu ve rezonansın belirli frekanslarda arttığını ortaya koymuştur (Pindoriya ve ark., 2018). Bulanık mantık tabanlı ve model tabanlı yaklaşımlarda, de Miguel ve Blázquez (2005), DC motorlarda arıza tespiti için model

tabanlı bir yaklaşımı bulanık mantık karar modülü ile birleştirmiş ve hız sensörü arızası, aktüatör sinyal sapması gibi arızaları başarıyla tespit etmiştir (De Miguel & Blázquez, 2005). Rodríguez ve ark. (2008), endüksiyon motorlarında motor akımı izlemeye dayalı yöntemle stator kısa devreleri, rotor çubuk kırıkları ve eksantriklik arızalarını yüksek doğrulukla tespit etmiş, ayrıca düşük hesaplama maliyetiyle çalışarak kapsamlı spektral analiz ihtiyacını ortadan kaldırmıştır (Rodríguez ve ark., 2008). Mini ve Ushakumari (2011), üç fazlı endüksiyon motorlarında elektriksel arızaların erken tespiti için simülasyon tabanlı bir model geliştirmiştir. Çalışmada dengesiz gerilim, aşırı yük ve toprak arızaları simüle edilmiş; stator akımı, negatif dizilim akımı ve hız bilgileri bulanık mantık karar sistemine giriş olarak kullanılmıştır. Yöntem, farklı arıza koşullarını yüksek doğrulukla belirlemiş ve dilsel değişkenlere dayalı karar verme kolaylığı sağlamıştır (Mini & Ushakumari, 2011).

Simülasyon temelli diğer çalışmalarda, Chattopadhyay ve ark. (2012) DWT tabanlı harmonik analizi kullanarak BLDC motor sürücüsünün davranışsal özelliklerini incelenmiş, Desheng ve ark. (2012) ise Hermite fonksiyonlarına dayalı geliştirilmiş bir zaman-frekans analizi olan Hermite S-yöntemini kullanarak rotor dinamik eksantrikliğin tespiti için yüksek çözünürlük elde etmişlerdir (Chattopadhyay ve ark., 2012; Desheng ve ark., 2012). Ayrıca, Seghior ve ark. (2015), endüksiyon motorlarında dinamik eksantriklik ve kırık rotor çubuklarının eşzamanlı tespiti için hava aralığındaki manyetik akı yoğunluğuna dayalı bir yöntem önermiştir. Motor FEM ile modellenmiş, akı yoğunluğu ölçümleri FFT tabanlı harmonik analizle yapılmıştır. Yöntem, hem tekil hem de çoklu arızaların konumunu ve şiddetini başarıyla belirlemiştir (Seghior ve ark., 2015). Sulisty ve ark. (2025), BLDC motorlarda rulman arızalarının tespitinde titreşim ve termal sinyallere dayalı yöntemleri karşılaştıran bir derleme sunmuştur. Çalışmada, hibrit yaklaşımların erken arıza tespiti ve sistem güvenilirliğinde daha etkili olduğu, ayrıca derin öğrenme ve TL tekniklerinin son yıllarda giderek daha fazla kullanıldığı vurgulanmıştır (Sulisty ve ark., 2025).

Ancak geleneksel yöntemler, arıza imzalarının önceden belirlenmesine ve manuel özellik mühendisliğine bağımlı oldukları için karmaşık arızalarda ve değişken çalışma koşullarında sınırlı performans göstermektedir. Özellikle HEA'ların sürekli değişen yük

ve hız koşullarında çalışması, sabit eşik değerlerine dayalı geleneksel yöntemlerin güvenilirliğini azaltmaktadır. Bu sınırlılıklar, veriden otomatik öğrenme yapabilen makine öğrenmesi tabanlı yöntemlerin gelişmesiyle aşılmıştır. Başlangıçta, geleneksel sinyal işleme teknikleriyle çıkarılan özellikler, k-en yakın komşu (k-NN), Karar Ağaçları (DT), Rastgele Orman (RF), Naive Bayes (NB), Yapay Sinir Ağları (ANN) veya Destek Vektör Makineleri (SVM) gibi sınıflandırıcılarla birleştirilmiş, sonrasında ise özellik çıkarımı, optimizasyon algoritmaları ve veri odaklı karar sistemlerinin entegre edildiği hibrit yaklaşımlar yaygınlaşmıştır.

Akı ve gerilim sinyallerinden çıkarılan özelliklerin makine öğrenmesi algoritmalarıyla sınıflandırılması da öne çıkan bir yaklaşım olmuştur. Filippetti ve ark. (2000), endüksiyon motorlarında yapay zeka tekniklerini incelemiş; ANN, FL ve GA tabanlı yaklaşımların arıza teşhisi ve şiddet tahmininde etkili olduğunu göstermiştir (Filippetti ve ark., 2002). Louzada ve ark. (2025) ise üç fazlı asenkron motorlarda stator sargı arızalarının tespiti için stray flux (kaçak akı) sinyallerinden çıkarılan istatistiksel özellikleri kullanarak farklı makine öğrenmesi algoritmalarını karşılaştırmıştır. Elde edilen akı sinyalinden çıkarılan özellikler RF, k-NN, SVM ve Çok Katmanlı Algılayıcı (MLP) sınıflandırıcılarına verilmiş, çalışma model tabanlı motor parametrelerine ihtiyaç duymadan erken aşama kısa devrelerin tespitinde yüksek performans sağlamıştır (Louzada ve ark., 2025). Başka bir çalışmada Younas ve ark. (2021), DWT tabanlı özelliklerle çoklu ML algoritmalarını karşılaştırmış ve stray flux verisinin stator akımına göre daha yüksek doğruluk verdiğini göstermiştir (Younas ve ark., 2021). Abdulkareem ve ark. (2025), dört adet üç fazlı endüksiyon motorundan elde edilen akım, rotor hızı ve verim bilgilerini kullanarak DT, RF, ANN ve k-NN modellerini karşılaştırmıştır. Çalışmada en yüksek doğruluk %91 ile RF modelinde, en düşük doğruluk ise %89 ile DT modelinde elde edilmiştir (Abdulkareem ve ark., 2025). Tran ve ark. (2021), DWT ve FFT tabanlı özelliklerle farklı ML algoritmalarını karşılaştırmış ve performansların modelden modele değiştiğini göstermiştir (Tran ve ark., 2021).

Bununla birlikte titreşim sinyalleri kullanılarak gerçekleştirilen arıza teşhisi çalışmalarında, Amarnath ve ark. (2013), akustik sinyallerden çıkarılan istatistiksel özellikleri DT algoritmasıyla sınıflandırarak rulman arızalarını yüksek doğrulukla tespit

etmiştir (Amarnath ve ark., 2013). Benzer şekilde, Ali ve ark. (2015), EMD tabanlı özellikleri ANN ile sınıflandırarak rulman arızalarını yüksek doğrulukla tespit etmiş ve erken aşama bozulmaları çevrim içi belirleyebilmiştir (Ali ve ark., 2015). Agrawal ve Jayaswal (2019), rulman arızalarının teşhisinde dalgacık dönüşümünden çıkarılan istatistiksel özellikleri kullanarak ANN ve SVM yöntemlerini karşılaştırmış; her iki yöntem yüksek doğruluk sağlasa da SVM'nin genelleme kabiliyetinin daha üstün olduğunu belirtmiştir (Agrawal & Jayaswal, 2020).

Stator ve rotor arızalarına odaklanan çalışmalarda da benzer yaklaşımlar görülmektedir. Doğan (2012), üç fazlı sincap kafesli asenkron motorlarda rulman, eksen kaçıklığı, stator sargı arızaları ve rotor kırığı teşhisine yönelik deneysel bir çalışma gerçekleştirmiştir. Çalışmada motor akım sinyalleri zaman boyutunda eşit genişlikli ve eşit frekanslı ayrıklaştırma yöntemleriyle işlenmiş, elde edilen özellikler çok katmanlı yapay sinir ağı ile sınıflandırılmıştır. Sonuçlar, yöntemin farklı yük koşullarında güvenilir biçimde çalıştığını ve motor arızalarının etkin bir şekilde tespit edilebildiğini göstermiştir (Doğan, 2012). Quiroz ve ark. (2018), line start-PMSM (LS-PMSM) motorunda kırık rotor çubuklarının tespiti için RF tabanlı bir yöntem önermiş ve diğer sınıflandırıcılarla karşılaştırmıştır. En yüksek başarıyı elde etmiştir RF ile elde etmiştir (Quiroz ve ark., 2018). Pietrzak ve Wolkiewicz (2023), PMSM'de demanyetizasyon arızasının tespiti için STFT tabanlı özellikler kullanmış ve k-NN'in MLP'ye göre daha yüksek doğruluk ve daha kısa yanıt süresi sağladığını göstermişlerdir (Pietrzak & Wolkiewicz, 2023).

Makine öğrenmesi tabanlı yöntemlerin başarısını artırmak için özellik seçimi, boyut indirgeme ve hibrit yaklaşımlar da yaygın olarak kullanılmıştır. Altug ve ark. (2002), endüksiyon motorlarında hibrit sinir ağı-bulanık mantık yöntemlerini karşılaştırmış ve bu yaklaşımların sürtünme arızasını başarıyla tespit edip daha anlaşılır sonuçlar ürettiğini belirtmiştir (Altug ve ark., 2002). Tran ve ark. (2009), endüksiyon motoru arıza teşhisi için titreşim ve akım sinyallerinden elde edilen istatistiksel özellikleri kullanarak karar ağaçları ile seçme ve bulanık mantıkla sınıflandırma yapan hibrit bir sistem geliştirmiş, yüksek sınıflandırma doğruluğu elde etmiştir (Tran ve ark., 2009).

Son yıllarda, PSO, GWO, GA vb. meta-sezgisel optimizasyon algoritmaları kullanılarak makine öğrenmesi modellerinin hiperparametreleri optimize edilmektedir. Emara ve ark. (2008), endüksiyon motorlarının parametre tahmini için Parçacık Sürü Optimizasyonu (PSO) tabanlı geliştirilmiş bir yöntem önermiş ve yöntemin Genetik Algoritma (GA) gibi diğer optimizasyon tekniklerine kıyasla daha hızlı ve daha doğru sonuçlar verdiğini göstermiştir (Emara ve ark., 2008). Nyanteh ve ark. (2013), PMSM stator kısa devre arızalarının yerini ve şiddetini belirlemek için PSO ile optimize edilmiş sinir ağı yöntemi önermiş, simülasyon ve gerçek verilerde yük ve hızdan bağımsız olarak güvenilir sonuçlar üretmiştir (Nyanteh ve ark., 2013). Dong ve ark. (2019), çok ölçekli özellik çıkarımı ve GWO ile optimize edilmiş SVM tabanlı bir yöntem önermiş, CWRU ve Soochow veri setlerinde arıza türü ve şiddetini yüksek doğrulukla sınıflandırmıştır (Dong ve ark., 2019). Zhou ve ark. (2022), VMD ile elde edilen öznitelikleri geliştirilmiş GWO ile optimize edilmiş SVM sınıflandırıcıyla birleştirerek rulman arızası teşhisi için bir yöntem önermiş ve hem CWRU veri seti hem de laboratuvar testlerinde yüksek doğruluk sağlamıştır (Zhou ve ark., 2022). Shen ve ark. (2023), zaman alanlı öznitelikleri kullanarak IGWO ile optimize edilmiş SVM tabanlı bir yöntem önermiş ve hem CWRU veri seti hem de deneysel testlerde PSO-SVM ve GWO-SVM'ye kıyasla daha yüksek doğruluk ve daha iyi yakınsama sağlamıştır (Shen ve ark., 2023). Ye ve ark. (2025), PMSM arızalarının teşhisi için WPT tabanlı enerji özniteliklerini GA ile optimize edilmiş Geri Yayılım (BP) sinir ağıyla kullanan bir yöntem önermiş ve özellikle manyetik arızaların tespitinde yüksek hassasiyet sağlamıştır (Ye ve ark., 2025). Rajini ve ark. (2024), endüksiyon makinelerinde arıza tanısı için DWT tabanlı zaman-frekans özelliklerini kullanarak SVM, DT, RF, NB ve XGBoost algoritmalarını karşılaştırmış ve özellikle RF ile XGBoost'un daha yüksek doğruluk sağladığını belirtmiştir (Rajini ve ark., 2024).

Titreşim/akustik sinyalleri kullanarak ML ile arıza tespitinde, Glowacz (2019), tek fazlı asenkron motorlarda rulman, stator ve rotor arızalarının teşhisi için akustik sinyallere dayalı bir yöntem önermiştir. k-NN algoritması ile sınıflandırma yapılarak başarılı sonuçlar elde etmiştir (Glowacz, 2019). Benzer şekilde Al-Haddad ve ark. (2024), üç fazlı PMSM stator arızalarının teşhisi için titreşim ve akım sinyallerinden çıkarılan istatistiksel öznitelikleri bilgi kazancı yöntemiyle seçmiş ve Gradient Boosting ile sınıflandırmıştır.

Sonuçlar, veri füzyonunun tekil sensörlere göre doğruluğu artırarak multimodal yaklaşımın avantaj sağladığını göstermiştir (Al-Haddad ve ark., 2024).

Çoklu sensör verilerinin birlikte kullanıldığı multimodal yaklaşımlar da giderek yaygınlaşmaktadır. Bu yaklaşımlarda birden fazla kaynaktan çıkarılan özellikler birleştirilerek daha güvenilir arıza imzaları elde edilmektedir. Wang ve ark. (2021), titreşim ve tork sinyallerinden çıkarılan özellikleri dikkat mekanizması (attention mechanism) içeren CNN tabanlı bir model ile birleştirmiştir. Çalışma, farklı modalitelerin birlikte kullanılmasının özellikle erken aşama arıza tespitinde önemli avantajlar sağladığını göstermiştir (D. Wang ve ark., 2021). Che ve ark. (2021), rulman arızalarının teşhisi için titreşim sinyallerinden elde edilen zaman serisi özellikleri ve gri seviye görüntüleri birleştiren hibrit bir multimodal derin öğrenme yöntemi önermiştir. Çalışma, tekil modellere kıyasla daha yüksek doğruluk sağlamış ve gürültü altında da güçlü performans göstermiştir (Che ve ark., 2021). Xu ve ark. (2025), üç fazlı akım, titreşim ve akustik sinyallerden oluşan çoklu sensör verilerini kullanarak ensemble Transformer tabanlı bir yöntem geliştirmiştir. Çalışma, tekli sensörlere dayalı yöntemlere göre daha yüksek doğruluk sağlamış ve multimodal veri füzyonunun motor arızası teşhisinde önemli avantaj sunduğunu göstermiştir (Xu ve ark., 2025).

Boyut indirgeme teknikleri, özellikle yüksek boyutlu özellik setlerinde model karmaşıklığını azaltmak ve aşırı uyumu engellemek için yaygın olarak kullanılmaktadır. Pule ve ark. (2022), değişken hız koşullarında rulman arızalarının teşhisi için PCA ile boyut indirgeme ve SVM tabanlı sınıflandırmayı birleştiren bir yöntem önermiştir. Çalışma, yüksek doğrulukla birlikte daha düşük hesaplama maliyeti sağlamıştır (Pule ve ark., 2022). Mari ve ark. (2024), endüksiyon motorlarında arıza tespiti için stator akımı ve anlık aktif güç sinyalleri üzerinde Fonksiyonel Temel Bileşen Analizi (FPCA) tabanlı boyut indirgeme uygulamış ve ANN ile sınıflandırma gerçekleştirmiştir. Çalışma, yüksek doğruluk sağlamış ve dengesiz veri sorununu azaltmak için çeşitli veri işleme stratejileri kullanmıştır (Mari ve ark., 2024).

Makine öğrenmesi tabanlı yöntemler, arıza teşhisinde özellik mühendisliğine duyulan ihtiyacı kısmen azaltmış olsa da karmaşık arıza koşullarında genelleme gücü ve veri temsili kısıtları devam etmiştir. Ayrıca, HEA'larda karşılaşılan sürekli değişen çalışma

koşulları (hız, yük, sıcaklık), önceden tasarlanmış özelliklerin etkinliğini azaltmaktadır. Özellikle son yıllarda, bu sınırlamaları aşmak amacıyla özellik çıkarımı ve sınıflandırma aşamalarını tek bir çatı altında birleştirebilen derin öğrenme tabanlı yaklaşımlar ön plana çıkmıştır.

Derin Öğrenme yöntemleri arasında, otomatik özellik çıkarma kabiliyeti ve yüksek sınıflandırma doğruluğu sayesinde Evrişimli Sinir Ağı (CNN) motor arızası teşhisinde en yaygın kullanılan modellerden biri haline gelmiştir.

Ham verilerle doğrudan çalışan 1D-CNN tabanlı yöntemler, öznelik mühendisliği ihtiyacını ortadan kaldırarak daha basit fakat etkili bir yapı sunmaktadır. Maraaba ve ark. (2020), PMSM’lerde sarımlar arası kısa devre arızalarının tespiti için üç fazlı stator akımı sinyallerini doğrudan girdi olarak kullanan bir CNN modeli geliştirmiş ve %97.7 doğruluk elde etmiştir (Maraaba ve ark., 2020). Benzer şekilde Lee ve ark. (2019), IPMSM motorlarında sarımlar arası kısa devre ve demanyetizasyon arızalarının yanı sıra hibrit arızaları tespit etmek için 1D-CNN tabanlı bir yöntem önermiş ve yalnızca stator akımı sinyallerini kullanarak %99.3 doğruluk oranı elde ettiklerini belirtmişlerdir (Lee ve ark., 2019). Jeong ve ark. (2018) ise FFT tabanlı özellik vektörlerini CNN’e giriş olarak vererek IPMSM motorlarında hibrit arızaların yüksek doğrulukla sınıflandırılabilirdiğini göstermişlerdir (Jeong ve ark., 2018). Ayrıca, Perminov ve ark. (2020), rulman veri seti ile eğitilen 1D-CNN modelini düşük güçlü edge cihazlarda çalıştırarak gerçek zamanlı rulman arızası tespitinde %88 doğruluk sağlamışlardır (Perminov ve ark., 2020). Bu çalışma, HEA’larda kullanılabilecek gömülü sistem uygulamalarının fizibilitesini göstermesi açısından önemlidir. Suawa ve ark. (2022) ise BLDC motorlarda ses ve titreşim verilerini birleştirerek CNN-LSTM hibrit modeliyle veri füzyonu gerçekleştirmiş ve doğruluğu %93.5’ten %98.8’e yükseltmiştir (Suawa ve ark., 2022). Benzer şekilde, X.Wang ve ark. (2021) rulman arızası teşhisi için titreşim ve akustik sinyallerin füzyonunu kullanan 1D-CNN tabanlı bir yöntem geliştirmiştir. Çalışma, özellikle düşük SNR koşullarında tekil sensör tabanlı yaklaşımlara kıyasla daha yüksek doğruluk sağlamıştır (X. Wang ve ark., 2021). Han ve ark. (2022), BLDC motorlarda demanyetizasyon arızasının tespiti için farklı seviyelerde elde edilen radyal titreşim verilerini kullanarak 1D-CNN, ANN ve XGBoost algoritmalarını karşılaştırmıştır.

Çalışmada 1D-CNN, diğer yöntemlere kıyasla daha düşük hata ve daha iyi genelleme sağlamıştır (Han ve ark., 2022).

Zaman-frekans temsilleriyle oluşturulan 2D-CNN tabanlı yöntemler, özellikle erken aşama arızaların tespitinde daha güçlü performans göstermiştir. Guo ve ark. (2016), rulman arızalarının teşhisi için titreşim sinyallerinden otomatik öznelik öğrenebilen hiyerarşik bir derin CNN yöntemi geliştirmiş ve arıza türü ile şiddetini yüksek doğrulukla tahmin etmiştir (Guo ve ark., 2016). Pietrzak ve ark. (2022), PMSM motorlarında stator arızalarının tespiti için bispektrum tabanlı 2D özellik haritalarını CNN modellerine giriş olarak kullanmış ve erken aşama kısa devrelerde dahi %99 civarında doğruluk elde etmiştir (Pietrzak ve ark., 2022). Flores ve Ostia (2023), BLDC motorlarında hızlı kurtogram tabanlı özellik çıkarımıyla üretilen görüntüleri 2D-CNN modeliyle sınıflandırmış ve %83 doğruluk elde etmiştir (Flores & Ostia, 2023). Ali ve Abed (2024) ise zaman-frekans analizi tabanlı hiyerarşik CNN yöntemi geliştirerek BLDC motorlarında rulman arızalarının teşhisinde %99'un üzerinde doğruluk elde etmiştir (Ali & Rafa Abed, 2024). Song ve ark. (2022), PMSM motorlarında sargılar arası kısa devre arızasının erken teşhisi için CNN mimarisi önermiştir. Önerilen yöntem, 1 sağlam ve 16 arıza durumunu içeren veri setinde %98 doğruluk sağlamıştır (Song ve ark., 2022). Sun ve ark. (2022), üç fazlı inverter tabanlı BLDC motor sürücülerinde MOSFET açık devre arızalarının teşhisi için hibrit CNN modeli geliştirmiştir. Yöntem, hem 1D-CNN hem de 2D-CNN tabanlı özellik çıkarımını birleştirerek güçlü bir özellik temsili sağlamış ve değişken yük koşullarında dahi %98'in üzerinde doğruluk elde etmiştir (Sun ve ark., 2022). Rajabioun ve ark. (2024), akım, titreşim ve manyetik akı sinyallerinden oluşturulan çoklu girişli iki boyutlu matrisleri kullanarak geliştirdikleri CNN tabanlı model ile indüksiyon motorlarında dağıtılmış rulman arızalarını sınıflandırmış ve %99'un üstünde doğruluk elde etmiştir (Rajabioun ve ark., 2024). Lin (2021), rulman ve eksenden kayma gibi motor arızalarının teşhisi için titreşim sinyallerini VMD ile ayrıştırıp Hilbert spektrumuna dönüştürerek CNN ile sınıflandırmıştır. Yöntem, altı farklı arıza türünde %94 doğruluk sağlamıştır (Lin, 2021).

Bunun yanında, CNN ve LSTM katmanlarının birleştirildiği hibrit modeller de geliştirilmiştir. Chen ve ark. (2021), ham titreşim sinyallerinden çok ölçekli CNN

katmanları ile farklı frekans bileşenlerini çıkarıp, LSTM katmanları ile zaman bağımlılığını modelleyen MCNN-LSTM yöntemini önermiş ve CWRU veri setinde %98 civarında doğruluk elde etmiştir (Chen ve ark., 2021). Ruan ve ark. (2023), CNN parametrelerini fizik tabanlı kurallarla belirleyen bir yöntem önermiş ve çalıştıkları veri setlerinde %99 civarı doğrulukla geleneksel CNN'lere kıyasla daha yüksek başarı ve daha düşük belirsizlik elde etmiştir (Ruan ve ark., 2023). Lee ve ark. (2023), BLDC motor rulman arızalarının tespisi için 1D-CNN ve LSTM tabanlı Auto-Encoder yapısına dayalı denetimsiz bir yöntem geliştirmiş ve farklı koşullarda değişen seviyelerde başarı elde etmiştir (Lee ve ark., 2023). Sun ve ark. (2023), senkron motorlarda beş farklı elektriksel arızayı kapsayan açık erişimli bir veri seti geliştirmiş ve bu veri seti üzerinde CNN ve LSTM tabanlı referans sınıflandırıcılar sunmuştur. Özellikle stator gerilimi, stator akımı ve rotor akımı gibi özelliklerin kullanıldığı CNN tabanlı modellerin %97'nin üzerinde doğruluk sağladığı ortaya koymuştur (Z. Sun ve ark., 2023). Lale ve Yüksek (2025), PMSM motorlarında ISCF ve DF arızalarının çoklu hız ve yük koşullarında tespiti için LSTM ve GRU tabanlı iki farklı derin öğrenme modeli önermiştir. Üç fazlı akım sinyalleri doğrudan giriş olarak kullanılmış ve yöntemler ile %98'in üzerinde doğruluk elde etmiştir (Lale & Yüksek, 2025).

Önceden eğitilmiş, AlexNet, VGG, ResNet, EfficientNet vb. derin ağların kullanıldığı TL tabanlı yöntemler, sınırlı veriyle eğitim süresini ve maliyetini azaltmakta, ayrıca küçük veri setlerinde aşırı öğrenme riskini düşürmektedir. BLDC motor arızaları için veri setlerinin kısıtlı olması nedeniyle, TL yaklaşımları uygulamalarda özellikle önemlidir. Pinedo-Sánchez ve ark. (2020), rulmanlarda aşınma seviyesini tahmin etmek amacıyla titreşim sinyallerinden otomatik etiketleme ve K-means kümeleme ile elde edilen verileri AlexNet tabanlı CNN modeliyle eğitmiş ve %99 civarında doğruluk sağlamıştır (Pinedo-Sanchez ve ark., 2020). Zia Ullah ve ark. (2020), PMSM motorlarında demanyetizasyon ve rulman arızalarının tespiti için stator akımı frekans spektrumu ile titreşim sinyallerini birleştirerek RGB görüntülere dönüştürmüş ve önceden eğitilmiş VGG-16 modeliyle TL uygulamıştır. Multimodal veri kullanımı sayesinde %96.7 doğruluk elde edilmiştir (Ullah ve ark., 2020). Benzer şekilde, Wang ve ark. (2021), BLDC motorlarda sarımlar arası kısa devre arızalarının tespisi için üç fazlı akım sinyallerini RGB görüntülere dönüştürerek TL tabanlı GoogLeNet modeli kullanmış ve yüksek doğrulukla sınıflandırma

gerçekleştirmiştir (J. Wang ve ark., 2021). Jia ve ark. (2018), rotor sargılarının otomatik tespiti için ikili görüntüleme ve TL tabanlı bir yaklaşım önermiştir. ImageNet üzerinde önceden eğitilmiş Inception V3 ağı, rotor sargı görüntülerine uyarlanarak sınırlı etiketli veri ve veri seti yansılığı sorunları aşılmış ve farklı rotor tipleri ile aydınlatma koşullarında yüksek doğruluk elde edilmiştir (Jia ve ark., 2018). Di Maggio (2023), önceden ses sınıflandırması için eğitilmiş VGG tabanlı bir modeli TL ile rulman arızası teşhisinde kullanmış ve 2000'den az titreşim örneğiyle %99.07 doğruluk sağlamıştır. Çalışma, ses ve titreşim spektrogramlarının benzer özelliklerinden yararlanarak küçük veri setlerinde TL'nin etkinliğini göstermiştir (Di Maggio, 2023).

CNN modellerinin başarısı, katman sayısı, filtre boyutu, öğrenme oranı gibi hiperparametrelere büyük ölçüde bağlıdır. Son yıllarda bu hiperparametrelerin Parçacık Sürü Optimizasyonu (PSO), Gri Kurt Optimizasyonu (GWO) ve Genetik Algoritma (GA) vb. gibi meta-sezgisel algoritmalarla optimize edildiği hibrit yaklaşımlarda geliştirilmiştir. Dong ve ark. (2019), rulman arızası tespiti için CNN hiperparametrelerini optimize etmek amacıyla GWO algoritmasını kullanmış ve CWRU veri setinde %99'un üzerinde doğruluk elde etmiştir (Dong ve ark., 2019). Benzer şekilde, Song ve ark. (2023), PMSM motorlarında kısa devre arızalarının erken tespiti için Bayesyen Optimizasyon (BO) ile optimize edilmiş artık bağlantılı CNN modeli önermiştir. Ağ mimarisindeki iyileştirmeler doğruluk kaybını önlemiş, üç fazlı akım sinyalleriyle model farklı arıza şiddetlerinde yüksek başarı sağlamıştır (Song ve ark., 2023). Tian ve ark. (2023), rulman arızası tespiti için CNN-LSTM tabanlı bir modeli PSO algoritmasıyla optimize etmiştir. Çalışma, CNN ve LSTM'in güçlü yönlerini birleştirirken hiperparametreleri dinamik olarak ayarlamış ve geleneksel yöntemlere göre daha yüksek sınıflandırma başarısı etmiştir (Tian ve ark., 2023). Huang ve ark. (2019), rulman arızası tespiti için gelişmiş özellik çıkarım teknikleri ve GWO ile optimize edilmiş SVM modeli önermiş ve CWRU veri setinde %99 civarında doğruluk elde etmiştir (Huang ve ark., 2019). Ye ve ark. (2021), rulman arızası tespiti için VMD ve çok ölçekli permütasyon entropisi tabanlı özellik çıkarımı gerçekleştirmiş ve bu özellikleri PSO algoritmasıyla optimize edilmiş SVM modeliyle sınıflandırmıştır. Çalışma, hem CWRU veri seti hem de laboratuvar verileri üzerinde yüksek doğruluk elde etmiştir (Ye ve ark., 2021).

Elektrik motorlarının arıza teşhisinde kullanılan kaçak akı, akım, akustik, gerilim veya titreşim sinyalleri çoğunlukla durağan olmayan yapıya sahiptir ve zamanla değişen frekans bileşenleri içerir. Bu sinyallerin spektral içeriğinin ayrıntılı biçimde incelenebilmesi, gürültüden arındırılması ve arıza ile ilişkili imzaların belirlenebilmesi için Wigner-Ville, Dalgacık Dönüşümü (CWT/DWT), Hilbert-Huang Dönüşümü (HHT) ve Kısa-Zaman Fourier Dönüşümü (STFT), gibi zaman-frekans tabanlı spektral dönüşümler kullanılmaktadır. Bu yöntemler, sinyalin zamana ve frekansa göre bileşenlerini aynı anda inceleme olanağı sağlayarak motor arızalarının daha doğru şekilde tespit edilmesinde kullanılmaktadır (Nagarajaiah & Basu, 2009; Randall, 1987).

Wigner-Ville dağılımı (WVD) ve türevleri, motor arızalarının tespitinde yüksek zaman-frekans çözünürlüğü sağlamasıyla öne çıkmıştır. Rosero ve ark. (2009), stator akımından elde edilen IMF bileşenlerine WVD tabanlı dönüşümler uygulayarak kısa devre arızalarının IMF1 ve IMF2’de belirgin şekilde ayrıştırılabildiğini göstermiştir (Rosero ve ark., 2009). Hafeez ve ark. (2013) ise kırık rotor çubuklarının tespitinde WVD’nin STFT’ye kıyasla daha üstün performans ortaya koyduğunu göstermiştir (Hafeez ve ark., 2013). Daha yakın tarihli çalışmalarda Reddy ve Pachori (2024), WVD’nin çapraz terim sorununu azaltmak için Dinamik Kip Ayrıştırma (DMD) tabanlı bir yöntem önermiş (Reddy & Pachori, 2025); Wu ve ark. (2025) ise BLDC motor titreşim sinyallerini WVD’ye dayalı YOLO-CNN modeliyle sınıflandırarak %99’un üzerinde doğruluk elde etmiştir (Wu ve ark., 2025).

Çok bileşenli sinyallerin analizi için Hilbert-Huang Dönüşümü (HHT) gibi alternatif yöntemler de kullanılmışlardır. Elbouchikhi ve ark. (2017), indüksiyon motorlarında rulman arızalarının tespiti için HHT kullanmış ve hem simülasyon hem de deneysel veriler üzerinde yöntemin arıza imzalarını güvenilir biçimde ortaya koyduğunu göstermiştir (Elbouchikhi ve ark., 2017). Osman ve Wang (2016), morfolojik filtreleme ile HHT’yi birleştirerek rulman arızalarının tespitinde kullanmış ve deneysel veriler üzerinde yöntemin arıza imzalarını klasik HHT’ye kıyasla daha güvenilir biçimde ortaya koyduğunu göstermiştir (Osman & Wang, 2016). Marcos-Andrade ve ark. (2024), HHT kullanarak akım sinyallerinden genlik ve frekans parametrelerini çıkarmış ve elektronik

hız kontrol cihazlarındaki erken arızaları başarılı biçimde ortaya koymuştur (Marcos-Andrade ve ark., 2024).

HHT tabanlı yaklaşımların yanı sıra, farklı ölçeklerde sinyal özelliklerini ortaya çıkaran ve zaman-frekans analizinde yaygın olarak kullanılan bir diğer yöntem de Wavelet dönüşümüdür. Lou ve Loparo (2004), dalgacık dönüşümüne dayalı özellik çıkarımı ve bulanık mantık tabanlı sınıflandırıcılar kullanan bir yöntem önermişler ve önerilen yöntemin farklı yük koşullarında güvenilir sonuçlar verdiğini göstermiştir (Lou & Loparo, 2004). Chattopadhyay ve ark. (2012), BLDC motor sürücüsünde stator akımı, rotor hızı ve ivmesindeki harmoniklerin tespitinde ayırık dalgacık dönüşümünü (DWT) kullanarak kontrol sisteminin doğruluğunu artırmış (Chattopadhyay ve ark., 2012); Agrawal ve Jayaswal (2019) ise rulman arızalarının sınıflandırılmasında sürekli dalgacık dönüşümünü (CWT) kullanarak yöntemin arızaları güvenilir biçimde ayırt edebildiğini göstermiştir (Agrawal & Jayaswal, 2020). Choudhary ve ark. (2023), BLDC ve SRM motorlarında rulman arızalarının tespisi için Wavelet tabanlı zaman-frekans temsilleri kullanmış ve bu temsilleri CNN ile sınıflandırarak %91 ile %98 doğruluk aralığında başarılı sonuçlar elde etmiştir (Choudhary ve ark., 2023). Liang ve ark. (2022), rulman arızalarının tespisi için Wavelet Dönüşümü ve geliştirilmiş ResNet tabanlı bir yöntem önermişler ve önerilen yöntemin gürültülü sinyaller ile hatalı etiketler altında dahi yüksek doğruluk ve güçlü dayanıklılık sağladığını göstermişlerdir (Liang ve ark., 2022). Gao ve ark. (2025), rulman arızalarının teşhisinde dalgacık dönüşümüne dayalı yöntemleri geliştirmiş ve önerdikleri uyarlamalı WT yaklaşımının hem simülasyon hem de deneysel sinyallerde arıza özelliklerini güvenilir biçimde ortaya koyduğunu göstermiştir (Gao ve ark., 2025)

Motor arıza teşhisinde en yaygın kullanılan zaman-frekans dönüşümlerinden biri olan Kısa Zamanlı Fourier Dönüşümü (STFT), hesaplama verimliliği ve uygulanabilirlik açısından HEA gibi gerçek zamanlı uygulamalar için özellikle uygun bir yöntemdir. Shifat ve Hur (2020), BLDC motorlarında sargı kısa devre arızalarının tespiti için titreşim ve akım sinyallerini birlikte kullanarak Fast Kurtogram, Autogram ve STFT tabanlı bir analiz çerçevesi geliştirmiştir. Çalışma, arızanın erken evrelerinde dahi frekans bileşenlerini ve arıza seviyesini güvenilir biçimde ortaya koymuştur. (Shifat & Hur,

2020). STFT'nin başarısı yalnızca motor arıza teşhisinde değil, farklı sinyal işleme uygulamalarında da ortaya konmuştur. Örneğin, Liyanagedera ve ark. (2025), EEG verilerinde STFT tabanlı zaman-frekans özelliklerini kullanarak sınıflandırma yapmış ve umut verici sonuçlar elde etmiştir (Liyanagedera ve ark., 2025). Biyomedikal alanda yapılan başka bir çalışmada ise Soontornnapar ve Ploysuwan (2025), STFT tabanlı özellik çıkarımı ile CNN tabanlı bir otoenkoderi birleştirerek düşme tespitinde yüksek doğruluk ve genelleme başarısı elde etmişlerdir (Soontornnapar & Ploysuwan, 2025). Motor arızaları bağlamında yapılan diğer bir çalışmada, Vippala ve ark. (2021), BLDC motorlarda rotor arızalarının tespiti için STFT tabanlı bir yöntem önermiştir. Çalışmada, stator akımı spektrogramından çıkarılan frekans bileşenleri kullanılarak hata metrikleri oluşturulmuş ve bu metrikler aracılığıyla dinamik eksantriklik ve dengesizlik arızaları başarılı şekilde sınıflandırılmıştır (Vippala ve ark., 2021). Ghafouri Matanagh ve ark. (2024) ise PMSM motorlarında kırık mıknatıs yüzdelerinin tespiti ve sınıflandırılması için stator faz akımlarına uygulanan STFT'den elde edilen spektrogramları kullanmış ve TL tabanlı, önceden eğitilmiş AlexNet modeli ile yüksek başarı elde etmişlerdir (Ghafouri Matanagh ve ark., 2024). Mohammad-Alikhani ve ark. (2025), gürültülü koşullarda arıza tespit performansını artırmak amacıyla Diferansiyel STFT (Short Time Fourier Transform) tabanlı çok kanallı bir özellik çıkarım yöntemi geliştirmiş ve bu özellikleri kanal bazlı düzenlenmiş bir CNN modelinde kullanmıştır. Önerilen yaklaşım, CWRU rulman veri seti, PMSM ITSC arızası ve karışık arıza veri setlerinde yüksek başarılar elde etmiştir (Mohammad-Alikhani ve ark., 2025). Benzer şekilde Zhou ve ark. (2025), STFT tabanlı zaman-frekans mod ayrıştırma (TFMD) yöntemini önermiş; bu yaklaşım yüksek gürültü koşullarında dahi modları doğru şekilde ayırarak sinyalin zaman-frekans çözümlemesini geliştirmiştir (Zhou ve ark., 2025).

Derin öğrenme modellerinin eğitimi, yeterli miktarda verinin bulunmaması durumunda önemli ölçüde kısıtlanmaktadır. Veri yetersizliği, modellerin aşırı öğrenme göstermesine ve dolayısıyla genelleme performansının azalmasına yol açmaktadır (Ahmed ve ark., 2023). HEA uygulamalarında, özellikle BLDC motorlar için yeterli arıza verisi elde etmek hem maliyetli hem de zaman alıcı olduğundan, veri artırma teknikleri büyük önem taşımaktadır. Bu sorunu gidermek amacıyla sinyal ve görüntü işleme temelli veri artırma (data augmentation) tekniklerinden yararlanılmaktadır.

Sinyal işleme tabanlı veri artırma yaklaşımlarında, ayrıştırma yöntemleri yaygın olarak kullanılmaktadır (Otero ve ark., 2022). Empirical Mode Decomposition (EMD) sinyali IMF'lere ayırır da mod karışımı sorunları nedeniyle sınırlı kalmış, bu sorunu azaltmak için Ensemble Empirical Mode Decomposition (EEMD) geliştirilmiş, ancak EEMD'nin eksiklerini gidermek üzere daha kararlı ve anlamlı bileşenler sunan Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) yöntemi önerilmiştir (Mohanty ve ark., 2016). EMD, sinyallerin daha ayrıntılı ve anlamlı özelliklerini ortaya çıkarmada, ayrıca sınırlı verinin artırılması ve filtrelenmesinde önemli bir yöntem olarak öne çıkmıştır. Cheng ve ark. (2009), döner makinelerin arıza teşhisinde EMD yöntemini kullanarak titreşim sinyallerinden elde edilen bileşenlerin arıza türlerini güvenilir biçimde ayırt etmede etkili olduğunu göstermiştir (Cheng ve ark., 2009). Fang ve ark. (2016) ise rulman arızalarının teşhisinde EMD yönteminin mod karışımı nedeniyle sınırlı kaldığını, buna karşılık Ensemble Empirical Mode Decomposition (EEMD) yönteminin bu sorunu gidererek arıza frekans bileşenlerini daha doğru ve güvenilir şekilde ortaya koyduğunu göstermiştir (Fang ve ark., 2018). Mohanty ve ark. (2016) ise rulman arızalarının vibro-akustik analizinde EMD, EEMD ve CEEMDAN yöntemlerini karşılaştırmış ve CEEMDAN'ın daha iyi spektral ayrışma ile daha kısa hesaplama süresinde güvenilir sinyal çıkarımı sağladığını bildirmişlerdir (Mohanty ve ark., 2016). Selçuk Aksoy (2022) çalışmasında, PMSM akı sinyallerini CEEMDAN yöntemi ile ayrıştırarak IMF bileşenlerini elde etmiş, bu bileşenlerden çıkarılan zaman, frekans ve zaman-frekans tabanlı özellikleri kullanarak arıza teşhisi ve sınıflandırmada başarılı sonuçlar elde etmiştir (Selçuk Aksoy, 2022).

Öte yandan, görüntü işleme tabanlı veri artırma yaklaşımlarında derin öğrenme yöntemleri, geleneksel makine öğrenmesi yöntemlerine kıyasla daha yüksek performans göstermekte, ancak eğitim için büyük veri kümelerine duyulan ihtiyaç önemli bir sınırlılık oluşturmaktadır. Bu sınırlılığın üstesinden gelmek için dönüşüme dayalı (rotation, scaling, flipping vb.) klasik artırma tekniklerinin yanı sıra, veri üretmeye dayalı yöntemler ve TL yaklaşımları da yaygın olarak kullanılmaktadır. Shorten ve Khoshgoftaar (2019), derin öğrenme modellerinin büyük veri kümelerine olan bağımlılığını vurgulayarak, sınırlı veri sorununu aşmak için dönüşüme dayalı (geometrik ve renk uzayı), oversampling ve GAN tabanlı yöntemler gibi çeşitli görüntü işleme

tabanlı veri artırma tekniklerinin yaygın olarak kullanıldığını belirtmişlerdir (Shorten & Khoshgoftaar, 2019). Alomar ve ark. (2023), derin öğrenme modellerinin sınırlı veri nedeniyle aşırı öğrenme sorununa yatkın olduğunu ve bu sorunun giderilmesinde veri artırma tekniklerinin kritik bir rol oynadığını vurgulamış, özellikle geometrik dönüşümler, fotometrik işlemler ve veri üretmeye dayalı yöntemler gibi yaklaşımların hem sınıflandırma hem de segmentasyon görevlerinde yaygın olarak kullanıldığını belirtmişlerdir (Alomar ve ark., 2023). Kumar ve ark. (2024), derin öğrenme tabanlı bilgisayarlı görü görevlerinde aşırı öğrenme sorununu azaltmada veri artırma yöntemlerinin kritik rolünü vurgulamış ve dönüşüme dayalı klasik tekniklerin yanı sıra gelişmiş yöntemler için kapsamlı bir sınıflandırma ve değerlendirme sunmuşlardır (Kumar ve ark., 2023).

Görüntü tabanlı analizlerde kullanılan derin öğrenme yöntemleri, büyük veri kümelerinde yüksek başarı sağlasa da uzun eğitim ve test süreleri gerektirmektedir. Bu sorunun üstesinden gelmek için önceden eğitilmiş modellerin yeniden kullanıldığı Transfer Learning (TL) yaklaşımı yaygın olarak tercih edilmekte, böylece veri yetersizliği, maliyet ve zaman kısıtları önemli ölçüde azaltılmaktadır (Chlap ve ark., 2021). Sun ve ark. (2023), arıza teşhisinde TL tabanlı bir yöntem önermiş ve bu yaklaşımın farklı veri setlerinde yüksek doğruluk ve güçlü genelleme sağladığını ortaya koymuştur (X. Sun ve ark., 2023). Yang ve ark. (2025), döner makinelerde arıza teşhisi için TL'ye dayalı bir yöntem önermiş ve farklı veri kümelerinde karşılaşılan sorunları azaltarak kabul edilebilir doğruluk oranları yakaladıklarını söylemişlerdir (Yang ve ark., 2025). Su ve ark. (2024), sınırlı veriye sahip hedef alanlarda sınıflandırma performansını artırmak amacıyla TL'yi veri artırma stratejileri ile birleştirmiş ve farklı veri setleri üzerinde yaptıkları deneylerle bu yaklaşımın etkinliğini ortaya koymuşlardır (Su ve ark., 2024).

Ayrıca, TL'nin bir parçası olan fine-tuning yöntemi, önceden eğitilmiş modelin yeni veri setine uyumunu artırmak amacıyla hiperparametrelerin yeniden ayarlanmasını sağlamaktadır [92]. Ding ve ark. (2023), önceden eğitilmiş modellerin yeni görev ve veri setlerine uyarlanmasında fine-tuning yönteminin temel bir yaklaşım olduğunu, ancak büyük ölçekli modellerdeki yüksek maliyetleri azaltmak amacıyla parametre-verimli fine-tuning tekniklerinin geliştirildiğini vurgulamışlardır (Ding ve ark., 2023). Dengfeng

ve ark. (2025), rulman arızalarının tespitinde TL ile önceden eğitilmiş modellerin fine-tuning edilmesini birleştirmiş ve bu yaklaşımın farklı yük koşullarında sınırlı veriyle dahi başarılı sonuçlar elde ettiklerini bildirmişlerdir (Dengfeng ve ark., 2025).

2.2. Hafif Elektrikli Araçlar (HEA)

Elektrikli araçlara ait ilk çalışmalar 19. yüzyılın sonlarına kadar uzansa da HEA'ların popülerleşmesi özellikle 2000'li yıllardan sonra gerçekleşmiştir. Bu dönemde elektrik motorlarındaki ilerlemelerle paralel olarak batarya teknolojilerindeki gelişmeler ve karbon salınımını azaltmaya yönelik küresel politikalar, HEA'ların kullanımını hızlandırmıştır (Chan, 2007; Ehsani ve ark., 2018; Suarez-Bertoa & Astorga, 2016). Günümüzde ürün çeşitliliği giderek artmış olup, elektrikli bisiklet, scooter ve motosikletler şehir içi ulaşımında öne çıkan temel kategorileri oluşturmaktadır. Avrupa Birliği düzenlemelerine göre 1 kW ile 10 kW motor gücü sınırına yada 24V - 72V gerilim sınırına sahip araçlar HEA kapsamında değerlendirilmektedir (Gössling, 2020; Infineon Technologies, 2019). Bu özellikleri sayesinde HEA'lar, hem bireysel kullanıcıların kişisel ulaşım ihtiyaçlarını karşılamakta hem de ortak kullanıma dayalı ulaşım sistemlerinin önemli bir parçası haline gelmektedir (Mesimäki & Lehtonen, 2023). Bu tez çalışmasında kullanılan elektrikli scooter Şekil 2.1'de görülmektedir.



Şekil 2.1. Elektrikli scooter

2.3. Elektrikli Araçlarda Kullanılan Motor Türleri

Elektrikli araçlarda kullanılan elektrik motoru tipi, aracın performans, enerji verimliliği, maliyeti ve sürdürülebilirliği üzerinde belirleyici bir rol oynamaktadır. Literatürde elektrikli araçlarda kullanılan başlıca motor türleri arasında Doğru Akım (DC) motorları, PMSM, IM, SRM ve BLDC motorlar yer almaktadır (Krishnamoorthy & Panikkar, 2024; Rimpas ve ark., 2023).

Klasik DC motorlar, yüksek ilk kalkış torku ve kolay hız kontrolü gibi avantajlar sunmakla birlikte fırça ve kollektör yapıları nedeniyle bakım ihtiyacı duyarlar. Bu özellik, motorların elektrikli araçlarda yaygın kullanımını sınırlandırmış ve yerlerini fırçasız alternatiflere bırakmıştır (Ehsani ve ark., 2018). İndüksiyon Motorlar (IM) ise düşük maliyet, sağlamlık ve güvenilirlikleri ile öne çıkmakta olup geniş hız aralığında çalışabilmeleri önemli bir avantaj sağlamaktadır. Ancak düşük hızlarda verimliliklerinin düşük olması bu motorların kullanımını sınırlamaktadır (Pellegrino ve ark., 2012). PMSM, yüksek güç yoğunluğu, geniş hız aralığında verimlilik ve sessiz çalışma özellikleri nedeniyle günümüzde en yaygın kullanılan motor tipidir. Bununla birlikte, nadir toprak elementlerine dayalı mıknatısların yüksek maliyetleri ve tedarik riskleri, PMSM'lerin en önemli dezavantajlarıdır (Zhu & Howe, 2007). Fırçasız doğru akım motorlar (BLDC), DC motorların basit kontrol avantajlarını PMSM'lerin yüksek verimlilik ve kompakt yapısıyla birleştirmekte; elektronik komütasyon sayesinde bakım gereksinimini azaltarak özellikle HEA'larda (örneğin elektrikli scooter ve e-bisikletlerde) yaygın bir kullanım alanı bulmaktadır (Krishnan, 2017). Anahtarlamalı Relüktans Motorlar (SRM) ise basit rotor yapısı, düşük maliyetleri ve mıknatıs gerektirmemeleriyle öne çıkmakta; ancak yüksek tork dalgalanmaları ve akustik gürültü sorunları sebebiyle gelişmiş kontrol algoritmalarına ihtiyaç duymaktadır (Abdel-Aziz ve ark., 2024). Elektrikli araçlarda kullanılan motor türlerinin temel özellikleri Çizelge 2.1'de özetlenmektedir. Gösterilen tabloda da özetlendiği gibi, her motor tipinin kendine özgü avantaj ve sınırlılıkları bulunmakta; motor seçimi, elektrikli araç tasarımında performans, maliyet, güvenilirlik ve sürdürülebilirlik kriterleri birlikte değerlendirilerek yapılmaktadır.

Bu tez kapsamında kullanılan HEA, BLDC bir motora sahip olduğundan, devam eden bölümde BLDC motorun yapısı, matematiksel modeli ve çalışma prensipleri ayrıntılı biçimde incelenecektir.

Çizelge 2.1. Elektrikli araçlarda kullanılan motor türlerinin temel özellikleri

Motor Tipi	Avantajları	Dezavantajları	Tipik Kullanım alanları
DC Motor (Brushed)	Basit kontrol Yüksek ilk kalkış torku	Bakım gerektirmesi, Düşük ömür, Kıvılcım, Gürültü	Erken dönem Elektrikli Araçlar (EA), küçük ölçekli araçlar
İndüksiyon Motor (IM)	Sağlamlık, düşük maliyet, fırçasız yapı, güvenilirlik, geniş hız aralığı	Düşük hızlarda verimin azalması, Yüksek akım ihtiyacı,	Tesla Model S, ticari EA'lar
Daimi Mıknatıslı Senkron Motor (PMSM)	Yüksek verimlilik, yüksek güç/tork yoğunluğu, geniş hız aralığında iyi performans, sessiz çalışma	Nadir toprak elementlerine bağımlılık, yüksek mıknatıs maliyeti	Nissan Leaf, BMW i3, Chevrolet Bolt
Fırçasız DC Motor (BLDC)	PMSM'ye benzer yüksek verimlilik, kompakt yapı, elektronik komütasyon düşük bakım, düşük gürültü	Karmaşık sürücü devresi, hassas kontrol ihtiyacı	Elektrikli scooter, e-bike, hafif EA'lar
Anahtarlama Relüktans Motor (SRM)	Basit ve sağlam rotor, düşük maliyet, mıknatıs gerekirmeme (kaynak bağımsızlığı), yüksek sıcaklık dayanımı	Tork dalgalanması, akustik gürültü, gelişmiş kontrol algoritması ihtiyacı	Ağır hizmet araçları, prototip EA'lar

2.4. Fırçasız Doğru Akım Motorları (BLDC)

Fırçasız Doğru Akım Motoru (BLDC), klasik DC motorlarda mekanik olarak fırça ve kollektör ile yapılan komütasyonun elektronik olarak yapıldığı yenilikçi bir elektrik makinesidir (Gamazo-Real ve ark., 2010). Rotorunda daimi mıknatıs, statorunda üç fazlı sargılar bulunmaktadır. Fırçaların kaldırılması, sürtünme ve bakım ihtiyacını azaltarak verimi artırmakta; böylece motorun daha sessiz ve uzun ömürlü olmasını sağlamaktadır (Kumar ve ark., 2025). BLDC motorlar; havacılık, uzay, otomotiv, tıp ve benzeri alanlarda, farklı hızlarda çalışabilme, frenleme yapabilme ve devir yönünü değiştirebilme özellikleri sayesinde yaygın olarak kullanılmaktadır (Padilla-García ve ark., 2023). BLDC motorların kaynak gerilimleri, uygulama alanına bağlı olarak geniş bir aralıkta değişmektedir. Küçük ölçekli uygulamalarda, örneğin taşınabilir cihazlar, hobi robotları ya da HEA'lar gibi düşük güçlü ekipmanlarda genellikle 12 V-24 V veya en fazla 48 V


gibi düşük gerilimler tercih edilmektedir. Öte yandan, endüstriyel otomasyon sistemleri, elektrikli araçlar ve benzer yüksek performans gerektiren uygulamalarda 200-300 V ve üzeri gerilimler de kullanılmaktadır (Electrical Technology, 2016; Rotontek, 2023). Bu motorlar kullanım yerlerine göre, dış rotorlu, iç rotorlu ve disk tipi olmak üzere farklı yapılarda üretilmektedir (Alias, 2020). Bunun yanında, çeşitli anahtarlama teknikleri ve konum bilgisini sağlayan sensörlü ya da kestirim tabanlı sensörsüz kontrol yöntemleri, BLDC motorun farklı uygulamalarda daha verimli çalışmasını sağlamaktadır (Gamazo-Real ve ark., 2010; Padilla-García ve ark., 2023). Şekil 2.2’de BLDC bir motorun kesit görünümü gösterilmiştir.



Şekil 2.2. BLDC motor

2.4.1. BLDC motorun yapısı

BLDC motorlar temel olarak stator ve rotordan oluşur. Stator, silisli sac paketler üzerine yerleştirilmiş üç fazlı sargılardan meydana gelir ve motorun manyetik alanını oluşturur (Gamazo-Real ve ark., 2010). Rotor kısmında ise daimi mıknatıslar bulunur. Bu mıknatıslar, yüksek enerji yoğunlukları sayesinde motorun kompakt yapıda olmasına ve yüksek verimle çalışmasına imkan tanır. Stator ile rotor arasındaki dar hava aralığı ise manyetik akının etkili bir şekilde iletilmesini sağlar (Mohanraj ve ark., 2022). Şekil 2.3’de motorun yapısını gösteren bileşenler görülmektedir.



Şekil 2.3. BLDC motor bileşenleri

Motorun yapısında ayrıca mil (şaft), rulmanlar ve koruyucu gövde yer alır. Mil, rotorun dönme hareketini mekanik sisteme aktarırken, rulmanlar sürtünmeyi en aza indirerek daha sessiz ve verimli çalışmayı sağlar. BLDC motorlarda rotorun konumunun belirlenmesi için sıklıkla Hall sensörleri veya enkoderler kullanılır. Bununla birlikte, bazı uygulamalarda ek sensörlere ihtiyaç duymadan, akım ve gerilim ölçümlerine dayalı sensörsüz kontrol teknikleri de tercih edilmektedir (Kumar ve ark., 2025; Mohanraj ve ark., 2022).

BLDC motorlar farklı ihtiyaçlara göre iç rotorlu, dış rotorlu veya disk tipi tasarımlarla üretilir. İç rotorlu motorlar daha kompakt yapıları ve yüksek hızlarda çalışabilme özellikleriyle öne çıkarken, dış rotorlu motorlar daha yüksek tork gerektiren uygulamalarda kullanılmaktadır. Disk tipi motorlar ise genellikle özel uygulamalarda tercih edilmektedir (Mohanraj ve ark., 2022; Padilla-García ve ark., 2023).

Stator yapısı

BLDC motorlarda stator, motorun sabit kısmını oluşturur ve genellikle lamine edilmiş silisli çelik saclardan meydana gelir. Bu yapı, girdap akımlarını ve demir kayıplarını azaltarak motor verimliliğini artırır (Lai ve ark., 2023; Mohanraj ve ark., 2022). Stator üzerinde açılmış oluklar arasına yerleştirilen faz sargıları, motorun manyetik alanını oluşturan en temel bileşenlerdir. Bu sargılar çoğunlukla yalıtılmış bakır telden imal edilir

ve faz sayısına bağılı olarak stator çevresine simetrik biçimde dağıtılır (Gamazo-Real ve ark., 2010; Mohanraj ve ark., 2022). BLDC motorlarda yaygın olarak kullanılan üç fazlı yapıda, sargılar çoğunlukla yıldız bağlantı şeklinde düzenlenmekte, bu bağlantı sayesinde stator uçlarına uygulanan gerilimle motorun dönmesi sağlanmaktadır. Böylece uygulanan kontrol stratejisine bağılı olarak trapezoidal veya sinüzoidal zıt elektromotor dalga şekilleri elde edilmektedir (Kumar ve ark., 2025; Padilla-García ve ark., 2023).

Statorun kutup sayısı ve oluk yapısı, motorun hız ve tork karakteristiğini doğrudan etkileyen parametrelerdir. Düşük hızda çalışması planlanan uygulamalarda çok kutuplu, yüksek hız gerektiren yerlerde ise az kutuplu stator tasarımları tercih edilmektedir. Ancak kutup sayısının artması, oluk sayısının da artmasına yol açarak motor boyutlarını sınırlayabilmektedir (Liu ve ark., 2024). Şekil 2.4’de stator yapısı görülmektedir.



Şekil 2.4. Stator yapısı

Rotor yapısı

BLDC motorlarda rotor, daimi mıknatısların yerleştirildiği ve motorun döner kısmını oluşturan yapıdır. Rotorun temel görevi, stator sargılarında oluşturulan manyetik alan ile etkileşime girerek dönme hareketini gerçekleştirmektir. Rotorun üzerine yerleştirilen mıknatıslar, genellikle neodimyum-demir-bor (NdFeB) veya samaryum-kobalt (SmCo) gibi yüksek manyetik enerji yoğunluğuna sahip nadir toprak elementlerinden üretilmektedir (Mohanraj ve ark., 2022). Rotor tasarımları, uygulamanın ihtiyaçlarına göre farklılık gösterebilir. İç rotorlu motorlarda, rotor statorun içinde yer almakta ve

düşük ataletleri sayesinde yüksek hız uygulamaları için uygun olmaktadır. Dış rotorlu motorlarda ise rotor statorun dış kısmında bulunur; bu tasarım daha büyük çap ve moment kolu sunduğundan yüksek tork gerektiren uygulamalarda tercih edilmektedir. Ayrıca özel uygulamalar için disk tipi rotor yapıları mevcuttur (Gamazo-Real ve ark., 2010; Mohanraj ve ark., 2022; Padilla-García ve ark., 2023). Rotor üzerinde kullanılan mıknatısların yerleşim biçimi motorun manyetik performansını doğrudan etkilemektedir. Mıknatıslar radyal, yüzeysel veya gömülü şekilde yerleştirilebilir. Yüzey montajlı mıknatıs yapıları üretim kolaylığı ve düşük maliyet avantajı sağlarken, gömülü mıknatıs tasarımları daha yüksek mekanik dayanım ve zayıflatılmış alan kontrolü imkanı sunar. Bunun sonucunda geniş hız aralığında çalışma imkanı sağlar. Rotorun mekanik tasarımı da motor performansı açısından kritik öneme sahiptir. Rotor mili, dönme hareketini mekanik sisteme iletirken, mıknatısların merkezkaç kuvvetlerine karşı güvenli bir şekilde sabitlenmesi gerekir (Gamazo-Real ve ark., 2010; Mohanraj ve ark., 2022). Şekil 2.5'te rotor yapısı gösterilmektedir.



Şekil 2.5. HEA BLDC'nin Hub rotor yapısı


Hava aralığı

Hava aralığı, elektrik makinelerinde rotor ile stator arasında motorun elektromanyetik performansını doğrudan etkileyen önemli bir tasarım parametresidir. Hava aralığının büyüklüğü, manyetik akının rotor ile stator arasında iletim verimliliğini doğrudan etkiler. Dar hava aralıkları tork üretimini desteklerken, geniş hava aralıkları mekanik açıdan avantaj sağlasa da motorun manyetik performansını olumsuz etkileyebilir. Bu nedenle, hava aralığı tasarımında elektromanyetik performans ile mekanik güvenilirlik arasında

bir denge gözetilmesi gerekmektedir. Ayrıca hava aralığının düzgünlüğü de motorun titreşim ve gürültü karakteristiklerini etkileyen bir faktördür (Liu ve ark., 2024).

2.4.2. BLDC motorun matematiksel modeli

BLDC motorun matematiksel modeli, motorun elektriksel ve mekanik davranışlarını ifade etmek amacıyla diferansiyel denklemler üzerinden kurulmaktadır. Modelleme yapılırken bazı parametreler ideal kabul edilmekte, bazıları ise analizleri basitleştirmek için ihmal edilmektedir. Genellikle hava aralığında manyetik akının trapezoidal dalga formuna sahip olduğu, stator sargılarının dengeli ve simetrik dağıldığı, faz dirençlerinin eşit olduğu varsayılmaktadır. Buna karşılık histerezis ve girdap (eddy) kayıpları, nüve doyumu, rotor reaksiyonu ve cogging momentleri çoğunlukla göz ardı edilmektedir. Ayrıca sürücü devresinde kullanılan BJT, MOSFET, IGBT vb. gibi yarı iletken anahtarlama elemanlarında ideal kabul edilerek denklemler basitleştirilmektedir. Bu varsayımlar altında geliştirilen elektriksel ve mekanik denklemler, motorun dinamik tepkilerinin incelenmesi ve farklı kontrol algoritmalarının uygulanması için temel oluşturmaktadır (Khan ve ark., 2025; Velchenko ve ark., 2024).



Şekil 2.6. BLDC motorun sargı bağlantısı


Şekil 2.6’da görüldüğü gibi, yıldız bağlı BLDC motor üç fazlıdır, nötr noktası dışarıya çıkarılmamıştır. Her faz için faz direnci R , faz endüktansı L ve her faz için zıt-EMK e_k kaynağının seri bağlanmasıyla modellenir ($k \in \{a, b, c\}$).

Varsayımlar:

- Faz parametreleri simetriktir ($R_a = R_b = R_c = R, L_a = L_b = L_c = L$);

- zıt-EMK trapezoidal dalga formundadır;
- demir kayıpları, nüve doyumu, cogging momentı ve armatür reaksiyonu ihmal edilir.
- inverterde kullanılan BJT, MOSFET, IGBT vb. gibi yarı iletkenler ideal kabul edilir.

Şekil 2.7’de BLDC motorun faz eksenleri ve rotor manyetik ekseninin koordinat sistemindeki görüntüsü görülmektedir.



Şekil 2.7. BLDC motor modelinin koordinat sisteminde gösterimi

Her faz için gerilim denklemleri; Ohm kanunu + endüktif etki + zıt-EMK olarak yazılır.

$$u_a = Ri_a + L \frac{di_a}{dt} + e_a(\theta_e), \quad (2.1)$$

$$u_b = Ri_b + L \frac{di_b}{dt} + e_b(\theta_e), \quad (2.2)$$

$$u_c = Ri_c + L \frac{di_c}{dt} + e_c(\theta_e). \quad (2.3)$$

Burada, i_a , i_b , i_c faz akımları, u_a , u_b , u_c faz gerilimleri, e_a , e_b , e_c ise zıt-EMK bileşenleridir. R faz direnci, L faz endüktansıdır.

Bu üç denklem matris formunda daha derli toplu yazılabilir.

$$u_{abc} = RI_{abc} + L \frac{d}{dt} I_{abc} + e_{abc}(\theta_e), \quad (2.4)$$

$$\begin{bmatrix} u_a \\ u_b \\ u_c \end{bmatrix} = \begin{bmatrix} R & 0 & 0 \\ 0 & R & 0 \\ 0 & 0 & R \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} + \begin{bmatrix} L & 0 & 0 \\ 0 & L & 0 \\ 0 & 0 & L \end{bmatrix} \frac{d}{dt} I_{abc} + \begin{bmatrix} e_a \\ e_b \\ e_c \end{bmatrix} \quad (2.5)$$

Eğer fazlar arası karşılıklı endüktanslar da hesaba katılmak istenirse L matrisi simetrik ama köşegen dışı elemanlara sahip olur.

$$L = \begin{bmatrix} L_s & M & M \\ M & L_s & M \\ M & M & L_s \end{bmatrix} \quad (2.6)$$

zıt-EMK denklemleri ise;

Rotor döndükçe stator sargılarında indüklenen zıt-EMK, elektriksel açıya (θ_e) ve açısal hızı (ω) bağlıdır.

$$e_k(\theta_e, \omega) = k_e \omega f_k(\theta_e), k \in \{a, b, c\} \quad (2.7)$$

Burada k_e zıt-EMK sabiti, $f_k(\theta_e)$ ise faza özgü trapezoidal dalga fonksiyonudur. Elektriksel açı $\theta_e = p\theta_m$ olup p kutup çifti sayısıdır.

Motorun ürettiği elektromanyetik tork, faz akımları ile zıt-EMK arasındaki ilişkiye dayanır ve şu şekilde ifade edilir:

$$T_e = \frac{e_a i_a + e_b i_b + e_c i_c}{\omega} \quad (2.8)$$

Alternatif olarak, tork sabiti k_t kullanılarak:

$$T_e = k_t [f_a(\theta_e) i_a + f_b(\theta_e) i_b + f_c(\theta_e) i_c] \quad (2.9)$$

şeklinde yazılabilir.

Rotorun mekanik davranışı Newton'un hareket denklemleri ile tanımlanır:

$$J \frac{d\omega}{dt} + B_\omega = T_e - T_L \quad (2.10)$$

Burada J rotorun atalet momenti, B viskoz sürtünme katsayısı, T_L yük momentidir.

Motorun fazlarına gerilim, altı anahtarlı üç fazlı inverter üzerinden uygulanır. DC bara gerilimi (V_{dc}) fazlara üst ve alt anahtarların durumuna bağlı olarak iletilir. Anahtarlama fonksiyonları $S_a, S_b, S_c \in \{0,1\}$ ile gösterilirse;

$$u_a = \frac{V_{dc}}{2} (2S_a - 1) - u_n, \quad (2.11)$$

$$u_b = \frac{V_{dc}}{2} (2S_b - 1) - u_n, \quad (2.12)$$

$$u_c = \frac{V_{dc}}{2} (2S_c - 1) - u_n. \quad (2.13)$$

Burada u_n nötr potansiyelidir. Komütasyon zamanlaması genellikle Hall sensörleriyle ya da sensörsüz yöntemlerle belirlenir.

BLDC motorun elektriksel ve mekanik dinamikleri durum-uzay formuna dönüştürülebilir. Durum vektörü, $x = [i_a \ i_b \ i_c \ \omega \ \theta_e]^T$ seçilirse, sistem denklemleri:

$$i_a = \frac{1}{L} (u_a - R i_a - e_a(\theta_e, \omega)), \quad (2.14)$$

$$i_b = \frac{1}{L} (u_b - R i_b - e_b(\theta_e, \omega)), \quad (2.15)$$

$$i_c = \frac{1}{L}(u_c - Ri_c - e_c(\theta_e, \omega)), \quad (2.16)$$

$$\omega = \frac{1}{J}(T_e(i, \theta_e, \omega) - T_L - B_\omega), \quad (2.17)$$

$$\theta_e = p\omega. \quad (2.18)$$

Bu model zamanla değişen ve doğrusal olmayan bir yapıdadır, çünkü zıt-EMK ve tork ifadeleri rotor konumuna (θ_e) ve hıza (ω) bağlıdır. BLDC motorun matematiksel modelinde kullanılan parametreler Çizelge 2.2’de özetlenmiştir.

Çizelge 2.2. BLDC motorun matematiksel modelinde kullanılan parametreler

Sembol	Açıklama	Birim
R	Faz direnci	Ohm
L	Faz endüktansı	H
k_e	zıt-EMK sabiti	V.s/rad
k_t	Tork sabiti	N.m/A
J	Rotor atalet momenti	kg.m ²
B	Viskoz sürtünme katsayısı	N.m.s
p	Kutup çifti sayısı	-
V_{dc}	DC bara gerilimi	V


2.4.3. BLDC motorun çalışma prensibi

BLDC motorlarda komütasyon işlemi, klasik DC motorlardaki fırça-kolektör mekanizması yerine elektronik anahtarlama elemanları aracılığıyla gerçekleştirilir. Stator üç fazlı sargılardan, rotor ise yüzey veya gömülü kalıcı mıknatıslardan oluşur. Çalışma prensibi, stator sargılarından belirli bir anahtarlama dizisine göre akım geçirilmesiyle döner manyetik alanın oluşturulmasına ve bu alanın rotor kutupları ile etkileşime girerek elektromanyetik tork üretmesine dayanır. Komütasyon zamanlaması, rotorun anlık konumuna bağlıdır ve genellikle Hall sensörleri veya sensörsüz konum kestirim algoritmaları kullanılarak belirlenir. BLDC motorlarda zıt elektromotor kuvveti (zıt-EMK) trapezoidal dalga formu ile modellenir; buna uygun olarak faz akımları da 120° iletim açısıyla anahtarlanır. Bu yöntem, üretilen torkun ortalama değerini sabit tutmayı ve dalgalanmaları azaltmayı amaçlar. Böylece BLDC motorlar, yüksek güç yoğunluğu,

geniş hız aralığında sabit tork karakteristiği ve kontrol edilebilirlik açısından avantaj sağlamaktadır (Krishnan, 2017; Mohanraj ve ark., 2022; Shifat & Hur, 2020)

2.4.4. BLDC motor arızaları

BLDC motorlar diğer elektrik motorlarında olduğu gibi, çoğunlukla zorlu çalışma koşullarında kullanılmaktadır. Bu koşullar altında motorlar; nem, toz, sıcaklık değişimleri, aşırı yüklenme, yetersiz soğutma, sık bir şekilde dur-kalk işlemleri veya titreşim gibi etkilere maruz kalabilmektedir. Bu durumlar, motorun performansını ve ömrünü olumsuz yönde etkiler (Shifat & Hur, 2020). Literatürde, BLDC motor bileşenlerinde karşılaşılan arızaların dağılımı Şekil 2.8’de yüzdelik oranlarıyla birlikte gösterilmiştir. Bu motorlarda en çok karşılaşılan arızaların başında %41 gibi yüksek bir oranla rulman arızaları gelmektedir. Bunu %37 ile sargı arızaları ve %12 ile rotor arızaları takip etmektedir. Sensör veya sürücü kaynaklı arızalar ise diğer arızalar kategorisinde değerlendirilmektedir (Da ve ark., 2011; Shifat & Hur, 2020; Zhang & Feng, 2018).



Şekil 2.8. BLDC Motor Arıza Dağılımları

Rulman arızaları

BLDC motorlarda en sık karşılaşılan arıza türü olan rulman arızaları; metal yorgunluğu, montaj hataları, korozyon, aşırı yüklenme ve kir-toz kaynaklı kontaminasyon gibi nedenlerden kaynaklanmaktadır. Bu arızaların en belirgin belirtisi gürültü artışıdır.

Ayrıca yüksek frekanslı titreşimler, motor veriminde azalma ve aşırı ısınma sorunlarıyla da kendini göstermektedir (Da ve ark., 2011; Shifat & Hur, 2020).

Dış bilezik arızası bulunduğunda rulman, rotorun dönme hareketi sırasında her bir bilye geçişi ile periyodik darbe etkisi oluşturur. Bu darbeler rulman titreşim sinyalinde karakteristik bir hata frekansı üretir. Dış Bilezik Arıza Frekansı (BPFO), rulmanın geometrisine ve rotor mekanik hızına bağlı olarak şu şekilde hesaplanır:

$$BPFO = \frac{n}{2} f_r \left(1 - \frac{d}{D} \cos \varphi \right) \quad (2.19)$$

Burada;

n bilye sayısı,

d bilye çapı,

D rulman orta çapı,

φ temas açısı,

$f_r = \frac{\omega}{2\pi}$ rotor mekanik dönüş frekansıdır.

Bu arıza kaynaklı darbe dizisi zaman domeninde şu şekilde modellenilebilir:

$$x(t) = \sum_{k=1}^{\infty} A e^{-\alpha(t-kT_f)} \sin(2\pi f_c(t-kT_f)) \quad (2.20)$$

Burada;

$T_f = 1/BPFO$ darbe periyodu,

A darbe genliği,

α sönüm katsayısı,

f_c darbenin taşıyıcı titreşim frekansıdır.

Bu darbeler rulmanın motor miline aktardığı kuvveti değiştirerek BLDC motorun mekanik dinamiğinde ek bir tork salınımı meydana getirir. Bölüm 2.4.2 (2.10)'da verilen denklem $J \frac{d\omega}{dt} + B_\omega = T_e - T_L$, rulman arızası durumunda şu şekilde güncellenir.

$$J \frac{d\omega}{dt} + B_\omega = T_e - (T_L + T_f(t)) \quad (2.21)$$

Arıza kaynaklı ek zorlayıcı moment; $T_f(t) = A_f \sin(2\pi BPFO t)$ şeklinde ifade edilir.

Bu nedenle dış bilezik arızası, BLDC motorda hız dalgalanmaları, akım sinyallerinde yan bant oluşumları, manyetik akı değişimlerine bağlı tork titreşimleri ve genel mekanik gürültü artışına neden olmaktadır (Li ve ark., 2017). Bu çalışmada oluşturulan yapay dış

bilezik arızası, BLDC motorun mekanik modelindeki bu matematiksel etkiler çerçevesinde değerlendirilmiştir.

Sargı arızaları

Stator sargı arızaları, BLDC motorlarda en sık karşılaşılan elektriksel arızalar arasında yer almaktadır. Bu arızalar; aşırı yüklenme, yüksek sıcaklık ve yetersiz soğutma, üretim hataları, geçici aşırı gerilimler ve titreşim kaynaklı mekanik zorlanmalar sonucunda ortaya çıkabilmektedir. Arızanın en belirgin göstergesi dengesiz faz akımlarıdır. Bunun yanı sıra faz akımlarında harmonik oluşumu, tork dalgalanmaları ve motorun aşırı ısınması da diğer tipik belirtiler arasında yer almaktadır.

Sargı arızası durumunda, BLDC motorun faz gerilimleri (2.1), (2.2) ve (2.3) denklemlerinde verilen faz gerilim modellerinin bozulması ile temsil edilmektedir. Sarım-sarım kısa devresi meydana geldiğinde, ilgili fazda hem direnç hem de endüktans değerleri değişmekte ve kısa devreli sarım grubundan geçen ek bir hata akımı oluşmaktadır. Bu durum, arızalı faz için eşdeğer faz direncinin $R_a^{fault} = R + \Delta R$, eşdeğer endüktansın ise $L_a^{fault} = L - \Delta L$ şeklinde değişmesine neden olur. Aynı zamanda, kısa devreli sarımlar üzerinde indüklenen zıt-EMK bileşeni nedeniyle faz akımı dengesiz hale gelir ve (2.9)'da ki tork ifadesi arızalı durumda;

$$T_e^{fault} = k_t [f_a(\theta_e)(i_a + \Delta i_a) + f_b(\theta_e)i_b + f_c(\theta_e)i_c] \quad (2.22)$$

biçimini alır. Bu ek akım Δi_a , arızalı fazın akı üretimini bozarak elektromanyetik torkta hem genlik düşümüne hem de harmonik içerikli tork dalgalanmalarına yol açmaktadır. Sargı arızası motorun mekanik denkleminde doğrudan bir kuvvet eklemeyiz; ancak üretilen torkun bozulması nedeniyle (2.10) denkleminde T_e terimi zamanla değişen bir yapıya dönüşür. Bu nedenle sargı arızasının matematiksel etkisi, faz dengesizliği kaynaklı tork salınımı ve elektromanyetik verimde azalma şeklinde özetlenebilir (Sharifi & Ebrahimi, 2011).

Mıknatıs arızaları

Rotor ve mıknatıs arızaları, BLDC motorlarda performansı doğrudan etkileyen kritik sorunlar arasında yer almaktadır. Bu arızalar; yüksek sıcaklık, ani akım etkileri, zamanla meydana gelen demanyetizasyon, mekanik zorlanmalar ile korozyon ve oksidasyon gibi faktörlerden kaynaklanır. Bu arızaların en önemli belirtisi, hava aralığında akı yoğunluğunun azalmasına bağlı olarak motor veriminin düşmesidir. Bunun yanı sıra dengesiz manyetik alan oluşumu, artan gürültü ve titreşim de tipik göstergeler arasında sayılmaktadır (Abacı & Kara, 2024; Da ve ark., 2011; Shifat & Hur, 2020).

Bir BLDC motorda rotor üzerindeki kalıcı mıknatısın manyetik akı yoğunluğu $\varphi_r = B_r A_m$ şeklinde ifade edilir. Demanyetizasyon meydana geldiğinde mıknatıs artık kalıcı mıknatıs kalıntı akı yoğunluğunu tam olarak üretmez ve $B_r^{fault} = \alpha B_r$, $0 < \alpha < 1$ şeklinde azalır. Isıl bozulma tipik olarak yerel olduğu için α bir mıknatıs için düşüktür; komşu mıknatıslarda ise hafif düşüş görülür.

BLDC motor matematiksel modelinde zıt-EMK, $e_a = f_a(\theta_r)\omega$, $e_b = f_b(\theta_r)\omega$, $e_c = f_c(\theta_r)\omega$ şeklindedir. Mıknatıs akısının azalması zıt-EMK genliğini doğrudan düşürür. Bu nedenle arızalı durumda; $e_a^{fault} = \alpha e_a$, $e_b^{fault} = \alpha e_b$, $e_c^{fault} = \alpha e_c$ olacaktır. Buradaki α mıknatısın ne kadar demanyetize olduğunun katsayısıdır. Yapılan deneyde tek bir mıknatıs ağır olarak ısıl hasar gördüğü için α lokla olarak daha küçüktür. Bu değişim, diğer fazlarda asimetrik bir zıt-EMK oluşmasına neden olur; bu durum literatürde mıknatıs arızasının temel matematiksel göstergesi olarak kabul edilir (Faiz & Mazaheri-Tehrani, 2017). BLDC faz modeli, $L \frac{di}{dt} + Ri + e = u$ arızalı zıt-EMK yerine yazıldığında;

$$L \frac{di}{dt} + Ri + \alpha e = u \quad (2.23)$$

olur. Bu durumda, arızalı mıknatısın hizasına denk gelen fazda akım formu bozulur, fazlar arasında dengesizlik meydana gelir ve harmonikler artmaya başlar (Faiz & Mazaheri-Tehrani, 2017). BLDC motorun tork denklemi, $T = K_t i$ şeklindedir. Kalıcı mıknatıs akısındaki azalma tork sabitini de azaltır; $K_t^{fault} = \alpha K_t$. Dolayısıyla demanyetizasyonun neden olduğu tork düşümünün matematiksel ifadesi $T^{fault} = \alpha K_t i$ elde edilir. Bölüm

2.4.2’de denklem (2.14 ve (2.18) BLDC motorun doğrusal olmayan durum uzayı modelini açık biçimde vermektedir. Bu model kontrol literatüründe yaygın olarak kullanılan, $\dot{x} = f(x) + g(x)u$ formuna indirgenir. Bu formda içindeki zıt-EMK fonksiyonları $f_a(\theta_r)$, $f_b(\theta_r)$, $f_c(\theta_r)$ kullanıldığından arıza etkisi, $f_{a,b,c}^{fault}(\theta_r) = \alpha f_{a,b,c}(\theta_r)$ olarak modele doğrudan eklenebilir.

Diğer arızalar


BLDC motorlarda sargı, rulman ve mıknatıs arızalarının yanı sıra farklı bileşenlerden kaynaklanan arızalar da ortaya çıkabilmektedir. Bunlar arasında en yaygın olanları eksantriklik arızaları, sürücü arızaları ve sensör arızalarıdır. Eksantriklik arızaları; stator ile rotor arasındaki hava aralığının üretim hataları, rulman aşınmaları veya mekanik hizalama bozuklukları nedeniyle dengesiz hale gelmesi sonucunda ortaya çıkmaktadır. Bu arızalar; dengesiz manyetik çekim, tork dalgalanmaları, gürültü ve titreşim artışı ile akım harmoniklerinde görülen anormalliklerle kendini göstermektedir. Sensör ve sürücü kaynaklı arızalar ise Hall sensörler, inverterler veya güç elektroniği bileşenlerinde meydana gelen bozulmalardan kaynaklanmakta olup; yanlış konum ya da hız ölçümü, motorun ani durması veya dengesiz çalışması gibi sonuçlara yol açabilmektedir (Abacı & Kara, 2024; Da ve ark., 2011; Shifat & Hur, 2020).

BLDC motorlarda mıknatıs-rulman çoklu arıza durumunda, BLDC motorun elektromanyetik ve mekanik dinamikleri Bölüm 3.2.1 ve Bölüm 3.2.2 de anlatılan etkilerin süperpozisyonu ile modellenmektedir. Mıknatıs arızası nedeniyle rotor akı yoğunluğu $\alpha (0 < \alpha < 1)$ katsayısı ile azaldığından (2.7) ve (2.9) denklemlerinde verilen zıt-EMK ve tork ifadeleri arızalı durumda $e_{a,b,c}^{çoklu} = \alpha e_{a,b,c}$ ve $T_e^{çoklu} = \alpha K_t i$ biçimine dönüşmektedir. Rulman arızası ise rotorun mekanik dengesini bozarak (2.10)’da verilen denkleme ek bir bozucu moment $T_{bf}(t)$ olarak yansımaktadır. Böylece çoklu arıza altında rotor dinamiği;

$$J \frac{d\omega}{dt} = \alpha K_t i - T_L - B\omega - T_{bf}(t) \quad (2.24)$$

şeklinde yazılabilir. Bu ifade, demanyetizasyonun tork üretimindeki azalmayı, rulman hasarının ise ek sürtünme ve titreşim kaynaklı tork salınımlarını aynı anda temsilini göstermektedir.

2.5. Arıza Tespit Yöntemi



Şekil 2.9. Arıza sınıflandırma yöntemi (Esmeray ve ark., 2025)

Bu tez çalışmasında, çoklu arıza durumu mevcut olan, BLDC motorla tahrik edilen bir HEA'dan kısa süreli olarak toplanan sınırlı sayıda veriye sahip, çoklu sensör sinyallerinin DL temelli analizine dayanan özgün bir arıza sınıflandırma yöntemi önerilmiştir. Önerilen yönteme ait mimari Şekil 2.9'da gösterilmiştir. Bu mimari dört ana bölümden oluşmaktadır: Birinci bölüm, ham sinyal bölümüdür; ikinci bölüm, veri ön işleme ve optimizasyon bloğudur; üçüncü bölüm, TL sürecidir; dördüncü bölüm ise sınıflandırma başarılarının değerlendirildiği kısımdır. İlk bölümde, ham sinyaller sisteme girdi olarak verilmiştir. İkinci bölümde, veri ön işleme aşamasında sinyal ve görüntü tabanlı olmak üzere iki aşamalı veri artırma işlemi gerçekleştirilmiştir. Bu bölümde ayrıca, veri seti için en iyi sonuçları veren CNN modeli, PSO algoritması kullanılarak optimize edilmiştir. Bu

işlem, en iyi model elde edilene kadar tekrarlanmıştır. Üçüncü bölümde, en iyi CNN modeli belirlendikten sonra, elde edilen hiperparametreler bir TL yöntemi olan fine-tuning ile önceden eğitilmiş derin öğrenme modellerine uygulanmıştır. Son bölümde ise bu modellerin sınıflandırma başarıları değerlendirilmiştir (Esmeray ve ark., 2025).

Bu tez çalışmasında önerilen yöntemin doğrulanması için önerilen sinyal işleme aşamaları, Loparo (Loparo, 2012) tarafından hazırlanan Case Western Reserve University (CWRU) tarafından yayımlanan (Case Western Reserve University, 2025) rulman arıza veri seti kullanılarak simüle edilmiş ve rulman arızası başarıyla tespit edilmiştir (Esmeray ve ark., 2025). Söz konusu veri seti titreşim sinyallerinden elde edilmiş olup, sağlam durumun yanı sıra bir rulmana ait iç bilezik, dış bilezik ve bilye arızalarını içermektedir. Bu tez kapsamında geliştirilen veri işleme yaklaşımı, aynı yöntemsel çerçeveye esas alınarak akı, akım, akustik, gerilim ve titreşim olmak üzere beş farklı sensörden deneysel olarak toplanan özgün veri setine uygulanmıştır.

2.6. Uyarlanabilir Gürültü ile Komple Topluluk Görgül Kip Ayırıştırması (CEEMDAN)

Bu yöntem, doğrusal olmayan zaman serilerinin analizi için, geleneksel Deneysel Mod Ayırıştırma (EMD) yöntemi geliştirilerek önerilmiştir. Ayırıştırma yöntemleri, sinyallerin filtrelenmesi ve özelliklerinin çıkarılması amacıyla yaygın biçimde kullanılmaktadır. Bunun yanında, sinyal tabanlı veri artırma süreçlerinde de önemli bir rol oynamaktadır. EMD, bir zaman serisinde, frekanslarda ve genliklerde olan verileri ayırıştırarak, her bir bileşeni "empirik mod" adı verilen dar bantlı frekans bileşenlerine dönüştürür. EMD sinyalin durumuna göre, sinyalde belirli bir aralığına odaklandığı için bir sonraki sinyal parçasını değerlendiremeyebilir. Bunun sonucunda mod karıştırma problemleri yaşanabilmektedir. CEEMDAN ise bu durumun üstesinden gelebilmek için her aşamada sinyale gürültü ekler ve bu gürültüyü adaptif olarak güncellediği için sinyallerin özellikleri korunur (Huang ve ark., 1998; Torres ve ark., 2011). CEEMDAN'ın matematiksel algoritması şu şekilde gösterilmektedir (Flandrin ve ark., 2004; Liu ve ark., 2021; Owusu Junior ve ark., 2021; Wu & Huang, 2009).

- i. Sinyale farklı genliklerde beyaz gürültü ekleme:

$$x_k(t) = x(t) + \omega_k(t) \quad (2.25)$$

ii. İlk IMF'yi ayrıştırma işlemi için (2.25) formülde EMD tekniği kullanılır.

iii. İlk IMF'nin ortalaması

$$\overline{IMF_1(n)} = \frac{1}{K} \sum_{k=1}^K IMF_{1k}(t) \quad (2.26)$$

iv. Sinyal bileşenlerinden geriye kalan şu şekilde hesaplanmaktadır.


$$C_n = \begin{cases} x(t) - IMF_1(n), n = 1, \\ C_{n-1} - IMF_1(n), n > 1. \end{cases} \quad (2.27)$$

v. Sinyalin EMD sonrası ρ . bileşeni gösterilir. Sonraki bileşenler;

$$IMF_{(L+1)}(n) = \frac{1}{K} \sum_{k=1}^K E_L\{C_L(t) + \sigma_L E_L(\omega_k(t))\} \quad (2.28)$$

vi. Son olarak n durağan durum IMF'leri orijinal sinyali tekrar yapılandırır.

$$x(t) = C(t) + \sum_{m=1}^M \overline{IMF_m}(t) \quad (2.29)$$




Şekil 2.10. Ham titreşim sinyalleri (Esmeray ve ark., 2025)

Şekil 2.10'da, rulmana ait farklı yük koşullarında toplanan titreşim verisinin ham sinyalleri gösterilmektedir. CEEMDAN yöntemi uygulanmasının ardından, Şekil 2.11'de titreşim arızalı bir sinyalin adım adım IMF bileşenlerine ayrıştırılma süreci sunulmaktadır (Esmeray ve ark., 2025).

İlk sinyal ham veriyi temsil ederken, son aşamada elde edilen sinyal artık sinyal olarak adlandırılmakta ve bu noktadan sonra yeni bir IMF bileşeni oluşmamaktadır. Artık sinyal, CEEMDAN ayrıştırması sırasında ayrıştırılamayan ve IMF'lere aktarılamayan düşük

frekanslı bileşenleri içerir. IMF'lerin yüksek frekanslı detayları yakalamasının ardından sinyalin düşük frekanslı yapısını temsil eder. Başka bir deyişle, sinyalin artık kısmını oluşturur. Bu süreçte, sinyallerin artıkları atılarak filtreleme işlemi gerçekleştirilmiş ve CEEMDAN ayrıştırması sonucunda elde edilen IMF'ler ile sinyal zaman boyutunda çoğaltılmıştır.



Şekil 2.11. Titreşim arızalı ham sinyalin IMF bileşenlerine ayrıştırılmış gösterimi (Esmeray ve ark., 2025)

2.7. Kısa Zamanlı Fourier Dönüşümü (STFT)

Bir sinyalde bulunan zaman ve frekans bilgilerini incelemek için kullanılan tekniktir. STFT, sinyali frame adı verilen kısa zaman aralıklarına ayırır ve her bir frame için Fourier Dönüşümü (FT) uygulanır. FT bir sinyalin frekans ve genlik bilgilerini içeren bir grafiklerdir. STFT, zaman içinde bu grafikleri takip ederek sinyalin frekans ve zaman spektrumunu elde eder. Bu spektrumunu inceleyerek sinyalin özelliklerini çıkarmak için kullanılır (Randall, 1987; Wang ve ark., 2017; Yeşilyurt ve ark., 2015). STFT, şu formülle hesaplanır;

$$X_k(t) = \sum_{n=-\infty}^{\infty} x(n) \cdot w(t - n) e^{-j2\pi kn/N} \quad (2.30)$$

Bu formülde;

- $X_k(t)$, STFT'nin çıktısı olan zaman-frekans spektrumunu temsil eder.
- $x(n)$, giriş sinyalini temsil eder.


- $w(t)$, pencere fonksiyonunu temsil eder.
- k , frekans indeksini temsil eder.
- N , sinyal uzunluğunu temsil eder.

İşlem basamakları şu şekilde gerçekleşir.

1. Giriş sinyali, kısa zaman aralıkları (frame) olarak bölünür.
2. Her bir frame için pencere fonksiyonu uygulanır.
3. Pencereli frame, Fourier Dönüşümü'ne tabi tutulur.
4. Sonuçta elde edilen zaman-frekans spektrumu, tüm frame'ler için takip edilir.

STFT, zaman-frekans çözünürlüğü sağlama ve sinyalin belirli zaman dilimlerindeki frekans bileşenlerini görüntüleme gibi önemli avantajlara sahiptir. Uygulaması nispeten kolay olan STFT, çeşitli sinyal işleme araçları tarafından desteklenmektedir, bu da onu yaygın olarak tercih edilen bir yöntem haline getirir. Özellikle ani meydana gelen arızaların tespit edilmesi konusunda oldukça etkili olan STFT, bu tip olayların görsel olarak kolayca izlenebilmesine olanak tanır. Ancak, yüksek hesaplama kapasitesi gerektirmesi ve gürültünün analiz sonuçlarını etkileyebilmesi gibi dezavantajlara da sahiptir (Wang ve ark., 2017; Zhang & Deng, 2023).

Şekil 2.9'da önerilen yöntemdeki adım izlenerek titreşim arızasına sahip sinyalin artık sinyaller atıldıktan sonra CEEMDAN ile IMF'lerine ayrıştırma işlemi yapıp STFT uygulanarak elde edilen 2D spektrogramları Şekil 2.12'de gösterilmektedir. Her bir IMF bileşenine ait spektrogramlar yukarıdan aşağıya doğru sıralanmış olup, böylece bileşenlerin zaman-frekans özellikleri ayrı ayrı incelenebilmektedir.



Şekil 2.12. IMF bileşenlerine STFT uygulanmasıyla elde edilen spektrogramlar (Esmeray ve ark., 2025)

2.8. Görüntü Verilerinin Çoğaltılması

Veri çoğaltma (data augmentation), var olan veri kümesinden yeni örnekler türeten ve böylelikle veri miktarını suni olarak artıran bir dizi dönüşüm tekniği olarak tanımlanmaktadır. Bu yöntem, modelin genelleme performansını artırmak, veri toplama maliyetlerini azaltmak ve gerçek dünya koşullarını daha iyi temsil eden örnekler oluşturmak için kullanılmaktadır. Görüntü verilerinde yaygın olarak kullanılan veri artırma teknikleri; döndürme (rotation), öteleme (translation), ölçeklendirme veya yakınlaştırma (scaling/zoom), renk uzayında ton ve doygunluk değişimleri (color jittering), simetri tabanlı çevirme (flipping) ve gürültü ekleme (noise injection) gibi işlemlerden oluşmaktadır (Mumuni & Mumuni, 2022; Shorten & Khoshgoftaar, 2019). Bu dönüşümler matematiksel olarak genel biçimde şu şekilde gösterilebilir:


$$x' = T_n(\dots(T_2(T_1(x; \theta_1); \theta_2) \dots); \theta_n) \quad (2.31)$$

Burada x orijinal görüntüyü, x' ise artırılmış görüntüyü; θ_i ise her bir dönüşümün parametrelerini (örneğin, döndürme açısı, kaydırma miktarı, gürültü varyansı vb.) temsil etmektedir. Bu bağlamda veri artırma işlemleri özel olarak aşağıdaki gibi tanımlanabilir:

a) Döndürme (Rotate);

$$x' = T_{rotate}(x; \alpha) \quad (2.32)$$

α döndürme açısını göstermektedir. Şekil 2.13’de, sol tarafta orijinal görüntü, sağ tarafta ise döndürme işlemi sonrası elde edilen görüntü görülmektedir.




Şekil 2.13. Orijinal ve döndürme işlemi uygulanmış örnek görüntü

b) Öteleme (Translation):

$$x' = T_{trans}(x; \{t_x, t_y\}) \quad (2.33)$$

t_x, t_y değerleri yatay ve dikey kaydırma miktarlarını ifade etmektedir. Şekil 2.14’de, sol tarafta orijinal görüntü, sağ tarafta ise öteleme işlemi sonrası elde edilen görüntü görülmektedir.




Şekil 2.14. Orijinal ve öteleme işlemi uygulanmış örnek görüntü

c) Yakınlaştırma (Zoom):

$$x' = T_{scale}(x; s) \quad (2.34)$$

s ölçek katsayısını temsil etmektedir. Şekil 2.15’te, sol tarafta orijinal görüntü, sağ tarafta ise yakınlaştırma işlemi sonrası elde edilen görüntü görülmektedir.




Şekil 2.15. Orijinal ve yakınlaştırma işlemi uygulanmış örnek görüntü

d) Renk Değişimi (Color Jittering):

$$x' = T_{color}(x; \{hue, saturation\}) \quad (2.35)$$

Buradaki parametreler, görüntüye uygulanan renk uzayı değişimlerini göstermektedir. Şekil 2.16'da, sol tarafta orijinal görüntü, sağ tarafta ise renk değişimi uygulandıktan sonra elde edilen görüntü görülmektedir.




Şekil 2.16. Orijinal ve renk değiştirme işlemi uygulanmış örnek görüntü

e) Çevirme (Flip);

$$x' = T_{flip}(x; d) \quad (2.36)$$

olarak gösterilir. d yatay veya dikeyde çevirme yönünü temsil eder. Şekil 2.17'de, sol tarafta orijinal görüntü, sağ tarafta ise çevirme işlemi uygulandıktan sonra elde edilen görüntü görülmektedir.




Şekil 2.17. Orijinal ve çevirme işlemi uygulanmış örnek görüntü

f) Gürültü Ekleme (Gaussian Noise)


$$x' = x + N(0, \sigma^2) \quad (2.37)$$

şeklinde gösterilmektedir. $N(0, \sigma^2)$ sıfır ortalamalı ve σ^2 varyanslı Gauss dağılımına sahip rastgele gürültüyü temsil etmektedir. Şekil 2.18'de, sol tarafta orijinal görüntü, sağ tarafta ise gürültü işlemi uygulandıktan sonra elde edilen görüntü görülmektedir.



Şekil 2.18. Orijinal ve gürültü işlemi uygulanmış örnek görüntü

Şekil 2.19’da veri çoğaltma işlemi gerçekleştirildikten sonra elde edilen veri setinden rastgele seçilmiş görüntü örnekleri sunulmaktadır.




Şekil 2.19. Çoğaltma işlemi sonrası veri setinden rastgele seçilmiş örnek görüntüler (Esmeray ve ark., 2025)

2.9. Evrişimli Sinir Ağı (CNN)

Evrişimli Sinir Ağı (CNN), yapay sinir ağlarının bir alt sınıfı olup özellikle görüntü, video, ses ve metin gibi uzamsal veya zamansal yapıya sahip verilerin işlenmesinde yaygın olarak kullanılmaktadır. CNN’ler, insan görsel korteksinden esinlenerek geliştirilmiş ve yerel uzamsal bağımlılıkları yakalamak amacıyla evrişim (convolution) işlemini temel almıştır. İlk olarak Fukushima’nın 1980’lerde ortaya koyduğu Neocognitron modeliyle kavramsal olarak tanımlanan bu yaklaşım, 1990’larda LeCun ve

arkadaşlarının el yazısı karakter tanıma (LeNet-5) çalışmalarıyla pratik uygulamalara taşınmıştır. Daha sonraki yıllarda derin öğrenmenin gelişimiyle birlikte CNN'ler, bilgisayarla görme ve diğer alanlarda temel yöntemlerden biri haline gelmiştir (Lecun ve ark., 1998; Li ve ark., 2022).



Şekil 2.20. CNN yapısı

Şekil 2.20’de görüldüğü gibi CNN mimarisinde, özellik çıkarma katmanları olarak Input Layer, Convolutional Layer ve Pooling Layer bulunmaktadır. Sınıflandırma, Fully Connected Layer ve ilgili katmanlar ile sağlanır. CNN’ler, girdi verilerini Convolutional Layer’da çeşitli filtre boyutlarıyla işler, ardından Pooling Layer’da boyutları azaltır. Bu işlemler, öğrenme sürecini optimize ederken hesaplama yükünü de azaltmaktadır. Fully Connected Layer sınıflandırma işlevini geliştirirken, ReLU ve Dropout katmanları modelin hızlı öğrenmesini ve aşırı öğrenmeyi önlemesini sağlar. Sonuçlar, Classification Layer ile üretilir ve Fully Connected Layer’dan sonra, elde edilen değerler ile gerçek değerler arasındaki fark, geri yayılım algoritmasıyla ayarlanır. Eğitim, belirlenen epoch sayısına ulaşıncaya sonlandırılır (Khan ve ark., 2019; Sinha ve ark., 2023; Zhao ve ark., 2024).

CNN’lerin en önemli avantajları arasında, parametre verimliliği, hiyerarşik özellik çıkarımı ve yerel yapılara duyarlılık sayılabilir. Alt katmanlarda kenar, köşe gibi basit özellikler öğrenilirken, üst katmanlarda nesne parçaları gibi daha karmaşık yapılar temsil edilir. Böylece, modelin özellik öğrenimi veri ile birlikte otomatik olarak gerçekleşir ve klasik yöntemlerdeki gibi el ile özellik mühendisliği ihtiyacı büyük ölçüde ortadan kalkar.

Ayrıca paylaşılan ağırlıklar sayesinde eğitim süreci daha verimli hale gelir (Alzubaidi ve ark., 2021; Yamashita ve ark., 2018).

Bununla birlikte CNN'lerin bazı sınırlılıkları da vardır. Öncelikle, derin mimariler çok sayıda eğitim verisine ihtiyaç duyar; veri yetersiz olduğunda aşırı öğrenme kaçınılmaz olabilir. Krizhevsky ve arkadaşları (2012), CIFAR-10 veya Caltech-101 gibi sayıları on binler düzeyindeki küçük ölçekli veri kümelerinin basit tanıma görevleri için yeterli olabileceğini, ancak daha karmaşık ve gerçekçi nesne tanıma problemleri için çok daha büyük eğitim kümelerine ihtiyaç duyulduğunu belirtmektedir (Krizhevsky ve ark., 2017). LeCun ve ark. (2015) ise, CNN'lerin yaygın olarak benimsenmesinin büyük ölçekli veri kümelerinin kullanıma girmesiyle mümkün olduğunu ve bu tür veri setlerinin derin mimarilerin başarısında büyük bir rolü olduğunu vurgulamaktadır (LeCun ve ark., 2015). Dolayısıyla küçük veri kümeleriyle çalışırken, veri artırma veya TL gibi yöntemlerin kullanılması bir zorunluluk haline gelmektedir (Shorten & Khoshgoftaar, 2019). Bunun yanı sıra, CNN'lerin bazı yapısal sınırlılıkları da bulunmaktadır. Bu modellerin yorumlanabilirliği sınırlıdır; katmanlardaki filtrelerin hangi özellikleri temsil ettiği çoğu zaman açık biçimde ortaya konulamamaktadır. Tüm bunlara ek olarak, derin mimarilerin yüksek hesaplama maliyeti, güçlü donanım gereksinimlerini beraberinde getirmekte ve bu da kullanım alanlarını kısıtlayan bir diğer faktör olarak öne çıkmaktadır (Guan ve ark., 2023; Rangel ve ark., 2024).

Şekil 2.21'de ön eğitilmiş CNN mimarileri görülmektedir. Bu mimariler, önceden eğitilmiş yapıları sayesinde daha hızlı öğrenme ve yüksek doğruluk değerleri elde etmek için tercih edilmektedir. Mimarilerin eğitimi, ImageNet (ImageNet, 2025) veritabanındaki geniş görüntü koleksiyonu üzerinde gerçekleştirilmiştir. Katman sayıları ve konfigürasyonlarındaki farklılıklar, bu mimarilerin çeşitliliğini oluşturmaktadır (Alzubaidi ve ark., 2021; Yamashita ve ark., 2018).

Bu çalışmada GoogLeNet, MobileNet-v2 ve ResNet-50 mimarileri tercih edilmiştir. Bu mimariler farklı derinlik ve mimari özelliklere sahip, TL'ye uygun ve görüntü sınıflandırma problemlerinde yaygın olarak kullanılan ön eğitilmiş evrensel modellerdir. Seçim gerekçeleri aşağıda detaylandırılmıştır.

a) Veri etiketleme sınırlılığı: Çalışmada kullanılan 2D spektral görüntülerde arıza bölgelerinin manuel olarak işaretlenmesi mümkün olmadığından, piksel veya bölge düzeyinde etiketleme gerektiren nesne tespiti (YOLO, Faster R-CNN) veya segmentasyon (U-Net, Mask R-CNN) gibi modeller tercih edilmemiştir. Bu nedenle doğrudan sınıflandırma yapan CNN tabanlı TL modelleri kullanılmıştır (He ve ark., 2016; Redmon & Farhadi, 2018; Ronneberger ve ark., 2015).


b) TL'ye uygunluk: Tercih edilen modellerin tamamı ImageNet veri kümesi üzerinde önceden eğitilmiş olup, sınırlı veri ile hızlı, kararlı ve genellenebilir bir öğrenme süreci sunmaktadır. Özellikle motor arıza tespiti gibi veri toplama maliyetinin yüksek olduğu alanlarda bu özellik oldukça önemlidir (Chollet, 2017; He ve ark., 2016; Krizhevsky ve ark., 2017; Sandler ve ark., 2018)

c) Eğitim süresi ve hesaplama maliyetinin yönetilebilir olması: YOLO gibi bölge tabanlı modeller veya VGG16/19 gibi çok büyük parametre setine sahip ağlar uzun eğitim süreleri ve yüksek hesaplama gücü gerektirmektedir. Buna karşın seçilen mimariler:

- GoogLeNet: Hesaplama açısından verimli ve daha az parametre içerir (Szegedy ve ark., 2015).
- MobileNet-v2: Mobil cihazlar için tasarlanmış hafif bir ağ olup düşük kaynaklı sistemlerde hızlı eğitilebilir (Sandler ve ark., 2018).
- ResNet-50: Katmanlar arası atlama bağlantıları (skip connections) sayesinde derin ağlarda doğruluğu artırır ve öğrenme sürecinde oluşabilecek bilgi kaybını azaltır (He ve ark., 2016).

Bu özellikler sayesinde ağların eğitim süresi kısalmış ve donanım gereksinimi azaltılmıştır.

d) Alternatif mimari adayların tercih edilmemesi: SqueezeNet, AlexNet, Inception, VGG16/19 ve DenseNet gibi mimariler TL açısından teknik olarak uygundur. Ancak bu modellerin bir kısmı (örneğin VGG16/19) yüksek parametre sayısı nedeniyle uzun eğitim süresi ve yüksek hesaplama maliyeti gerektirmektedir. DenseNet ise kendinden önceki tüm katmanların çıkışlarını doğrudan girdi olarak aldığı için bellek tüketimi fazladır. AlexNet ve SqueezeNet gibi daha hafif mimariler ise karmaşık desenleri öğrenme kapasitesi bakımından sınırlıdır. GoogLeNet, MobileNet-v2 ve ResNet-50 ise hafiflik-doğruluk dengesi, donanım uygunluğu ve literatür uyumu bakımından daha uygun bir seçimdir (Chollet, 2017; He ve ark., 2016; Sandler ve ark., 2018; Szegedy ve ark., 2015).



Şekil 2.21. Ön eğitilmiş CNN Mimarileri (Mathwork, 2025)

Çizelge 2.3’de, bu çalışmada kullanılan modeller ve özellikleri hakkında bilgiler sunulmaktadır.

Çizelge 2.3. Çalışmada kullanılan ön eğitilmiş modeller ve özellikleri

Mimari	Kaynak	Parametre sayısı	Katman Sayısı	Girdi Boyutu	Temel Özellik	Öne Çıkan Kullanım
GoogLeNet	(Szegedy ve ark., 2015)	~6.8 milyon	22	224x224	Inception modülü (çoklu filtre yapısı)	Görüntü sınıflandırma, (ILSVRC 2014 birincisi)
MobileNet-v2	(Sandler ve ark., 2018)	~3.4 milyon	53	224x224	Az parametre ile daha hızlı hesaplama yapma	Mobil/ gömülü cihazlarda verimli sınıflandırma
ResNet-50	(He ve ark., 2016)	~25.6 milyon	50	224x224	Artık bağlantılı bloklar (Vanishing gradient kaybını azaltır)	Derin ağların eğitimi, büyük ölçekli sınıflandırma

GoogLeNet (Inception-v1), 22 katmandan oluşan ve Inception modülleri ile çok ölçekli özellik çıkarımını aynı anda gerçekleştirebilen bir CNN mimarisidir. Farklı filtre boyutlarının paralel kullanımı, modele hem derinlik hem genişlik kazandırırken hesaplama maliyetinin düşük tutulmasını sağlar. Yaklaşık 6.8 milyon parametre ile oldukça hafif bir yapı sunan mimari, ILSVRC 2014 yarışmasında birincilik elde ederek literatürde önemli bir yer kazanmıştır (Szegedy ve ark., 2015).

MobileNet-v2, mobil ve gömülü cihazlarda çalışacak şekilde optimize edilmiştir. 3.4 milyon parametre sayısı ile hafif ve verimli bir CNN mimarisidir. Yapısında inverted artık

bağlantılı bloklar ve depthwise separable convolution teknikleri kullanılarak parametre sayısı azaltılmış ve hesaplama maliyeti düşürülmüştür. Bu sayede düşük işlem gücü gerektiren ortamlarda yüksek doğruluklu sonuçlar elde edilebilmiştir (Sandler ve ark., 2018).

ResNet-50, 50 katmanlı derin bir CNN mimarisi olup, temel yeniliği artık bağlantılar (skip connections) kullanmasıdır. Bu yaklaşım, derin ağlarda karşılaşılan vanishing gradient yani aktivasyon fonksiyonlarının türevlerinin küçülmesi problemini azaltmakta ve çok daha derin mimarilerin eğitilebilir olmasını sağlamaktadır. 25.6 milyon civarında parametre sayısı, önceki modellere göre daha iyi performans göstermiştir ve bilgisayarla görme alanında yaygın olarak kullanılmaktadır (He ve ark., 2016).

2.10. Parçacık Sürü Optimizasyonu (PSO)

Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO), Kennedy ve Eberhart tarafından 1995 yılında kuş sürülerinin ve balık topluluklarının kolektif hareketinden esinlenerek geliştirilmiş bir meta-sezgisel optimizasyon algoritmasıdır. Evrimsel hesaplama yöntemlerinden biri olan PSO, doğadan esinlenmiş optimizasyon teknikleri arasında en çok kullanılanlardan biridir. Algoritma, çözüm uzayında hareket eden çok sayıda aday çözüm (parçacık) üzerinden çalışır ve bu parçacıklar birbirleriyle bilgi paylaşarak global optimuma yaklaştırmaya çalışırlar (Eberhart & Kennedy, 1995).

2.10.1. Temel kavramlar ve yapı

PSO, popülasyon temelli bir yöntemdir. Her parçacık, potansiyel bir çözümü temsil eder ve şu bileşenlerden oluşur:

Konum vektörü: $x_i = (x_{i1}, x_{i2}, \dots, x_{id})$, d boyutlu çözüm uzayındaki mevcut çözüm.

Hız vektörü: $v_i = (v_{i1}, v_{i2}, \dots, v_{id})$, parçacığın çözüm uzayındaki hareket yönü ve büyüklüğü.

Kişisel en iyi konum P_{best} : Parçacığın kendi geçmişinde bulunduğu en iyi çözüm.

Küresel en iyi konum G_{best} : Tüm parçacıkların arasında bulunan en iyi çözüm.

2.10.2. Matematiksel model

Her iterasyonda parçacıkların hızı ve konumu güncellenir. Her bir parçacık i olarak kabul edilirse; position $x_i(t)$, hız $v_i(t)$ vektörü ile temsil edilir. Bu değişkenlere bağlı olarak hız güncelleme denklemi;

$$v_i(t+1) = wv_i(t) + c_1r_1(P_{best\ i}(t) - x_i(t)) + c_2r_2(G_{best}(t) - x_i(t)) \quad (2.38)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (2.39)$$

şeklinde ifade edilir (Eberhart & Kennedy, 1995).


Burada;

- w , atalet katsayısı yani parçacığın hızını koruma eğilimidir. Önceki hızın etkisini belirler.
- c_1 , bilişsel bileşendir yani parçacığın kendi en iyi konumuna olan güvenini gösterir.
- c_2 , sosyal bileşendir yani parçacığın sürü içindeki en iyi konumunu temsil eder.
- r_1 ve r_2 , $[0,1)$ aralığındaki rastgele değerler

olup çözüm için algoritmaya çeşitlilik katılması anlamına gelir.

- P_{best} , i .parçacığın en iyi konumudur.
- G_{best} , tüm popülasyonun en iyi konumudur.

Bu yapı sayesinde parçacıklar hem kendi deneyimlerini gösteren bilişsel bileşen hem de sürünün en iyi bilgisini gösteren sosyal bileşenden faydalanır (Eberhart & Kennedy, 1995). PSO algoritmasına ait akış şeması Şekil 2.22’de görülmektedir.



Şekil 2.22. PSO algoritması akış diyagramı

2.10.3. PSO özellikleri

PSO'nun kuramsal özellikleri incelendiğinde, algoritmanın başarısında keşif ve sömürü dengesinin önemli bir etkiye sahip olduğu görülmektedir. Atalet ağırlığı w büyüdükçe parçacıkların arama uzayında daha geniş alanları keşfetmesi sağlanırken, küçük değerler sömürü sürecini artırarak mevcut iyi çözümlerin etrafında yoğunlaşmaya yol açar. Algoritma, iterasyonlar ilerledikçe parçacıkların küresel en iyi çözüm G_{best} çevresinde toplanmasıyla yakınsama eğilimi gösterir. PSO'nun başlıca avantajları arasında kolay uygulanabilir olması, az sayıda parametreye sahip bulunması, diferansiyellenebilir olmayan fonksiyonlarda da kullanılabilmesi ve çok boyutlu karmaşık problemlerde etkin performans sergilemesi yer almaktadır. Bununla birlikte, yerel optimumlara takılma riski ve parametre seçimlerine (w, c_1, c_2) olan duyarlılığı yöntemin önemli sınırlılıkları arasında sayılmaktadır (Clerc & Kennedy, 2002; Eberhart & Kennedy, 1995; Shi & Eberhart, 1998).

2.11. Transfer Öğrenme (TL)

Transfer öğrenme (TL), bir makine öğrenmesi modelinin önceden çözdüğü bir görevde elde ettiği bilgi ve temsilleri, benzer ancak farklı bir görevde yeniden kullanmasını sağlayan yaklaşımdır. Geleneksel makine öğrenmesi yöntemlerinde her yeni görev için modelin sıfırdan eğitilmesi gerekirken, TL sayesinde önceden öğrenilmiş özellikler yeniden kullanılabilir ve bu durum özellikle sınırlı veri setlerinde önemli avantajlar sağlamaktadır. Derin öğrenme yapısı içerisinde TL genellikle, ImageNet gibi büyük ölçekli veri tabanları üzerinde eğitilmiş CNN mimarilerinin, farklı veri setlerine ve görevlere uyarlanması şeklinde uygulanır (Pan & Yang, 2009; Weiss ve ark., 2016; Zhuang ve ark., 2020).

TL'nin temelinde, kaynak görevde öğrenilen temsillerin hedef görev için yeniden kullanılması vardır. Bu süreçte modelin erken katmanları genellikle düşük seviyeli görsel özellikleri yakaladığı için sabit tutulur, daha üst katmanlar ise hedef görevin ihtiyaçlarına göre yeniden eğitilir. Böylece hem genel özellikler korunur hem de hedef probleme özgü temsiller öğrenilmiş olur (Pan & Yang, 2009; Weiss ve ark., 2016).

Literatürde TL üç ana strateji ile açıklanmaktadır. İlki, özellik çıkarımı (feature extraction) yaklaşımıdır ki, önceden eğitilmiş modelin özellik çıkarıcı katmanları kullanılır ve yalnızca sınıflandırıcı kısmı yeniden eğitilir. İkincisi, katman dondurma (frozen layers) yöntemi, belirli katmanlar sabitlenirken üst katmanlar hedef görev için optimize edilir. Üçüncüsü olan fine-tuning yönteminde ise, önceden eğitilmiş modelin tüm ağırlıkları veya belirli bir kısmı hedef veri seti ile yeniden güncellenerek, modelin yeni problem için uyarlanması sağlanır (Buterez ve ark., 2024; Sarı ve ark., 2022).


TL uygulamada şu şekilde yapılmaktadır. CNN katmanları erken ve üst katmanlar olarak ikiye ayrılır. Erken katmanlar, görüntülerdeki kenar, köşe, doku gibi düşük seviyeli bilgileri öğrenir. Üst katmanlar ise daha soyut ve örneğin arızalı rulmandaki titreşim desenleri gibi probleme özgü özellikleri öğrenir. Bir katmanı dondurmak demek, o katmandaki ağırlıkların eğitim sırasında güncellenmemesi anlamına gelir. Yani modelin erken katmanları, önceden eğitildiği büyük veri setinden (örneğin ImageNet) öğrendiği

bilgiyle sabit kalır. Sadece son katmanlar veya belirlenen üst katmanlar yeniden eğitilerek, model mevcut veri setine uyum sağlar. Fine-tuning aşamasına gelindiğinde ise ilk olarak sadece yeni eklenen katmanlar eğitilir. Sonra üst katmanlar kademeli olarak serbest bırakılır ve küçük öğrenme oranlarıyla güncellenir. Böylece model hem önceden öğrendiği bilgiyi korur hem de uygulamada kullanılan veri setine özel ince ayar yapar (Coraci ve ark., 2023; Lu ve ark., 2015; Mari ve ark., 2019).

TL, sınırlı veriyle yüksek doğruluk elde edilmesini sağlamanın yanı sıra, eğitim süresini de kısaltmaktadır. Ancak, kaynak ve hedef görevler arasında yeterli benzerlik bulunmadığında negative transfer adı verilen olumsuz durumlar ortaya çıkabilmekte, ayrıca büyük ölçekli önceden eğitilmiş modeller yüksek hesaplama maliyeti gerektirebilmektedir (Pan & Yang, 2009; Weiss ve ark., 2016).

3. MATERYAL VE YÖNTEM

Bu tez çalışmasında, HEA’larda kullanılan BLDC motorlar için arıza tespiti ve sınıflandırmasına yönelik, PSO ile optimize edilen DL tabanlı bir CNN modeli kullanılarak TL’ye dayalı bir yöntem geliştirilmiştir. Önerilen yöntemin yapısı Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Önerilen yöntemin blog diyagramı


Önerilen yöntem dört ana adımda gerçekleştirilmiştir. Birinci adım, veri ön işleme bloğu olup, deneylerde kullanılan elektrikli scooter’ın motorundan sağlam, mıknatıs, rulman ve çoklu arıza (mıknatıs-rulman) durumlarına ait 1D sinyaller toplanmıştır. Toplanan bu sinyaller CEEMDAN yöntemiyle IMF bileşenlerine ayrıştırılmış, ardından artık sinyal atılarak filtre edilmiş ve daha sonra bu ayrıştırılmış sinyaller STFT yöntemi kullanılarak 2D spektrogramlara dönüştürülmüştür. Elde edilen spektrogramlar, veri artırma

yöntemleriyle çoğaltılarak CNN eğitimi için daha geniş bir veri seti oluşturulmuştur. Son olarak, bu veriler kullanılacak CNN modellerinin giriş boyutlarına uygun olarak 64x64x3 ve 224x224x3 piksel boyutlarına ölçeklendirilmiştir. Böylece veri ön işleme aşaması tamamlanmıştır. İkinci adım optimizasyon aşamasıdır. Bu adımda, elde edilen veri seti kullanılarak PSO algoritmasıyla en başarılı CNN modelini bulmak için optimizasyon işlemi gerçekleştirilmiştir. Yöntemin uygulanmasına ait ayrıntılar Bölüm 3.4’de detaylı bir şekilde ele alınmıştır. Bu optimizasyon sonucu elde edilen hiperparametreler, ön eğitilmiş derin öğrenme modellerinin yapılandırılmasında referans olarak kullanılmıştır. Üçüncü adım, koşullu hiyerarşik yapı üzerinden arıza tespit sürecini kapsamaktadır. Bu aşamada önce arıza sınıflandırması yapılmış; ardından her bir arıza türü için, ilgili sensör verileriyle aynı CNN modelleri ayrı ayrı eğitilmiştir. Böylece, her arıza türü için en yüksek doğruluk oranına sahip sensör modeli belirlenmiştir. Aynı işlemler, ikinci adımda yapılandırılan ön eğitilmiş modeller üzerinde de gerçekleştirilmiş ve karşılaştırmalı sayısal sonuçlar elde edilmiştir. Dördüncü adım, model değerlendirme aşamasıdır. Bu adımda elde edilen sayısal sonuçlar kullanılarak karışıklık matrisi, başarı-kayıp grafikleri, performans metrikleri (Doğruluk, Kesinlik, Duyarlılık, F1 Skoru) ile ROC eğrileri ve AUC değerleri hem arıza sınıflandırma hem de her bir arıza durumu için ayrı ayrı hesaplanmıştır. Bu sonuçlar tablo ve grafik biçiminde sunulmuştur.

Deneyisel çalışmalar için donanım olarak iki farklı bilgisayar kullanılmıştır. İlk bilgisayar Intel® Core™ i5-3450 CPU (3.10 GHz), 16 GB RAM ve NVIDIA GeForce RTX 2060 grafik kartına sahiptir. İkinci bilgisayar ise 13th Gen Intel® Core™ i5-13500H işlemci, 32 GB RAM ve NVIDIA GeForce RTX 4050 (6 GB) ekran kartına sahiptir. Yazılım tarafında ise tüm hesaplamalar ve analizler için Matlab R2025b 64-bit Student sürümü kullanılmıştır. Bu çalışmada kullanılan çizimlerin tamamı draw.io (JGraph Ltd., 2025) platformunda hazırlanmıştır.


3.1. Deney Düzenegi ve Veri Toplama

Yapılacak analizlerin en önemli aşaması, verilerin deney düzeneginden güvenilir biçimde toplanmasıdır. Bu amaçla laboratuvar ortamında hazırlanan deney düzenegi Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Deney düzeneği

Düzenegın bileşenleri; elektrikli scooter, DAQ kartı, kaçak akı sensörü, titreşim sensörü, döner bant sistemi ve akustik verilerin toplanması için kullanılan cep telefonundan oluşmaktadır. Önerilen yöntemin deneysel veri toplama aşamasını gösteren blok diyagramı ise Şekil 3.3’de sunulmuştur.



Şekil 3.3. Veri toplama blok diyagramı

Elektrikli scooter, Onvo OV-012 X-Plus 1600W modeli olup 800 watt gücünde çift motor konfigürasyonuna sahiptir. Model, 48 V 15 Ah lityum batarya ile donatılmış olup tam


dolu şarjda yaklaşık 50-55 km menzile sahip ve 30°'lik eğimleri tırmanabilme kapasitesine sahiptir. Fren sistemi olarak disk fren kullanılırken, ön ve arka amortisör ile desteklenmiştir (Onvo, 2025). Bu tez çalışmasında kullanılan elektrikli scooter'a ait resim, Bölüm 2 Şekil 2.1'de gösterilmiştir. Elektrikli scooter'da kullanılan motor tipi, literatürde hub motor veya in-wheel motor olarak tanımlanan dıştan rotorlu motorlardır. Hub motor teknolojisi, tekerlek göbeğine entegre yapısıyla doğrudan güç aktarımı sağlamakta ve mekanik aktarma elemanlarına olan ihtiyacı ortadan kaldırmaktadır (Aloeyi ve ark., 2022; Deepak ve ark., 2023).

Gerçekleştirilen deneysel çalışmada üç adet özdeş motor kullanılmıştır. Ancak kullanılan motorun teknik özellikleri herhangi bir kaynaktan yayınlanmadığından, mevcut verilerden yararlanılarak motorun nominal hızı ve nominal torku elle hesaplanmıştır. Buna göre motorun varolan özellikleri ile hesaplanan özellikleri Çizelge 3.1'de sunulmuştur.

Çizelge 3.1. BLDC motorun özellikleri

Özellik adı	Değeri
Motor gücü	800 Watt
Motor çalışma gerilimi	48 V
Motor lastik çapı	10 inch (10x2,54)
Motor kutup sayısı	15 çift
Motor max hızı	55 km/sa
Nominal Hız	~1100-1150 rpm
Nominal Tork	~13 N.m

Deney düzeneğinde her çalışma durumu için dört arıza senaryosunda (sağlam, rulman arızalı, mıknatıs arızalı, çoklu arıza) beş farklı sensörden veri toplanmış; her durum için 20, toplamda 60 ham veri seti elde edilmiştir. Her veri kaydı 33 saniye sürmüştür. Elektrikli scooter üç hız konumunda çalıştırılmıştır: birinci hız 0-27 km/sa, ikinci hız 28-39 km/sa ve üçüncü hız 40-55 km/sa. Motor her çalıştırıldığında sırasıyla 11 sn birinci hızda, 11 sn ikinci hızda ve 11 sn üçüncü hızda çalıştırılmış; her aşamada ilgili konumun azami hızına çıkarılmıştır. Scooter hızını yaklaşık 7 s koruduğunda hız sabitleme özelliği devreye girdiğinden, aşamalar arası geçiş ve veri toplama kontrollü biçimde yürütülmüştür. Bu sürecin sonucunda Şekil 3.4'de gösterilen hız grafiği elde edilmiştir.



Şekil 3.4. Deney aşamasında elektrikli scooter'a ait hız-zaman grafiği

Deney düzeneğinden veri toplamak amacıyla NI9174 DAQ veri toplama modülü kullanılmıştır. Bu DAQ kartı, 24 bit çözünürlüğe ve 50 ks/s örnekleme hızına sahiptir. Kart üzerinde bulunan notch filtresi, sinüs dışındaki belirli frekans bileşenlerini bastırarak ölçülen sinyaldeki bazı harmonikleri ortadan kaldırmakta ve sinyal kalitesini iyileştirmektedir (National Instruments, 2005).

Gerilim ölçümleri, National Instruments NI-9225 modülü ile gerçekleştirilmiştir. Modül her bir kanal için 300 Vrms seviyesine kadar ölçüm yapabilmektedir. Çalışmada kullanılan motor sürücü kartı 48 V gerilim ile çalıştığından, üç faz gerilimleri (R, S ve T) doğrudan modül üzerinden kaydedilmiştir (National Instruments, 2024a).

Akım ölçümleri, National Instruments NI-9239 modülü kullanılarak gerçekleştirilmiştir. Modülün doğrudan ölçebildiği akım 5A ile sınırlıdır. Çalışmada kullanılan motorun sürücü kartı 20 Ampere kadar akım desteklediğinden, doğrudan bağlantı yapılmamıştır. Bu nedenle ölçümler sırasında pens ampermetre kullanılarak yüksek akım değerleri güvenli voltaj seviyelerine dönüştürülmüş ve NI-9239 modülü üzerinden kaydedilmiştir (National Instruments, 2024c). Bu yaklaşım sayesinde hem modül koruma altına alınmış hem de yüksek akım değerleri doğru şekilde sisteme aktarılmıştır.

Manyetik akı ölçümleri, Texas Instruments DRV425EVM kaçak akı sensörü kullanılarak gerçekleştirilmiştir. Sensör, $\pm 2\text{mT}$ ölçüm aralığına ve 47 kHz bant genişliğe sahiptir. Düşük ofset ve gürültü düzeyi ile yüksek doğruluk sağlayan bu sensör, motorda meydana

gelen kaçak akıların hassas biçimde izlenmesine olanak tanımaktadır (Texas Instruments, 2020).

Titreşim ölçümleri için National Instruments NI-9234 modülü kullanılmıştır. Bu modül, düşük seviyeli ivmeölçer ve titreşim sensörlerinden gelen sinyalleri yüksek çözünürlükle kaydetmeye uygundur (National Instruments, 2024b). Çalışmada üç adet titreşim sensörü kullanılmıştır. T1 sensörü motorun miline, T2 sensörü milin yanına, T3 sensörü ise milin üstüne yerleştirilmiştir. Bu yerleşim sayesinde motorun farklı noktalarındaki titreşim davranışları eş zamanlı kaydedilmiştir.


Akustik veriler, Samsung Galaxy Note 8 marka cep telefonunun dahili mikrofonu ve cihazın kendi ses kaydetme uygulaması kullanılarak manuel olarak kaydedilmiştir. Kayıt işlemleri laboratuvar ortamında, her deneysel uygulama için ayrı ayrı motor sesi dışındaki seslerden izole edilerek gerçekleştirilmiştir. Ses sinyalleri telefonun motor gövdesine yaklaşık 5 cm uzaklıkta konumlandırılmasıyla alınmış olup, kayıtlar 44.1 kHz örnekleme frekansı ve 16 bit çözünürlükte saklanmıştır.

Toplanan verilerin tamamı (kaçak akı, akım, gerilim, titreşim) 25,6 kHz örnekleme frekansı ve 64 bit çözünürlük ile kaydedilmiştir. Ölçümlerden elde edilen verilerin toplanması için DAQ kart ile uyumlu olan LabView NI Signal Express 2010 programı kullanılarak “.tdms” formatında alınmıştır. Bu program, donanım kapasitesine de bağlı olarak yüksek örnekleme hızlarında veri toplama imkanı sunar (National Instruments, 2024d). Verilerin temel özelliklerini belirten tablo Çizelge3.2’de gösterilmiştir.


Çizelge 3.2. Toplanan ham verilerin özellikleri

Sensör / Veri Türü	Örnekleme Frekansı	Bit Derinliği	Orijinal Formatı
Gerilim (NI-9225)	25.6 kHz	64 bit (double)	.tdms
Akım(NI-9239+pens ampermetre)	25.6 kHz	64 bit (double)	.tdms
Kaçak Akı (DRV425EVM	25.6 kHz	64 bit (double)	.tdms
Titreşim (NI-9234)	25.6 kHz	64 bit (double)	.tdms
Akustik (Samsung Galaxy Note 8)	44.1 kHz	16 bit	.m4a


Sensörlerden toplanan ve Çizelge 3.2’de sunulan sinyallere ait, farklı çalışma koşullarında elde edilen sağlam duruma ilişkin ham sinyal örnekleri Şekil 3.5, Şekil 3.6 ve Şekil 3.7’de gösterilmiştir. Şekil 3.5 motorun boşa çalıştırılması, Şekil 3.6 motorun bant üzerinde yüksüz çalıştırılması ve Şekil 3.7 ise motorun bant üzerinde yüklü çalıştırılması durumlarında kaydedilen ham sinyalleri temsil etmektedir.



Şekil 3.5. Sağlam durumda boşa çalışma koşulu için toplanan sinyaller



Şekil 3.6. Sağlam durumda yüksüz bant koşulu için toplanan sinyaller



Şekil 3.7. Sağlam durumda yüklü bant koşulu için toplanan sinyaller

Veri toplama süreci üç farklı çalışma durumu için gerçekleştirilmiştir: motorun boşta çalışması, motorun bant üzerinde yüksüz çalışması ve motorun bant üzerinde yüklü çalışması.

- Motorun boşta çalışması, elektrikli scooter'ın bir sehpa üzerine yerleştirilerek sürtünmesiz ve yüksüz şekilde çalıştırılmasını ifade etmektedir. Bu çalışma koşulunda kaydedilen ham sinyaller Şekil 3.5'te gösterilmiştir.
- Motorun bant üzerinde yüksüz çalışması, scooter'ın deney düzeneği içerisinde yer alan döner bant üzerinde herhangi bir yük uygulanmadan çalıştırılması durumudur. Bu çalışma koşulunda kaydedilen ham sinyaller Şekil 3.6'da gösterilmiştir.
- Motorun bant üzerinde yüklü çalışması ise scooter'ın aynı deney düzeneği içerisindeki döner bant üzerinde belirli bir sabit yük altında çalıştırılmasını tanımlamaktadır. Bu çalışma koşulunda kaydedilen ham sinyaller Şekil 3.7'de gösterilmiştir.

Her bir durum için sensörlerden gelen akı, akım, akustik, gerilim ve titreşim verileri eş zamanlı olarak kaydedilmiştir. Deney düzeneğinde veri toplama süreci motorun sağlam durumunun yanı sıra, rulman arızası, mıknatıs arızası ve çoklu (mıknatıs-rulman) arıza durumlarında kaydedilmiştir. Çalışmada yapılan deneyler Çizelge 3.3'de tablo halinde sunulmuştur.

Çizelge 3.3. Deneysel veri setinde çalışma durumları, arıza tipleri ve toplanan sinyal türleri

Çalışma Koşulu	Arıza Durumu	Toplanan Veriler
Motor Boşta	Sağlam	Kaçak Akı, Akım, Akustik, Gerilim, Titreşim
	Rulman Arızalı	
	Mıknatıs Arızalı	
	Çoklu (Rulman+Mıknatıs)	
	Arıza	
Bant üzerinde yüksüz	Sağlam	Kaçak Akı, Akım, Akustik, Gerilim, Titreşim
	Rulman Arızalı	
	Mıknatıs Arızalı	
	Çoklu (Rulman+Mıknatıs)	
	Arıza	
Bant üzerinde yüklü	Sağlam	Kaçak Akı, Akım, Akustik, Gerilim, Titreşim
	Rulman Arızalı	
	Mıknatıs Arızalı	
	Çoklu (Rulman+Mıknatıs)	
	Arıza	

Bu çalışmada kullanılan farklı türde sensör verileri (kaçak akı, akım, akustik, gerilim ve titreşim) incelendiğinde, yöntemlerin sisteme müdahale gerektirip gerektirmediğine göre invaziv ve non-invaziv olarak sınıflandırılması mümkündür. Kaçak akı sensörü ile akustik (ses) verisi, motora herhangi bir kablo bağlantısı, devre montajı veya fiziksel müdahale gerektirmeden elde edilebilmektedir. Bu nedenle tamamen non-invaziv yöntemler arasında yer alırlar. Bu sensörlerle veri toplama süreci pratik, kolay uygulanabilir ve maliyet açısından oldukça düşüktür. HEA’larda arıza tespiti için bu tür non-invaziv yöntemler, hem kurulum kolaylığı hem de düşük donanım ihtiyacı nedeniyle ekonomik ve uygulanabilir çözümlerden biri olarak karşılaşılmaktadır (Alotaibi ve ark., 2021).

Buna karşılık, gerilim ve akım verileri, motorun çalışma sırasında çektiği elektriksel yükleri temsil ettiğinden, bu büyüklüklerin ölçülmesi ancak motor sürücüsü ya da motor güç kabloları üzerinden sisteme fiziksel bağlantı yapılmasıyla mümkündür. Bu nedenle akım ve gerilim ölçümleri invaziv yöntemler olarak değerlendirilmektedir. Titreşim ölçümü ise teorik olarak non-invaziv bir yöntem olmakla birlikte, sensörün motor

gövdesine uygun şekilde sabitlenmesi gerektiğinden diğer yöntemlere kıyasla daha maliyetli ve uygulaması daha zordur (Alotaibi ve ark., 2021; Nandi ve ark., 2005).


Bu doğrultuda, çalışmada kullanılan sensörler hem maliyet hem de uygulama kolaylığı açısından değerlendirilmiş; kaçak akı ve akustik temelli ölçümlerin HEA’larda en uygun non-invaziv veri toplama yöntemleri, akım ve gerilim ölçümlerinin ise invaziv nitelikte olduğu görülmektedir (Alotaibi ve ark., 2021). Titreşim ölçümü ise non-invaziv sınıfta yer almasına rağmen uygulama zorluğu ve ek maliyet nedeniyle ayrı olarak değerlendirilmiştir.

3.2. Arıza Durumlarının Oluşturulması

Çalışmada rulman, mıknatıs ve çoklu (mıknatıs-rulman) arızalar incelenmiştir. Gerçekleştirilen deneyler, Çizelge 3.3’de tablo halinde özetlenmiştir. Arızalar laboratuvar ortamında suni olarak oluşturulmuş ve her bir arıza senaryosu için Çizelge 3.3’de belirtilen deney adımları sistemli bir şekilde takip edilmiştir.

3.2.1. Rulman arızası

Yapılan uygulamada, elektrikli scooter motorunda yer alan rulmanın dış bileziğine 3 mm çapında matkap ucu ile suni bir delik açılarak kontrollü bir arıza oluşturulmuştur. Dış bilezik hataları genellikle yük taşıyan yüzeylerde çatlak, aşınma veya çentik şeklinde ortaya çıkar (Wang ve ark., 2024); çalışmada bu durum suni olarak modellenmiştir. Şekil 3.8(a)’da sağlam ve Şekil 3.8(b)’de arızalı rulmana ait görseller sunulmakta olup, deneylerde kullanılan arızalı rulman bu suni hata üzerinden değerlendirilmiştir.



Şekil 3.8. Sağlam ve arızalı rulmanların üstten görüntüsü (a: Sağlam rulman, b: Arızalı rulman)

3.2.2. Mıknatıs arızası

Yapılan uygulamada motorun stator ve rotoru ayrılarak, rotorda bulunan mıknatıslardan biri kontrollü bir şekilde ısıtılmış ve böylece mıknatıs üzerinde bozulma (demanyetizasyon) oluşturulmuştur. Isıl işlemin etkisiyle yanındaki iki mıknatıs da kısmen zarar görmüştür. Literatürde manyetik materyallerde demanyetizasyonun özellikle yüksek sıcaklık, mekanik zorlanma ve ters yönlü manyetik alan etkisiyle meydana geldiği belirtilmektedir (Li ve ark., 2023). Bu çalışmada demanyetizasyon durumu ısıl yöntemle suni olarak oluşturulmuştur. Demanyetize seviyesi bir Gaussmetre ile ölçülmüştür. Şekil 3.10’da sağlam mıknatısa ait ölçülen akı değeri 29.99mT iken, Şekil 3.9’da arıza oluşturulan mıknatısın akı değeri 7.99mT değerine düşürülmüştür.



Şekil 3.9. Mıknatıs arızası oluşturulduktan sonra yapılan ölçüm



Şekil 3.10. Sağlam mıknatıs ölçüm değeri

3.2.3. Çoklu arıza (Mıknatıs-Rulman)

Deney kapsamında çoklu arıza durumu oluşturmak amacıyla motor rulmanı arızalı rulman ile değiştirilmiş, rotoruna ise suni olarak mıknatıs arızası uygulanmış stator birleştirilmiştir. Böylece motor hem rulman hem de mıknatıs kaynaklı arızaları aynı anda içerecek şekilde çalıştırılmıştır.

3.3. Veri Seti Önışleme ve Dosya Yapısı

Oluşturulan deney setinde sağlam durum ile birlikte dört arıza senaryosu, üç farklı çalışma durumu ve beş sensör tarafından toplanan veriler dikkate alındığında toplam 60 farklı ham veri seti elde edilmiştir. Bu içerik bilgisi Çizelge 3.3’de sunulmaktadır. Akustik dışındaki tüm veriler, “.tdms” uzantılı dosyalar halinde kaydedilmiş ve Matlab yazılımı kullanılarak “.mat” formatına dönüştürülmüştür. Akustik veriler ise “.m4a” formatından “.mat” formatına dönüştürülerek veri setine dahil edilmiştir. Veri türleri ve özelliklerine ait tablo Çizelge 3.2’de görölmektedir.

Matlab ortamında işlenebilir hale getirilen 1D sinyaller için, yalnızca filtreleme yapmayan aynı zamanda sinyali farklı bileşenlere ayırarak sinyal tabanlı çoğaltma imkanı sunan CEEMDAN yöntemi uygulanmıştır. Bu yöntem, Bölüm 2.6’da verilen (2.25) numaralı formüle göre uyarlandığında $x_k(t) = x(t) + \omega_k(t)$ ifadesindeki k tekrar sayısı çalışmada $k=500$ olarak seçilmiştir. Dolayısıyla sinyale 500 farklı beyaz gürültü realizasyonu eklenmiş ve bu gürültülü sinyaller üzerinden IMF bileşenleri hesaplanmıştır. Formülde yer alan $\omega_k(t)$ beyaz gürültüyü ifade etmekte olup standart sapması, 0.2 olarak seçilmiştir. Her bir IMF’nin çıkarımı için EMD algoritmasına izin verilen maksimum iterasyon sayısı ise 500 olarak belirlenmiştir. Bu parametrelere göre elde edilen IMF’ler Bölüm 2.6’da verilen (2.26) numaralı formülde ifade edildiği gibi farklı gürültü eklenmiş sinyallerden elde edilen IMF’lerin hepsi toplanıp ortalaması alınarak birleştirilmiştir.


Elde edilen IMF matrisinin her satırına STFT uygulanarak 2D spektrogramlar elde edilmiştir. Bu işlemde 256 örnek uzunluğunda Hamming penceresi tercih edilmiştir. Daha küçük pencere boyutları zaman çözünürlüğünü artırmasına karşın frekans çözünürlüğünü

düşürdüğünden, bu çalışmada 256 örnek seçilerek zaman ve frekans çözünürlüğü arasında dengeli bir yapı sağlanmıştır. Ayrıca ardışık pencereler arasında 250 örnek örtüşme kullanılmış, böylece spektrogramlarda süreklilik korunmuştur. FFT noktası da 256 olarak belirlenmiş ve her IMF bileşeni zaman-frekans düzleminde logaritmik ölçekli 2D spektral görüntülere dönüştürülmüştür. Elde edilen 2D spektrogramlar, veri çeşitliliğini artırmak ve aşırı uyumu azaltmak amacıyla ikinci kez veri çoğaltma işlemlerine tabi tutulmuştur. Bu kapsamda, sınıf bilgisini koruyacak biçimde parametre aralıkları kısıtlanmış döndürme, öteleme, yakınlaştırma/ölçekleme, renk uzayı değişimleri, simetri tabanlı çevirme ve Gauss gürültüsü ekleme teknikleri uygulanmıştır. Yöntemler hakkında detaylı bilgi Bölüm 2.8’de detaylı bir şekilde verilmiştir. Artırma işlemleri sırasında değerler rastgele fakat belirlenen aralıklar içerisinde seçilerek uygulanmıştır. Rastgele oluşturulan her bir değer kontrolü sağlanmış ve tekrar edilmesine izin verilmemiştir. Bu sayede, küçük hizalama hataları, ölçek farklılıkları ve renk haritasına bağlı yoğunluk değişimleri gibi varyasyonlara karşı veri kümesi yapay olarak zenginleştirilmiştir. Çizelge 3.4’de, elde edilen görüntülerin artırma işlemi öncesindeki ve sonrasındaki sayıları tablo halinde sunulmuştur.

Çizelge 3.4. Spektrogramların veri artırma işleminden önceki ve sonraki sayıları

Tür	Sinyal	Sağlam		Rulman		Mıknatıs		Çoklu		Toplam	Genel
	Tipi	Önce	Sonra	Önce	Sonra	Önce	Sonra	Önce	Sonra		Toplam
Motor Boşta	Akı	13	1105	14	1106	13	1105	13	1105	4421	22572
	Akım	36	1116	35	1085	36	1116	35	1085	4502	
	Akustik	11	1067	11	1067	12	1092	11	1067	4293	
	Gerilim	26	1118	27	1161	25	1075	26	1118	4472	
	Titreşim	33	1221	33	1221	33	1221	33	1221	4884	
Bantta Yüksüz	Akı	14	1106	14	1106	13	1105	13	1105	4422	22582
	Akım	36	1116	36	1116	35	1085	36	1116	4433	
	Akustik	14	1106	11	1067	12	1092	14	1106	4371	
	Gerilim	28	1204	24	1176	25	1075	34	1054	4509	
	Titreşim	33	1221	32	1184	33	1221	33	1221	4847	
Bantta Yüklü	Akı	13	1105	13	1105	13	1105	13	1105	4420	22811
	Akım	36	1116	36	1116	32	1184	36	1116	4682	
	Akustik	11	1067	11	1067	12	1092	12	1092	4318	
	Gerilim	27	1161	26	1118	30	1110	26	1118	4507	
	Titreşim	33	1221	33	1221	33	1221	33	1221	4884	
Toplam		17050		16916		16899		16850		67715	

Veri seti için oluşturulan klasör yapısı Şekil 3.11’de görülmektedir. Taban dağılımda, her durum için üç türde ortalama 120 civarında resim bulunmaktadır. Literatürde veri artırma için çoğunlukla on binler düzeyinde örnek önerildiği dikkate alınarak (Krizhevsky ve ark., 2017), 60 hücreden oluşan bu yapının dengeli ve orantılı bir dağılım göstermesi amacıyla her klasörde en az yaklaşık bin örnek bulunacak şekilde veri artırma işlemi gerçekleştirilmiştir. Bu yaklaşımla, artırma katsayıları orantılı biçimde uygulanarak binin üzerine çıkılana kadar veri üretimi yapılmıştır. Her çalışma türünde ortalama 5500 civarında, sağlam ile beraber her arıza durumunda ortalama 17 bin civarında görüntü elde edilmiştir.



Şekil 3.11. Oluşturulan veri seti için klasör yapısı

Veri artırma adımlarından geçirilen tüm görüntüler, Çizelge 3.8’de belirtilen giriş boyutları referans alınarak sınıflandırma aşamasında kullanılacak standart piksel

boyutlarına yeniden ölçeklendirilmiştir. Yeniden boyutlandırma sırasında görüntülerin yapısal bütünlüğünü koruyabilmek için kenar yumuşatma (antialiasing) tekniği uygulanmış ve pikseller arası geçişler daha doğal hale getirilebilmesi için biküçük interpolasyon yöntemi tercih edilmiştir. Böylece, küçültme işlemi sonrasında ayrıntı kayıpları en aza indirilmiş ve daha yüksek kaliteli görüntüler elde edilmiştir. CNN modeli için klasör yapısı Çizelge 3.3’de gösterilen tablo referans alınarak Şekil 3.11’deki gibi oluşturulmuştur.

3.4. CNN Modeli Optimizasyonu

CNN modeli optimizasyonu, en yüksek doğruluğu sağlayan CNN yapısını ve bu yapıya ait parametreleri belirlemek amacıyla gerçekleştirilir. Ancak, çok sayıda parametrenin aynı anda optimize edilmesi, hesaplama maliyetlerini artırarak süreci zorlaştırmaktadır. Bu nedenle, yüksek hesaplama maliyetlerini azaltmak ve sürecin getirdiği zorlukları aşmak için, sınırlı iterasyon sayısı ile dahi etkili sonuçlar verebilecek güçlü optimizasyon algoritmalarına ihtiyaç duyulmaktadır (Han ve ark., 2020). Çizelge 3.3’de gösterilen hiyerarşik yapıya sahip veri seti kullanılarak en iyi CNN modelini belirlemek üzere PSO algoritması uygulanmıştır. En yüksek doğruluk elde edilene kadar süreç tekrarlanmıştır. Algoritmanın akış diyagramı ise Bölüm 2.10, Şekil 2.22’de gösterilmektedir. Algoritmanın çalışma prensipleri ve iç yapısına ilişkin ayrıntılı açıklamalar Bölüm 2.10’da verilmiştir.


Algoritmanın yaklaşımı, Junior ve Yen (2019) tarafından ortaya atılmıştır. Buna göre, PSO-CNN algoritması, parçacıkların doğrudan CNN katmanları ile temsil edilmesi prensibine dayanmaktadır. Başlangıçta sürü rastgele CNN mimarilerinden oluşturulur, ilk ve son katman sabitlenir (Convolution Layer, Fully Connected Layer), parçacık hızları P_{best} ve G_{best} farklarıyla güncellenir, aynı tip katmanlar eşleşirse fark sıfır kabul edilir (Junior & Yen, 2019). Bu yaklaşım, İnık (2023) tarafından da benzer bir çalışmada kullanılmış, CNN katman yapılarının gösterimi için yeni bir gösterim önerilmiştir (İnik, 2023).

Bu çalışmada ise, söz konusu algoritmanın prensipleri temel alınmış ancak bazı uyarlamalar yapılmıştır. Örneğin, kernel boyutları 2×2 ile 11×11 aralığında seçilmiş, stride değerleri 2 ile 7 arasında tutulmuş ve fully connected katmandaki nöron sayısı 10 ile 1024 arasında bir değer olarak belirlenmiştir. Ayrıca, convolution katmanlarından sonra ReLU, fully connected katmanlarından sonra dropout katmanları otomatik eklenmiştir. Böylece parametre aralığı daha geniş tutulmuş ve daha karmaşık CNN mimarilerinin denenmesi sağlanmıştır. PSO algoritmasına ait başlatma değerleri Çizelge 3.5'te tablo halinde gösterilmiştir.

Çizelge 3.5. PSO algoritması başlatma değerleri

Parametre	Başlatma Değeri
Parçacık sayısı (i)	20
Epoch sayısı	10
x_0 (konum)	Katman sayısı [3,7], filtre [16,128], stride [1,3]
v_0 (hız)	(0,1)
w	0.73
c_1, c_2	1.5 - 2.0
$Pbest$	x_0
$Gbest$	En yüksek doğruluk üreten x_0

Bu çalışma kapsamında algoritmanın özel uygulama süreci ise şu adımlarla ilerlemektedir: Her iterasyonda sürüdeki her bir parçacık CNN katmanları ve hiperparametreleri güncelleyerek en yüksek başarıyı arar. En iyi parçacık belirlenerek sürü içerisindeki en iyi çözümlere aktarılır. Böylece parametre optimizasyonu her defasında baştan başlamaz ve en iyi çözümler korunmuş olur. Ayrıca her bloğun parametresinin manuel olarak optimize edilmesine gerek kalmaz. Örneğin, 2 parçacığın 5.katmanı aynı ise fark sıfır olacağından parçacığın konumunun değişmesine gerek yoktur. PSO ile optimizasyon işlemi yapabilmek için Bölüm 2.10.2'de bahsedilen (2.38) ve (2.39) nolu denklemler CNN yapısına uyarlanmıştır.




Şekil 3.12. Parçacıkların CNN mimarisini temsil eden gösterimi

Şekil 3.12’de her bir parçacığın bir CNN modelini temsil edecek şekilde oluşturulmuş hali gösterilmiştir. Convolutional, pooling and fully connected layer olmak üzere üç tür katman tanımlanmıştır. Bu üç katman aynı zamanda katman sayılarını temsil etmektedir. Convolution katmanından sonra ReLu katmanı ve fully connected katmanından sonra dropout katmanı otomatik olarak eklenir. Katmanlar konum, tür ve hiperparametrelerine ait bilgiler içerir. Mesela, convolutional katman türünde, filtre sayısı ve kernel boyutu; fully connected’da nöron sayısı, pooling ise çekirdek boyutu bilgisini içermektedir. Sürü hareketi başlatıldıktan sonra rastgele CNN mimarilerine sahip n adet parçacık oluşturulacaktır. Katman, filtre, filtre büyüklüğü, kaydırma değeri ve nöron sayılarına ait başlangıç değerleri ve aralıkları Çizelge 3.6’da tablo halinde sunulmuştur.


Çizelge 3.6. Model optimizasyonu için başlangıç referans aralıkları

Parametreler	Değeri
Katman sayısı	3 - 21
Filtre sayısı	16 - 256
Filtre boyutu	2x2 ile 11x11
Kaydırma değeri	2 ile 9
Nöron sayısı	10 - 1024




Şekil 3.13. P_{best} ve G_{best} 'in hesaplanması

Şekil 3.13'de P_{best} veya G_{best} durumunun nasıl hesaplandığı blok şema ile gösterilmiştir. Aynı katmanlar eşleştirildiğinde oluşan durum “Eşleşme” olarak tanımlanmıştır. Katmanların farklı olması durumunda ise P_{best} veya G_{best} dikkate alınır. Uygulanabilir bir CNN modeli oluşturabilmek için her modelin ilk ve son katmanları sırasıyla convolution ve fully connected olarak seçilir. Fully connected katmanları diğer katmanlar tarafından çıkarılan özellikleri sınıflandırdığı için bu katmanın rastgele kullanımı parametre sayısını artırmaktadır. Bir parçacığın hızını ölçebilmek için iki parçacık arasındaki farkı bulmak gerekir. Convolution ve fully connected sabit olduğu için aradaki katmanların mesafelerine bakılır. P_{best} bireyin en iyi çözümü, G_{best} ise sürünün en iyi çözümü olduğu için parçacığın hızı $G_{best} - P$ ile bulunur. Nihai hız ise $[0,1)$ aralığından rastgele bir r sayısı çekilerek ve referans değerine dayalı iki farktan birinden bir katman seçilerek hesaplanır. r , referans değerinden küçük ve eşit olduğu durumlarda $G_{best} - P$, aksi durumda $P_{best} - P$ farkından bir katman seçilir. Hız yalnızca katman tipleri karşılaştırılarak hesaplandığı için en iyi durumlar (G_{best}, P_{best}) aynı katman tiplerinde olduğunda mümkün olur.



Şekil 3.14. P_{best} ve G_{best} referans değere göre hesaplanması

Yani, Şekil 3.14’de görüldüğü gibi referans değeri rastgele üretilen r sayısından küçükse G_{best} , büyükse P_{best} sütunda bulunan parçacık alınır ve değiştirilmesi gereken katmanlar için parçacık hızı esas alınır. Hız, tüm katmanlar karşılaştırıldıktan sonra elde edilir. Hız elde edildikten sonra parçacıklar Şekil 3.15’deki halini almaktadır. Hız ve parçacık katmanları farklıysa hız katmanı esas alınır.



Şekil 3.15. PSO tarafından güncellenmiş katman yapısı

3.5. Parametre Kullanımı

Bu tez çalışmasında kullanılan PSO algoritmasında parametreler üç grupta incelenir: PSO başlatma parametreleri, CNN mimarisi başlatma parametreleri ve CNN eğitim parametreleri.

İlk grupta yer alan PSO başlatma parametreleri şu şekilde belirlenmiştir: Sürü büyüklüğü 30, iterasyon sayısı ise 5 olarak seçilmiştir. Bu doğrultuda her iterasyonda 30 farklı CNN mimarisi oluşturulmuştur. Ayrıca, model için referans değeri 0.73 olarak alınmıştır. İkinci grup parametreler, modele ait CNN mimarisi parametreleridir ve Çizelge 3.7’de sunulmuştur. Önerilen algoritmanın ilk adımı, rastgele oluşturulan parçacıklardan meydana gelen CNN modellerinden oluşan sürüyü oluşturmaktır. Optimizasyon sürecinde katman sayısı sürekli olarak artış veya azalış gösterebilir, ancak belirlenen sınırların dışına çıkmaz. Bu parametreler, arama uzayının boyutunu kontrol altında tutar. Boyutun aşılması durumunda, algoritmanın çalışabilirliği donanımsal olarak kullanılan CPU veya GPU’nun kapasitesiyle sınırlıdır; aksi halde algoritma çalışmayacaktır.

Çizelge 3.7. Referans aralıkları

Parametreler	Değeri
Katman sayısı	3 - 21
Filtre sayısı	16 - 256
Filtre boyutu	2x2 ile 11x11
Kaydırma değeri	2 ile 9
Nöron sayısı	10 - 1024

Üçüncü grup eğitim parametreleridir. Eğitim aşamasında en iyi performansa sahip CNN modelini bulmak için epoch sayısı, aşamalı bir şekilde 1 ve 10 olarak seçilmiştir. 1 ve 10 epoch, bir CNN modelini eğitmek için düşük bir değerdir. Fakat parçacık değerlendirmesi sırasında yüksek epoch değerleri mimari arama süresini artırmaktadır. Ayrıca bu sayı ne kadar yüksek seçilirse aşırı öğrenme ve eğitim hata riskini artırır. Tüm modellere bu epoch değerleri uygulandığı için en iyi modelin seçilebilmesi kabul edilebilir yaklaşımdır (İnik, 2023). En iyi model belirlendikten sonra 30 epoch kullanılarak eğitim tamamlanmıştır. PSO algoritması ile 8 katmanlı bir CNN modeli elde edilmiştir. Ancak

ReLU ve dropout gibi otomatik eklenen katmanlar da hesaba katıldığında, modelin toplam katman sayısı 15'e ulaşmaktadır. Katmanlara ilişkin ayrıntılı bilgiler Çizelge 3.8'de sunulmuştur.

Çizelge 3.8. PSO mimarisinin katman sayıları

Katman Tipi	Sayısı	Açıklama
InputLayer	1	64×64×3
Convolution Layer	3	32, 64, 128 filtre (5×5, 3×3, 3×3, 3×3)
relu Layer	4	-
Pooling Layer	3	2x2
Fully Connected Layer	1	128 nöron
Dropout Layer	1	0.3
Softmax Layer	1	-
Classification Layer	1	4
Toplam	15	-
Toplam parametre sayısı		1,14 milyon

Çizelge 3.9. Eğitim için kullanılan hiperparametreler

Parametreler	Değeri
Optimizer	SGDM
Epoch	30
Mini Batch Size	64
Initial Learn Rate	0.001
Max Epoch	30

Elde edilen PSO-CNN modeli Çizelge 3.9'da gösterilen hiper parametrelerle eğitilmiştir. Veri seti, %80 eğitim ve %20 test için ayrılmıştır. Bu bölümlere, birçok makine öğrenimi ve derin öğrenme uygulamasında yaygın bir pratiktir. Ana gerekçe, modelin yeterince büyük bir veri seti üzerinde eğitilmesini sağlamak, böylece genelleme yeteneğini artırmak, aynı zamanda bağımsız bir test setinde modelin performansını doğru bir şekilde değerlendirebilmektir (İnik, 2023; Yildirim ve ark., 2019).

3.6. İki Aşamalı Hiyerarşik Sınıflandırma Yöntemi


Veri seti için model oluşturulurken iki aşamalı hiyerarşik sınıflandırma yapısı benimsenmiştir. Bu yaklaşım, hiyerarşik bir etiketleme yapısı üzerine inşa edilmiştir. Şekil 3.1’de, önerilen yöntemin genel akış yapısını; üçüncü adım ise yöntemin uygulanma sürecini göstermektedir. Bu yöntemde uygulanan koşullu CNN yapısı, aşağıdaki nedenlerle tercih edilmiştir:

- Bellek taşması riskini azaltmak: Tüm arıza-sensör kombinasyonlarını ($4 \text{ arıza} \times 5 \text{ sensör} = 20 \text{ sınıf}$) tek bir modelde sınıflandırmak yerine, iki aşamalı yaklaşım benimsenerek bellek tüketimi optimize edilmiştir.
- Arıza tipine özgü sensör performansını değerlendirmek: Her arıza tipi için hangi sensörün en yüksek ayırt ediciliği sağladığını belirlemek amacıyla, her arıza için ayrı veri sınıflandırma modelleri oluşturulmuştur.
- Hiyerarşik etiket yapısını kullanmak: Veri seti klasör hiyerarşisi, birinci katmanda arıza durumlarını (sağlam, rulman, mıknatıs, çoklu arıza), ikinci katmanda ise veri tiplerini (akı, akım, akustik, gerilim, titreşim) içermektedir. Bu yapı, sınıf etiketlerinin doğrudan klasör isimlerinden türetilmesine olanak tanımıştır.

Şekil 3.16’da, yöntemde kullanılacak veri setinin düzenlenmiş klasör yapısı gösterilmektedir. Bu klasör yapısına göre hazırlanan veri seti Bölüm 3.4’de ayrıntıları verilen PSO algoritmasıyla optimize edilen CNN mimarisi kullanılarak eğitilmiştir.

Veri seti klasör hiyerarşisi, birinci katmanda arıza durumlarını (sağlam, rulman, mıknatıs ve çoklu arıza), ikinci katmanda ise veri tiplerini (akı, akım, akustik, gerilim ve titreşim) içermektedir. Klasör isimleri, model tarafından doğrudan sınıf etiketi olarak algılanmakta olup, veri etiketleme süreci için ek bir işlem yapılmamaktadır.

Eğitim süreci iki aşamadan oluşmaktadır. Birinci aşamada, tüm veri seti kullanılarak arıza durumlarının tespiti için bir CNN modeli eğitilmiştir. Bu aşamada, klasör hiyerarşisinin birinci katmanı (arıza tipi) sınıf etiketi olarak kullanılmış, ikinci katman (sensör tipi) göz ardı edilmiştir. Model, $64 \times 64 \times 3$ boyutlarında RGB görüntüler üzerinde dört sınıflı (sağlam, rulman, mıknatıs, çoklu) bir sınıflandırma gerçekleştirmektedir. Modelde eğitilen görüntü sayıları Çizelge 3.4’de detaylı olarak gösterilmiştir.



Şekil 3.16. Hiyerarşik klasör yapısı


İkinci aşamada, aynı CNN mimarisi her bir arıza durumu için ayrı ayrı eğitilerek toplam dört model daha oluşturulmuştur. Bu aşamada, birinci katman (arıza tipi) filtre olarak kullanılarak her arıza tipine ait veriler ayrıştırılmış ve ikinci katman (sensör tipi) sınıf etiketi olarak atanmıştır. Örneğin, rulman arızası için eğitilen model, yalnızca rulman sınıfına ait görüntüleri kullanmış ve bu görüntülerin hangi sensör tipinden (titreşim, akım, akustik vb.) elde edildiğini sınıflandırmıştır. Bu yaklaşım sayesinde, her arıza tipi için en yüksek ayırt edicilik sağlayan sensör tipinin belirlenmesi mümkün olmuştur. Şekil 3.17’de yapının sözde kodu, Şekil 3.18’de ise hiyerarşik yapının akış diyagramı gösterilmiştir.

```

input: test_image (64×64×3)
output: (fault_type, sensor_type, confidence)
fault_model ← load('fault_model.mat')
fault_pred ← classify(fault_model, test_image)
if fault_pred == 'rulman':
    sensor_model ← load('sensor_rulman.mat')
elseif fault_pred == 'miknatis':
    sensor_model ← load('sensor_miknatis.mat')
elseif fault_pred == 'sağlam':
    sensor_model ← load('sensor_saglam.mat')
else:
    sensor_model ← load('sensor_coklu.mat')
    sensor_pred ← classify(sensor_model, test_image)
return (fault_pred, sensor_pred, confidence_scores)
  
```

Şekil 3.17. Hiyerarşik sınıflandırma yapısının sözde kodu

Model performansı karışıklık matrisi, kesinlik, duyarlılık, F1 skoru ve ROC-AUC metrikleri ile değerlendirilmiştir. Birinci aşamada elde edilen arıza tespit doğruluğu ile ikinci aşamada her arıza tipi için elde edilen sensör sınıflandırma doğrulukları karşılaştırılarak, arıza tipine özgü en uygun sensör seçimi yapılmıştır. Bu hiyerarşik sınıflandırma yaklaşımı, literatürde coarse-to-fine classification ve hierarchical multi-label classification yöntemleriyle benzerlik göstermektedir (Mirza & Osindero, 2014; Yan ve ark., 2015).



Şekil 3.18. Hiyerarşik sınıflandırma yapısının akış diyagramı

3.7. Transfer Öğrenme Uygulaması

Bu tez çalışmasında iki farklı derin öğrenme yaklaşımı uygulanmıştır. İlk olarak, Bölüm 3.4 ve Bölüm 3.5’de açıklandığı üzere PSO algoritması kullanılarak CNN mimarisine ait katman sayısı, filtre boyutu, kaydırma değeri ve fully connected katmanındaki nöron sayısı gibi parametreler optimize edilmiştir. Elde edilen mimari Bölüm 3.6’da açıklandığı şekilde sıfırdan eğitilmiş ve iki aşamalı hiyerarşik sınıflandırma yaklaşımıyla performansı değerlendirilmiştir. İkinci olarak, TL yaklaşımı benimsenmiştir. TL ile ilgili genel açıklama Bölüm 2.11’de verilmiştir. Bu aşamada GoogLeNet, MobileNet-v2 ve ResNet-

50 gibi ImageNet veri seti üzerinde önceden eğitilmiş CNN modelleri kullanılmıştır. Bu modellerin seçim gerekçeleri ise Bölüm 2.9’da detaylı olarak açıklanmıştır.

TL sürecinde fine-tuning stratejisi tercih edilmiştir (Yosinski ve ark., 2014). Bu stratejide, önceden eğitilmiş modellerin tüm katmanları eğitilebilir durumda tutulmuş, ancak yeni eklenen çıkış katmanlarının öğrenme hızı ($\text{WeightLearnRateFactor}=10$, $\text{BiasLearnRateFactor}=10$) artırılarak bu katmanların daha hızlı adapte olması sağlanmıştır. Çıkış katmanları bu çalışmadaki sınıf sayısına uygun şekilde yeniden yapılandırılmıştır. Bu yaklaşım, literatürde tam fine-tuning (full fine-tuning) olarak bilinmektedir. Böylece modelin hem düşük seviye özellikleri (kenarlar, dokular) hem de yüksek seviye özellikleri (arıza paternleri) hedef probleme göre uyarlanabilmesi mümkün olmaktadır (Yosinski ve ark., 2014).

GoogLeNet modeli için TL uygulaması şu şekilde gerçekleştirilmiştir. GoogLeNet (Inception-v1), toplam dokuz adet Inception modülü içeren bir mimaridir (Szegedy ve ark., 2015). Inception modülü, farklı boyutlarda filtreleri (1×1 , 3×3 , 5×5 konvolüsyon ve havuzlama) aynı anda uygulayan ve çıktıları birleştiren özel bir blok yapısıdır. TL uygulanmasında, MATLAB Deep Learning Toolbox’tan yüklenen önceden eğitilmiş GoogLeNet modelinin son sınıflandırma katmanı (loss3-classifier) ve çıkış katmanı (output) kaldırılarak yerine yeni bir tam bağlı katman (fullyConnectedLayer) ve softmax ile sınıflandırma katmanı (classificationLayer) eklenmiştir. Yeni eklenen tam bağlı katmanın öğrenme hız çarpanları ($\text{WeightLearnRateFactor}=10$, $\text{BiasLearnRateFactor}=10$) ayarlanarak, bu katmanın diğer katmanlara göre 10 kat daha hızlı öğrenmesi sağlanmıştır. Modelin geri kalan tüm katmanları varsayılan öğrenme hızı ile eğitilebilir durumda bırakılmış, herhangi bir katman dondurulmamıştır. Bu yaklaşım, özellikle hedef veri setinin kaynak veri setinden (ImageNet) farklı olduğu durumlarda önerilmektedir (Kornblith ve ark., 2019).

Modelin giriş boyutu $224\times 224\times 3$ olarak belirlenmiştir; bu boyut GoogLeNet mimarisinin orijinal tasarımına uygundur. Çıkış katmanı, bu çalışmadaki sınıf sayısını (arıza türü sınıflandırması için dört sınıf: sağlam, rulman arızası, mıknaş arızası ve çoklu arıza; veri tipi sınıflandırması için beş sınıf) temsil edecek şekilde yapılandırılmıştır. Eğitim

sürecinde SGDM (Stochastic Gradient Descent with Momentum) optimizasyon algoritması kullanılmış, başlangıç öğrenme oranı 0.001, mini-batch boyutu 32 ve epoch sayısı 10 olarak belirlenmiştir. Eğitim sırasında doğrulama verisi üzerinde performans izlenmiş (ValidationData parametresi ile), her 30 mini-batch'te bir doğrulama frekansı hesaplanmıştır (ValidationFrequency=30). Eğitim GPU üzerinde gerçekleştirilmiştir (ExecutionEnvironment = 'gpu').

Bu yaklaşımda, modelin tüm katmanlarının ağırlıkları güncellenebildiğinden, ImageNet üzerinde öğrenilmiş genel görsel özellikler korunurken, elektrik motoru arıza sınıflandırması gibi probleme özgü ayırt edici özellikler de öğrenilmiştir. Literatürde, tam fine-tuning yaklaşımının özellikle hedef veri setinin yeterli büyüklükte olduğu ve kaynak veri setinden farklı özelliklere sahip olduğu durumlarda daha iyi sonuçlar verdiği rapor edilmiştir (Tajbakhsh ve ark., 2016).

MobileNet-v2 ve ResNet-50 modelleri için de GoogLeNet ile aynı TL stratejisi uygulanmıştır. Her modelin önceden eğitilmiş ağırlıkları MATLAB Deep Learning Toolbox'tan yüklenmiş, son sınıflandırma katmanları hedef sınıf sayısına göre yeniden yapılandırılmıştır. Tüm modellerde tam fine-tuning yaklaşımı benimsenmiş, herhangi bir katman dondurulmamış ve yeni eklenen çıkış katmanlarının öğrenme hız çarpanları artırılmıştır. Kullanılan modeller için TL eğitim parametreleri Çizelge 3.10'da sunulmuştur.

Çizelge 3.10. Kullanılan modeller için TL eğitim parametreleri

Model	Giriş Boyutu	Öğrenme Oranı	Epoch	Mini-Batch	Optimizer	Fine-Tuning Stratejisi
GoogLeNet	224x224x3	0.001	10	32	SGDM	Learn Rate Çarpanı x10
MobileNet-v2	224x224x3	0.001	10	32	SGDM	Learn Rate Çarpanı x10
ResNet-50	224x224x3	0.001	10	32	SGDM	Learn Rate Çarpanı x10

4. BULGULAR VE TARTIŞMA

Bu bölümde, HEA motorundan toplanan veriler üzerinde gerçekleştirilen sınıflandırma sonuçları sunulmakta ve tartışılmaktadır. Analizler; sağlam durum tespiti, mıknatıs arızası tespiti, rulman arızası tespiti ve arıza sınıflandırması olmak üzere dört ana başlıktan oluşmaktadır. Veri seti, Bölüm 3.6’da Şekil 3.13’de gösterildiği gibi organize edilerek hazır hale getirilmiştir. Modelin eğitimi için kullanılan optimizier, öğrenme oranı ve diğer hiperparametreler Bölüm 3’de detaylı bir şekilde anlatılmıştır. Bu kısımda ilgili eğitim sürecinin sonuçları ve modelin doğrulama performansı ele alınmaktadır. Bulgular, hem PSO algoritması ile optimize edilerek elde edilen CNN mimarisi hem de TL kapsamında fine-tuning uygulanmış ön eğitilmiş CNN modelleri (GoogLeNet, MobileNet-v2 ve ResNet-50) için ayrı ayrı sunulmuş ve karşılaştırılmıştır.


4.1. Çoklu Arıza Durum Tespiti

Bu bölümde, HEA’ların BLDC motorundan elde edilen sağlam ve çoklu arızaya sahip motor verileri incelenmiştir. Beş farklı sensörden (akı, akım, akustik, gerilim ve titreşim) elde edilen sinyaller, hem PSO algoritmasıyla optimize edilmiş CNN modeli hem de önceden eğitilmiş GoogLeNet, MobileNet-v2 ve ResNet-50 derin öğrenme mimarileri kullanılarak TL yaklaşımıyla ayrı ayrı analiz edilmiştir. Bu bölümün temel amacı, motorun sağlam durumunun çoklu arıza durumuyla sınıflandırılmasında kullanılan CNN modellerinin performansını karşılaştırmak ve bu karşılaştırmayı analize dayalı sayısal verilerle ortaya koymaktır.

4.1.1. Eğitim performansının incelenmesi


PSO algoritması ile optimize edilmiş CNN modelinin eğitim süreci Şekil 4.1’de sunulmuştur. Model 30 epoch boyunca eğitilmiş ve motorun sağlam durumu %96.06 test doğruluğuna ulaşmıştır. Eğitim sürecinde, modelin doğrulama başarısı (kırmızı kesikli çizgi) yaklaşık onuncu epoch’dan sonra %90’ın üzerine çıkmış ve kalan iterasyonlarda %90-100 aralığında stabil bir seyir izlemiştir. Eğitim başarısı (mavi sürekli çizgi) ise benzer bir trend göstererek %95 civarında stabilize olmuştur. Her iki eğrinin birbirine

paralel seyretmesi, modelde aşırı öğrenme probleminin bulunmadığını göstermektedir. Kayıp fonksiyonu grafiğinde, eğitim kaybı (mavi çizgi) ve doğrulama kaybı (kırmızı kesikli çizgi) başlangıçta 0.6-0.8 seviyelerinden başlamış ve süreç boyunca düzenli bir azalma göstermiştir. Başarı grafiğine paralel olarak onuncu epoch'dan sonra her iki kayıp değeri 0.1'in altına düşmüş ve son iterasyonlarda 0.05 civarında kararlı hale gelmiştir. Eğitim ve doğrulama kayıpları arasındaki tutarlı yakınlık, modelin genelleme kabiliyetinin yüksek olduğuna işaret etmektedir. Grafiklerde gözlemlenen periyodik dalgalanmalar, mini-batch bazlı stokastik gradyan iniş optimizasyonunun doğal bir sonucudur. Ancak bu dalgalanmalara rağmen, genel trend her iki metrikte de sürekli iyileşme yönündedir ve model yakınsaması başarılı bir şekilde gerçekleşmiştir.



Şekil 4.1. Çoklu arıza durum tespiti PSO-CNN eğitim ve doğrulama grafiği

Şekil 4.2'de, TL aşamasından sonra en yüksek performansı gösteren GoogLeNet modeline ait eğitim ve doğrulama başarı grafikleri sunulmaktadır. GoogLeNet mimarisine uygulanan TL yöntemi, 10 epoch boyunca eğitilmiştir. Model, ImageNet veri seti üzerinde önceden eğitilmiş ağırlıkları kullanması sayesinde, PSO-CNN modeline kıyasla daha az epoch ile yüksek bir performansa ulaşmıştır. Doğrulama başarısı (kırmızı kesikli çizgi), eğitimin erken aşamalarında hızlı bir artış göstermiş ve %90-100 aralığında stabilize olmuştur. Eğitim başarısı (mavi çizgi) ise benzer bir eğilim sergilemiş ve sürecin büyük bölümünde %90'ın üzerinde seyretmiştir. Eğitim ve doğrulama başarıları arasındaki bu tutarlı yakınlık, TL yaklaşımının genelleme kabiliyetinin güçlü olduğunu ortaya koymaktadır.



Şekil 4.2. Çoklu durum arıza tespiti GoogLeNet eğitim ve doğrulama grafiği

Kayıp fonksiyonu grafiğinde, başlangıçtaki kayıp değerlerinin yaklaşık 0.7-1.2 aralığından başlayarak eğitimin ilk aşamalarında hızlı bir düşüş sergilediği görülmektedir. Eğitimin ilerleyen bölümlerinde ise hem eğitim hem de doğrulama kayıpları 0.2'nin altına inmiş ve sıfıra yakın değerlerde kararlı bir şekilde seyretnmiştir. Eğitim ve doğrulama kayıplarının birbirine paralel bir eğilim göstermesi, modelin aşırı öğrenme sorunu yaşamadığını ortaya koymaktadır. PSO-CNN modelinin 30 epoch boyunca eğitilmesine karşın, GoogLeNet modelinin yalnızca 10 epoch ile benzer doğruluk seviyelerine ulaşması, TL'nin verimliliğini ve avantajını açık biçimde göstermektedir. Bu durum, önceden öğrenilmiş özelliklerin motor arıza görüntülerinin sınıflandırılmasında etkili bir şekilde yeniden kullanılabildiğini ortaya koymaktadır. Grafikte gözlemlenen yüksek frekanslı dalgalanmalar, stokastik gradyan iniş (SGD) optimizasyon algoritmasının doğal bir sonucu olup, PSO-CNN modeline kıyasla daha belirgin şekilde gözlenmiştir.


4.1.2. Sınıflandırma performansının değerlendirilmesi

PSO-CNN modelinin sınıflandırma performansı Şekil 4.3'deki karışıklık matrisi ile detaylı olarak incelenmektedir. Test veri seti üzerinde toplam 6780 görüntü değerlendirilmiş olup, matris modelin her iki sınıf için de yüksek doğruluk oranlarına sahip olduğunu göstermektedir.

Sağlam durum için, toplam 3410 test örneğinden 3332 tanesi doğru bir şekilde sağlam olarak tespit edilmiş (%97.7 doğruluk), yalnızca 78 örnek (%2.3) yanlışlıkla çoklu arıza


olarak sınıflandırılmıştır. Bu durum, modelin sağlam durumunu yüksek güvenilirlikle tanıyabildiğini ortaya koymaktadır.

Çoklu arıza sınıfında ise, 3370 test örneğinden 3301'i başarıyla çoklu arıza olarak belirlenmiş (%98 doğruluk) ve sadece 69 örnek (%2.0) sağlam durum için yanlış sınıflandırılmıştır. Bu sonuç, modelin arızalı motor görüntülerini ayırt etmede oldukça başarılı olduğunu göstermektedir.



Şekil 4.3. Çoklu arıza durum tespiti için PSO-CNN'e ait karışıklık matrisi

Model, her iki sınıf için de dengeli bir performans sergilemekte olup, False Positive (FP=78) ve False Negative (FN=69) hata sayıları oldukça düşük seviyelerdedir. True Positive oranlarının her iki sınıfta da %97'nin üzerinde olması, modelin hem sağlam hem de arızalı motor durumlarını güvenilir şekilde tespit edebildiğini doğrulamaktadır. Toplam 6633 doğru sınıflandırma ve yalnızca 147 hata ile yüksek bir başarı elde edilmiştir.




Şekil 4.4. Çoklu arıza durum tespiti için GoogLeNet'e ait karışıklık matrisi

TL uygulandığında en başarılı model GoogLeNet olarak tespit edilmiştir. Şekil 4.4’de GoogLeNet’e ait karışıklık matrisi görüntülenmektedir. GoogLeNet ile yapılan TL uygulaması, PSO-CNN modeline kıyasla daha yüksek sınıflandırma performansı göstermiştir. Motorun sağlam durum tespitinde %99.0 doğruluk ile PSO-CNN’in %97.7 başarısının 1.3 puan üzerinde performans sergilemiştir. Çoklu arıza sınıfında ise %98.2 doğruluk elde edilmiş olup, PSO-CNN’in %98.0 başarısına yakın bir sonuç göstermiştir.

Toplam hata sayısı açısından GoogLeNet 92 hata ile PSO-CNN’in 147 hatasına göre %37 daha az yanlış sınıflandırma gerçekleştirmiştir. False Positive değerinde GoogLeNet (FP=33), PSO-CNN’e (FP=78) göre belirgin şekilde daha düşüktür. TL yaklaşımının, ImageNet üzerinde önceden öğrenilmiş özellikler sayesinde motor görüntülerinde daha hassas ayırt edici özellikler çıkarabildiği görülmektedir.

4.1.3. ROC eğrisi ve AUC değeri

Şekil 4.5’te sağlam durum tespiti için PSO-CNN modeliyle elde edilen ROC eğrileri görüntülenmektedir.



Şekil 4.5. Çoklu arıza durum tespiti için PSO-CNN’e ait ROC eğrisi

Her iki sınıf için de elde edilen ROC eğrileri sol üst köşeye yakın seyretmekte olup, modelin yüksek ayırt etme kabiliyetine sahip olduğunu göstermektedir. Motorun sağlam durumunu gösteren sınıfı (mavi sürekli çizgi) ve çoklu arıza sınıfı (turuncu kesikli çizgi) için AUC değerleri 0.997 olarak hesaplanmıştır. Bu değer, modelin rastgele tahmin yapan bir sınıflandırıcıya ($AUC=0.5$) göre son derece üstün performans sergilediğini ortaya koymaktadır.

Çizelge 4.1. Çoklu arıza durum tespitinde AUC test değerleri

	Sağlam	Çoklu Arıza	Mikro	Makro
PSO-CNN	0.9973	0.9973	0.9972	0.9973
GoogLeNet	0.9987	0.9987	0.9986	0.9987
Mobilnetv2	0.9983	0.9983	0.9977	0.9983
ResNet-50	0.9941	0.9941	0.9934	0.9941

Tüm modellerin AUC değerleri karşılaştırıldığında, dört modelin de 0.99'un üzerinde değerlere ulaştığı görülmektedir. GoogLeNet mimarine uygulanan TL yöntemi 0.9987 AUC değeri ile en yüksek sınıf ayırma kalitesini göstermiş olup, PSO-CNN'in 0.9973 değerine göre 0.0014 puan daha yüksek performans sergilemiştir. MobileNet-v2 modeli 0.9983 değeri ile ikinci sırada yer alırken, ResNet-50 modeli 0.9941 değeri ile dört model arasında en düşük AUC değerine sahiptir.

Her dört modelde de sağlam ve çoklu arıza sınıfları için AUC değerlerinin eşit olması, modellerin her iki sınıf için dengeli bir ayırt etme performansına sahip olduğunu göstermektedir. Mikro ve Makro AUC değerlerinin birbirine çok yakın olması da sınıflar arası dengeli performansı desteklemektedir. Tüm modellerin 0.99'un üzerinde AUC değerlerine sahip olması, motorun sağlam durumu ile çoklu arızalı durumu arasındaki ayrımın görüntü tabanlı derin öğrenme yöntemleri ile yüksek güvenilirlikle gerçekleştirilebildiğini kanıtlamaktadır.

ROC eğrilerinin sol üst köşeye yakın seyretmesi ve AUC değerlerinin 1'e yakın olması, eşik değeri ayarlamasından bağımsız olarak modellerin yüksek doğruluk oranlarını koruyabildiğini ifade etmektedir. Özellikle False Positive Rate'in düşük değerlerinde bile

True Positive Rate'in yüksek seviyelerde kalması, kritik uygulamalar için bu modellerin güvenle kullanılabileceğini göstermektedir.

4.1.4. Performans metrikleri

Çizelge 4.2'de sağlam durum tespiti için sınıf bazlı kesinlik, duyarlılık, F1 skoru ve genel doğruluk değerleri sunulmaktadır. PSO-CNN modelinde her iki sınıf için de yaklaşık %97-98 düzeyinde kesinlik ve duyarlılık değerleri elde edilmiştir. Bu sonuç modelin, sağlam durum ile çoklu arızalı durumlarını dengeli biçimde ayırt edebildiğini göstermektedir. GoogLeNet modeli ise her iki sınıfta da %98.6 F1 skoru ile en yüksek performansı sergilemiş, PSO-CNN modeline kıyasla yaklaşık %1.0'lık bir iyileşme sağlamıştır. MobileNet-v2 modeli benzer doğruluk oranına sahipken, ResNet-50 modeli diğer modellere göre bir miktar daha düşük performans göstermiştir.

Çizelge 4.2. Çoklu arıza durum tespiti için modellere ait performans metrikleri

Model	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Genel Doğruluk
PSO-CNN	Çoklu Arıza	0.9797	0.9771	0.9784	0.9783
	Sağlam	0.9769	0.9795	0.9782	
GoogLeNet	Çoklu Arıza	0.9828	0.9903	0.9866	0.9864
	Sağlam	0.9901	0.9825	0.9863	
Mobilnetv2	Çoklu Arıza	0.9756	0.9865	0.9810	0.9808
	Sağlam	0.9862	0.9751	0.9806	
ResNet-50	Çoklu Arıza	0.9631	0.9478	0.9554	0.9554
	Sağlam	0.9480	0.9632	0.9555	


GoogLeNet modeli, her iki sınıfta da dengeli ve yüksek performans sergilemektedir. Motorun sağlam durum sınıfında %99.01 kesinlik ve %98.25 duyarlılık değerleri ile çok az sayıda yanlış pozitif ve yanlış negatif üretmektedir. Çoklu arıza sınıfında ise %98.28 kesinlik ve %99.03 duyarlılık değerleri elde edilmiş olup, özellikle duyarlılık değerinin yüksek olması modelin arızalı durumları kaçırma oranının oldukça düşük olduğunu göstermektedir.

PSO algoritması ile optimize edilmiş CNN modeli, TL modellerine yakın bir performans göstermekte ve tüm metriklerde %97'nin üzerinde değerlere ulaşmaktadır. Her iki sınıf

için kesinlik ve duyarlılık değerlerinin birbirine çok yakın olması (%97.69-97.97 aralığı), modelin dengeli bir sınıflandırma yaptığını ortaya koymaktadır. F1 skoru değerlerinin her iki sınıfta da %97.82-97.84 aralığında olması, kesinlik ve duyarlılık arasındaki harmonik dengenin sağlandığını göstermektedir.

MobileNet-v2 modeli, hafif mimarisi ile dikkat çekmekte olup %98.08 genel doğruluk ile GoogLeNet'e oldukça yakın bir performans sergilemektedir. Motorun sağlam durum tespitinde %98.62 kesinlik değeri, yanlış alarm oranının düşük olduğunu gösterirken, çoklu arıza tespitinde %98.65 duyarlılık değeri ile arızalı durumları yüksek oranda yakalayabilmektedir.

ResNet-50 modeli, dört model arasında en düşük performansı göstermesine rağmen %95.54 genel doğruluk ile hala yüksek bir başarı seviyesindedir. Ancak özellikle çoklu arıza sınıfında %94.78 duyarlılık değeri, diğer modellere kıyasla daha fazla arızalı durumu kaçırdığına işaret etmektedir. Bu durum, ResNet-50'nin 50 katmanlı derin mimarisinin bu veri seti boyutu için aşırı karmaşık olabileceğini düşündürmektedir.



Şekil 4.6. Çoklu arıza durum tespitinde modellerin genel başarı düzeyleri

Modellerin genel başarı düzeylerini gösteren grafik Şekil 4.6'da görülmektedir. Tüm modellerin her iki sınıf için de dengeli performans göstermesi, veri setinin sınıflar arası dengeli dağılıma sahip olduğunu ve modellerin bir sınıfa eğilimli (biased) olmadığını ortaya koymaktadır. TL modellerinin (GoogLeNet ve MobileNet-v2) PSO-CNN

modeline göre hafif üstünlük göstermesi, ImageNet üzerinde önceden öğrenilmiş özelliklerin motor görüntülerinin sınıflandırılmasında katkı sağladığını desteklemektedir. Ayrıca, PSO-CNN modelinin daha az parametreyle benzer performans göstermesi, donanımsal sınırlamaların olduğu gerçek zamanlı sistemlerde bu modelin uygulanabilirliğini öne çıkarmaktadır.

4.1.5. Sensör türüne göre sınıflandırma

Arıza tespit edildikten sonra ikinci aşamada, her bir veri türünün arıza durumu üzerindeki etkisi Çizelge 4.3’de görülmektedir. Elde edilen karışıklık matrislerinden yararlanılarak oluşturulan bu tablo, dört farklı modelin beş farklı veri tipi üzerindeki sınıflandırma başarı oranlarını göstermektedir.

Çizelge 4.3. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları

Model	Durum	Akı (%)	Akım (%)	Akustik (%)	Gerilim (%)	Titreşim (%)
PSO-CNN	Sağlam	96.70	98.50	97.40	99.00	95.10
	Çoklu	98.60	97.60	100	99.70	98.80
GoogLeNet	Sağlam	100	99.60	100	100	99.60
	Çoklu	100	99.70	100	99.80	99.20
MobileNet-v2	Sağlam	97.60	98.80	99.80	98.30	95.50
	Çoklu	99.10	94.00	98.90	99.40	98.90
ResNet-50	Sağlam	100	96.60	99.10	98.90	96.60
	Çoklu	98.30	98.80	98.60	97.90	96.70

Veri türleri performanslarının genel olarak değerlendirilmesi

Akustik ve gerilim veri türü, tüm modellerde en yüksek sınıflandırma başarısını gösteren veri tipleri olarak öne çıkmaktadır. GoogLeNet modelinde akustik verisi hem sağlam hem de çoklu arıza durumlarında %100 başarı oranına ulaşmış olup, gerilim verisi de benzer şekilde %99.80-100 aralığında performans sergilemiştir. Bu durum, motor arızalarının akustik sinyallerde ve gerilim değişimlerinde belirgin izler bıraktığını göstermektedir.

Literatürde mekanik arızaların tespitinde en duyarlı veri türünün titreşim olduğu geniş ölçüde kabul edilmektedir (Nandi ve ark., 2005). Ancak bu çalışmada, beklentinin aksine

titreşim verisine dayalı sınıflandırma diğer veri türlerine kıyasla daha düşük başarı oranları üretmiştir. PSO-CNN modelinde sağlam durum tespiti %95.10, MobileNet-v2’de %95.50 ve ResNet-50’de çoklu arıza tespiti %96.70 değerleri elde edilmiştir. Bu sonuç, titreşim sinyallerinin görüntü tabanlı temsil edilmesinde bazı bilgi kayıplarının yaşanabileceğini veya diğer veri türlerine göre daha fazla gürültü içerebileceğini düşündürmektedir. Genel olarak bakıldığında, sağlam durum tespiti açısından veri türlerinin başarı performansı tüm modellerde benzer bir eğilim izlediği ve performans sıralamasının akustik, gerilim, akı, akım ve titreşim şeklinde olduğu görülmektedir.

Model bazlı performans analizleri

GoogLeNet mimarisi, veri türü tabanlı sınıflandırmada da en başarılı model olarak öne çıkmaktadır. Beş veri türünün tamamında %99.20’nin üzerinde başarı oranlarına ulaşılmış ve akı, akustik ve gerilim verilerinde sağlam durum için %100 başarı elde edilmiştir. Bu sonuç, GoogLeNet’in özellik çıkarma kapasitesinin farklı sensörlerden gelen verilere etkili bir şekilde adapte olabildiğini göstermektedir.

PSO-CNN modeli, özellikle çoklu arıza durumunda yüksek performans sergilemekte olup akustik veri türünde %100 başarı oranına ulaşmıştır. Gerilim verisiyle hem sağlam (%99.00) hem de çoklu arıza (%99.70) durumlarında yüksek değerler elde edilmiş, ancak titreşim verisiyle sağlam durum tespiti %95.10 ile en düşük performansı göstermiştir.

MobileNet-v2 modeli, hafif mimarisi ile dikkat çekmekte ancak akım verisiyle çoklu arıza tespiti %94.00 ile en düşük başarı oranını göstermektedir. Bu durum, modelin sıkıştırılmış yapısının bazı karmaşık veri desenlerini tam olarak öğrenemediğine işaret edebilir.

ResNet-50 modeli, kaçak akı verisinde sağlam durum için %100 başarı göstermesine rağmen, genel olarak diğer modellere bakıldığında daha düşük ve daha dengesiz bir performans göstermektedir. Özellikle titreşim verisiyle çoklu arıza tespiti %96.70 ile en düşük değerlere sahiptir.

Sağlam ve çoklu arıza durumlarının karşılaştırması

Dikkat çekici bir şekilde, çoklu arıza durumunun sağlam duruma göre bazı veri türlerinde daha yüksek sınıflandırma başarısı gösterdiği gözlemlenmektedir. PSO-CNN modelinde akustik veri çoklu arıza için %100 iken sağlam durum için %97.40, benzer şekilde GoogLeNet'te kaçak akı verisi, çoklu arıza için %100 iken sağlam durum için de %100'dür. Bu durum, arıza durumlarının veri türlerinde daha belirgin ve ayırt edici özellikler oluşturduğunu göstermektedir.

Pratik uygulama açısından değerlendirildiğinde, çoklu arıza tespitinde en başarılı veri türleri olan akustik (%100) ve gerilim (%99-100) verilerinin her ikisi de yüksek performans sergilemektedir. Akustik verisi non-invaziv bir yöntemle elde edilebildiğinden, kurulum kolaylığı ve düşük maliyet avantajı sunmaktadır. Gerilim verisi ise invaziv bir ölçüm yöntemi gerektirmesine rağmen, benzer düzeyde yüksek başarı oranlarına ulaşmaktadır. Kaçak akı ve akım verileri de %97-99 aralığında güvenilir sonuçlar üretmekte olup, uygulama tercihinde performans-maliyet dengesi göz önünde bulundurulabilir. Titreşim verisinin görece düşük performansı (%95-99), sensör montajının ek iş gücü ve maliyet gerektirmesiyle birlikte değerlendirildiğinde, diğer veri türlerine kıyasla daha az tercih edilebilir bir seçenek olarak öne çıkmaktadır.

Bu bölümde, motorun sağlam durumu ile çoklu arızalı durumu arasındaki ayrım için dört farklı derin öğrenme modelinin performansı kapsamlı olarak değerlendirilmiştir. GoogLeNet modeline uygulanan TL yöntemi %98.64 genel doğruluk ve 0.9987 AUC değeri ile en yüksek performansı göstermiş, PSO-CNN modeli ise %97.83 doğruluk ile TL modellerine yakın bir başarı sergilemiştir. Her iki yaklaşımın da %95'in üzerinde doğruluk oranlarına ulaşması, görüntü tabanlı arıza tespit sistemlerinin sağlam durumun belirlenmesinde güvenilir sonuçlar üretebildiğini ortaya koymuştur.


Veri türüne dayanan analizler, akustik ve gerilim verilerinin tüm modellerde %98'in üzerinde başarı oranlarıyla arıza tespitinde en belirleyici sinyaller olduğunu göstermiştir. Titreşim verisinde karşılaşılan düşük performans, farklı veri tiplerinin arıza belirtilerini farklı düzeylerde yansıttığını ve çok sensörlü sistemlerde sensör seçiminin önemini

vurgulamaktadır. Bu bulgular, bir sonraki bölümde ele alınacak mıknatıs ve rulman arızalarının ayrı ayrı tespiti için temel oluşturmaktadır.

4.2. Mıknatıs Arızası Durum Tespiti

Bu bölümde, motorun sağlam durumu ile mıknatıs arızalı durumu arasındaki ayrım detaylı bir şekilde incelenmiştir. Mıknatıs arızası, rotor üzerindeki kalıcı mıknatıslardan birkaçının kontrollü bir şekilde yüksek sıcaklığa maruz bırakılması sonucu manyetik özelliklerinin zayıflatılması veya tamamen kaybedilmesiyle oluşturulmuştur. Arızanın oluşturulma yöntemi Bölüm 3.2.2’de açıklanmaktadır. Motorun beş farklı sensöründen (akı, akım, akustik, gerilim ve titreşim) elde edilen sinyaller, hem elde edilen PSO-CNN modeli hem de önceden eğitilmiş CNN mimarileri üzerinde TL uygulanarak analiz edilmiştir. Bu analizler sonucunda veri türlerinin mıknatıs arızasının tespitindeki başarımı değerlendirilmiş ve modeller arasındaki performans karşılaştırması yapılmıştır.

4.2.1. Eğitim performansının incelenmesi




Şekil 4.7. Mıknatıs arızası durum tespiti PSO-CNN eğitim ve doğrulama grafiği

PSO-CNN modelinin mıknatıs arızası tespiti için eğitim süreci Şekil 4.7’de sunulmuştur. Model 30 epoch boyunca eğitilmiş ve %97.89 test doğruluğuna ulaşmıştır. Mıknatıs arızası durum tespitine benzer şekilde, doğrulama başarısı (kırmızı kesikli çizgi) erken aşamalarda hızlı bir artış göstermiş ve %90-100 aralığında stabilize olmuştur. Eğitim

başarısı (mavi çizgi) benzer bir trend izlemiş ve her iki eğrinin birbirine paralel seyretmesi, modelin aşırı öğrenme probleminden uzak olduğunu göstermektedir.

Kayıp fonksiyonu grafiğinde, eğitim ve doğrulama kayıpları başlangıçta yaklaşık 0.7-0.8 seviyelerinden başlamış ve eğitim ilerledikçe düzenli bir azalma göstermiştir. Eğitimin ilerleyen aşamalarında her iki kayıp değeri 0.1'in altına düşmüş ve sıfıra yakın değerlerde kararlı hale gelmiştir. Grafiklerde gözlemlenen periyodik dalgalanmalar, stokastik gradyan iniş optimizasyonunun doğal bir sonucu olup, genel yakınsama başarılı bir şekilde gerçekleşmiştir.



Şekil 4.8. Mıknatıs arızası durum tespiti GoogLeNet eğitim ve doğrulama grafiği

GoogLeNet modeline uygulanan TL yöntemi, 10 epoch ile eğitilmiş ve %99.01 test doğruluğuna ulaşarak mıknatıs arızası tespitinde en yüksek performansı göstermiştir. Doğrulama başarısı (kırmızı kesikli çizgi), eğitimin başlangıcında %40-60 seviyelerinden hızla yükselmiş ve yaklaşık 2 000 iterasyon civarında %90-100 aralığına ulaşmıştır. Eğitim başarısı (mavi çizgi) benzer bir eğilim göstermiş ve sürecin büyük bölümünde yüksek doğruluk seviyelerinde seyretmiştir.


Kayıp fonksiyonu grafiğinde, başlangıç kayıp değerleri 0.7-1.2 aralığından başlayarak eğitimin erken aşamalarında keskin bir düşüş sergilemiştir. Eğitimin ilerleyen bölümlerinde her iki kayıp değeri de 0.2'nin altına inmiş ve sıfıra yakın değerlerde stabilize olmuştur. Eğitim ve doğrulama kayıplarının birbirine paralel seyretmesi, TL yaklaşımının mıknatıs arızası tespitinde etkili bir genelleme kabiliyetine sahip olduğunu

ortaya koymaktadır. PSO-CNN modeline kıyasla grafikte daha belirgin dalgalanmalar gözlenmekte olup, bu durum SGD optimizasyon algoritmasının karakteristik davranışını yansıtmaktadır.

4.2.2. Sınıflandırma performansının değerlendirilmesi

PSO-CNN modelinin mıknatıs arızası tespitindeki sınıflandırma performansı Şekil 4.9'daki karışıklık matrisi ile incelenmektedir. Test veri seti üzerinde toplam 6790 görüntü değerlendirilmiş olup, model her iki sınıf için de yüksek doğruluk oranlarına ulaşmıştır.


Motorun sağlam durum sınıfında, toplam 3410 test örneğinden 3343 tanesi doğru bir şekilde tespit edilmiş (%98.0 doğruluk) ve 67 örnek (%2.0) yanlışlıkla mıknatıs arızası olarak sınıflandırılmıştır. Mıknatıs arızası sınıfında ise, 3380 test örneğinden 3304'ü başarıyla belirlenmiş (%97.8 doğruluk) ve 76 örnek (%2.2) motorun sağlam durumunda olarak hatalı sınıflandırılmıştır. Model toplamda 6647 doğru sınıflandırma ile yalnızca 143 hata yapmıştır.



Şekil 4.9. Mıknatıs arızası durum tespiti için PSO-CNN'e ait karışıklık matrisi

Şekil 4.10'da GoogLeNet mimarisi kullanılarak yapılan TL yaklaşımı, mıknatıs arızası tespitinde PSO-CNN'e kıyasla daha yüksek performans sergilemiştir. Motorun sağlam durumu sınıfında 3410 test örneğinden 3374 tanesi doğru tespit edilmiş (%98.9 doğruluk) ve sadece 36 örnek (%1.1) yanlışlıkla mıknatıs arızası olarak sınıflandırılmıştır. Mıknatıs

arızası sınıfında ise 3380 örnekten 3349'u başarıyla belirlenmiş (%99.1 doğruluk) ve yalnızca 31 örnek (%0.9) motor sağlam durumda olarak hatalı sınıflandırılmıştır.




Şekil 4.10 Mıknatis arızası durum tespiti için GoogLeNet'e ait karışıklık matrisi

Toplam hata sayısı açısından GoogLeNet 67 hata ile PSO-CNN'in 143 hatasına göre %53 daha az yanlış sınıflandırma gerçekleştirmiştir. False Positive değerinde GoogLeNet (FP=36), PSO-CNN'e (FP=67) kıyasla %46 daha düşük hata oranına sahiptir. Benzer şekilde False Negative değerinde de GoogLeNet (FN=31), PSO-CNN'e (FN=76) göre %59 daha az hata üretmiştir. Bu sonuçlar, TL yaklaşımının mıknatis arızası gibi spesifik arıza tiplerinin tespitinde de önceden öğrenilmiş özelliklerin etkili bir şekilde kullanılabildiğini ortaya koymaktadır. Her iki modelde de True Positive oranlarının %97'nin üzerinde olması, mıknatis arızasının görüntü tabanlı yöntemlerle güvenilir şekilde tespit edilebildiğini göstermektedir.

4.2.3. ROC eğrisi ve AUC değeri

PSO-CNN modelinin mıknatis arızası tespiti için elde edilen ROC eğrileri Şekil 4.11'de sunulmuştur. Her iki sınıf için de ROC eğrileri sol üst köşeye yakın seyretmekte olup, modelin yüksek ayırt etme kabiliyetine sahip olduğunu göstermektedir. Motorun sağlam durum sınıfı (mavi sürekli çizgi) ve mıknatis arızalı sınıfı (turuncu kesikli çizgi) için AUC değerleri 0.998 olarak hesaplanmış olup, bu değer motorun sağlam durum tespitine (0.997) göre hafif bir iyileşme göstermektedir.



Şekil 4.11. Mıknatıs arızası durum tespiti için PSO-CNN'e ait ROC eğrisi

Çizelge 4.4'de mıknatıs arızası durum tespiti için kullanılan tüm modellere ait AUC değerlerini gösteren tablo sunulmuştur. Tüm modellerin AUC değerleri incelendiğinde, dört modelin de 0.997'nin üzerinde değerlere ulaştığı görülmektedir. GoogLeNet mimarisine uygulanan TL yöntemi 0.9985 AUC değeri ile en yüksek sınıf ayırım kalitesini göstermiş olup, PSO-CNN'in 0.9976 değerine göre 0.0009 puan daha yüksek performans sergilemiştir. MobileNet-v2 ve ResNet-50 modelleri 0.9980 değeri ile ikinci sırada yer almaktadır.

Çizelge 4.4. Mıknatıs arızası durum tespitinde AUC test değerleri

Model	Sağlam	Mıknatıs Arızası	Mikro	Makro
PSO-CNN	0.9976	0.9976	0.9977	0.9976
GoogLeNet	0.9985	0.9985	0.9985	0.9985
MobilNet-v2	0.9980	0.9980	0.9978	0.9980
ResNet-50	0.9980	0.9980	0.9980	0.9980

Her dört modelde de sağlam ve mıknatıs arızalı sınıflar için AUC değerlerinin eşit olması, modellerin her iki sınıf için dengeli bir ayırt etme performansına sahip olduğunu göstermektedir. Mikro ve Makro AUC değerlerinin birbirine çok yakın olması da sınıflar arası dengeli performansı desteklemektedir. Dikkat çekici bir şekilde, mıknatıs arızası

tespitindeki AUC değerleri (0.9976-0.9985), çoklu arıza tespitindeki değerlerle (0.9941-0.9987) karşılaştırılabilir düzeydedir, bu durum mıknatıs arızasının da görüntü tabanlı yöntemlerle güvenilir şekilde tespit edilebildiğini ortaya koymaktadır.

ROC eğrilerinin sol üst köşeye yakın seyretmesi ve AUC değerlerinin 0.99'un çok üzerinde olması, eşik değeri ayarlamasından bağımsız olarak modellerin yüksek doğruluk oranlarını koruyabildiğini ifade etmektedir. Özellikle False Positive Rate'in düşük değerlerinde bile True Positive Rate'in %95'in üzerinde kalması, mıknatıs arızası tespitinde yanlış alarm oranının minimumda tutulabileceğini göstermektedir.

4.2.4. Performans metrikleri

Çizelge 4.5'de mıknatıs arızası tespiti için sınıf bazlı kesinlik, duyarlılık, F1 skoru ve genel doğruluk değerleri sunulmaktadır. GoogLeNet modeli %99.01 genel doğruluk ile en yüksek performansı sergilemiş olup, çoklu arıza tespitindeki performansına (%98.64) göre %0.37'lik bir iyileşme göstermiştir. Her iki sınıfta da %98.9'un üzerinde kesinlik ve duyarlılık değerleri elde edilmiş, özellikle mıknatıs arızası sınıfında %99.08 duyarlılık değeri, modelin arızalı durumları kaçırma oranının son derece düşük olduğunu ortaya koymaktadır.

Çizelge 4.5. Mıknatıs arızası durum tespiti için modellere ait performans metrikleri


Model	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Genel Doğruluk
PSO-CNN	Mıknatıs	0.9778	0.9804	0.9791	0.9789
	Sağlam	0.9801	0.9775	0.9788	
GoogLeNet	Mıknatıs	0.9894	0.9908	0.9901	0.9901
	Sağlam	0.9909	0.9894	0.9902	
Mobilnetv2	Mıknatıs	0.9892	0.9754	0.9823	0.9825
	Sağlam	0.9760	0.9894	0.9827	
ResNet-50	Mıknatıs	0.9851	0.9814	0.9833	0.9834
	Sağlam	0.9816	0.9853	0.9835	

PSO-CNN modeli, %97.89 genel doğruluk ile TL modellerine yakın bir performans göstermekte ve tüm metriklerde %97.7'nin üzerinde değerlere ulaşmaktadır. Her iki sınıf için kesinlik ve duyarlılık değerlerinin birbirine çok yakın olması (%97.75-98.04 aralığı),

modelin dengeli bir sınıflandırma yaptığını göstermektedir. F1 skoru değerlerinin her iki sınıfta da %97.88-97.91 aralığında olması, kesinlik ve duyarlılık arasındaki harmonik dengenin sağlandığını ortaya koymaktadır.

MobileNet-v2 modeli %98.25 genel doğruluk ile üçüncü sırada yer alırken, ResNet-50 modeli %98.34 doğruluk ile dördüncü sıradadır. Dikkat çekici bir şekilde, mıknaş arızası tespitinde ResNet-50'nin çoklu arıza tespitine (%95.54) kıyasla %2.8'lik belirgin bir iyileşme göstermesi, modelin ikili sınıflandırma problemlerinde daha etkin çalışabildiğini düşündürmektedir. MobileNet-v2'de ise mıknaş arızası sınıfında %97.54 duyarlılık değeri, diğer modellere göre daha fazla arızalı durumu kaçırdığına işaret etmektedir.

Tüm modellerin mıknaş arızası tespitinde %97.89'un üzerinde genel doğruluk elde etmesi ve her iki sınıf için dengeli performans göstermesi, mıknaş arızasının sağlam durumdan görüntü tabanlı derin öğrenme yöntemleri ile güvenilir şekilde ayırt edilebildiğini kanıtlamaktadır. GoogLeNet'in %99'un üzerindeki performansı, TL'nin mıknaş gibi spesifik arıza tiplerinin tespitinde de etkili olduğunu desteklemektedir.



Şekil 4.12. Mıknaş arızası durum tespitinde modellerin başarı grafiği

Şekil 4.12'de, mıknaş arızası durum tespitinde kullanılan modellerin genel doğruluk performansları karşılaştırmalı olarak sunulmaktadır. Elde edilen sonuçlar, önceden eğitilmiş GoogLeNet modelinin %99.01 doğruluk oranı ile tüm modeller arasında en yüksek performansa ulaştığını göstermektedir. ResNet-50 (%98.34) ve MobileNet-v2

(%98.25) modelleri birbirine yakın başarımlar düzeyleri sergilerken, PSO-CNN modeli %97.89 doğruluk oranı ile dördüncü sırada yer almıştır. Bununla birlikte, PSO-CNN'in daha düşük parametre sayısına sahip olmasına rağmen TL tabanlı modellere yakın bir performans sunması dikkat çekici bir sonuçtur. Tüm modellerin %97.89'un üzerinde doğruluk elde etmesi, mıknatıs arızasının sınıflandırılmasının yüksek güvenilirlikte gerçekleştirilebildiğini ve önerilen yaklaşımın uygulama açısından güçlü bir performans sunduğunu ortaya koymaktadır.

4.2.5. Sensör türüne göre sınıflandırma

Mıknatıs arızası tespit edildikten sonra ikinci aşamada, her bir veri türünün arıza durumu üzerindeki etkisi Çizelge 4.6'da görülmektedir. Elde edilen karışıklık matrislerinden yararlanılarak oluşturulan bu tablo, dört farklı modelin beş veri türü üzerindeki sınıflandırma başarı oranlarını göstermektedir.

Çizelge 4.6. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları

Model	Durum	Akı (%)	Akım (%)	Akustik (%)	Gerilim (%)	Titreşim (%)
PSO-CNN	Sağlam	97.90	98.50	98.60	99.40	92.90
	Mıknatıs	97.90	97.90	97.30	98.60	96.50
GoogLeNet	Sağlam	96.70	98.40	100	97.60	85.50
	Mıknatıs	100	99.10	96.90	99.80	99.60
MobileNet-v2	Sağlam	99.10	99.30	99.20	99.70	98.50
	Mıknatıs	99.20	99.40	99.20	97.10	98.90
ResNet-50	Sağlam	99.10	96.70	97.70	99.30	96.50
	Mıknatıs	99.20	96.60	93.90	98.80	96.90

Veri türlerinin genel değerlendirilmesi

Mıknatıs arızası tespitinde veri türlerinin performansı, çoklu arıza tespitinden belirgin farklılıklar göstermektedir. Kaçak akı, akım ve gerilim veri türleri, tüm modellerde %96'nın üzerinde başarı oranlarıyla öne çıkmaktadır. Özellikle kaçak akı verisi, GoogLeNet modelinde mıknatıs arızası için %100 başarı oranına ulaşmış olup, MobileNet-v2 ve ResNet-50 modellerinde de %99.10-99.20 aralığında yüksek değerler

sergilemiştir. Bu durum, mıknatıs arızasının rotor manyetik alanında oluşturduğu değişimlerin kaçak akı sensörü tarafından etkili bir şekilde algılanabildiğini göstermektedir.

Gerilim verisi, PSO-CNN modelinde hem sağlam (%99.40) hem de mıknatıs arızalı (%98.60) durumlar için yüksek başarı göstermiş, benzer şekilde MobileNet-v2 ve ResNet-50 modellerinde de %97-99 aralığında değerler elde edilmiştir. Akım verisi, tüm modellerde dengeli bir performans sergilemekte ve özellikle MobileNet-v2 modelinde mıknatıs arızası için %99.40'a ulaşmaktadır.

Akustik verisi, çoklu arıza tespitinde yüksek performans göstermesine rağmen, mıknatıs arızası tespitinde görece daha düşük ve dengesiz sonuçlar üretmiştir. GoogLeNet modelinde sağlam durum için %100 başarı elde edilirken, mıknatıs arızası için %96.90'a düşmüştür. ResNet-50'de ise mıknatıs arızası tespitinde %93.90 ile en düşük değer gözlenmiştir. Bu sonuç, akustik sinyallerin mıknatıs arızasının belirtilerini diğer arıza tiplerine göre daha az belirgin şekilde yansıttığını düşündürmektedir.

Titreşim verisi, düşük performans göstermiştir. GoogLeNet modelinde sağlam durum tespitinde %85.50 ile tüm tablodaki en düşük değer elde edilmiş, ancak mıknatıs arızası tespitinde %99.60'a yükselerek dikkat çekici bir iyileşme göstermiştir. PSO-CNN modelinde ise sağlam durum için %92.90 ile titreşim verisi en zayıf performansı sergilemiştir. Bu durum, mıknatıs arızasının mekanik titreşim desenlerinde belirgin değişiklikler oluşturduğunu, ancak sağlam durumun titreşim sinyalleriyle güvenilir şekilde temsil edilemediğini göstermektedir.

Model bazlı performans analizi

MobileNet-v2 modeli, mıknatıs arızası tespitinde veri türü bazlı sınıflandırmada en dengeli ve tutarlı performansı göstermiştir. Beş veri türünün tamamında hem sağlam hem de mıknatıs arızalı durumlar için %97-99.70 aralığında başarı oranlarına ulaşılmış, titreşim verisi dışında tüm veri türlerinde %98.50'nin üzerinde değerler elde edilmiştir.

Bu sonuç, MobileNet-v2'nin hafif mimarisine rağmen farklı veri türlerine etkili bir şekilde adapte olabildiğini ortaya koymaktadır.

GoogLeNet modeli, mıknatıs arızası için kaçak akı verisiyle %100 başarı göstermesine rağmen, sağlam durum tespitinde titreşim verisiyle %85.50'ye düşerek en dengesiz performansı sergilemiştir. Ancak mıknatıs arızası sınıfında tüm veri türlerinde %96.90'ın üzerinde değerler elde edilmesi, modelin arıza belirtilerini güçlü bir şekilde öğrenebildiğini göstermektedir.

PSO-CNN modeli, gerilim verisiyle hem sağlam (%99.40) hem de mıknatıs arızalı (%98.60) durumlar için en yüksek başarı oranlarını göstermiş, ancak titreşim verisinde sağlam durum için %92.90 ile en düşük performansı sergilemiştir. Model genel olarak dengeli bir performans göstermekte olup, akı, akım ve gerilim veri türlerinde %97.90-99.40 aralığında tutarlı değerler elde etmiştir.

ResNet-50 modeli, kaçak akı verisinde %99.10-99.20 aralığında yüksek başarı göstermesine rağmen, akustik verisinde mıknatıs arızası için %93.90 ile en düşük değere sahiptir. Bu durum, derin mimarinin bazı veri türlerinde öğrenme zorluğu yaşadığını düşündürmektedir.

Mıknatıs arızası için en iyi veri türünün belirlenmesi

Mıknatıs arızası tespitinde en etkili veri türünün belirlenmesi için tüm modellerin performansları değerlendirildiğinde, kaçak akı verisi öne çıkmaktadır. GoogLeNet'te %100, MobileNet-v2 ve ResNet-50'de %99.20 başarı oranları, kaçak akı sensörünün mıknatıs arızasını tespit etmedeki üstünlüğünü ortaya koymaktadır.

Gerilim verisi, ikinci en etkili veri türü olarak belirlenmiştir. PSO-CNN'de %98.60, GoogLeNet'te %99.80 ve ResNet-50'de %98.80 değerleri, gerilim sinyallerinin mıknatıs arızasının elektriksel etkilerini başarıyla yansıttığını göstermektedir.

Akım verisi, üçüncü sırada yer almakta olup MobileNet-v2’de %99.40’a ulaşsa da, diğer modellerde %96.60-99.10 aralığında değerler göstermektedir. Titreşim verisi, mıknatıs arızası tespitinde %96.50-99.60 aralığında değerler sergilemesine rağmen, sağlam durum tespitindeki düşük performansı (%85.50-98.50) nedeniyle güvenilirlik açısından sorunludur.

Dikkat çekici bir şekilde, çoklu arıza durum tespitinde en başarılı olan akustik verisi, mıknatıs arızası tespitinde görece daha düşük performans göstermiştir. Bu durum, mıknatıs arızasının akustik sinyallerde daha az belirgin özellikler oluşturduğunu ve arıza tipine özgü sensör seçiminin önemini vurgulamaktadır.

Mıknatıs arızası tespitinde en yüksek başarıyı gösteren kaçak akı verisi (%99-100), non-invaziv bir yöntemle elde edilebildiğinden hem yüksek performans hem de pratik uygulama kolaylığı sunmaktadır. Motor yapısına herhangi bir fiziksel müdahale gerektirmemesi, kaçak akı sensörünün kurulum maliyetini ve iş yükünü minimize etmektedir. Gerilim verisi de benzer şekilde yüksek başarı oranlarına (%98.60-99.80) ulaşmakta ancak invaziv bir ölçüm yöntemi gerektirmektedir. Akım verisi %96.60-99.40 aralığında güvenilir sonuçlar üretirken, akustik verisinin mıknatıs arızasında görece değişken performansı (%93.90-100), arıza tipine özgü sensör seçiminin önemini vurgulamaktadır. Sonuç olarak, mıknatıs arızası için kaçak akı verisi, hem performans hem de uygulama kolaylığı açısından en uygun seçenek olarak öne çıkmaktadır.

Bu bölümde, motorun sağlam durumu ile mıknatıs arızalı durumu arasındaki ayrım için dört farklı derin öğrenme modelinin performansı kapsamlı olarak değerlendirilmiştir. GoogLeNet mimarisine uygulanan transfer yöntemi %99.01 genel doğruluk ve 0.9985 AUC değeri ile en yüksek performansı göstermiş, PSO-CNN modeli ise %97.89 doğruluk ile TL modellerine yakın bir başarı sergilemiştir. Tüm modellerin %97.89’un üzerinde doğruluk oranlarına ulaşması, mıknatıs arızasının görüntü tabanlı derin öğrenme yöntemleri ile güvenilir şekilde tespit edilebildiğini ortaya koymuştur.


Veri türü bazlı analizler, mıknatıs arızası tespitinde kaçak akı verisinin %99-100 başarı oranlarıyla en belirleyici sinyal olduğunu göstermiştir. Gerilim ve akım veri türleri de

%96'nın üzerinde başarı oranlarıyla etkili performans sergilerken, akustik ve titreşim veri türlerinin mıknatıs arızası tespitinde görece daha düşük ve dengesiz sonuçlar üretmesi, arıza tipine özgü sensör seçiminin önemini vurgulamaktadır. Bu bulgular, bir sonraki bölümde ele alınacak rulman arızasının tespiti için temel oluşturmakta ve farklı arıza tiplerinin farklı sensör türleri ile daha etkili tespit edilebileceğini ortaya koymaktadır.

4.3. Rulman Arızası Durum Tespiti

Bu bölümde, motorun sağlam durumu ile rulman arızalı durumu arasındaki ayrım incelenmiştir. Rulman arızası, rulmanın dış yüzeyinde yapay olarak oluşturularak simüle edilmiştir. Arızanın oluşturulma yöntemi Bölüm 3.2.3'de açıklanmaktadır. Beş farklı sensörden (akı, akım, akustik, gerilim ve titreşim) elde edilen veri türleri, PSO-CNN ve TL modelleri kullanılarak analiz edilmiş ve rulman arızasının tespitindeki etkinlikleri karşılaştırılmıştır.

4.3.1. Eğitim performansının incelenmesi




Şekil 4.13. Rulman arızası durum tespiti PSO-CNN eğitim ve doğrulama grafiği

PSO-CNN modelinin rulman arızası tespiti için eğitim süreci Şekil 4.13'de sunulmuştur. Model 30 epoch boyunca eğitilmiş ve %98.22 test doğruluğuna ulaşmıştır. Doğrulama başarıları (kırmızı kesik çizgi) erken aşamalarda hızlı bir artış göstermiş ve %90-100 aralığında stabilize olmuştur. Eğitim başarıları (mavi çizgi) benzer bir trend izlemiş ve her

iki eğrinin birbirine paralel seyretmesi, modelin aşırı öğrenme probleminden uzak olduğunu göstermektedir.

Kayıp fonksiyonu grafiğinde, eğitim ve doğrulama kayıpları başlangıçta yaklaşık 0.7-1.0 seviyelerinden başlamış ve eğitim ilerledikçe düzenli bir azalma göstermiştir. Eğitimin ilerleyen aşamalarında her iki kayıp değeri sıfıra yakın değerlerde kararlı hale gelmiştir. Grafiklerde gözlemlenen dalgalanmalar, stokastik gradyan iniş optimizasyonunun doğal bir sonucudur.




Şekil 4.14. Rulman arızası durum tespiti GoogLeNet eğitim ve doğrulama grafiği

GoogLeNet modeline uygulanan TL yöntemine ait eğitim ve doğrulama grafiği Şekil 4.14’de görülmektedir. Model, 10 epoch ile eğitilmiş ve %98.55 test doğruluğuna ulaşarak rulman arızası tespitinde en yüksek performansı göstermiştir. Doğrulama başarısı (kırmızı kesikli çizgi), eğitimin erken aşamalarında hızla yükselmiş ve %90-100 aralığında stabilize olmuştur. Eğitim başarısı (mavi çizgi) benzer bir eğilim göstermiş ve sürecin büyük bölümünde yüksek doğruluk seviyelerinde seyretmiştir.

Kayıp fonksiyonu grafiğinde, başlangıç kayıp değerleri eğitimin erken aşamalarında keskin bir düşüş sergilemiş ve ilerleyen bölümlerde sıfıra yakın değerlerde stabilize olmuştur. Eğitim ve doğrulama kayıplarının birbirine paralel seyretmesi, TL yaklaşımının rulman arızası tespitinde etkili bir genelleme kabiliyetine sahip olduğunu ortaya koymaktadır.


4.3.2. Sınıflandırma performansının değerlendirilmesi

PSO-CNN modelinin rulman arızası tespitindeki sınıflandırma performansı Şekil 4.15'deki karışıklık matrisi ile incelenmektedir. Test veri seti üzerinde toplam 6793 görüntü değerlendirilmiş olup, model her iki sınıf için de yüksek doğruluk oranlarına ulaşmıştır.



Şekil 4.15. Rulman arızası durum tespiti için PSO-CNN'e ait karışıklık matrisi

Motorun sağlam durum sınıfında, toplam 3410 test örneğinden 3377 tanesi doğru bir şekilde tespit edilmiş (%99.0 doğruluk) ve 33 örnek (%1.0) yanlışlıkla rulman arızası olarak sınıflandırılmıştır. Rulman arızası sınıfında ise, 3383 test örneğinden 3295'i başarıyla belirlenmiş (%97.4 doğruluk) ve 88 örnek (%2.6) sağlam durumda olarak hatalı sınıflandırılmıştır. Model toplamda 6672 doğru sınıflandırma ile yalnızca 121 hata yapmıştır.




Şekil 4.16. Rulman arızası durum tespiti için GoogLeNet'e ait karışıklık matrisi

Şekil 4.16’da rulman arızası durum tespiti için GoogLeNet’e ait karışıklık matrisi görülmektedir. GoogLeNet mimarisine uygulanan TL yöntemi, rulman arızası tespitinde PSO-CNN’e kıyasla daha yüksek performans sergilemiştir. Motorun sağlam durum sınıfında 3410 test örneğinden 3396 tanesi doğru tespit edilmiş (%99.6 doğruluk) ve sadece 14 örnek (%0.4) yanlışlıkla rulman arızası olarak sınıflandırılmıştır. Rulman arızası sınıfında ise 3383 örnekten 3299’u başarıyla belirlenmiş (%97.5 doğruluk) ve yalnızca 84 örnek (%2.5) sağlam durumda olarak hatalı sınıflandırılmıştır.

Toplam hata sayısı açısından, GoogLeNet 98 hata ile PSO-CNN’in 121 hatasına göre %19 daha az yanlış sınıflandırma gerçekleştirmiştir. False Positive değerinde GoogLeNet (FP=14), PSO-CNN’e (FP=33) kıyasla %58 daha düşük hata oranına sahiptir. Her iki modelde de True Positive oranlarının %97’nin üzerinde olması, rulman arızasının görüntü tabanlı yöntemlerle güvenilir şekilde tespit edilebildiğini göstermektedir.

4.2.3. ROC eğrisi ve AUC değeri



Şekil 4.17. Rulman arızası durum tespiti için PSO-CNN’e ait ROC eğrisi

PSO-CNN modelinin rulman arızası tespiti için elde edilen ROC eğrileri Şekil 4.17’de sunulmuştur. Her iki sınıf için de ROC eğrileri sol üst köşeye yakın seyretmekte olup,

modelin yüksek ayırt etme kabiliyetine sahip olduğunu göstermektedir. Sağlam motor sınıfı (mavi sürekli çizgi) ve rulman arızası sınıfı (turuncu kesikli çizgi) için AUC değerleri 0.999 olarak hesaplanmış olup, bu değer hem çoklu arıza (0.997) hem de mıknaş arızası (0.998) tespitine göre hafif bir iyileşme göstermektedir.

Çizelge 4.7’de rulman arızası durum tespitinde kullanılan modellere ait AUC değerleri tablo halinde sunulmuştur. Tüm modellerin AUC değerleri incelendiğinde, dört modelin de 0.996’nın üzerinde değerlere ulaştığı görülmektedir. GoogLeNet modeline uygulanan TL yöntemi 0.9991 AUC değeri ile en yüksek sınıf ayırma kalitesini göstermiş olup, PSO-CNN’in 0.9987 değerine göre 0.0004 puan daha yüksek performans sergilemiştir. PSO-CNN’in rulman arızası tespitindeki AUC değeri (0.9987), mıknaş arızası (0.9976) ve çoklu arıza (0.9973) tespitine göre daha yüksektir, bu durum rulman arızasının diğer arıza tiplerine kıyasla daha belirgin özelliklere sahip olduğunu düşündürmektedir.

Çizelge 4.7. Rulman arızası durum tespitinde AUC test değerleri

Model	Sağlam	Rulman Arızası	Mikro	Makro
PSO-CNN	0.9987	0.9987	0.9986	0.9987
GoogLeNet	0.9991	0.9991	0.9985	0.9991
Mobilnetv2	0.9970	0.9970	0.9968	0.9970
ResNet-50	0.9960	0.9960	0.9960	0.9960

Her dört modelde de sağlam durum ve rulman arızalı durum sınıfları için AUC değerlerinin eşit olması, modellerin her iki sınıf için dengeli bir ayırt etme performansına sahip olduğunu göstermektedir. Mikro ve Makro AUC değerlerinin birbirine çok yakın olması da sınıflar arası dengeli performansı desteklemektedir. Tüm modellerin 0.996’nın üzerinde AUC değerlerine sahip olması, rulman arızasının görüntü tabanlı derin öğrenme yöntemleri ile yüksek güvenilirlikle tespit edilebildiğini ortaya koymaktadır.

ROC eğrilerinin sol üst köşeye yakın seyretmesi ve AUC değerlerinin 0.99’un çok üzerinde olması, eşik değeri ayarlamasından bağımsız olarak modellerin yüksek doğruluk oranlarını koruyabildiğini ifade etmektedir. Özellikle False Positive Rate’in düşük değerlerinde bile True Positive Rate’in %95’in üzerinde kalması, rulman arızası tespitinde yanlış alarm oranının minimumda tutulabileceğini göstermektedir.

4.2.4. Performans metrikleri

Çizelge 4.8’de rulman arızası tespiti için sınıf bazlı kesinlik, duyarlılık, F1 skoru ve genel doğruluk değerleri sunulmaktadır. GoogLeNet modeli %98.55 genel doğruluk ile en yüksek performansı sergilemiş olup, motorun sağlam durumu sınıfında %99.59 duyarlılık değeri, modelin sağlam durumları kaçırma oranının son derece düşük olduğunu ortaya koymaktadır. Rulman arızası sınıfında ise %99.58 kesinlik değeri, yanlış alarm oranının minimize edildiğini göstermektedir.

PSO-CNN modeli, %98.22 genel doğruluk ile GoogLeNet’e yakın bir performans göstermekte ve tüm metriklerde %97.40’ın üzerinde değerlere ulaşmaktadır. Rulman arızası sınıfında %99.01 kesinlik değeri, modelin yüksek güvenilirlikle arıza tespiti yapabildiğini ortaya koymaktadır. Her iki sınıf için kesinlik ve duyarlılık değerlerinin birbirine yakın olması, modelin dengeli bir sınıflandırma yaptığını göstermektedir.


MobileNet-v2 modeli %97.98 genel doğruluk ile üçüncü sırada yer alırken, ResNet-50 modeli %97.11 doğruluk ile dördüncü sıradadır. ResNet-50’nin her iki sınıfta da %97.10-97.13 aralığında son derece dengeli değerler göstermesi dikkat çekicidir. MobileNet-v2’de rulman arızası sınıfında %98.70 duyarlılık değeri, modelin arızalı durumları yüksek oranda yakalayabildiğini göstermektedir.

Çizelge 4.8. Rulman arızası durum tespiti için modellere ait performans metrikleri

Model	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Genel Doğruluk
PSO-CNN	Rulman	0.9901	0.9740	0.9820	0.9822
	Sağlam	0.9778	0.9804	0.9791	
GoogLeNet	Rulman	0.9958	0.9752	0.9854	0.9855
	Sağlam	0.9759	0.9959	0.9858	
MobilNet-v2	Rulman	0.9729	0.9870	0.9799	0.9798
	Sağlam	0.9869	0.9727	0.9798	
ResNet-50	Rulman	0.9710	0.9710	0.9710	0.9711
	Sağlam	0.9713	0.9713	0.9713	

Tüm modellerin rulman arızası tespitinde %97.11’in üzerinde genel doğruluk elde etmesi ve her iki sınıf için dengeli performans göstermesi, rulman arızasının sağlam durumdan görüntü tabanlı derin öğrenme yöntemleri ile güvenilir şekilde ayırt edilebildiğini

kanıtlamaktadır. Özellikle GoogLeNet ve PSO-CNN modellerinin %98'in üzerindeki performansları, rulman arızası gibi mekanik arızaların tespitinde TL ve PSO optimizasyonunun etkinliğini desteklemektedir.



Şekil. 4.18. Rulman arızası durum tespitinde modellerin başarı grafiği

Modellerin genel başarı düzeylerini gösteren grafik Şekil 4.18'de görülmektedir. GoogLeNet modeli %98.55 doğruluk ile en yüksek performansı gösterirken, PSO-CNN %98.22 ile ikinci sırada yer almaktadır. MobileNet-v2 (%97.98) ve ResNet-50 (%97.11) modelleri birbirine yakın değerlerde performans sergilemektedir. Tüm modellerin %97.11'in üzerinde performans göstermesi, rulman arızası tespitinin yüksek güvenilirlikle gerçekleştirilebildiğini ortaya koymaktadır.

4.2.5. Sensör türüne göre sınıflandırma

Rulman arızası tespit edildikten sonra ikinci aşamada, her bir veri türünün arıza durumu üzerindeki etkisi Çizelge 4.9'da görülmektedir. Elde edilen karışıklık matrislerinden yararlanılarak oluşturulan bu tablo, dört farklı modelin beş veri türü üzerindeki sınıflandırma başarı oranlarını göstermektedir.

Çizelge 4.9. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları

Model	Durum	Akı (%)	Akım (%)	Akustik (%)	Gerilim (%)	Titreşim (%)
PSO-CNN	Sağlam	91.40	97.30	99.40	99.70	94.80
	Rulman	99.80	99.10	99.70	99.70	98.10
GoogLeNet	Sağlam	99.80	100	100	99.90	99.30
	Rulman	99.70	99.50	100	99.90	100
MobileNet-v2	Sağlam	100	99.10	99.10	99.40	91.70
	Rulman	99.50	99.10	99.50	99.90	99.70
ResNet-50	Sağlam	99.50	96.70	100	99.30	93.50
	Rulman	96.70	92.80	100	99.70	99.30

Veri türlerinin genel değerlendirmesi

Rulman arızası tespitinde veri türlerinin performansı, mıknaş ve çoklu arıza tespitlerinden farklı özellikler göstermektedir. Akustik, gerilim ve akım veri türleri, tüm modellerde %92.80'in üzerinde başarı oranlarıyla öne çıkmaktadır. Özellikle akustik verisi, GoogLeNet modelinde hem sağlam hem de rulman arızalı durumlar için %100 başarı oranına ulaşmış olup, ResNet-50 modelinde de her iki durum için %100 değerleri sergilemiştir. Bu durum, rulman arızasının mekanik olarak ürettiği akustik sinyallerin son derece belirgin ve ayırt edici özellikler içerdiğini göstermektedir.

Gerilim verisi, tüm modellerde %99.30'un üzerinde tutarlı bir performans sergilemiş ve özellikle MobileNet-v2'de rulman arızası için %99.90'a ulaşmıştır. Akım verisi, GoogLeNet modelinde sağlam durum için %100, rulman arızası için %99.50 başarı göstermiş, ancak ResNet-50'de rulman arızası tespitinde %92.80 ile görece daha düşük bir değer elde edilmiştir.

Kaçak akı verisi, rulman arızası tespitinde dikkat çekici bir performans göstermiştir. GoogLeNet ve MobileNet-v2 modellerinde %99.50-100 aralığında değerler elde edilirken, PSO-CNN modelinde sağlam durum tespitinde %91.40 ile tüm tablodaki en düşük değer gözlenmiştir. Ancak aynı model rulman arızası tespitinde %99.80'e yükselmiştir. Bu durum, kaçak akı sensörünün rulman arızasının etkilerini güçlü bir

şekilde yansıttığını, ancak sağlam durumun akı sinyalleriyle daha az belirgin şekilde temsil edildiğini göstermektedir.

Rulman arızaları gibi mekanik kökenli bozulmaların saptanmasında titreşim sinyallerinin yüksek performans sağladığı literatürde kapsamlı biçimde ortaya konmuştur (Nandi ve ark., 2005; Randall, 2021); bu bağlamda, çalışmadaki titreşim verisinin yüksek performansı literatürle uyumludur. GoogLeNet modelinde rulman arızası için %100 başarı oranına ulaşılmış, PSO-CNN’de %98.10, MobileNet-v2’de %99.70 ve ResNet-50’de %99.30 değerleri elde edilmiştir. Ancak sağlam durum tespitinde MobileNet-v2 (%91.70), PSO-CNN (%94.80) ve ResNet-50 (%93.50) modellerinde görece daha düşük değerler gözlenmiştir. Bu sonuç, titreşim verisinin rulman arızasını belirgin şekilde ayırt edebildiğini, ancak sağlam durum için daha değişken sonuçlar ürettiğini göstermektedir.

Model bazlı performans analizi

GoogLeNet modeli, rulman arızası tespitinde veri türü bazlı sınıflandırmada en dengeli ve yüksek performansı göstermiştir. Beş veri türünün tamamında %99.30’un üzerinde başarı oranlarına ulaşılmış ve akustik verisiyle her iki durum için, akım verisiyle sağlam durum için %100 başarı elde edilmiştir. Bu sonuç, GoogLeNet’in özellik çıkarma kapasitesinin farklı veri türlerinden gelen rulman arızası belirtilerini etkili bir şekilde öğrenebildiğini göstermektedir.

MobileNet-v2 modeli, kaçak akı verisinde sağlam durum için %100 başarı göstermiş, ancak titreşim verisinde sağlam durum tespitinde %91.70 ile en düşük değeri elde etmiştir. Rulman arızası sınıfında ise tüm veri türlerinde %99.10’un üzerinde tutarlı değerler sergilemiştir.

PSO-CNN modeli, gerilim ve akustik verilerinde hem sağlam hem de rulman arızalı durumlar için %99’un üzerinde başarı oranlarını göstermiş, ancak kaçak akı verisinde sağlam durum için %91.40 ile en düşük performans sergilemiştir. Rulman arızası sınıfında ise kaçak akı verisi %99.80’e yükselerek, modelin arıza belirtilerini güçlü bir şekilde öğrenebildiğini ortaya koymuştur.

ResNet-50 modeli, akustik verisinde %100 başarı göstermesine rağmen, akım verisinde rulman arızası için %92.80 ile en düşük değere sahiptir. Bu durum, derin mimarinin bazı veri türlerinde öğrenme zorluğu yaşadığını düşündürmektedir.

Rulman arızası için en iyi veri türünün belirlenmesi

Rulman arızası tespitinde en etkili veri türünün belirlenmesi için tüm modellerin performansları değerlendirildiğinde, akustik verisi öne çıkmaktadır. GoogLeNet ve ResNet-50 modellerinde her iki durum için %100, PSO-CNN'de %99.40-99.70 aralığında başarı oranları, akustik sensörünün rulman arızasını tespit etmedeki üstünlüğünü ortaya koymaktadır. Bu sonuç fiziksel olarak da beklenen bir durumdur; rulman arızası mekanik bir hasara bağlı olduğundan, rulmanın dönüş sırasında ürettiği ses sinyallerinde belirgin değişimler oluşturmaktadır.

Gerilim verisi, ikinci en etkili veri türü olarak belirlenmiştir. Tüm modellerde %99.30'un üzerinde değerler elde edilmiş ve özellikle MobileNet-v2'de rulman arızası için %99.90'a ulaşılmıştır. Gerilim sinyallerinin rulman arızasının motor üzerindeki elektriksel etkilerini başarıyla yansıttığı görülmektedir.

Titreşim verisi, rulman arızası gibi mekanik bir arıza için beklenen yüksek performansı sergilemiş olup, rulman arızası tespitinde %98.10-100 aralığında değerler göstermiştir. Ancak sağlam durum tespitindeki görece düşük performansı (%91.70-99.30), sensör montajının hassasiyetine bağlı olarak değişkenlik gösterebileceğini düşündürmektedir. Akı ve akım verileri de %92.80-100 aralığında değerler sergilemesine rağmen, akustik ve gerilim verilerine kıyasla daha değişken sonuçlar üretmiştir. Özellikle PSO-CNN'de kaçak akı verisinin sağlam durum için %91.40'a düşmesi ve ResNet-50'de akım verisinin rulman arızası için %92.80 göstermesi, bu veri türlerinin model ve durum bağımlı performans gösterdiğini ortaya koymaktadır.

Pratik uygulama açısından değerlendirildiğinde, rulman arızası tespitinde en yüksek başarıyı gösteren akustik verisi (%99.40-100), non-invaziv bir yöntemle elde

edilebildiğinden hem yüksek performans hem de pratik uygulama kolaylığı sunmaktadır. Motor yapısına herhangi bir fiziksel müdahale gerektirmemesi, akustik sensörünün kurulum maliyetini ve iş yükünü minimize etmektedir. Gerilim verisi de benzer şekilde yüksek başarı oranlarına (%99.30-99.90) ulaşmakta ancak invaziv bir ölçüm yöntemi gerektirmektedir. Titreşim verisi, rulman arızasında yüksek performans sergilemesine rağmen (%98.10-100), sensör montajının ek iş gücü ve maliyet gerektirmesi, akustik verisine kıyasla daha az tercih edilebilir bir seçenek haline getirmektedir. Sonuç olarak, rulman arızası için akustik verisi, hem performans hem de uygulama kolaylığı açısından en uygun seçenek olarak öne çıkmaktadır.

Bu bölümde, motorun sağlam durumu ile rulman arızalı durumu arasındaki ayrım için dört farklı derin öğrenme modelinin performansı kapsamlı olarak değerlendirilmiştir. GoogLeNet modeline uygulanan TL yöntemi %98.55 genel doğruluk ve 0.9991 AUC değeri ile en yüksek performansı göstermiş, PSO-CNN modeli ise %98.22 doğruluk ile TL modellerine yakın bir başarı sergilemiştir. Tüm modellerin %97.11'in üzerinde doğruluk oranlarına ulaşması, rulman arızasının görüntü tabanlı derin öğrenme yöntemleri ile yüksek güvenilirlikle tespit edilebildiğini ortaya koymuştur.


Veri türü bazlı analizler, rulman arızası tespitinde akustik verisinin %99.40-100 başarı oranlarıyla en belirleyici sinyal olduğunu göstermiştir. Gerilim ve titreşim veri türleri de %98'in üzerinde başarı oranlarıyla etkili performans sergilerken, akustik verisinin non-invaziv olması ve yüksek performansı bir arada sunması, rulman arızası tespitinde en uygun seçenek olduğunu ortaya koymaktadır. Bu bulgular, bir sonraki bölümde ele alınacak genel arıza sınıflandırması (sağlam, mıknatıs, rulman ve çoklu arıza) için temel oluşturmaktadır.

4.4. Arıza Sınıflandırması

Bu bölümde, motorun dört farklı durumunun (sağlam, çoklu arıza, mıknatıs arızası ve rulman arızası) aynı anda sınıflandırılması incelenmiştir. Önceki bölümlerde ikili sınıflandırma problemleri ele alınmış olup, bu bölümde dört sınıflı çok kategorili sınıflandırma problemi ele alınmıştır. Bu yaklaşım, gerçek zamanlı durum izleme

uygulamalarında motorun durumunun tek bir model ile tespit edilmesini sağlayarak, sistem karmaşıklığını azaltmakta ve işlem süresini kısaltmaktadır. Beş farklı sensörden (akı, akım, akustik, gerilim ve titreşim) elde edilen veri türleri, bu çalışma için optimize edilen PSO-CNN modeli ve ön eğitilmiş CNN modelleri kullanılarak analiz edilmiş ve çok sınıflı arıza sınıflandırmasındaki performansları karşılaştırılmıştır.

4.4.1. Eğitim performansının incelenmesi




Şekil 4.19. Arıza sınıflandırmasında PSO-CNN'e ait eğitim ve doğrulama grafiği

PSO-CNN modelinin arıza sınıflandırması için eğitim süreci Şekil 4.19'da sunulmuştur. Model 30 epoch boyunca eğitilmiş ve %95.70 test doğruluğuna ulaşmıştır. İkili sınıflandırma problemlerine (%97-98) kıyasla doğruluk oranının düşmesi, sınıf sayısının artmasıyla birlikte problemin karmaşıklığının arttığını göstermektedir. Doğrulama başarısı (kırmızı kesikli çizgi) eğitimin ilerleyen aşamalarında %90-100 aralığında stabilize olmuş ve eğitim başarısı (mavi çizgi) benzer bir trend izlemiştir. Her iki eğrinin birbirine paralel seyretmesi, modelin aşırı öğrenme probleminden uzak olduğunu göstermektedir.

Kayıp fonksiyonu grafiğinde, eğitim ve doğrulama kayıpları başlangıçta yüksek değerlerden (1.5-4.5) başlamış ve eğitim ilerledikçe düzenli bir azalma göstermiştir.

Eğitimin ilerleyen aşamalarında kayıp değerleri sıfıra yakın seviyelerde kararlı hale gelmiştir. Genel olarak, sınıf sayısının artması modelin öğrenmesi gereken karar sınırlarının karmaşıklığını artırdığı için çok sınıflı problemlerde başlangıç kayıplarının daha yüksek, yakınsama süresinin ise daha uzun olması beklenmektedir.




Şekil 4.20. Arıza sınıflandırmasında GoogLeNet’e ait eğitim ve doğrulama grafiği

GoogLeNet mimarisine uygulanan TL yöntemi, 10 epoch ile eğitilmiş ve %98.26 test doğruluğuna ulaşarak arıza sınıflandırmasında en yüksek performansı göstermiştir. Doğrulama başarısı (kırmızı kesikli çizgi), eğitimin erken aşamalarında hızlı bir yükseliş göstermiş ve %80-90 aralığında stabilize olmuştur. Eğitim başarısı (mavi çizgi) benzer bir eğilim göstermiş ve sürecin büyük bölümünde %90’ın üzerinde seyretmiştir.

Kayıp fonksiyonu grafiğinde, başlangıç kayıp değerleri eğitimin erken aşamalarında keskin bir düşüş sergilemiş ve ilerleyen bölümlerde düşük değerlerde stabilize olmuştur. Eğitim ve doğrulama kayıplarının birbirine paralel seyretmesi, TL yaklaşımının dört sınıflı problemde de etkili bir genelleme kabiliyetine sahip olduğunu ortaya koymaktadır. GoogLeNet’in PSO-CNN’e kıyasla %2.56’lık performans artışı, TL’nin çok sınıflı problemlerde daha belirgin avantajlar sağladığını göstermektedir.

4.4.2. Sınıflandırma performansının değerlendirilmesi

PSO-CNN modelinin arıza sınıflandırma performansı Şekil 4.21'deki karışıklık matrisi ile incelenmektedir. Test veri seti üzerinde toplam 13563 görüntü değerlendirilmiş olup, matris her sınıf için farklı başarı oranlarını göstermektedir.




Şekil 4.21. Arıza sınıflandırmasında PSO-CNN modeli için karışıklık matrisi

Motorun sağlam durum sınıfında, 3410 test örneğinden 3 304 tanesi doğru tespit edilmiş (%96.9) ve toplam 106 örnek diğer sınıflarla karıştırılmıştır. En fazla hata çoklu arıza sınıfıyla (%1.8, 63 örnek) yapılmıştır. Çoklu arıza sınıfında 3370 örnekten 3275'i başarıyla belirlenmiş (%97.2) ve 95 örnek yanlış sınıflandırılmıştır. Mıknatis arızası sınıfında 3380 örnekten 3192'si doğru tespit edilmiş (%94.4) ve 188 örnek hatalı sınıflandırılmıştır, en fazla hata çoklu arıza (%2.7, 91 örnek) ve sağlam durum (%2.0, 68 örnek) ile yapılmıştır. Rulman arızası sınıfında 3383 örnekten 3189'u başarıyla belirlenmiş (%94.3) ve 194 örnek yanlış sınıflandırılmıştır.

Karışıklık matrisinden görüldüğü üzere, modelin en başarılı olduğu sınıf çoklu arıza durumu (%97.2), en düşük performans ise rulman arızası (%94.3) ve mıknatis arızası (%94.4) sınıflarında gözlenmiştir. Sınıflar arası karışıklıkların en çok mıknatis-çoklu

arıza ve rulman-çoklu arıza arasında olması, çoklu arızanın her iki arızayı da içermesinden kaynaklanan benzerliklerden kaynaklanmaktadır.




Şekil 4.22. Arıza sınıflandırmasında GoogLeNet mimarisinin karışıklık matrisi

GoogLeNet modeline uygulanan TL yöntemi, arıza sınıflandırmasında PSO-CNN'e kıyasla belirgin bir performans artışı göstermiştir. Sağlam motor sınıfında 3410 örnekten 3372'si doğru tespit edilmiş (%98.9) ve sadece 38 örnek yanlış sınıflandırılmıştır. Çoklu arıza sınıfında 3370 örnekten 3289'u başarıyla belirlenmiş (%97.6) ve 81 örnek hatalı sınıflandırılmıştır. Miknatis arızası sınıfında 3380 örnekten 3332'si doğru tespit edilmiş (%98.6) ve yalnızca 48 örnek yanlış sınıflandırılmıştır. Rulman arızası sınıfında 3383 örnekten 3315'i başarıyla belirlenmiş (%98.0) ve 68 örnek hatalı sınıflandırılmıştır. GoogLeNet'in her sınıfta PSO-CNN'den daha yüksek True Positive oranlarına ulaşması, TL'nin çok sınıflı problemlerde özellik çıkarma kapasitesinin üstünlüğünü göstermektedir. Toplam 13308 doğru sınıflandırma ile yalnızca 255 hata yapılmış olup, bu değer PSO-CNN'in 603 hatasına göre %58 daha azdır. Sınıflar arası karışıklıkların minimize edilmesi, modelin her arıza tipini ayırt edici özellikleriyle öğrenebildiğini ortaya koymaktadır.

4.4.3. ROC eğrisi ve AUC değeri

PSO-CNN modeline ait arıza sınıflandırması için elde edilen ROC eğrileri Şekil 4.23’de sunulmuştur. Dört sınıfın tamamı için ROC eğrileri sol üst köşeye yakın seyretmekte olup, modelin yüksek ayırt etme kabiliyetine sahip olduğunu göstermektedir.



Şekil 4.23. Arıza sınıflandırmasında kullanılan PSO-CNN modeline ait ROC eğrisi

Sağlam motor (mavi sürekli çizgi), çoklu arıza (turuncu kesikli çizgi), mıknatıs arızası (sarı noktalı çizgi) ve rulman arızası (mor kesik-noktalı çizgi) sınıflarının tamamı için AUC değerleri 0.996’nın üzerindedir.

Çizelge 4.10. Arıza sınıflandırmada AUC test değerleri

Model	Sağlam	Çoklu	Mıknatıs	Rulman	Mikro	Makro
PSO-CNN	0.9970	0.9962	0.9970	0.9966	0.9965	0.9967
GoogLeNet	0.9993	0.9995	0.9988	0.9992	0.9992	0.9992
MobilNet-v2	0.9966	0.9968	0.9963	0.9973	0.9967	0.9968
ResNet-50	0.9975	0.9945	0.9906	0.9970	0.9942	0.9949

Tüm modellerin AUC değerleri incelendiğinde, dört modelin de tüm sınıflarda 0.990’ın üzerinde değerlere ulaştığı görülmektedir. GoogLeNet modeline uygulanan TL

yöntemiyle Makro AUC değeri 0.9992 ile en yüksek sınıf ayırma kalitesini göstermiş olup, PSO-CNN'in 0.9967 değerine göre 0.0025 puan daha yüksek performans sergilemiştir. Dikkat çekici bir şekilde, GoogLeNet'in çoklu arıza sınıfı için 0.9995 AUC değeri, tüm modeller ve sınıflar arasında en yüksek değerdir.

PSO-CNN modelinde sağlam ve miknatıs arızası sınıfları 0.9970 ile en yüksek AUC değerlerine sahipken, çoklu arıza sınıfı 0.9962 ile görece daha düşük bir değer göstermektedir. MobileNet-v2'de tüm sınıflar 0.9963-0.9973 aralığında dengeli değerler sergilerken, ResNet-50'de miknatıs arızası sınıfı 0.9906 ile en düşük AUC değerine sahiptir.

Her dört modelde de Mikro ve Makro AUC değerlerinin birbirine çok yakın olması, modellerin tüm sınıflar için dengeli bir ayırt etme performansına sahip olduğunu göstermektedir. Dört sınıflı problemde bile tüm modellerin 0.994'ün üzerinde Makro AUC değerlerine ulaşması, görüntü tabanlı derin öğrenme yöntemlerinin çoklu arıza sınıflandırmada güvenilir şekilde kullanılabileceğini ortaya koymaktadır.

ROC eğrilerinin sol üst köşeye yakın seyretmesi ve AUC değerlerinin 0.99'un çok üzerinde olması, eşik değeri ayarlamasından bağımsız olarak modellerin yüksek doğruluk oranlarını koruyabildiğini ifade etmektedir. Dört sınıflı problemde elde edilen bu yüksek AUC değerleri, ikili sınıflandırma problemlerine yakın seviyede olup, modellerin çok sınıflı problemlerde de etkili bir şekilde çalışabildiğini göstermektedir.

4.4.4. Performans metrikleri

Çizelge 4.11. Arıza sınıflandırmada modellere ait performans metrikleri

Model	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Genel Doğruluk
PSO-CNN	Sağlam	0.9563	0.9689	0.9626	0.9570
	Çoklu	0.9312	0.9718	0.9511	
	Miknatıs	0.9655	0.9444	0.9548	
	Rulman	0.9767	0.9427	0.9594	

Çizelge 4.11. (Devam) Arıza sınıflandırmada modellere ait performans metrikleri

GoogLeNet	Sağlam	0.9729	0.9889	0.9808	0.9826
	Çoklu	0.9919	0.9760	0.9838	
	Mıknatıs	0.9797	0.9858	0.9827	
	Rulman	0.9866	0.9799	0.9832	
MobilNet-v2	Sağlam	0.9564	0.9654	0.9609	0.9603
	Çoklu	0.9514	0.9653	0.9583	
	Mıknatıs	0.9580	0.9657	0.9618	
	Rulman	0.9759	0.9447	0.9600	
ResNet-50	Sağlam	0.9873	0.9337	0.9598	0.9541
	Çoklu	0.9284	0.9730	0.9502	
	Mıknatıs	0.9626	0.9293	0.9457	
	Rulman	0.9415	0.9805	0.9606	


Çizelge 4.11’de arıza sınıflandırmada, sınıf bazlı kesinlik, duyarlılık, F1 skoru ve genel doğruluk değerleri sunulmaktadır. GoogLeNet modeli %98.26 genel doğruluk ile en yüksek performansı sergilemiş olup, tüm sınıflarda %97.29’un üzerinde değerlere ulaşmıştır. Özellikle çoklu arıza sınıfında %99.19 kesinlik değeri, modelin yanlış alarm oranını minimize ettiğini göstermektedir. Sağlam motor sınıfında %98.89 duyarlılık değeri, modelin sağlam durumları kaçırma oranının son derece düşük olduğunu ortaya koymaktadır.

PSO-CNN modeli, %95.70 genel doğruluk ile ikinci sırada yer almakta ve ikili sınıflandırma problemlerine (%97-98) kıyasla %2-3’lük bir performans düşüşü göstermektedir. Rulman arızası sınıfında %97.67 kesinlik değeri en yüksek değer olmasına rağmen, duyarlılık değeri %94.27 ile görece daha düşüktür. Çoklu arıza sınıfında %97.18 duyarlılık değeri, modelin çoklu arıza durumlarını yüksek oranda tespit edebildiğini göstermektedir. Mıknatıs arızası sınıfında %94.44 duyarlılık değeri ile en düşük performans gözlenmiş olup, bu sınıfın diğer arıza tipleriyle karıştırılma eğiliminin daha yüksek olduğunu göstermektedir.

MobileNet-v2 modeli %96.03 genel doğruluk ile üçüncü sırada yer alırken, tüm sınıflarda %94.47-96.57 aralığında dengeli değerler sergilemiştir. ResNet-50 modeli %95.41 doğruluk ile dördüncü sıradadır. ResNet-50’de motorun sağlam durumu

sınıflandırmasında %98.73 kesinlik değerine karşın %93.37 duyarlılık değeri, modelin sağlam durumları tespit etmede daha muhafazakar davrandığını göstermektedir. Rulman arızası sınıfında ise %98.05 duyarlılık değeri, modelin rulman arızalarını yüksek oranda yakalayabildiğini ortaya koymaktadır.

Tüm modellerin dört sınıflı problemde %95'in üzerinde genel doğruluk elde etmesi, arıza sınıflandırmanın görüntü tabanlı derin öğrenme yöntemleri ile güvenilir şekilde gerçekleştirilebildiğini göstermektedir. GoogLeNet'in %98.26 performansı, TL'nin karmaşık çok sınıflı problemlerde belirgin avantajlar sağladığını ortaya koymaktadır.



Şekil 4.24. Arıza sınıflandırmada modellere ait başarı grafiği

Modellerin genel başarı düzeylerini gösteren grafik Şekil 4.24'de görülmektedir. GoogLeNet modeli %98.26 doğruluk ile açık ara en yüksek performansı gösterirken, MobileNet-v2 (%96.03), PSO-CNN (%95.70) ve ResNet-50 (%95.41) modelleri birbirine yakın değerlerde performans sergilemektedir. İkili sınıflandırma problemleriyle karşılaştırıldığında, dört sınıflı problemde tüm modellerde %2-3'lük bir doğruluk düşüşü gözlenmekte, ancak bu düşüşe rağmen %95'in üzerinde performans elde edilmesi, modellerin çok sınıflı problemlerde de güvenilir sonuçlar ürettiğini ortaya koymaktadır.

4.4.5. Sensör türüne göre sınıflandırma

Arıza sınıflandırma gerçekleştirildikten sonra, her bir veri türünün arıza durumu üzerindeki etkisi Çizelge 4.12’de görülmektedir. Elde edilen karışıklık matrislerinden yararlanılarak oluşturulan bu tablo, dört farklı modelin beş veri türü ve dört sınıf üzerindeki sınıflandırma başarı oranlarını göstermektedir.

Çizelge 4.12. Modellere göre veri türü ve durum bazlı sınıflandırma doğrulukları

Model	Durum	Akı (%)	Akım (%)	Akustik (%)	Gerilim (%)	Titreşim (%)
PSO-CNN	Sağlam	98.80	99.90	99.20	100	96.70
	Çoklu	99.80	98.00	99.40	99.80	99.30
	Mıknatıs	98.50	98.10	98.30	99.50	97.30
	Rulman	99.80	99.20	99.70	99.90	99.40
GoogLeNet	Sağlam	99.70	99.40	100	99.60	96.90
	Çoklu	100	99.20	100	98.80	99.60
	Mıknatıs	99.80	99.00	100	99.10	95.60
	Rulman	100	98.50	99.80	99.70	99.20
MobileNet-v2	Sağlam	98.00	98.20	98.10	98.70	91.50
	Çoklu	99.10	98.90	99.40	98.20	98.10
	Mıknatıs	97.30	99.40	99.50	99.40	95.50
	Rulman	99.50	99.80	98.90	99.60	98.90
ResNet-50	Sağlam	99.50	99.00	99.80	100	95.80
	Çoklu	99.80	99.20	99.70	99.80	99.70
	Mıknatıs	98.60	98.70	99.80	99.10	99.00
	Rulman	99.80	99.70	99.80	99.70	99.20

Veri türlerinin genel değerlendirmesi

Arıza sınıflandırmada, veri türlerinin performansı, ikili sınıflandırma problemlerine benzer ancak bazı farklılıklar gösteren bir eğilim sergilemektedir. Gerilim verisi, tüm modellerde ve tüm sınıflarda %98.20’nin üzerinde başarı oranlarıyla en tutarlı performansı gösteren veri türü olarak öne çıkmaktadır. PSO-CNN modelinde sağlam durum için %100 başarı oranına ulaşmış, ResNet-50’de de sağlam durum için %100

değeri elde edilmiştir. Bu sonuç, gerilim verisinin dört farklı motor durumunu ayırt etmede güvenilir bir veri türü olduğunu göstermektedir.

Akustik verisi, GoogLeNet modelinde sağlam durum, çoklu arıza ve mıknatıs arızası sınıflarında %100 başarı oranına ulaşmış olup, dört sınıflı problemde de yüksek performans sergilemiştir. PSO-CNN’de ise tüm sınıflarda %98.30’un üzerinde değerler elde edilmiştir. ResNet-50’de mıknatıs ve rulman arızalarında %99.80 değerleri, akustik verisinin mekanik ve elektromanyetik arızaları ayırt edebildiğini göstermektedir.

Kaçak akı verisi, dört sınıflı problemde dikkat çekici bir performans göstermiştir. GoogLeNet’te çoklu arıza ve rulman arızası için %100, PSO-CNN’de çoklu arıza ve rulman arızası için %99.80 başarı oranları, kaçak akı sensörünün arıza tespitindeki etkinliğini ortaya koymaktadır. Akım verisi, tüm modellerde %98’in üzerinde tutarlı değerler sergilemiş ve özellikle PSO-CNN’de sağlam durum için %99.90’a ulaşmıştır.

Titreşim verisi, dört sınıflı problemde de en değişken performansı gösteren veri türü olmuştur. Rulman ve çoklu arıza sınıflarında genellikle %98-99 aralığında yüksek değerler elde edilirken, sağlam durum ve mıknatıs arızası sınıflarında görece daha düşük değerler gözlenmiştir. MobileNet-v2’de sağlam durum için %91.50 ile en düşük değer elde edilmiş, GoogLeNet’te mıknatıs arızası için %95.60 değeri görülmüştür. Bu durum, titreşim verisinin rulman arızalarını güçlü bir şekilde ayırt edebildiğini, ancak sağlam durum ve mıknatıs arızalarının tespitinde daha az etkili olduğunu göstermektedir.

Model bazlı performans analizi

GoogLeNet modeli, arıza sınıflandırması ve veri türü bazlı sınıflandırma görevlerinde en yüksek ve en dengeli performansı göstermiştir. Hiyerarşik yapısından dolayı elde edilen toplam 20 farklı durum-veri türü kombinasyonunun 16’sında %99’un üzerinde başarı oranına ulaşılmış ve akustik verisiyle sağlam durum, çoklu arıza ve mıknatıs arızası için, kaçak akı verisiyle çoklu arıza ve rulman arızası için %100 başarı elde edilmiştir. Bu sonuç, GoogLeNet’in farklı veri türlerinden elde edilen karmaşık özellikleri etkili bir şekilde öğrenebildiğini göstermektedir.

PSO-CNN modeli, gerilim verisiyle sağlam durum için %100 başarı göstermiş ve genel olarak %96.70-100 aralığında tutarlı değerler sergilemiştir. Rulman arızası ve çoklu arıza sınıflarında tüm veri türlerinde %97.30'un üzerinde değerler elde edilmiş, bu durum modelin bu arıza tiplerini güçlü bir şekilde ayırt edebildiğini ortaya koymaktadır.

MobileNet-v2 modeli, titreşim verisinde sağlam durum için %91.50 ile en düşük değeri göstermiş, ancak rulman arızası ve mıknatıs arızası sınıflarında akım ve gerilim verileriyle %99'un üzerinde değerler elde etmiştir. Modelin hafif mimarisi dört sınıflı problemde bazı veri türlerinde zorlanmış olmasına rağmen, genel olarak dengeli bir performans sergilemiştir.

ResNet-50 modeli, gerilim verisiyle sağlam durum için %100, akustik verisiyle sağlam, mıknatıs ve rulman arızaları için %99.80 başarı göstermiştir. Ancak titreşim verisinde sağlam durum için %95.80 ile görece daha düşük bir değer elde edilmiş, bu durum derin mimarinin titreşim verisinde sağlam durum özelliklerini öğrenmede zorluk yaşadığını düşündürmektedir.

Arıza sınıflandırma için en iyi veri türünün belirlenmesi

Arıza sınıflandırmada en etkili veri türünün belirlenmesi için tüm modellerin performansları değerlendirildiğinde, gerilim verisi öne çıkmaktadır. Tüm modellerde ve tüm sınıflarda %98.20'nin üzerinde tutarlı başarı oranları, gerilim sensörünün dört farklı motor durumunu güvenilir şekilde ayırt edebildiğini ortaya koymaktadır. PSO-CNN ve ResNet-50'de sağlam durum için %100 başarı oranları, gerilim verisinin özellikle sağlam durumu tespit etmedeki üstünlüğünü göstermektedir.

Akustik verisi, ikinci en etkili veri türü olarak belirlenmiştir. GoogLeNet'te üç sınıf için %100 başarı göstermesi, akustik sinyallerin motor arızalarının akustik belirtilerini güçlü bir şekilde yansıttığını ortaya koymaktadır. Özellikle rulman ve mıknatıs arızalarının akustik sinyallerde belirgin değişimler oluşturması, bu veri türünün çok sınıflı problemlerde etkili olmasını sağlamaktadır.

Kaçak akı verisi, mıknatıs arızası ve çoklu arıza sınıflarında yüksek performans sergilemesine rağmen, sağlam durum ve rulman arızası sınıflarında görece daha düşük değerler göstermiştir. Bu durum, kaçak akı verisinin mıknatıs arızalarını güçlü bir şekilde tespit edebildiğini, ancak rulman arızalarının kaçak akı sinyallerinde daha az belirgin etkiler oluşturduğunu düşündürmektedir.

Akım verisi, %98-99.90 aralığında dengeli ve yüksek değerler sergilemiş, dört sınıflı problemde güvenilir sonuçlar üretmiştir. Titreşim verisi ise rulman ve çoklu arıza sınıflarında yüksek performans göstermesine rağmen, sağlam durum ve mıknatıs arızası sınıflarında %91.50-97.30 aralığında görece daha düşük değerler elde etmiştir.

Pratik uygulama açısından değerlendirildiğinde, arıza sınıflandırmada en tutarlı performansı gösteren gerilim verisi (%98.20-100), invaziv bir ölçüm yöntemi gerektirmektedir. Akustik verisi ise non-invaziv bir yöntemle elde edilebildiğinden ve %95.60-100 aralığında yüksek başarı oranlarına ulaştığından, kurulum kolaylığı ve performans dengesi açısından öne çıkmaktadır. Kaçak akı verisi de non-invaziv olması ve %97.30-100 aralığında değerler göstermesiyle, özellikle elektromanyetik arızaların (mıknatıs, çoklu) tespitinde tercih edilebilir bir seçenek olarak değerlendirilebilir. Akım verisi yüksek performans sergilemesine rağmen invaziv bir yöntem gerektirmektedir. Titreşim verisi, rulman arızasında yüksek başarı göstermesine rağmen sağlam durum tespitindeki düşük performansı ve sensör montajının ek iş gücü gerektirmesi nedeniyle, arıza sınıflandırmada diğer veri türlerine kıyasla daha az tercih edilebilir bir seçenektir. Sonuç olarak, arıza sınıflandırmada, akustik ve kaçak akı verisi hem performans hem de uygulama kolaylığı açısından en uygun seçenek olarak öne çıkmakta, gerilim verisi ise performans öncelikli uygulamalar için önerilmektedir.

Bu bölümde, motorun dört farklı durumunun aynı anda sınıflandırılması için dört farklı derin öğrenme modelinin performansı kapsamlı olarak değerlendirilmiştir. GoogLeNet modeline uygulanan TL yöntemi %98.26 genel doğruluk ve 0.9992 Makro AUC değeri ile en yüksek performansı göstermiş, PSO-CNN modeli ise %95.70 doğruluk ile ön eğitilmiş CNN modellerine yakın bir başarı sergilemiştir. İkili sınıflandırma problemlerine

kıyasla %2-3'lük bir performans düşüşü gözlenmesine rağmen, tüm modellerin %95'in üzerinde doğruluk oranlarına ulaşması, arıza sınıflandırmanın görüntü tabanlı derin öğrenme yöntemleri ile güvenilir şekilde gerçekleştirilebildiğini ortaya koymuştur.

Veri türü bazlı analizler, dört sınıflı problemde gerilim verisinin %98.20-100 başarı oranlarıyla en tutarlı performansı gösterdiğini, akustik verisinin ise non-invaziv olması ve %95.60-100 aralığında yüksek başarı oranlarıyla pratik uygulamalar için en uygun seçenek olduğunu göstermiştir. Kaçak akı verisi elektromanyetik arızalarda, titreşim verisi ise mekanik arızalarda (rulman) yüksek performans sergilemiş, ancak arıza sınıflandırmada, akustik ve gerilim verilerinin daha dengeli sonuçlar ürettiği görülmüştür. Bu bulgular, arıza sınıflandırma sistemlerinin tasarımında veri türü seçiminin performans-maliyet dengesi açısından önemini vurgulamaktadır.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, HEA’larda kullanılan BLDC motorların arıza sınıflandırması için DL tabanlı özgün bir yöntem geliştirilmiştir. Önerilen yöntem, CEEMDAN tabanlı IMF ayrıştırması, STFT tabanlı spektral dönüşüm, PSO algoritması ile optimize edilen CNN mimarisi ve ön eğitilmiş CNN mimarilerine uygulanan TL yöntemlerinin birlikte kullanılmasına dayanmaktadır. Çalışma kapsamında, elektrikli scooter motorunda sağlam, rulman arızalı, mıknatıs arızalı ve çoklu (rulman-mıknatıs) arızalı durumlar suni olarak oluşturulmuştur. Bu motor durumları için kaçak akı, akım, akustik, gerilim ve titreşim olmak üzere beş farklı sensörden veriler toplanmıştır. Veri toplam işlemi kısa süreli olup veri sayısı sınırlıdır. Toplanan veriler CEEMDAN ayrıştırılmış, STFT ile spektral görüntülere dönüştürülmüş ve iki aşamalı hiyerarşik bir sınıflandırma yaklaşımıyla düzenlenmiştir. Elde edilen veri seti, PSO-CNN modeli ile TL’ye dayalı GoogLeNet, MobileNet-v2 ve ResNet-50 mimarileri kullanılarak analiz edilmiş ve arıza sınıflandırması gerçekleştirilmiştir.

Deneyisel analizler, ikili sınıflandırmaya dayalı arıza tespiti ile dörtlü sınıflandırmaya dayalı arıza sınıflandırma senaryoları üzerinden gerçekleştirilmiştir. İkili sınıflandırma problemlerinden olan, sağlam-çoklu arıza, sağlam-mıknatıs arızası ve sağlam-rulman arızası olarak analiz edilen tüm modellerin %97’nin üzerinde doğruluk oranlarına ulaştığı, çoklu arıza durum tespitinde GoogLeNet modeli %98.64 doğruluk ve 0.9987 AUC değeri ile en yüksek performansı gösterirken, PSO-CNN modeli %97.83 doğrulukla benzer bir başarı sergilemiştir. Mıknatıs arızası durum tespitinde, GoogLeNet %99.01 genel doğruluk ve 0.9985 AUC değeri ile en başarılı model olmuş, PSO-CNN ise %97.89 doğrulukla ikinci sırada yer almıştır. Rulman arızası durum tespitinde, GoogLeNet %98.55 doğruluk ve 0.9991 AUC değeri ile en yüksek performansı göstermiş, PSO-CNN modeli %98.22 doğrulukla yakın bir başarı elde etmiştir. Arıza sınıflandırmada, PSO-CNN modeli %95.70 doğruluk oranını yakalamıştır. TL uygulanan GoogLeNet, MobileNet-v2 ve ResNet-50 modelleri ise sırasıyla %98.26, %96.03 ve %95.41 doğruluk değerlerini elde etmiştir. Bu sonuçlar, TL uygulanan modellerin arıza sınıflandırmada yüksek başarı sergilediğini göstermiştir. Önerilen yöntem hem arıza tespiti hem de arıza

sınıflandırma çalışmalarında GoogLeNet modeline uygulanan TL yaklaşımı ile %98'in üzerinde başarıyla gerçekleştirmiştir.

Elde edilen sonuçlar, HEA'lardan elde edilen spektral görüntülerin TL uygulanan modeller tarafından yüksek doğrulukla işlenebildiğini ve motor arızalarının güvenilir bir şekilde tespit edilebildiğini ortaya koymuştur. Çalışmada önerilen metodoloji sınırlı veri koşullarında %98'in üzerinde başarı elde etmiştir. TL yaklaşımının, özellikle GoogLeNet mimarisi ile, PSO-CNN modeline kıyasla daha yüksek performans göstermesi, önceden öğrenilmiş özelliklerin, arıza sınıflandırmada etkili bir şekilde kullanılabileceğini göstermiştir. Ancak, PSO-CNN modelinin daha az parametre ile yakın performans sergilemesi, kaynakların kısıtlı olduğu sistemlerde alternatif bir çözüm sunabilmektedir. Arıza tipine özgü sensör seçiminin performans üzerindeki etkisi, çalışmanın önemli bulgularından biridir. Elde edilen veriler, farklı sensör türlerinin arıza tespitindeki etkinliğinin arıza tipine göre değiştiğini ortaya koymuştur. Çoklu durum arıza tespitinde akustik ve gerilim verileri en yüksek başarıyı gösterirken, mıknatıs arızası durum tespitinde kaçak akı, gerilim ve akım verileri yüksek performans sergilemiştir. Rulman arızası durum tespitinde, akustik ve gerilim verileri en belirleyici sinyaller olmuştur. Arıza sınıflandırmada, gerilim verisi en tutarlı performansı gösterirken, akustik verisi non-invaziv olması nedeniyle öne çıkmıştır. Her arıza tipi için en etkili sensör türlerinin belirlenmesi, pratik uygulamalarda sensör seçiminde maliyet-performans dengesinin sağlanmasına olanak tanıyacaktır.

Bu çalışmanın literatüre katkıları; geliştirilen metodoloji, HEA'larda motor durumunun gerçek zamanlı izlenmesi için alternatif bir yöntemdir. Erken arıza tespitine olanak sunar. Özellikle paylaşımlı mobilite sistemlerinde (elektrikli scooter kiralama), araç filosunun uzaktan durum izlemesi operasyonel verimliliği artırabilir. Erken arıza tespiti sayesinde, reaktif bakım yerine prediktif bakım stratejileri uygulanabilir. Bu yaklaşım, beklenmeyen arızaları azaltarak araç kullanılabilirliğini artırabilir ve işletme maliyetlerini düşürebilir. Akustik ve kaçak akı sensör kullanımının non-invaziv doğası, mevcut sistemlere minimum müdahale ile entegrasyon imkanı sunmaktadır. Önerilen yöntem gömülü sistemlerde kullanılabilir.

Yukarıda belirtilen katkılarının yanında bu çalışmanın sınırlılıkları da vardır. Kullanılan veri setinin kısıtlı olması, modele aşırı öğrenme yapma riski getirebilmektedir. Bunu önlemek amacıyla veri artırma tekniklerinden yararlanılmıştır. Veri artırma işlemlerinde, aşırı döndürme, yakınlaştırma veya gürültü ekleme gibi yoğun dönüşümler sinyalin temel özelliklerini bozabilmektedir. Bu durum modelin genelleme yeteneğini azaltabilmektedir. Ayrıca veri artırma yoluyla üretilen örnekler, orijinal sinyallere göre daha düşük güvenilirliğe sahip olabildiğinden model performansını sınırlayabilmektedir.

Gelecekteki araştırmalar için çeşitli öneriler sunulabilir. Farklı güç seviyelerindeki motorlardan toplanan veriler ile modelin genelleme kabiliyeti test edilebilir. Bununla birlikte farklı arıza türleri veri setine dahil edilerek kapsamlı bir arıza kütüphanesi oluşturulabilir. Farklı çevresel koşullar (sıcaklık, nem, yol koşulları) altında ve arızanın farklı şiddet seviyelerini içeren veriler toplanarak modelin genelleme kabiliyeti artırılabilir. Elektrikli bisiklet, elektrikli motosiklet gibi diğer HEA kategorilerinde metodolojinin uygulanabilirliği test edilebilir.

KAYNAKLAR

- Abaci, M., & Kara, D. B. (2024). ANSYS-Based Broken Magnet, Demagnetization and Short Circuit Fault Evaluation for a BLDC Motor Designed for Light Electric Vehicle. *Turkish Journal of Electrical Power and Energy Systems*, 4(3), 118-126.
- Abdel-Aziz, A., Elgenedy, M., & Williams, B. (2024). Review of switched reluctance motor converters and torque ripple minimisation techniques for electric vehicle applications. *Energies*, 17(13), 3263.
- Abdulkareem, A., Anyim, T., Popoola, O., Abubakar, J., & Ayoade, A. (2025). Prediction of induction motor faults using machine learning. *Heliyon*, 11(1).
- Acosta, G. G., Verucchi, C., & Gelso, E. (2006). A current monitoring system for diagnosing electrical failures in induction motors. *Mechanical Systems and Signal Processing*, 20(4), 953-965.
- Agrawal, P., & Jayaswal, P. (2020). Diagnosis and classifications of bearing faults using artificial neural network and support vector machine. *Journal of The Institution of Engineers (India): Series C*, 101, 61-72.
- Ahmed, S., Alam, M. S. B., Hassan, M., Rozbu, M., Ishtiak, T., Rafa, N., Mofijur, M., Ali, A. S., & Gandomi, A. (2023). Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artificial Intelligence Review*, 56, 13521-13617. <https://doi.org/10.1007/s10462-023-10466-8>
- Al-Haddad, L. A., Jaber, A. A., Hamzah, M. N., & Fayad, M. A. (2024). Vibration-current data fusion and gradient boosting classifier for enhanced stator fault diagnosis in three-phase permanent magnet synchronous motors. *Electrical Engineering*, 106(3), 3253-3268. <https://doi.org/10.1007/s00202-023-02148-z>
- Ali, A. K., & Rafa Abed, W. (2024). Hierarchical Deep Learning for Bearing Fault Detection in BLDC Motors Using Time-Frequency Analysis. *Journal of Electrical and Computer Engineering*, 2024(1), 3376733.
- Ali, J. B., Fnaiech, N., Saidi, L., Chebel-Morello, B., & Fnaiech, F. (2015). Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Applied Acoustics*, 89, 16-27.

- Ali, Z., Calasan, M., Gandoman, F., Jurado, F., & Aleem, S. A. (2023). Review of batteries reliability in electric vehicle and E-mobility applications. *Ain Shams Engineering Journal*. <https://doi.org/10.1016/j.asej.2023.102442>
- Alias, A. (2020). Overview of brushless DC motor: Construction and application. *International Journal for Technological Research in Engineering*, 7(8), 6669-6675.
- Aloeyi, E. F., Ali, N., & Wang, Q. (2022, 28-31 Oct. 2022). A Review of In-Wheel Motors for Electric Vehicle Propulsion. 2022 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific),
- Alomar, K., Aysel, H. I., & Cai, X. (2023). Data Augmentation in Classification and Segmentation: A Survey and New Strategies. *Journal of Imaging*, 9. <https://doi.org/10.3390/jimaging9020046>
- Alotaibi, M., Honarvar Shakibaei Asli, B., & Khan, M. (2021). Non-invasive inspections: A review on methods and tools. *Sensors*, 21(24), 8474.
- Altug, S., Chen, M.-Y., & Trussell, H. J. (2002). Fuzzy inference systems implemented on neural architectures for motor fault detection and diagnosis. *IEEE transactions on industrial electronics*, 46(6), 1069-1079.
- Alzubaidi, L., Zhang, J., Humaidi, A., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8. <https://doi.org/10.1186/s40537-021-00444-8>
- Amarnath, M., Sugumaran, V., & Kumar, H. (2013). Exploiting sound signals for fault diagnosis of bearings using decision tree. *Measurement*, 46(3), 1250-1256. <https://doi.org/https://doi.org/10.1016/j.measurement.2012.11.011>
- Anbalagan, S., SaiShashank, G., Agarwal, D., Natarajan, B., & Srinivasan, B. (2023). Active Foundational Models for Fault Diagnosis of Electrical Motors. *ArXiv*, abs/2311.15516. <https://doi.org/10.48550/arxiv.2311.15516>
- Baćanin, N., Bezdan, T., Venkatachalam, K., Zivkovic, M., Strumberger, I., Abouhawwash, M., & Ahmed, A. (2021). Artificial Neural Networks Hidden Unit and Weight Connection Optimization by Quasi-Refection-Based Learning Artificial Bee Colony Algorithm. *IEEE Access*, PP, 1-1. <https://doi.org/10.1109/access.2021.3135201>

- Bretones, A., Marquet, O., Daher, C., Hidalgo, L., Nieuwenhuijsen, M., Miralles-Guasch, C., & Mueller, N. (2023). Public Health-Led Insights on Electric Micro-mobility Adoption and Use: a Scoping Review. *Journal of Urban Health : Bulletin of the New York Academy of Medicine*, 100, 612-626. <https://doi.org/10.1007/s11524-023-00731-0>
- Buterez, D., Janet, J., Kiddle, S., Oglic, D., & Lió, P. (2024). Transfer learning with graph neural networks for improved molecular property prediction in the multi-fidelity setting. *Nature Communications*, 15. <https://doi.org/10.1038/s41467-024-45566-8>
- Case Western Reserve University, C. (2025). *Bearing Data Center*. Case Western Reserve University <https://engineering.case.edu/bearingdatacenter/download-data-file>
- Chan, C. C. (2007). The State of the Art of Electric, Hybrid, and Fuel Cell Vehicles. *Proceedings of the IEEE*, 95(4), 704-718. <https://doi.org/10.1109/JPROC.2007.892489>
- Chattopadhyay, M., Roy, P., & Dutta, S. (2012). Simulation Modeling of BLDC Motor Drive and Harmonic Analysis of Stator Current, Rotor Speed and Acceleration using Discrete Wavelet Transform Technique. *Procedia Technology*, 4, 666-670. <https://doi.org/https://doi.org/10.1016/j.protcy.2012.05.107>
- Che, C., Wang, H., Ni, X., & Lin, R. (2021). Hybrid multimodal fusion with deep learning for rolling bearing fault diagnosis. *Measurement*, 173, 108655. <https://doi.org/https://doi.org/10.1016/j.measurement.2020.108655>
- Chen, X., Zhang, B., & Gao, D. (2021). Bearing fault diagnosis base on multi-scale CNN and LSTM model. *Journal of Intelligent Manufacturing*, 32(4), 971-987.
- Chen, Y., Liang, S., Li, W., Liang, H., & Wang, C. (2019). Faults and diagnosis methods of permanent magnet synchronous motors: A review. *Applied Sciences*, 9(10), 2116.
- Cheng, J., Yu, D., Tang, J., & Yang, Y. (2009). Application of SVM and SVD Technique Based on EMD to the Fault Diagnosis of the Rotating Machinery. *Shock and Vibration*, 16(1), 519502. <https://doi.org/https://doi.org/10.3233/SAV-2009-0457>
- Chlap, P., Min, H., Vandenberg, N., Dowling, J., Holloway, L., & Haworth, A. (2021). A review of medical image data augmentation techniques for deep learning

- applications. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 545-563.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Choudhary, A., Mian, T., Fatima, S., & Panigrahi, B. K. (2023). Fault Diagnosis of Electric Two-Wheeler Under Pragmatic Operating Conditions Using Wavelet Synchrosqueezing Transform and CNN. *IEEE Sensors Journal*, 23(6), 6254-6263. <https://doi.org/10.1109/JSEN.2023.3239383>
- Clerc, M., & Kennedy, J. (2002). The particle swarm-explosion, stability, and convergence in a multidimensional complex space. *IEEE transactions on Evolutionary Computation*, 6(1), 58-73.
- Coraci, D., Brandi, S., Hong, T., & Capozzoli, A. (2023). Online transfer learning strategy for enhancing the scalability and deployment of deep reinforcement learning control in smart buildings. *Applied Energy*. <https://doi.org/10.1016/j.apenergy.2022.120598>
- Çelik, Y., Yıldız, İ., & Karadeniz, A. T. (2019). Son Üç Yılda Geliştirilen Metasezgisel Algoritmalar Hakkında Kısa Bir İnceleme. *Avrupa Bilim ve Teknoloji Dergisi*, 463-477.
- Da, Y., Shi, X., & Krishnamurthy, M. (2011). Health monitoring, fault diagnosis and failure prognosis techniques for Brushless Permanent Magnet Machines. 2011 IEEE vehicle power and propulsion conference,
- De Miguel, L. J., & Blázquez, L. F. (2005). Fuzzy logic-based decision-making for fault diagnosis in a DC motor. *Engineering Applications of Artificial Intelligence*, 18(4), 423-450.
- Deepak, K., Frikha, M. A., Benômar, Y., El Baghdadi, M., & Hegazy, O. (2023). In-Wheel Motor Drive Systems for Electric Vehicles: State of the Art, Challenges, and Future Trends. *Energies*, 16(7), 3121. <https://www.mdpi.com/1996-1073/16/7/3121>
- Dengfeng, Z., Chaoyang, T., Zhijun, F., Yudong, Z., Junjian, H., & Wenbin, H. (2025). Multi scale convolutional neural network combining BiLSTM and attention mechanism for bearing fault diagnosis under multiple working conditions. *Scientific Reports*, 15(1), 13035.

- Desheng, L., Beibei, Y., Yu, Z., & Jinping, S. (2012, 25-27 May 2012). Time-frequency analysis based on BLDC motor fault detection using Hermite S-method. 2012 IEEE International Conference on Computer Science and Automation Engineering (CSAE),
- Di Maggio, L. G. (2023). Intelligent Fault Diagnosis of Industrial Bearings Using Transfer Learning and CNNs Pre-Trained for Audio Classification. *Sensors*, 23(1), 211. <https://www.mdpi.com/1424-8220/23/1/211>
- Dias, C. G., & Chabu, I. E. (2014). Spectral Analysis Using a Hall Effect Sensor for Diagnosing Broken Bars in Large Induction Motors. *IEEE Transactions on Instrumentation and Measurement*, 63(12), 2890-2902. <https://doi.org/10.1109/TIM.2014.2328184>
- Ding, N., Qin, Y., Yang, G., Wei, F., Yang, Z., Su, Y., Hu, S., Chen, Y., Chan, C.-M., Chen, W., Yi, J., Zhao, W., Wang, X., Liu, Z., Zheng, H., Chen, J., Liu, Y., Tang, J., Li, J., & Sun, M. (2023). Parameter-efficient fine-tuning of large-scale pre-trained language models. *Nature Machine Intelligence*, 5, 220-235. <https://doi.org/10.1038/s42256-023-00626-4>
- Doğan, Z. (2012). *Ayrıklaştırma yöntemleri ve yapay sinir ağı kullanarak asenkron motorlarda arıza teşhisi* Marmara Üniversitesi (Turkey)].
- Dong, Z., Zheng, J., Huang, S., Pan, H., & Liu, Q. (2019). Time-shift multi-scale weighted permutation entropy and GWO-SVM based fault diagnosis approach for rolling bearing. *Entropy*, 21(6), 621.
- Dreßler, A., Höfer, E., Brost, M., Gebhardt, L., & Böhm, M. (2024). Car commuters' requirements for using light electric vehicles (LEV). *Advances in Human Factors of Transportation*. <https://doi.org/10.54941/ahfe1005218>
- Eberhart, R., & Kennedy, J. (1995). Particle swarm optimization. Proceedings of the IEEE international conference on neural networks,
- Ehsani, M., Gao, Y., Longo, S., & Ebrahimi, K. (2018). *Modern electric, hybrid electric, and fuel cell vehicles*. CRC press.
- Elbouchikhi, E., Choqueuse, V., Amirat, Y., Benbouzid, M. E. H., & Turri, S. (2017). An Efficient Hilbert–Huang Transform-Based Bearing Faults Detection in Induction Machines. *IEEE Transactions on Energy Conversion*, 32(2), 401-413. <https://doi.org/10.1109/TEC.2017.2661541>

- Electrical Technology. (2016). BLDC motor: Construction, working principle & applications. <https://www.electricaltechnology.org/2016/05/bldc-brushless-dc-motor-construction-working-principle.html>
- Emara, H. M., Elshamy, W., & Bahgat, A. (2008, 30 June-2 July 2008). Parameter identification of induction motor using modified Particle Swarm Optimization algorithm. 2008 IEEE International Symposium on Industrial Electronics,
- Esmeray, H., Dogan, Z., & İşeri, İ. (2025). A novel approach for classifying LEV motor bearing faults using a PSO-optimized CNN model and parameters based on transfer learning. *Evolving Systems*, 16(3), 1-23.
- Ewert, A., Brost, M., Eisenmann, C., & Stieler, S. (2020). Small and light electric vehicles: An analysis of feasible transport impacts and opportunities for improved urban land use. *Sustainability*, 12(19), 8098.
- Faiz, J., & Mazaheri-Tehrani, E. (2017). Demagnetization Modeling and Fault Diagnosing Techniques in Permanent Magnet Machines Under Stationary and Nonstationary Conditions: An Overview. *IEEE Transactions on industry applications*, 53(3), 2772-2785. <https://doi.org/10.1109/TIA.2016.2608950>
- Fang, K., Zhang, H., Qi, H., & Dai, Y. (2018). Comparison of EMD and EEMD in rolling bearing fault signal analysis. 2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC),
- Filippetti, F., Franceschini, G., Tassoni, C., & Vas, P. (2002). Recent developments of induction motor drives fault diagnosis using AI techniques. *IEEE transactions on industrial electronics*, 47(5), 994-1004.
- Flandrin, P., Rilling, G., & Goncalves, P. (2004). Empirical mode decomposition as a filter bank. *IEEE signal processing letters*, 11(2), 112-114.
- Flores, J. A., & Ostia, C. F. (2023, 21-23 April 2023). Motor Fault Diagnosis of a Brushless DC Motor Using Fast Kurtogram on Convolutional Neural Network. 2023 9th International Conference on Control, Automation and Robotics (ICCAR),
- Gamazo-Real, J. C., Vázquez-Sánchez, E., & Gómez-Gil, J. (2010). Position and Speed Control of Brushless DC Motors Using Sensorless Techniques and Application Trends. *Sensors*, 10(7), 6901-6947. <https://www.mdpi.com/1424-8220/10/7/6901>

- Gao, Z., Zheng, J., Pan, H., Cheng, J., & Tong, J. (2025). Adaptive generalized empirical wavelet transform and its application to fault diagnosis of rolling bearing. *Measurement*, 249, 116958. <https://doi.org/https://doi.org/10.1016/j.measurement.2025.116958>
- Garcia-Calva, T., Moriñigo-Sotelo, D., Fernández-Cavero, V., & Romero-Troncoso, R. (2022). Early Detection of Faults in Induction Motors—A Review. *Energies*. <https://doi.org/10.3390/en15217855>
- Gediya, N. C. (2025). Reliability Testing of Semiconductor Components under Mechanical Shock and Vibration in Automotive Systems. *International Journal for Research in Applied Science and Engineering Technology*. <https://doi.org/10.22214/ijraset.2025.73228>
- Ghafouri Matanagh, A., Ozturk, S. B., Goktas, T., & Hegazy, O. (2024). Classifying the Percentage of Broken Magnets in Permanent Magnet Synchronous Motors Using Combined Short-Time Fourier Transform and a Pre-Trained Convolutional Neural Network. *Energies*, 17(2), 368. <https://www.mdpi.com/1996-1073/17/2/368>
- Gherghina, I.-S., Bizon, N., Iana, G.-V., & Vasilică, B.-V. (2025). Recent Advances in Fault Detection and Analysis of Synchronous Motors: A Review. *Machines*, 13(9), 815. <https://www.mdpi.com/2075-1702/13/9/815>
- Glowacz, A. (2019). Fault diagnosis of single-phase induction motor based on acoustic signals. *Mechanical Systems and Signal Processing*, 117, 65-80. <https://doi.org/https://doi.org/10.1016/j.ymssp.2018.07.044>
- Gössling, S. (2020). Integrating e-scooters in urban transportation: Problems, policies, and the prospect of system change. *Transportation Research Part D: Transport and Environment*, 79, 102230. <https://doi.org/https://doi.org/10.1016/j.trd.2020.102230>
- Guan, Y., Subel, A., Chattopadhyay, A., & Hassanzadeh, P. (2023). Learning physics-constrained subgrid-scale closures in the small-data regime for stable and accurate LES. *Physica D: Nonlinear Phenomena*, 443, 133568. <https://doi.org/https://doi.org/10.1016/j.physd.2022.133568>
- Guo, X., Chen, L., & Shen, C. (2016). Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis. *Measurement*, 93, 490-502.

- Hafeez, S., Zaidi, C. S. H., & Siddiqui, A. (2013). Broken rotor bar detection of single phase induction motor using Wigner-Ville Distributions. 2013 IEEE 18th Conference on Emerging Technologies & Factory Automation (ETFA),
- Han, J.-H., Choi, D.-J., Park, S.-U., & Hong, S.-K. (2020). Hyperparameter optimization using a genetic algorithm considering verification time in a convolutional neural network. *Journal of Electrical Engineering & Technology*, 15, 721-726.
- Han, L., Fu, X., Tian, S., & Shen, Z. (2022, 18-20 Nov. 2022). Demagnetization Fault Detection Research of Brushless DC Motor Based on Machine Learning. 2022 5th World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM),
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Hu, R., Wang, J., Mills, A. R., Chong, E., & Sun, Z. (2021). Current-Residual-Based Stator Interturn Fault Detection in Permanent Magnet Machines. *IEEE transactions on industrial electronics*, 68(1), 59-69. <https://doi.org/10.1109/TIE.2020.2965500>
- Huang, D., Li, S., Qin, N., & Zhang, Y. (2021). Fault diagnosis of high-speed train bogie based on the improved-CEEMDAN and 1-D CNN algorithms. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11.
- Huang, H., Fan, Q., Wei, J., & Huang, D. (2019). An intelligent fault identification method of rolling bearings based on SVM optimized by improved GWO. *Systems Science & Control Engineering*, 7(1), 289-303.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C., & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995.
- Huang, T., Zhang, Q., Tang, X., Zhao, S., & Lu, X. (2022). A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems. *Artificial Intelligence Review*, 55(2), 1289-1315. <https://doi.org/10.1007/s10462-021-09993-z>

- Hussain, N. Y. (2024). Deep Learning Architectures Enabling Sophisticated Feature Extraction and Representation for Complex Data Analysis. *International Journal of Innovative Science and Research Technology (IJISRT)*. <https://doi.org/10.38124/ijisrt/ijisrt24oct1521>
- Im, S.-H., & Gu, B.-G. (2022). Study of induction motor inter-turn fault part II: online model-based fault diagnosis method. *Energies*, 15(3), 977.
- ImageNet. (2025). ImageNet. <http://www.image-net.org>
- Infineon Technologies, A. (2019). *Application Brochure: Light Electric Vehicles (LEVs)*. <https://www.infineon.com/lev>
- İnik, Ö. (2023). CNN hyper-parameter optimization for environmental sound classification. *Applied Acoustics*, 202, 109168.
- Jena, B., Saxena, S., Nayak, G., Saba, L., Sharma, N., & Suri, J. (2021). Artificial intelligence-based hybrid deep learning models for image classification: The first narrative review. *Computers in Biology and Medicine*, 137, 104803. <https://doi.org/10.1016/j.compbiomed.2021.104803>
- Jeong, H., Lee, H., & Kim, S. W. (2018, 23-27 Sept. 2018). Classification and Detection of Demagnetization and Inter-Turn Short Circuit Faults in IPMSMs by Using Convolutional Neural Networks. 2018 IEEE Energy Conversion Congress and Exposition (ECCE),
- JGraph Ltd. (2025). *draw.io (diagrams.net)*. In JGraph Ltd. <https://www.drawio.com/>
- Jia, Y., Zhang, X., & Chen, G. (2018, 23-25 Nov. 2018). Rotor Winding Image Detection Method Based on Model-Based Transfer Learning. 2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS),
- Jiang, Y., Ji, B., Zhang, J., Yan, J., & Li, W. (2024). An Overview of Diagnosis Methods of Stator Winding Inter-Turn Short Faults in Permanent-Magnet Synchronous Motors for Electric Vehicles. *World Electric Vehicle Journal*. <https://doi.org/10.3390/wevj15040165>
- Jin, B., & Vai, M. I. (2014). An adaptive ultrasonic backscattered signal processing technique for instantaneous characteristic frequency detection. *Bio-medical materials and engineering*, 24(6), 2761-2770.

- Junior, F. E. F., & Yen, G. G. (2019). Particle swarm optimization of deep neural networks architectures for image classification. *Swarm and Evolutionary Computation*, 49, 62-74.
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2019). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53, 5455-5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Khan, M. A., Asad, B., Kudelina, K., Vaimann, T., & Kallaste, A. (2023). The Bearing Faults Detection Methods for Electrical Machines—The State of the Art. *Energies*, 16(1), 296. <https://www.mdpi.com/1996-1073/16/1/296>
- Khan, M. A., Baig, D.-e.-Z., Ali, H., & Albogamy, F. R. (2025). Optimized System Identification (SI) of Brushless DC (BLDC) motor using Data-Driven Modeling Methods. *Scientific Reports*, 15(1), 8497. <https://doi.org/10.1038/s41598-025-93444-0>
- Khan, M. U. I., Pathan, M. I. H., Rahman, M. M., Islam, M. M., Chowdhury, M. A. R., Anower, M. S., Rana, M. M., Alam, M. S., Hasan, M., Sobuj, M. S. I., Islam, M. B., Meena, V., & Benedetto, F. (2024). Securing Electric Vehicle Performance: Machine Learning-Driven Fault Detection and Classification. *IEEE Access*, 12, 71566-71584. <https://doi.org/10.1109/access.2024.3400913>
- Khaneghah, M. Z., Alzayed, M., & Chaoui, H. (2023). Fault Detection and Diagnosis of the Electric Motor Drive and Battery System of Electric Vehicles. *Machines*. <https://doi.org/10.3390/machines11070713>
- Kim, U., & Lieu, D. K. (2005). Effects of magnetically induced vibration force in brushless permanent-magnet motors. *IEEE Transactions on Magnetics*, 41(6), 2164-2172. <https://doi.org/10.1109/TMAG.2005.847628>
- Kornblith, S., Shlens, J., & Le, Q. V. (2019). Do better imagenet models transfer better? Proceedings of the IEEE/CVF conference on computer vision and pattern recognition,
- Krishnamoorthy, S., & Panikkar, P. P. K. (2024). A comprehensive review of different electric motors for electric vehicles application. *International Journal of Power Electronics and Drive Systems (IJPEDS)*. <https://doi.org/10.11591/ijpeds.v15.i1.pp74-90>

- Krishnan, R. (2017). *Permanent magnet synchronous and brushless DC motor drives*. CRC press.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kudelina, K., Vaimann, T., Rassölkin, A., & Kallaste, A. (2021, 13-16 Oct. 2021). Impact of Bearing Faults on Vibration Level of BLDC Motor. IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society,
- Kumar, A., Marwaha, S., Manna, M. S., Marwaha, A., Kumar, R., Amir, M., Bajaj, M., & Zaitsev, I. (2025). Comparative analysis of brushless DC and switched reluctance motors for optimizing off-grid water pumping. *Scientific Reports*, 15(1), 3527.
- Kumar, T., Brennan, R., Mileo, A., & Bendeache, M. (2023). Image Data Augmentation Approaches: A Comprehensive Survey and Future Directions. *IEEE Access*, 12, 187536-187571. <https://doi.org/10.1109/ACCESS.2024.3470122>
- Lai, Y., Hu, X., Shi, G., Yu, J., Wang, L., & Gao, Z. (2023). Loss and Efficiency Analysis of the Brushless Direct Current Motor with an Amorphous Stator Core. *Journal of Electrical Engineering & Technology*, 18(3), 2075-2085. <https://doi.org/10.1007/s42835-022-01291-0>
- Lale, T., & Yürksek, G. (2025). Identification and classification of turn short-circuit and demagnetization failures in PMSM using LSTM and GRU methods. *Bulletin of the Polish Academy of Sciences. Technical Sciences*, 73(1).
- Lan, T., Gao, Z.-W., Yin, H., & Liu, Y. (2023). A Sensor-Fault-Estimation Method for Lithium-Ion Batteries in Electric Vehicles. *Sensors (Basel, Switzerland)*, 23. <https://doi.org/10.3390/s23187737>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. <https://doi.org/10.1109/5.726791>
- Lee, D., Choo, H., & Jeong, J. (2023). Anomaly detection based on 1D-CNN-LSTM auto-encoder for bearing data. *WSEAS Trans. Inf. Sci. Appl*, 20, 1-6.

- Lee, H., Jeong, H., & Kim, S. W. (2019, 1-4 Dec. 2019). Detection of Interturn Short-Circuit Fault and Demagnetization Fault in IPMSM by 1-D Convolutional Neural Network. 2019 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC),
- Lei, Y., Lin, J., He, Z., & Zuo, M. J. (2013). A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 35(1-2), 108-126.
- Lei, Y., Liu, Z., Ouazri, J., & Lin, J. (2015). A fault diagnosis method of rolling element bearings based on CEEMDAN. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 231(10), 1804-1815. <https://doi.org/10.1177/0954406215624126>
- Li, J., Li, Z., Zhang, J., Zhao, S., Cheng, F., Qian, C., Hu, X., & Zhou, G. (2023). Automated Monitoring of the Uniform Demagnetization Faults in Permanent-Magnet Synchronous Motors: Practical Methods and Challenges. *Sustainability*, 15(23), 16326. <https://www.mdpi.com/2071-1050/15/23/16326>
- Li, Q., Yan, M., & Xu, J. (2021). Optimizing Convolutional Neural Network Performance by Mitigating Underfitting and Overfitting. *2021 IEEE/ACIS 19th International Conference on Computer and Information Science (ICIS)*, 126-131. <https://doi.org/10.1109/ICIS51600.2021.9516868>
- Li, W., Qiu, M., Zhu, Z., Jiang, F., & Zhou, G. (2017). Fault diagnosis of rolling element bearings with a spectrum searching method. *Measurement Science and Technology*, 28(9), 095008.
- Li, Y.-x., & Wang, L. (2020). A novel noise reduction technique for underwater acoustic signals based on complete ensemble empirical mode decomposition with adaptive noise, minimum mean square variance criterion and least mean square adaptive filter. *Defence Technology*, 16(3), 543-554. <https://doi.org/10.1016/j.dt.2019.07.020>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019. <https://doi.org/10.1109/TNNLS.2021.3084827>

- Liang, P., Wang, W., Yuan, X., Liu, S., Zhang, L., & Cheng, Y. (2022). Intelligent fault diagnosis of rolling bearing based on wavelet transform and improved ResNet under noisy labels and environment. *Engineering Applications of Artificial Intelligence*, 115, 105269. <https://doi.org/10.1016/j.engappai.2022.105269>
- Lin, J., & Silfvenius, C. (2025). Some Critical Thinking on Electric Vehicle Battery Reliability: From Enhancement to Optimization. *Batteries*. <https://doi.org/10.3390/batteries11020048>
- Lin, S.-L. (2021). Application Combining VMD and ResNet101 in Intelligent Diagnosis of Motor Faults. *Sensors*, 21(18), 6065. <https://www.mdpi.com/1424-8220/21/18/6065>
- Liu, H., Li, L., & Ma, J. (2016). Rolling Bearing Fault Diagnosis Based on STFT-Deep Learning and Sound Signals. *Shock and Vibration*, 2016, 6127479. <https://doi.org/10.1155/2016/6127479>
- Liu, Y., Wang, L., Yang, L., Liu, X., & Wang, L. (2021). Runoff prediction and analysis based on improved CEEMDAN-OS-QR-ELM. *IEEE Access*, 9, 57311-57324.
- Liu, Z., Zhang, G., & Du, G. (2024). An Investigation into the Pole–Slot Ratio and Optimization of a Low-Speed and High-Torque Permanent Magnet Motor. *Applied Sciences*. <https://doi.org/10.3390/app14103983>
- Liyanagedera, N. D., Bareham, C. A., Kempton, H., & Guesgen, H. W. (2025). Novel machine learning-driven comparative analysis of CSP, STFT, and CSP-STFT fusion for EEG data classification across multiple meditation and non-meditation sessions in BCI pipeline. *Brain Informatics*, 12(1), 4. <https://doi.org/10.1186/s40708-025-00251-4>
- Loparo, K. (2012). Case western reserve university bearing data center. *Bearings Vibration Data Sets, Case Western Reserve University*, 22-28.
- Lou, X., & Loparo, K. A. (2004). Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical Systems and Signal Processing*, 18(5), 1077-1095. [https://doi.org/10.1016/S0888-3270\(03\)00077-3](https://doi.org/10.1016/S0888-3270(03)00077-3)
- Louzada, A. O., Souza, W. A., Vitor, A. L., Castoldi, M. F., & Goedel, A. (2025). Detection of Stator Faults in Three-Phase Induction Motors Using Stray Flux and Machine Learning. *Energies*, 18(6), 1516.

- Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., & Zhang, G. (2015). Transfer learning using computational intelligence: A survey. *Knowl. Based Syst.*, 80, 14-23. <https://doi.org/10.1016/j.knosys.2015.01.010>
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91-99. <https://doi.org/https://doi.org/10.1016/j.gltp.2022.04.020>
- Maraaba, L. S., Milhem, A. S., Nemer, I. A., Al-Duwaish, H., & Abido, M. A. (2020). Convolutional Neural Network-Based Inter-Turn Fault Diagnosis in LSPMSMs. *IEEE Access*, 8, 81960-81970. <https://doi.org/10.1109/ACCESS.2020.2991137>
- Marcos-Andrade, D., Beltran-Carbajal, F., Esquivel-Cruz, E., Rivas-Camero, I., Gabbar, H. A., & Castelan-Perez, A. (2024). Power Signal Analysis for Early Fault Detection in Brushless DC Motor Drivers Based on the Hilbert–Huang Transform. *World Electric Vehicle Journal*, 15(4), 159. <https://www.mdpi.com/2032-6653/15/4/159>
- Mari, A., Bromley, T., Izaac, J., Schuld, M., & Killoran, N. (2019). Transfer learning in hybrid classical-quantum neural networks. *Quantum*, 4, 340. <https://doi.org/10.22331/Q-2020-10-09-340>
- Mari, S., Bucci, G., Ciancetta, F., Fiorucci, E., & Fioravanti, A. (2024). Impact of measurement uncertainty on fault diagnosis systems: A case study on electrical faults in induction motors. *Sensors*, 24(16), 5263.
- Martyushev, N., Malozyomov, B., Demin, A., Pogrebnoy, A., Efremenkov, E., Valuev, D., & Boltrushevich, A. (2025). Modeling the Reliability of an Electric Car Battery While Changing Its Charging and Discharge Characteristics. *Mathematics*. <https://doi.org/10.3390/math13111832>
- Mathwork. (2025). *Comparison of pre-trained networks* mathworks. <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>
- Mehala, N., & Dahiya, R. (2008). A comparative study of FFT, STFT and wavelet techniques for induction machine fault diagnostic analysis. Proceedings of the 7th WSEAS international conference on computational intelligence, man-machine systems and cybernetics, Cairo, Egypt,

- Mesimäki, J., & Lehtonen, E. (2023). Light electric vehicles: the views of users and non-users. *European Transport Research Review*, 15(1), 33.
- Mini, V., & Ushakumari, S. (2011). Incipient fault detection and diagnosis of induction motor using fuzzy logic. 2011 IEEE Recent Advances in Intelligent Computational Systems,
- Mirza, M., & Osindero, S. (2014). Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784*.
- Mohammad-Alikhani, A., Jamshidpour, E., Dhale, S., Akrami, M., Pardhan, S., & Nahid-Mobarakeh, B. (2025). Fault Diagnosis of Electric Motors by a Channel-Wise Regulated CNN and Differential of STFT. *IEEE Transactions on industry applications*, 61(2), 3066-3077. <https://doi.org/10.1109/TIA.2025.3532556>
- Mohanraj, D., Arul David, R., Verma, R., Sathiyasekar, K., Barnawi, A. B., Chokkalingam, B., & Mihet-Popa, L. (2022). A Review of BLDC Motor: State of Art, Advanced Control Techniques, and Applications. *IEEE Access*, 10, 54833-54869. <https://doi.org/10.1109/ACCESS.2022.3175011>
- Mohanty, S., Gupta, K. K., & Raju, K. S. (2016, 2016/). Vibro-Acoustic Fault Analysis of Bearing Using FFT, EMD, EEMD and CEEMDAN and Their Implications. *Advances in Machine Learning and Signal Processing*, Cham.
- Moseler, O., & Isermann, R. (2000). Application of model-based fault detection to a brushless DC motor. *IEEE transactions on industrial electronics*, 47(5), 1015-1020. <https://doi.org/10.1109/41.873209>
- Mumuni, A., & Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, 16, 100258. <https://doi.org/https://doi.org/10.1016/j.array.2022.100258>
- Muratori, M., Alexander, M., Arent, D., Bazilian, M., Cazzola, P., Dede, E. M., Farrell, J., Gearhart, C., Greene, D., & Jenn, A. (2021). The rise of electric vehicles—2020 status and future expectations. *Progress in Energy*, 3(2), 022002.
- Nagarajaiah, S., & Basu, B. (2009). Output only modal identification and structural damage detection using time frequency & wavelet techniques. *Earthquake Engineering and Engineering Vibration*, 8(4), 583-605.

- Nandi, S., Toliyat, H. A., & Li, X. (2005). Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review. *IEEE Transactions on Energy Conversion*, 20(4), 719-729. <https://doi.org/10.1109/TEC.2005.847955>
- National Instruments. (2005). *LabVIEW Order Analysis Toolkit User Manual*. National Instruments.
- National Instruments. (2024a). *NI-9225 Specifications*. <https://www.ni.com/docs/en-US/bundle/ni-9225-specs/resource/ni-9225-specs.pdf>
- National Instruments. (2024b). *NI-9234 Specifications*. <https://www.ni.com/docs/en-US/bundle/ni-9234-specs/page/specs.html>
- National Instruments. (2024c). *NI-9239 Specifications*. <https://www.ni.com/docs/en-US/bundle/ni-9239-specs/page/specs.html>
- National Instruments. (2024d). *NI SignalExpress*. In National Instruments. <https://www.ni.com/en/support/downloads/software-products/download.signalexpress.html#322415>
- Nyanteh, Y. D., Srivastava, S. K., Edrington, C. S., & Cartes, D. A. (2013). Application of artificial intelligence to stator winding fault diagnosis in Permanent Magnet Synchronous Machines. *Electric Power Systems Research*, 103, 201-213.
- Omakor, J., Miah, M. S., & Chaoui, H. (2024). Battery Reliability Assessment in Electric Vehicles: A State-of-the-Art. *IEEE Access*, 12, 77903-77931. <https://doi.org/10.1109/access.2024.3406424>
- Onvo. (2025, 27 September 2025). *Onvo OV-012 X-Plus 1600W Elektrikli Scooter*. <https://onvo.com.tr/ov-012-x-plus-1600w-elektrikli-scooter>
- Osman, S., & Wang, W. (2016). A Morphological Hilbert-Huang Transform Technique for Bearing Fault Detection. *IEEE Transactions on Instrumentation and Measurement*, 65(11), 2646-2656. <https://doi.org/10.1109/TIM.2016.2598019>
- Otero, J. F. A., López-de-Ipina, K., Caballer, O. S., Marti-Puig, P., Sánchez-Méndez, J. I., Iradi, J., Bergareche, A., & Solé-Casals, J. (2022). EMD-based data augmentation method applied to handwriting data for the diagnosis of Essential Tremor using LSTM networks. *Sci Rep*, 12(1), 12819. <https://doi.org/10.1038/s41598-022-16741-y>
- Owusu Junior, P., Frimpong, S., Adam, A. M., Agyei, S. K., Gyamfi, E. N., Agyapong, D., & Tweneboah, G. (2021). COVID-19 as Information Transmitter to Global

- Equity Markets: Evidence from CEEMDAN-Based Transfer Entropy Approach. *Mathematical Problems in Engineering*, 2021, 8258778. <https://doi.org/10.1155/2021/8258778>
- Oyelade, O., Ezugwu, A., Saha, A., Thieu, N., & Gandomi, A. (2025). Deep learning at the service of metaheuristics for solving numerical optimization problems. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-024-10610-7>
- Padilla-García, E. A., Cervantes-Culebro, H., Rodriguez-Angeles, A., & Cruz-Villar, C. A. (2023). Selection/control concurrent optimization of BLDC motors for industrial robots. *Plos one*, 18(8), e0289717.
- Pan, S. J., & Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359.
- Pellegrino, G., Vagati, A., Boazzo, B., & Guglielmi, P. (2012). Comparison of Induction and PM Synchronous Motor Drives for EV Application Including Design Examples. *IEEE Transactions on industry applications*, 48(6), 2322-2332. <https://doi.org/10.1109/TIA.2012.2227092>
- Perminov, V., Ermakov, V., & Korzun, D. (2020). Fault diagnosis for industrial rotary machinery based on edge computing and neural networking. UBICOMM 2020: The Fourteenth International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies,
- Pietrzak, P., & Wolkiewicz, M. (2023). Demagnetization fault diagnosis of permanent magnet synchronous motors based on stator current signal processing and machine learning algorithms. *Sensors*, 23(4), 1757.
- Pietrzak, P., Wolkiewicz, M., & Orłowska-Kowalska, T. (2022). PMSM stator winding fault detection and classification based on bispectrum analysis and convolutional neural network. *IEEE transactions on industrial electronics*, 70(5), 5192-5202.
- Pindoriya, R. M., Mishra, A. K., Rajpurohit, B. S., & Kumar, R. (2018, 5-10 Aug. 2018). An Analysis of Vibration and Acoustic Noise of BLDC Motor Drive. 2018 IEEE Power & Energy Society General Meeting (PESGM),
- Pinedo-Sanchez, L. A., Mercado-Ravell, D. A., & Carballo-Monsivais, C. A. (2020). Vibration analysis in bearings for failure prevention using CNN. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 42(12), 628.

- Pires, D. F., Pires, V. F., Martins, J., & Pires, A. (2009). Rotor cage fault diagnosis in three-phase induction motors based on a current and virtual flux approach. *Energy conversion and management*, 50(4), 1026-1032.
- Pule, M., Matsebe, O., & Samikannu, R. (2022). Application of PCA and SVM in fault detection and diagnosis of bearings with varying speed. *Mathematical Problems in Engineering*, 2022(1), 5266054.
- Quiroz, J. C., Mariun, N., Mehrjou, M. R., Izadi, M., Misron, N., & Radzi, M. A. M. (2018). Fault detection of broken rotor bar in LS-PMSM using random forests. *Measurement*, 116, 273-280.
- Rajabioun, R., Afshar, M., Mete, M., Ö, A., & Akin, B. (2024). Distributed Bearing Fault Classification of Induction Motors Using 2-D Deep Learning Model. *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, 5(1), 115-125. <https://doi.org/10.1109/JESTIE.2023.3323253>
- Rajini, V., Sundharakumar, K., Nagarajan, V., Karunya, H., Manogaran, H. B., & Memala, W. A. (2024). A Classification Approach for Induction Motor Faults Based on Empirical Mode Decomposition and Machine Learning Algorithms. *Electrica*, 24(2).
- Ramesh Balaji, S., & Chinnusamy, M. (2015). Wavelet transform based fault diagnosis of BLDC motor drive. *TELKOMNIKA Indonesian Journal of Electrical Engineering*, 14(3), 434-440.
- Randall, R. B. (1987). Frequency analysis. *Naerum (DK): Bruel & Kjaer*.
- Randall, R. B. (2021). *Vibration-based condition monitoring: industrial, automotive and aerospace applications*. John Wiley & Sons.
- Rangel, G., Cuevas-Tello, J., Nuñez-Varela, J., Puente, C., & Silva-Trujillo, A. (2024). A Survey on Convolutional Neural Networks and Their Performance Limitations in Image Recognition Tasks. *Journal of Sensors*. <https://doi.org/10.1155/2024/2797320>
- Rastegaeva, I., Rastegaev, I., Agletdinov, E., & Merson, D. (2022). The Comparison of The Main Time-Frequency Transformations of Spectral Analysis of Acoustic Emission Signals. *Frontier materials & technologies*. <https://doi.org/10.18323/2782-4039-2022-1-49-60>

- Reddy, A. S. S., & Pachori, R. B. (2025). Dynamic mode decomposition-based technique for cross-term suppression in the Wigner-Ville distribution. *Digital Signal Processing*, 156, 104833. <https://doi.org/https://doi.org/10.1016/j.dsp.2024.104833>
- Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- Rimpas, D., Kaminaris, S., Piromalis, D., Vokas, G., Arvanitis, K., & Karavas, C.-S. (2023). Comparative Review of Motor Technologies for Electric Vehicles Powered by a Hybrid Energy Storage System Based on Multi-Criteria Analysis. *Energies*. <https://doi.org/10.3390/en16062555>
- Rodríguez, P. V. J., Negrea, M., & Arkkio, A. (2008). A simplified scheme for induction motor condition monitoring. *Mechanical Systems and Signal Processing*, 22(5), 1216-1236. <https://doi.org/https://doi.org/10.1016/j.ymssp.2007.11.018>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. International Conference on Medical image computing and computer-assisted intervention,
- Rosero, J. A., Romeral, L., Ortega, J. A., & Rosero, E. (2009). Short-Circuit Detection by Means of Empirical Mode Decomposition and Wigner–Ville Distribution for PMSM Running Under Dynamic Condition. *IEEE transactions on industrial electronics*, 56(11), 4534-4547. <https://doi.org/10.1109/TIE.2008.2011580>
- Rotontek. (2023). How to choose the right BLDC motor. <https://rotontek.com/how-to-choose-the-right-blcd-motor/>
- Roy, D., & Kumar, C. C. (2024). A Comprehensive Analysis of the Reliability of Electric Vehicle Motor Systems: Exploring the Intricacies of Performance and Durability. *Qeios*. <https://doi.org/10.32388/54rcsu.2>
- Ruan, D., Wang, J., Yan, J., & Gühmann, C. (2023). CNN parameter design based on fault signal analysis and its application in bearing fault diagnosis. *Advanced Engineering Informatics*, 55, 101877.
- Saha, B., Singh, B., & Sen, A. (2023). SMO Based Position Sensorless BLDC Motor Drive Employing Canonical Switching Cell Converter for Light Electric Vehicle. *IEEE Transactions on industry applications*, 59(3), 2974-2984. <https://doi.org/10.1109/TIA.2023.3241607>

- Saifullah, S., Dreżewski, R., Yudhana, A., Caesarendra, W., & Huda, N. (2025). Bio-Inspired Metaheuristics in Deep Learning for Brain Tumor Segmentation: A Decade of Advances and Future Directions. *Information*. <https://doi.org/10.3390/info16060456>
- Samanta, B., & Al-Balushi, K. (2003). Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical Systems and Signal Processing*, 17(2), 317-328.
- Sampath, D. B., Subramaniam, A., & Rodrigues, V. (2023). Life Estimation of Power Electronic Components in Electric Vehicle for Vibration Loads. *2023 IEEE International Transportation Electrification Conference (ITEC-India)*, 1-5. <https://doi.org/10.1109/itec-india59098.2023.10471481>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Sanguesa, J. A., Torres-Sanz, V., Garrido, P., Martinez, F. J., & Marquez-Barja, J. M. (2021). A Review on Electric Vehicles: Technologies and Challenges. *Smart Cities*, 4(1), 372-404. <https://www.mdpi.com/2624-6511/4/1/22>
- Sarmas, E., Dimitropoulos, N., Marinakis, V., Mylona, Z., & Doukas, H. (2022). Transfer learning strategies for solar power forecasting under data scarcity. *Scientific Reports*, 12. <https://doi.org/10.1038/s41598-022-18516-x>
- Saufi, S., Ahmad, Z., Leong, M., & Lim, M. (2019). An intelligent bearing fault diagnosis system: A review. *MATEC Web of Conferences*,
- Scholl, S. (2021). Fourier, Gabor, Morlet or Wigner: Comparison of Time-Frequency Transforms. <https://consensus.app/papers/fourier-gabor-morlet-or-wigner-comparison-of-scholl/a15702656e2d508d8ae5612677f1d86e/>
- Seghiour, A., Seghier, T., & Zegnini, B. (2015, 25-27 May 2015). Diagnostic of the simultaneous of dynamic eccentricity and broken rotor bars using the magnetic field spectrum of the air-gap for an induction machine. 2015 3rd International Conference on Control, Engineering & Information Technology (CEIT),
- Selçuk Aksoy, R. (2022). *Sürekli Mıknatıslı Senkron Motorda Akı Sinyali Kullanılarak Stator Sargı Arızası Teşhisi* (Publication Number Yüksek Lisans) Tokat Gaziosmanpaşa Üniversitesi, Lisansüstü Eğitim Enstitüsü]. Tokat.

- Sharifi, R., & Ebrahimi, M. (2011). Detection of stator winding faults in induction motors using three-phase current monitoring. *ISA Transactions*, 50(1), 14-20. <https://doi.org/https://doi.org/10.1016/j.isatra.2010.10.008>
- Shen, W., Xiao, M., Wang, Z., & Song, X. (2023). Rolling bearing fault diagnosis based on support vector machine optimized by improved grey wolf algorithm. *Sensors*, 23(14), 6645.
- Shi, Y., & Eberhart, R. (1998). A modified particle swarm optimizer. 1998 IEEE international conference on evolutionary computation proceedings. IEEE world congress on computational intelligence (Cat. No. 98TH8360),
- Shifat, T. A., & Hur, J. W. (2020). An Effective Stator Fault Diagnosis Framework of BLDC Motor Based on Vibration and Current Signals. *IEEE Access*, 8, 106968-106981. <https://doi.org/10.1109/ACCESS.2020.3000856>
- Shinde, S., Kulkarni, U., Mane, D., & Sapkal, A. (2021). Deep Learning-Based Medical Image Analysis Using Transfer Learning. 19-42. https://doi.org/10.1007/978-981-15-9735-0_2
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1-48.
- Singh, P., & Harsha, S. (2019). Statistical and frequency analysis of vibrations signals of roller bearings using empirical mode decomposition. *Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics*, 233(4), 856-870. <https://doi.org/10.1177/1464419319847921>
- Sinha, P., Psaromiligkos, I., & Zilic, Z. (2023). A Structurally Regularized CNN Architecture via Adaptive Subband Decomposition. *IEEE Transactions on Neural Networks and Learning Systems*, PP. <https://doi.org/10.1109/tnnls.2024.3486181>
- Song, Q., Wang, M., Lai, W., & Zhao, S. (2022). Multiscale Kernel-Based Residual CNN for Estimation of Inter-Turn Short Circuit Fault in PMSM. *Sensors*, 22(18), 6870. <https://www.mdpi.com/1424-8220/22/18/6870>
- Song, Q., Wang, M., Lai, W., & Zhao, S. (2023). On Bayesian Optimization-Based Residual CNN for Estimation of Inter-Turn Short Circuit Fault in PMSM. *IEEE Transactions on Power Electronics*, 38(2), 2456-2468. <https://doi.org/10.1109/TPEL.2022.3207181>

- Soontornnapar, T., & Ploysuwan, T. (2025). A novel approach to enhanced fall detection using STFT and magnitude features with CNN autoencoder. *Neural Computing and Applications*, 37(6), 4229-4245.
- Srivastava, N., Hinton, G., & Krizhevsky, A. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929.
- Su, J., Yu, X., Wang, X., Wang, Z., & Chao, G. (2024). Enhanced transfer learning with data augmentation. *Engineering Applications of Artificial Intelligence*, 129, 107602. <https://doi.org/10.1016/j.engappai.2023.107602>
- Suarez-Bertoa, R., & Astorga, C. (2016). Unregulated emissions from light-duty hybrid electric vehicles. *Atmospheric Environment*, 136, 134-143. <https://doi.org/10.1016/j.atmosenv.2016.04.021>
- Suawa, P., Meisel, T., Jongmanns, M., Huebner, M., & Reichenbach, M. (2022). Modeling and fault detection of brushless direct current motor by deep learning sensor data fusion. *Sensors*, 22(9), 3516.
- Sulistyo, M. E., Susilo, D. D., Nizam, M., & Ubaidillah, U. (2025). A Literature Review: Bearing Fault in BLDC Motor Based on Vibration and Thermal Signals. *Journal of Electrical, Electronic, Information, and Communication Technology*, 7(1), 10-15.
- Sun, Q., Yu, X., Li, H., & Fan, J. (2022). Adaptive feature extraction and fault diagnosis for three-phase inverter based on hybrid-CNN models under variable operating conditions. *Complex & Intelligent Systems*, 8(1), 29-42. <https://doi.org/10.1007/s40747-021-00337-6>
- Sun, X., Wang, S., Jing, J., Shen, Z., & Zhang, L. (2023). Fault diagnosis using transfer learning with dynamic multiscale representation. *Cognitive Robotics*, 3, 257-264. <https://doi.org/10.1016/j.cogr.2023.07.006>
- Sun, Z., Machlev, R., Wang, Q., Belikov, J., Levron, Y., & Baimel, D. (2023). A public data-set for synchronous motor electrical faults diagnosis with CNN and LSTM reference classifiers. *Energy and AI*, 14, 100274. <https://doi.org/10.1016/j.egyai.2023.100274>

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE transactions on medical imaging*, 35(5), 1299-1312.
- Tang, Q., Shu, X., Zhu, G., Wang, J., & Yang, H. (2021). Reliability Study of BEV Powertrain System and Its Components—A Case Study. *Processes*, 9(5), 762. <https://www.mdpi.com/2227-9717/9/5/762>
- Tao, Y., Wang, X., Bao, X., Xue, H., Yue, H., Feng, H., & Yang, D. (2025). Fault Diagnosis of In-Wheel Motors Used in Electric Vehicles: State of the Art, Challenges, and Future Directions. *Machines*. <https://doi.org/10.3390/machines13080711>
- Texas Instruments. (2020). *DRV425-Q1 Automotive, Integrated Fluxgate Magnetic-Field Sensor*. Texas Instruments.
- Tian, H., Fan, H., Feng, M., Cao, R., & Li, D. (2023). Fault Diagnosis of Rolling Bearing Based on HPSO Algorithm Optimized CNN-LSTM Neural Network. *Sensors*, 23(14), 6508. <https://www.mdpi.com/1424-8220/23/14/6508>
- Tomar, V., Bansal, M., & Singh, P. (2024). Metaheuristic Algorithms for Optimization: A Brief Review. *RAiSE-2023*. <https://doi.org/10.3390/engproc2023059238>
- Torres, M. E., Colominas, M. A., Schlotthauer, G., & Flandrin, P. (2011). A complete ensemble empirical mode decomposition with adaptive noise. 2011 IEEE international conference on acoustics, speech and signal processing (ICASSP), 1-5.
- Tran, T. H., Liang, H., Li, W., & Pham, M. T. (2021). Comparison of Machine Learning Algorithms for Induction Motor Rotor Single Fault Diagnosis using Stator Current Signal. *International Journal of Advanced Trends in Computer Science and Engineering*, 10(3), 1509-1514.
- Tran, V. T., Yang, B.-S., Oh, M.-S., & Tan, A. C. C. (2009). Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 36(2, Part 1), 1840-1849. <https://doi.org/https://doi.org/10.1016/j.eswa.2007.12.010>

- Ullah, Z., Lodhi, B. A., & Hur, J. (2020). Detection and identification of demagnetization and bearing faults in PMSM using transfer learning-based VGG. *Energies*, 13(15), 3834.
- Usman, A., & Rajpurohit, B. S. (2019). Comprehensive Analysis of Demagnetization Faults in BLDC Motors Using Novel Hybrid Electrical Equivalent Circuit and Numerical Based Approach. *IEEE Access*, 7, 147542-147552. <https://doi.org/10.1109/ACCESS.2019.2946694>
- Usman, A., & Rajpurohit, B. S. (2020). Modeling and Classification of Stator Inter-Turn Fault and Demagnetization Effects in BLDC Motor Using Rotor Back-EMF and Radial Magnetic Flux Analysis. *IEEE Access*, 8, 118030-118049. <https://doi.org/10.1109/ACCESS.2020.3005038>
- Usman, A., & Rajpurohit, B. S. (2024). Condition monitoring of permanent magnet AC machines for all-electric transportation systems: State of the art. *IET Energy Systems Integration*, 6(3), 213-229.
- Velchenko, A., Pauliukavets, S., & Radkevich, A. (2024). Mathematical model of brushless dc motor based on the voltage equation of a three-phase winding. «System analysis and applied information science». <https://doi.org/10.21122/2309-4923-2024-1-19-25>
- Vippala, S. R., Bhat, S., & Reddy, A. A. (2021, 8-10 Jan. 2021). Condition Monitoring of BLDC Motor Using Short Time Fourier Transform. 2021 IEEE Second International Conference on Control, Measurement and Instrumentation (CMI),
- Vrbancic, G., & Podgorelec, V. (2020). Transfer Learning With Adaptive Fine-Tuning. *IEEE Access*, 8, 196197-196211. <https://doi.org/10.1109/access.2020.3034343>
- Wang, D., Li, Y., Jia, L., Song, Y., & Liu, Y. (2021). Novel Three-Stage Feature Fusion Method of Multimodal Data for Bearing Fault Diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-10. <https://doi.org/10.1109/TIM.2021.3071232>
- Wang, J., Wang, H., Lu, S., & Shao, H. (2021, 21-23 Oct. 2021). Interturn Short Circuit Fault Diagnosis of Brushless DC Motor Based on Image Feature Extraction and Transfer Learning. 2021 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD),

- Wang, L.-H., Zhao, X.-P., Wu, J.-X., Xie, Y.-Y., & Zhang, Y.-H. (2017). Motor fault diagnosis based on short-time Fourier transform and convolutional neural network. *Chinese Journal of Mechanical Engineering*, 30(6), 1357-1368.
- Wang, L., Qin, P., Du, Z.-t., & Wu, Y. (2024). Failure analysis for outer ring cracking of GCr15 rolling bearing. *Engineering Failure Analysis*, 157, 107874. <https://doi.org/https://doi.org/10.1016/j.engfailanal.2023.107874>
- Wang, X., Mao, D., & Li, X. (2021). Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network. *Measurement*, 173, 108518. <https://doi.org/https://doi.org/10.1016/j.measurement.2020.108518>
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big Data*, 3(1), 9.
- Wu, J.-D., Luo, W.-J., & Yao, K.-C. (2025). Electric Motor Vibration Signal Classification Using Wigner–Ville Distribution for Fault Diagnosis. *Sensors*, 25(4), 1196. <https://www.mdpi.com/1424-8220/25/4/1196>
- Wu, Z., & Huang, N. E. (2009). Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, 1(01), 1-41.
- Xu, B., Li, H., Ding, R., & Zhou, F. (2025). Fault diagnosis in electric motors using multi-mode time series and ensemble transformers network. *Scientific Reports*, 15(1), 7834. <https://doi.org/10.1038/s41598-025-89695-6>
- Xu, L., Teoh, S. S., & Ibrahim, H. (2024). A deep learning approach for electric motor fault diagnosis based on modified InceptionV3. *Scientific Reports*, 14(1), 12344.
- Yamashita, R., Nishio, M., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9, 611-629. <https://doi.org/10.1007/s13244-018-0639-9>
- Yan, Z., Zhang, H., Piramuthu, R., Jagadeesh, V., DeCoste, D., Di, W., & Yu, Y. (2015). HD-CNN: hierarchical deep convolutional neural networks for large scale visual recognition. Proceedings of the IEEE international conference on computer vision,
- Yang, Y., Jing, J., Zhang, J., Liu, Z., & Li, X. (2025). Discriminative fault diagnosis transfer learning network under joint mechanism. *Scientific Reports*, 15(1), 8888.
- Ye, M., Gong, R., Wu, W., Peng, Z., & Jia, K. (2025). Fault Diagnosis of Permanent Magnet Synchronous Motor Based on Wavelet Packet Transform and Genetic

- Algorithm-Optimized Back Propagation Neural Network. *World Electric Vehicle Journal*, 16(4), 238.
- Ye, M., Yan, X., & Jia, M. (2021). Rolling Bearing Fault Diagnosis Based on VMD-MPE and PSO-SVM. *Entropy*, 23(6), 762. <https://www.mdpi.com/1099-4300/23/6/762>
- Yeşilyurt, İ., Özdemir, Ö., & Uşak, U. (2015). Dengesiz Yüke Maruz Silindirik Masuralı Rulman Arızasının Kısa Zamanlı Fourier Dönüşümü Yardımıyla Belirlenmesi. *Uluslararası Katılımlı*, 17, 14-17.
- Yildirim, O., Talo, M., Ay, B., Baloglu, U. B., Aydın, G., & Acharya, U. R. (2019). Automated detection of diabetic subject using pre-trained 2D-CNN models with frequency spectrum images extracted from heart rate signals. *Computers in Biology and Medicine*, 113, 103387. <https://doi.org/https://doi.org/10.1016/j.compbiomed.2019.103387>
- Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in neural information processing systems*, 27.
- Younas, M. B., Ullah, N., Goktas, T., Arkan, M., & Gurusamy, V. (2021, 22-25 Aug. 2021). The Performance Evaluation of Machine Learning based Techniques via Stator Current and Stray Flux for Broken Bar Fault in Induction Motors. 2021 IEEE 13th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED),
- Zhang, J., Sun, Y., Guo, L., Gao, H., Hong, X., & Song, H. (2020). A new bearing fault diagnosis method based on modified convolutional neural networks. *Chinese Journal of Aeronautics*, 33(2), 439-447. <https://doi.org/https://doi.org/10.1016/j.cja.2019.07.011>
- Zhang, Q., & Deng, L. (2023). An Intelligent Fault Diagnosis Method of Rolling Bearings Based on Short-Time Fourier Transform and Convolutional Neural Network. *Journal of Failure Analysis and Prevention*, 23(2), 795-811. <https://doi.org/10.1007/s11668-023-01616-9>
- Zhang, Q., & Feng, M. (2018). Fast fault diagnosis method for Hall sensors in brushless DC motor drives. *IEEE Transactions on Power Electronics*, 34(3), 2585-2596.
- Zhang, X., Xiong, Y., Pan, Y., Du, H., & Liu, B. (2023). Crushing stress and vibration fatigue-life optimization of a battery-pack system. *Structural and*

- Multidisciplinary Optimization*, 66(3), 48. <https://doi.org/10.1007/s00158-023-03510-2>
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artif. Intell. Rev.*, 57, 99. <https://doi.org/10.1007/s10462-024-10721-6>
- Zhou, J., Xiao, M., Niu, Y., & Ji, G. (2022). Rolling bearing fault diagnosis based on WGWOA-VMD-SVM. *Sensors*, 22(16), 6281.
- Zhou, W., Li, W.-J., & Ren, W.-X. (2025). STFT-based Time-Frequency Mode Decomposition: A Fast and Robust Method for Multicomponent Signal Analysis. *arXiv preprint arXiv:2507.11919*.
- Zhu, Z. Q., & Howe, D. (2007). Electrical Machines and Drives for Electric, Hybrid, and Fuel Cell Vehicles. *Proceedings of the IEEE*, 95(4), 746-765. <https://doi.org/10.1109/JPROC.2006.892482>
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76.
- Zou, Y. (2025). Advancing Mathematical Optimization Methods: Applications, Challenges, and Future Directions. *Theoretical and Natural Science*. <https://doi.org/10.54254/2753-8818/2025.20116>

ÖZGEÇMİŞ

