


Asenkron Motorlarda Arıza Tespiti ve Akıllı Sınıflandırma Teknikleri

Dr. Eyüp ÇAKI

Editör: Prof. Dr. Abdülkadir ÇAKIR



Asenkron Motorlarda Arıza Tespiti ve Akıllı Sınıflandırma Teknikleri

Dr. Eyüp ÇAKI

Editör

Prof. Dr. Abdülkadir ÇAKIR



Published by

Özgür Yayın-Dağıtım Co. Ltd.

Certificate Number: 45503

📍 15 Temmuz Mah. 148136. Sk. No: 9 Şehitkamil/Gaziantep

☎ +90.850 260 09 97

📞 +90.532 289 82 15

🌐 www.ozgurayinlari.com

✉ info@ozgurayinlari.com

Asenkron Motorlarda Arıza Tespiti ve Akıllı Sınıflandırma Teknikleri

Dr. Eyüp ÇAKI • Editör: Prof. Dr. Abdülkadir ÇAKIR

Language: Turkish

Publication Date: 2024

Cover design by Mehmet Çakır

Cover design and image licensed under CC BY-NC 4.0

Print and digital versions typeset by Çizgi Medya Co. Ltd.

ISBN (PDF): 978-625-5958-07-5

DOI: <https://doi.org/10.58830/ozgur.pub629>



This work is licensed under the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0). To view a copy of this license, visit <https://creativecommons.org/licenses/by-nc/4.0/>
This license allows for copying any part of the work for personal use, not commercial use, providing author attribution is clearly stated.

Suggested citation:

Çakı, E., Çakır, A. (ed) (2024). *Asenkron Motorlarda Arıza Tespiti ve Akıllı Sınıflandırma Teknikleri*.

Özgür Publications. DOI: <https://doi.org/10.58830/ozgur.pub629>. License: CC-BY-NC 4.0

The full text of this book has been peer-reviewed to ensure high academic standards. For full review policies, see <https://www.ozgurayinlari.com/>



Önsöz

Bu kitap, endüstriyel uygulamalarda yaygın olarak kullanılan asenkron motorlar için arıza tespit ve teşhis süreçlerini kapsamlı bir şekilde ele almaktadır. Çalışma, rotor çubuğu arızaları, eksenel kaçıklıklar ve rulman problemleri gibi arızaların tespiti, sınıflandırılması ve önlenmesine odaklanmaktadır. Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve ansambl yaklaşımları (Rastgele Orman, XGBoost) gibi makine öğrenimi ve yapay zeka tabanlı yöntemlerin arıza sınıflandırma ve tahminindeki avantajları vurgulanmaktadır.

PCA ve LDA gibi boyut indirgeme tekniklerinin, hesaplama etkinliğini artırmadaki ve aşırı öğrenme risklerini azaltmadaki önemi ele alınmıştır. Gerçek zamanlı uygulamalar, IoT entegrasyonu ve bulut tabanlı analizler, dinamik endüstriyel ortamlarda kesintisiz ve verimli arıza izleme açısından önemli katkılar sağlamaktadır. Kestirimci bakım stratejileri, zaman serisi analizi ve gelişmiş sınıflandırma algoritmaları ile makine sağlığı izlemeyi ve bakım planlarını optimize etmeyi hedefleyen etkili yaklaşımlar sunulmaktadır.

Gürültülü ortamların, eksik verilerin ve sensör hatalarının oluşturduğu zorluklar üzerinde durulmuş; sensör füzyonu ve ansambl yöntemlerin bu sorunlara karşı sunduğu çözümler tartışılmıştır. Doğruluk, hassasiyet, duyarlılık, F1 skoru ve AUC-ROC gibi performans ölçütleri kapsamlı bir şekilde değerlendirilmiş; algoritmaların hız, bellek kullanımı ve ölçeklenebilirlik açısından güçlü ve zayıf yönleri karşılaştırılmıştır.

Otomotiv, enerji ve petrokimya gibi çeşitli sektörlerdeki vaka analizleriyle, asenkron motorlarda arıza teşhis sistemlerinin etkinliğini artırmaya yönelik teorik ve pratik yaklaşımlar ortaya konulmuştur. Bu çalışma, mühendisler ve araştırmacılar için değerli bir rehber niteliği taşımaktadır.

İçindekiler

Önsöz	iii
Simgeler ve Kısaltmalar Dizini	vii
1. Giriş	1
2. Üç Fazlı Asenkron Motorların Yapısı ve İşleyişi	5
Stator, Rotor ve Rulmanların Temel Yapısı	5
Elektriksel ve Mekanik Arızaların Sınıflandırılması	7
Üç Fazlı Asenkron Motorların Çalışma Prensipleri, Performans ve Verimlilik İlişkisi	8
Endüstriyel Uygulamalarda Üç Fazlı Asenkron Motorların Rolü	9
3. Asenkron Motor Arızaları: Türler ve Nedenler	11
Rulman Arızaları	12
Rotor Arızaları (Kırık Rotor Çubuğu)	13
Stator Arızaları	14
Kapsamlı Bakış, Uygulama Yöntemleri ve Geleceğe Dönük Yaklaşımlar	14
4. Akıllı Sınıflandırma Yöntemleri	17
Örüntü Tanıma Tekniklerinin Tanıtımı	18
Naive Bayes Sınıflandırıcısı	18
Destek Vektör Makineleri (SVM)	19
Yapay Sinir Ağları (ANN)	20
C4.5 Karar Ağacı ve Diğer Yöntemler	20
Uygulama Örnekleri, Veri Ön İşleme ve Parametre Seçimi	21
Gelecek Yönelimleri ve Derin Öğrenme	21
5. Deneysel Yöntemler ve Veriler	23
Deney Düzenliği ve Asenkron Motor Özellikleri	23
Veri Toplama ve İşleme Yöntemleri	29
Gerilim ve Yük Değişkenliğinin Etkileri	30
Arıza Oluşturma ve Test Senaryoları	30
Doğrulama, Eğitim-Doğrulama Stratejileri ve Model Genellemesi	31

6. Akıllı Sınıflandırıcılarla Arıza Tespiti	33
Veri Hazırlama, Ön İşleme ve Özellik Seçimi	34
Farklı Arıza Türlerinde Sınıflandırıcıların Uygulanması	35
Gerçek Zamanlı Uygulamalar, IoT Entegrasyonu ve Bulut Tabanlı Analiz	36
Kestirimci Bakım ve Dijital İkiz Teknolojisi	36
Gürültülü Ortamlar, Sensör Füzyonu ve Ansambl Yöntemler	37
Performans Ölçütleri ve Karar Alma Süreçleri	37
Uygulama Örnekleri	38
7. Yöntemlerin Performans Değerlendirmesi	39
Sınıflandırma Algoritmalarının Avantaj ve Dezavantajları	39
Performans Metriklerinin Değerlendirilmesi	45
Algoritmaların Karşılaştırılması	48
Uygulama Alanları ve Vaka Analizleri	50
Karar Alma Süreçleri	53
Yöntemlerin Sınırlılıkları ve Gelecek Çalışmalar İçin Öneriler	55
8. Endüstriyel Uygulamalar ve Gelecek Perspektifleri	59
Akıllı Arıza Tespiti Sistemlerinin Endüstrideki Uygulamaları	59
Gerçek Zamanlı Sistemler ve Gelecek Perspektifleri	60
9. Sonuç ve Öneriler	63
Çalışmanın Ana Bulguları	63
Akıllı Yöntemlerin Geleceği	65
Kaynaklar	69

Simgeler ve Kısaltmalar Dizini

AA	Alternatif Akım
ANN	Yapay Sinir Ağları (Artificial Neural Networks).
AUC	Area Under Curve (Eğri Altındaki Alan).
B	Naive Bayes.
CNN	Evrışimsel Sinir Ağı (Convolutional Neural Network).
Cos phi	Güç katsayısı
d/dk	devir/dakika
DAQ	Veri Toplama Kartı (Data Acquisition Card).
DC	Direct Current (Doğru Akım)
DSP	Dijital Sinyal İşleme (Digital Signal Processing)
f	Frekans
F1 Skoru	Harmonik Ortalama (Precision ve Recall).
FN	Yanlış Negatif (False Negative).
FP	Yanlış Pozitif (False Positive).
FPGA	Programlanabilir Kapı Dizisi (Field-Programmable Gate Array).
GRU	Kapılı Tekrarlayan Ünite (Gated Recurrent Unit).
IEEE	Elektrik ve Elektronik Mühendisleri Enstitüsü
IoT	Nesnelerin İnterneti (Internet of Things).
KNN	K-En Yakın Komşu (K-Nearest Neighbors).
kW	Kilowatt
LDA	Lineer Ayrıştırıcı Analiz (Linear Discriminant Analysis).
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory).
MCSA	Motor Current Signature Analysis (Motor Akım Sinyalleri Analizi)

MLP	Multi-layer Perceptron (Çok Katmanlı Algılayıcılar)
mm	milimetre
PCA	Temel Bileşen Analizi (Principal Component Analysis).
RF	Rastgele Orman (Random Forest).
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği).
s	Kayma
STFT	Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transform).
SVM	Destek Vektör Makineleri (Support Vector Machines).
TN	Doğru Negatif (True Negative).
TP	Doğru Pozitif (True Positive).
TSE	Türk Standartlar Enstitüsü
XGBoost	Extreme Gradient Boosting.

1. Giriş

A. Elektrik Motorlarının Sanayi Sektöründeki Önemi

Elektrik motorları, endüstrinin birçok alanında enerji dönüşümünde kullanılmaktadır. Küresel ölçekte artan rekabet, yoğun üretim talebi, yüksek kalite beklentileri ve sürdürülebilirlik hedefleri, işletmelerin üretim süreçlerini daha verimli, kesintisiz ve esnek hale getirme arayışını zorunlu kılmaktadır. Bu noktada, elektrik motorlarının güvenilir, uzun ömürlü, verimli ve öngörülebilir bir şekilde çalışması, sanayi kuruluşlarının başarısı açısından önem arz etmektedir. Üretim hatlarında meydana gelebilecek herhangi bir motor arızası; plansız duruşlar, maliyet artışları, ürün kalitesinde düşüşler ve müşteri memnuniyetsizliği ile sonuçlanabilir. Özellikle sanayi kuruluşlarında tüketilen elektriğin önemli bir bölümünü motorlar oluşturmaktadır ve bu nedenle, enerji maliyetlerinin azaltılması, karbon salınımının düşürülmesi, işletme giderlerinin kontrol altına alınması gibi hedefler doğrudan motor performansına bağlıdır. Bu nedenlerle, elektrik motorlarının durumu, sadece teknik değil, aynı zamanda ekonomik ve çevresel bir öneme de sahiptir [1-3].

B. Üç Fazlı Asenkron Motorların Özellikleri ve Yaygın Kullanımı

Üç fazlı asenkron motorlar, elektrik enerjisinin mekanik enerjiye dönüşümünde en yaygın ve tercih edilenidir. Bu konumun oluşmasında birçok etken rol oynamaktadır. Öncelikle, basit ve sağlam yapıları onları hem tasarım hem de üretim açısından avantajlı kılmaktadır. Rotorlarında fırça, bilezik veya karmaşık sargılar yerine sincap kafes yapısının kullanılması, bu motorların dayanıklılığını arttırmakta ve bakım gereksinimlerini azaltmaktadır. Ayrıca, sincap kafesli rotor yapısı, motorun uzun süre yüksek

performansta, neme, toza, titreşime ve hatta değişken ortam koşullarına rağmen güvenilir bir şekilde çalışmasını sağlamaktadır [4,5].

Asenkron motorların bir diğer önemli özelliği, farklı güç, hız ve tork gereksinimlerine uyum sağlamada esneklerdir. Küçük atölyelerden endüstriyel fabrikalara, basit pompa ve fan uygulamalarından çelik haddehanelere, otomotiv üretim bantlarından kimya tesislerine kadar uzanan geniş bir yelpazede. Tek bir motor tipinin bu kadar farklı uygulama alanına hitap edebilmesi, endüstrinin vazgeçilmez bir elemanı olmasını sağlar. Örneğin, gıda işleme tesislerinde hassas hijyen standartlarını korurken, çelik üretiminde yüksek sıcaklık ve ağır yüklere karşı dayanım gösterebilirler. Bu motorların aynı zamanda enerji kalitesine ve şebeke koşullarına toleranslı oluşu, endüstriyel altyapıda kolayca kullanılabilir kılmıştır [6-8].

Üç fazlı asenkron motorların endüstriyel otomasyon sistemlerine entegrasyonu da oldukça kolaydır. Güç elektroniği teknolojilerinin ve akıllı sürücülerin (VFD – Değişken Frekanslı Sürücü) yaygınlaşması, asenkron motorların hız, tork ve güç kontrolünü daha kolay hale getirmiştir. Bu sayede prosesler optimize edilebilir, enerji verimliliği artırılabilir ve belirli üretim parametrelerine hassas bir şekilde uyum sağlanabilmektedir. Modern izleme, kontrol ve haberleşme protokolleri (örn. Endüstri 4.0 konseptinde IoT tabanlı çözümler) ile desteklenen asenkron motorlar, üretim hatlarının dijitalleşme süreçlerinde merkezi bir rol üstlenmektedir. Bu motorlar, sürekli gelişen yalıtım malzemeleri, rulman teknolojisi, soğutma yöntemleri ve kaplama teknikleriyle de uzun vadeli performans sağlamaktadır.

Ayrıca, asenkron motorların standart olması ve yaygın olarak kabul görmüş tasarım normları, bakım-onarım ve yedek parça tedarik süreçlerinde de kolaylıklar sunmaktadır. Dünya çapında birçok tedarikçinin benzer standartları takip etmesi, motor değişim, revizyon ve modernizasyon çalışmalarını basitleştirir, maliyetleri düşürür ve duruş sürelerini kısaltır. Bu standartlaşma, mühendislerin ve teknisyenlerin eğitimini kolaylaştırdığı gibi global ölçekte bir bilgi birikimi ve tecrübe havuzunun oluşmasına da katkıda bulunmaktadır. Böylece, firma ve çalışanlar teknik açıdan hızlı uyum sağlayabildiği, öngörülebilir bakım stratejisine imkân tanıyan güvenilir makineler olarak ön plana çıkmaktadır.

Sonuç olarak, üç fazlı asenkron motorlar, işletmelerin üretim süreçlerini kesintisiz, verimli ve esnek bir şekilde yönetmelerine yardımcı olur. Sağlam yapıları, düşük bakım ihtiyacı, geniş kullanım alanı, kontrol edilebilirlikleri, enerji verimliliğine elverişli olmaları ve yaygın standardizasyonları nedeniyle, elektrik enerjisinin mekanik enerjiye dönüşümünde önemli rol oynamaktadır. Bu özellikleri onların sadece endüstriyel üretim hatlarında değil, tarımdan

su arıtmaya, ısıtma-soğutma sistemlerinden denizcilik uygulamalarına kadar geniş bir alanda çeşitli kullanılmaları bulunmaktadır.

C. Motor Arızalarının Önemi ve Arıza Tespitine Olan İhtiyaç

Üç fazlı asenkron motorların sağlam yapıları ve bakım gerektirmemelerine rağmen zamana ve çalışma koşullarının zorluklarına bağlı olarak arızalanabilirler. Bu arızalar; rotor çubuklarının kırılması, stator sargısında meydana gelen izolasyon hataları, rulman problemleri, eksenel kaçıklık, şebeke dengesizlikleri şeklinde ortaya çıkmaktadır. Bu sorunlar motor performansının düşmesine, enerji sarfiyatının artmasına ve işletme maliyetlerinin yükselmesine neden olmaktadır. Örneğin beklenmeyen bir motor arızası, tüm üretim hattını durma noktasına getirebilir ve yüksek miktarda üretim kaybına yol açabilir. Bu durumda işletmeler sadece bakım ve onarım giderleriyle değil, aynı zamanda müşteri memnuniyetinde azalma, pazar payı kaybı ve rekabet gücünde düşüş ile de karşı karşıya kalmaktadır [7].

Geleneksel periyodik bakım yaklaşımları, belli aralıklarla bakım ve kontrol yaparak arızaları engellemeye çalışır. Ancak bu yöntem, her zaman yeterince etkili değildir. Bekleme süresi gerektirmeden üretimin her anında motorun durumunu izleyebilmek, potansiyel bir arızanın ilk işaretlerini yakalayabilmek işletmeye büyük avantajlar sağlamaktadır. Özellikle pahalı önleyici bakım masraflarını azaltmak, bakım planlamasını daha etkin hale getirmek ve gereksiz parça değiştirme veya motor duruşlarını önlemek için, daha gelişmiş, sürekli izleme tabanlı uyarıcı bakım yaklaşımları geliştirilmektedir [5].

Son yıllarda, makine öğrenmesi, derin öğrenme, istatistiksel analiz, dalgacık dönüşümü, yapay sinir ağları, destek vektör makineleri, C4.5 karar ağaçları, Naive Bayes, KNN ve ANFIS gibi yapay zekâ teknikleri, arıza tespit sürecine entegre edilmiştir. Böylece, birden fazla arızanın aynı anda meydana gelmesi durumunda bile her bir sorunu ayrı ayrı tespit etmek, kaynağını belirlemek ve zamanında müdahale etmek mümkün hale gelmiştir. Sıfır Geçiş Anı (SGA) [5] analizi, ek sensör kullanımı gerektirmeden mevcut akım bilgisinden yararlanarak düşük yük seviyelerinde dahi doğru sonuçlar verebilmekte, bu sayede rotor çubuk kırıkları, şebeke dengesizliği ve eksenel kaçıklık gibi birbirine yakın frekans bileşenlerini ayırıştırarak güvenilir arıza teşhisini sağlamaktadır [8-13].

Ayrıca, FPGA gibi yüksek hızlı donanım platformlarının kullanımıyla gerçek zamanlı arıza tespiti yapılabilmektedir. Bu sayede bakım kararları hızlı ve doğru bir şekilde verilebilmektedir [14]. Derin öğrenme tabanlı modeller, ham sinyaller üzerinde ön işleme ihtiyaç duymadan yüksek başarımla

sınıflandırma yaparak %98'e varan doğruluk seviyeleri sunmaktadır. Bu durumda işletmelerin elde edeceği kazanç sadece ekonomik boyutta kalmayarak; verimlilik artışı, makine ömrünün uzaması, enerji tüketiminin düşmesi, çevresel etkinin azalması ve üretim güvenilirliğinin artması gibi çok boyutlu faydaları ortaya çıkmaktadır.

Asenkron motorlarda arıza tespiti ve teşhisi, geleneksel bakım stratejilerini aşarak akıllı, gerçek zamanlı, çoklu arıza tespit sistemleri ile yeni bir boyut kazanmaktadır. Bu gelişmeler, sanayi kuruluşları için rekabet avantajı, operasyonel mükemmellik, sürdürülebilirlik ve kârlılık anlamına gelmektedir. Bu çalışmada söz konusu yeni yaklaşım ve teknolojilerin kapsamlı bir değerlendirmesini sunarak, okuyucuya hem teorik hem de pratik bir bakış açısı kazandırmayı amaçlamaktadır.

2. Üç Fazlı Asenkron Motorların Yapısı ve İşleyişi

Üç fazlı asenkron motorlar, endüstriyel uygulamalarda en çok kullanılan elektrik makinelerinden biridir. Bu yaygınlık; sağlamlık, güvenilirlik, düşük bakım maliyeti, basit yapısal özellikler, geniş güç aralığı ve farklı çalışma koşullarına kolay uyum sağlama kapasitesi gibi pek çok avantaja dayanmaktadır. Bu bölümde, üç fazlı asenkron motorların temel yapısı, işleyiş prensipleri ve arıza türlerinin genel sınıflandırılması ele alınacaktır. Böylece ilerleyen bölümlerde incelenecek arıza tespit yöntemlerinin teorik temelini daha iyi anlamak mümkün olacaktır [15].

2.1. Stator, Rotor ve Rulmanların Temel Yapısı

Üç fazlı asenkron motorlar, temelde üç ana bileşenin yapısal bütünlüğü ve tasarım kalitesi üzerine inşa edilir: stator, rotor ve rulmanlar (yataklar). Bu bileşenlerin her biri, motorun verimli, güvenilir ve uzun ömürlü çalışmasında kritik bir rol oynamaktadır [15].

2.1.1. Stator Yapısı ve Malzemeleri:

Stator, motorun sabit (hareketsiz) kısmıdır ve silisli çelikten imal edilen paketlenmiş saçlar (laminasyonlar) üzerine yerleştirilen üç fazlı sargılardan oluşmaktadır. Bu sargılar, birbirinden belirli açılarla yerleştirilmiş olup, üç fazlı besleme gerilimi uygulandığında döner manyetik alan üretir. Stator saç paketlerinde kullanılan silisli çelik, elektriksel kayıpları azaltmak ve manyetik akının verimli iletilmesini sağlamak amacıyla özel olarak üretilmektedir. Bu laminer yapılar, eddy (girdap) akımlarını ve histerezis kayıplarını minimize ederek, motorun toplam verimliliğini artırır. [15]

Stator oyuklarına yerleştirilen sargılar çoğunlukla bakır iletkenlerden yapılır. Bakırın yüksek iletkenliği, sargılarda meydana gelen ısınmayı düşürerek daha yüksek verim sağlamaktadır. Sargı yalıtımında kullanılan malzemeler (emaye, reçine, fiber malzeme, yüksek sıcaklık dayanımlı sentetik filmler vb.) motorun çalışma sıcaklığı, nem, kimyasal ortam ve mekanik titreşimler gibi dış etkenlere karşı dayanımını belirler. İyi yalıtılmış bir stator sargısı, motorun ömrünü uzatır, arıza riskini azaltır ve bakım maliyetlerini düşürür.

2.1.2. Rotor Yapısı ve Çeşitleri:

Rotor, motorun dönen parçasıdır ve stator tarafından oluşturulan döner manyetik alan etkisiyle hareket eder. Günümüzde endüstride en çok kullanılan tasarım sincap kafesli rotorlardır. Sincap kafesli rotorlar, laminasyonlu çelik gövde içindeki oyuklara döküm yöntemiyle yerleştirilmiş alüminyum veya bakır çubukların iki uçta kısa devre halkalarıyla birleştirilmesiyle oluşur. Böylece rotor sargısı, fırça veya bilezik gibi ek parçalara ihtiyaç duymadan basit, sağlam ve bakım gerektirmeyen bir yapı kazanır.

Bunun yanı sıra bazı özel uygulamalarda bilezikli rotora da rastlanır. Bilezikli rotolarda rotor sargıları uçlarına bağlanan bilezikler ve fırçalar aracılığıyla dış devrelere ulaşılabilir. Bu sayede kalkış akımının ve torkunun kontrolü veya hız ayarlamaları daha esnek bir şekilde yapılabilir. Ancak bilezikli rotorlar bakım gereksinimi açısından daha dezavantajlıdır.

Sincap kafesli rotorun en büyük avantajı basitliği ve bakım kolaylığıdır. Ancak rotor imalatında kullanılan malzemenin kalitesi, çubuk kesitleri, rotorun balansı ve üretim toleransları rotorun dengesini ve dolayısıyla motorun mekanik bütünlüğünü doğrudan etkiler. Zamanla rotor çubuklarında meydana gelebilecek kırılmalar, mekanik zorlanmalar veya eksenel kaçıklıklar arıza riskini artırmaktadır.

2.1.3. Rulmanlar (Yataklar) ve Yağlama Koşulları:

Rulmanlar, rotor milini stator gövdesine sabitleyerek, rotorun sürtünme kayıplarını minimuma indirir ve yatay-dikey doğrultudaki yükleri karşılar. Rulmanlar genellikle çelik bilyeli veya makaralı yapıda olur. Rulmanların seçimi motorun güç kapasitesi, hız aralığı, ortam koşulları ve işletme ömrü beklentilerine göre yapılır. Doğru seçilmiş ve uygun şekilde yağlanmış rulmanlar, titreşim seviyelerini düşürerek motorun sessiz ve verimli çalışmasını sağlar [16].

Rulman arızalarının önemli bir kısmı yağlama yetersizliği, kirlenme (toz, nem, kimyasal maddeler), aşırı yüklenme veya yanlış montaj sonucu

ortaya çıkar. Rulmanlardaki küçük hatalar zamanla büyüyerek iç/dış izlerde yıpranmaya, bilye yüzeylerinde deformasyonlara ve sonuçta motorun titreşime belirgin artışa neden olur. Literatürde rulman kaynaklı arızaların, toplam elektrik motoru arızalarının önemli bir kısmını oluşturduğu sıklıkla vurgulanmaktadır.

2.1.4. Yapısal Tasarımın İşletme Performansına Etkisi

Bu üç ana bileşenin (stator, rotor, rulmanlar) uyumlu çalışması, motorun genel performansını ve güvenilirliğini belirler. Kaliteli malzemeler, doğru imalat toleransları, uygun montaj teknikleri ve düzenli bakım, hem elektriksel hem de mekanik kayıpları azaltarak enerji verimliliğini artırır, arıza riskini düşürür ve motor ömrünü uzatır. Böylece işletmeler bakım maliyetlerini, enerji tüketimini ve duruş sürelerini minimize ederek rekabetçi bir üretim ortamına kavuşurlar [17].

2.2. Elektriksel ve Mekanik Arızaların Sınıflandırılması

Üç fazlı asenkron motorlar, pek çok avantaja sahip olsa da, zamanla veya yanlış işletme koşullarında çeşitli arızalara ortaya çıkabilir. Bu arızalar genel olarak elektriksel ve mekanik olmak üzere iki ana kategori altında toplanır. Arızaların doğru teşhisi, erken tespiti ve uygun sınıflandırılması, fabrikadaki üretim süreçlerinde kesintisizliği sağlamak ve bakım stratejilerini optimize etmek açısından kritik önemdedir.

2.2.1. Elektriksel Arızalar

Elektriksel arızalar çoğunlukla stator sargıları ve besleme koşullarıyla ilgilidir. Sargı yalıtımının bozulması (nem, aşırı sıcaklık, kimyasallar, mekanik titreşimler sonucu), fazlar arası kısa devreler, faz-toprak kısa devreleri veya faz hataları sık rastlanan arızalardır. Ayrıca şebeke dengesizliği, harmonikli şebeke veya invertör çıkışlı bir beslemede motorun çalışma koşullarını zorlaştırmaktadır. Bu durumlar stator akımında anormalliklere, motorun ısınmasına, verim düşüşüne ve beklenmedik duruşlara neden olur [17].

Bilezikli rotor yapıya sahip motorlarda rotor sargısı arızaları nadirde olsa gerçekleşebilmektedir. Bu arızalar, rotorda endüklenen akımların dengesizliğine ve istenmeyen titreşimlere yol açar. Elektriksel arızaların erken teşhisi, akım analizi, gerilim vektörü izleme, manyetik alan ölçümleri, kısmi deşarj testleri ve yapay zekâ tabanlı örüntü tanıma yöntemleri ile yapılabilir.

2.2.2. Mekanik Arızalar

Mekanik arızalar, dönen parçalar (rotor, rulmanlar, şaft, kaplin) ve motorun yapısal bütünlüğü ile ilgilidir. Rulman aşınmaları, iç/dış iz çatlakları, bilye yüzey kusurları, yağlama eksikliği, rotor çubuk kırıkları, rotor eksenel kaçıklığı, şaft eğrilmesi, dengesiz yük dağılımı ve kaplin uyumsuzluğu gibi problemler mekanik kategoride yer almaktadır. Bu tür arızalar çoğunlukla titreşim ölçümleri, akustik analizler, kızılötesi termografi, ultrasonik ölçümler ve mekanik sensör verilerinin değerlendirilmesi aracılığıyla tespit edilebilir. Mekanik arızaların erken fark edilmesi, üretim hattındaki duruş sürelerini önemli ölçüde azaltır [15, 17].

2.2.3. Arıza Sınıflandırmasında Dikkate Alınan Ölçütler

Arızaların sınıflandırılmasında kullanılan temel ölçütler arasında arızanın kaynağı (stator, rotor, rulman, şaft), arıza seviyesi (küçük bir kusurdan tam bir bileşen arızasına kadar), oluşum hızı (ani gelişen veya zamanla ilerleyen), tekrar etme sıklığı, çalışma koşullarının (yük, hız, sıcaklık, besleme kalitesi) etkisi ve üretim hattına verdiği zarar yer alır. Bu parametrelerin doğru analizi, bakım stratejilerinin optimize edilmesine, önleyici veya kestirimci bakım yaklaşımlarının geliştirilmesine olanak tanır [17].

2.2.4. Arıza Tespitinde İleri Yöntemler

Geleneksel tespit yöntemlerinin yanı sıra, son yıllarda yapay zeka ve makine öğrenmesi tabanlı teknikler arıza tespitinde sıklıkla kullanılmaktadır. Naive Bayes, k-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN), Karar Ağaçları (C4.5) ve Nöro-Bulanık sistemler (ANFIS) gibi örüntü tanıma yöntemleri, karmaşık arızaların erken ve doğru teşhisinde büyük rol oynamaktadır. Bu yöntemler, akım sinyalleri, titreşim verileri veya akustik imzalar üzerinde çalışarak arıza tiplerini yüksek doğrulukla sınıflandırabilir.

Bu akıllı sistemler, farklı yük ve besleme koşulları altında dahi yüksek performans gösterebilmektedir. Böylece motorlar sadece periyodik bakım sürecinde değil, sürekli olarak izlenebilir ve en uygun bakım müdahalesi, arıza kritik hale gelmeden gerçekleştirilebilir.

2.3. Üç Fazlı Asenkron Motorların Çalışma Prensipleri, Performans ve Verimlilik İlişkisi

Üç fazlı asenkron motorlar, stator sargılarına uygulanan üç fazlı besleme gerilimiyle oluşan döner manyetik alanın, rotorda endüklenen akımlar aracılığıyla elektromekanik tork üretmesi prensibine dayanır. Rotor

döndükçe, senkron hızdan (stator alanının dönme hızı) az miktarda geride kalır. Bu fark “kayma” (s) olarak tanımlanır. Kayma, motordan çekilen yük miktarına bağlı olarak değişir. Yük arttıkça kayma artar, rotor akımları yükselir ve motor buna karşılık daha yüksek tork üretir [15].

Motorun performansı (tork, verim, güç faktörü, hız kararlılığı) doğrudan stator, rotor ve rulmanların tasarım kalitesine, seçilen malzemelere ve motorun çalışma koşullarına bağlıdır. Örneğin, yüksek verimli motorlarda kullanılan üstün yalıtım malzemeleri, daha kaliteli rulmanlar ve optimize edilmiş rotor tasarımları, işletmelerin enerji maliyetlerini düşürür ve karbon ayak izini azaltır.

2.4. Endüstriyel Uygulamalarda Üç Fazlı Asenkron Motorların Rolü

Üç fazlı asenkron motorlar, pompalardan kompresörlere, fanlardan konveyörlere, pres makinelerinden mikserlere kadar birçok uygulamada kullanılır. Sanayi tesislerinin büyük çoğunluğu, mekanik güç ihtiyacını bu motorlar aracılığıyla karşılar. Üretim hatlarında meydana gelebilecek herhangi bir motor arızası, tüm üretim zincirinde aksamalara ve ekonomik kayıplara yol açabilir. Bu nedenle motorun doğru seçimi, doğru bakım stratejilerinin uygulanması ve arıza tespit yöntemlerinin geliştirilmesi, sürdürülebilir bir üretim için kaçınılmazdır [18].

3. Asenkron Motor Arızaları: Türler ve Nedenler

Asenkron motorlar, endüstriyel üretim hatlarında en çok kullanılan elektrik makinelerinden biridir. Enerji verimliliği, düşük bakım maliyeti, dayanıklılık, farklı güç ve hız aralıklarında stabil performans gibi avantajları sayesinde çok çeşitli sektörlerde tercih edilirler. Ancak, her ne kadar güvenilir ve bakım gerektirmiyor olsalar da asenkron motorlar uzun çalışma saatleri, olumsuz çalışma koşulları, düzensiz bakım, aşırı yüklenme, besleme gerilim kalitesizliği (harmonikler, dengesiz gerilimler), nem, toz, kimyasal etkenler ve mekanik zorlanmalar gibi nedenlerle zamanla arızalara maruz kalırlar [17].

Motor arızaları genel olarak iki ana sınıfa ayrılır: elektriksel arızalar ve mekanik arızalar. Elektriksel arızalar çoğunlukla stator sargıları veya rotor çubuklarıyla ilgiliyken, mekanik arızalar rulmanlar, mil, yataklar, kapaklar ve montaj hatalarıyla ilişkilidir. Bu arızalar, beklenmeyen üretim duruşları, bakım maliyetlerinde artış, verimlilik kaybı ve işletme karlılığında azalma gibi problemlere neden olur [19].

Bu bölümde, asenkron motorlarda en sık görülen üç temel arıza türü detaylı biçimde incelenecektir: rulman arızaları, rotor arızaları (özellikle kırık rotor çubuğu) ve stator arızaları (kısa devreler vb.). Her bir arıza türü, oluşum nedenleri, belirtileri, performans üzerindeki etkileri, tespit yöntemleri, önleme stratejileri ve literatürdeki yaklaşımlarla birlikte değerlendirilerek bütüncül bir bakış sunulacaktır.

3.1. Rulman Arızaları

3.1.1. Rulmanların Önemi ve Yapısı

Rulmanlar, asenkron motorun mekanik yapısının kritik unsurlarından biridir. Rotor milini stator gövdesi içinde düşük sürtünme ile döndürerek titreşimi, gürültüyü ve enerji kayıplarını minimum düzeyde tutarlar. Rulmanlar sayesinde rotor dengeli ve sorunsuz bir şekilde hareket eder. Ancak rulman arızaları endüstriyel tesislerde en sık görülen mekanik sorunlardan biri olup hem motor ömrünü kısaltır hem de planlanmamış üretim kesintileriyle maliyetleri artırır.

Nedenleri ve Türleri:

Rulman arızaları birçok faktörün bir araya gelmesi sonucunda oluşur. Bunlar arasında yetersiz yağlama, kirlilik, aşırı veya dengesiz yük, yanlış hizalama, hatalı montaj, elektriksel akımlar ve malzeme yorgunluğu sayılabilir. Rulman arızaları genellikle dört ana kategoride incelenir [1,2]:

- **Bilye arızaları:** Bilye yüzeylerinde oluşan pitting, çukurlaşmalar veya çatlaklar rulmanın düzgün dönmesini engeller.
- **İç bilezik arızaları:** İç bilezik yüzeyindeki deformasyonlar rulmanın rahat hareketini kısıtlar bilye-yuva temasını bozarak titreşim ve gürültü artışına neden olur.
- **Dış bilezik arızaları:** Dış bilezik yüzeyinde oluşan bozukluklar rulmanın stator gövdesiyle olan etkileşimini olumsuz etkileyerek mil denge koşullarını bozar.
- **Kafes arızaları:** Kafesin çatlaması veya deforme olması bilyelerin düzgün konumunu engeller, sürtünmeyi artırır ve rulman ömrünü kısaltır.

Yetersiz yağlama, zamanla yağın bozulması veya eksilmesi sonucu sürtünmeyi artırır; bu da yüzeylerde aşırı ısınmaya, aşınmaya ve metal yorgunluğuna neden olur. Kirlilik, toz, nem, metal partikülleri şeklinde rulman içine sızarak yüzeyleri zedeler. Aşırı veya dengesiz yük ise rulman yüzeylerinde yüksek gerilmeler yaratarak çatlakların oluşmasını hızlandırır. Yanlış hizalama ve hatalı montaj, rulmanda lokal gerilmeler oluşturup metal yorgunluğunu artırır.

Belirtiler, Tespit ve Önleme:

Rulman arızaları titreşim seviyesinin artması, anormal sesler, sıcaklık yükselmesi, verimlilikte azalma, mil oynaklığı gibi belirtiler gösterir. Bu belirtileri erken yakalamak için titreşim analizi, ultrasonik sensörler, motor akım imzası analizi (MSCA), kızılötesi termografi analizi gibi yöntemler

kullanılır. Rulman arızalarının erken tespiti, kestirimci bakım stratejileri ile birleştğinde planlı bakım çalışmalarını mümkün kılarak arıza sonucu ortaya çıkan üretim kesintilerini en aza indirir. Periyodik yağlama, kaliteli rulman seçimi, temiz çalışma ortamı sağlama, doğru montaj ve hizalama, ayrıca çevrimiçi durum izleme uygulamaları rulman arızalarının oluşumunu geciktirir veya önler.

3.2. Rotor Arızaları (Kırık Rotor Çubuğu)

Rotorun Rolü ve Özellikleri:

Asenkron motorun rotor bileşeni, statorun oluşturduğu döner manyetik alanı takip ederek rotor çubuklarında endüklenen akım aracılığıyla mekanik torka dönüştürür. Özellikle sincap kafesli rotorlar, basit ve sağlam tasarımları nedeniyle endüstride yaygın olarak kullanılır. Ancak rotor çubuklarında meydana gelen çatlaklar, kırıklar veya deformasyonlar sıklıkla karşılaşılan elektriksel arızalardandır [4, 5].

Nedenleri ve Etkileri:

Kırık rotor çubukları, motorun dengesiz çalışmasına neden olur. Aşırı yüklenme, sık kalkış-duruşlar, dengesiz gerilim beslemesi, termal stres, malzeme kalitesi ve imalat toleransları rotor çubuklarının zayıf noktalarını ortaya çıkarır. Bu zayıf noktalar zamanla mikro çatlaklara dönüşür ve sonunda çubuk kırılmaları meydana gelir. Kırık bir rotor çubuğunun yakınındaki çubuklar daha fazla akım çekerek akım dengesizliği ve tork dalgalanmaları yaratır. Bu durum titreşim seviyesinin artmasına, verimlilik kaybına, motorda aşırı ısınmaya ve uzun vadede daha ciddi yapısal sorunlara neden olur [19].

Tespit Yöntemleri, İleri Teknikler ve Önleme:

Geleneksel MCSA (Motor Akım İmza Analizi) yöntemi rotor arızalarını stator akımındaki yan bant bileşenlerinden saptar. Ancak $(1-2s)f$ bileşeni ana besleme frekansı yanında düşük genlikte kaldığından arıza belirteci kolay fark edilemeyebilir. Bu durumda sıfırdan geçiş anı (SGA) analizi devreye girerek $2sf$ bileşenine odaklanır ve rotor arızasını daha net tespit edebilir. Ayrıca titreşim analizi rotor dengesizliğini, yeni harmonik bileşenleri ortaya koyarak rotor arızalarını destekleyici bir yöntem sunar [20].

Günümüz teknolojileri gerçek zamanlı durum izleme, sensör füzyonu, makine öğrenmesi ve derin öğrenme tabanlı sınıflandırma algoritmaları ile düşük yük seviyelerinde bile rotor arızalarını erken tespit etmeye imkanı sunmaktadır. Bu sayede planlı bakım veya parça değişimi yapılarak beklenmedik duruşlar önlenir, işletme maliyetleri düşer. Yük dağılımının dengelenmesi, uygun tasarım ve malzeme seçimi, kaliteli üretim toleransları,

invertör beslemeli sürücülerde etkin kontrol stratejileri ve düzenli izleme uygulamaları rotor arızalarının önlenmesinde kritik rol oynamaktadır.

3.3. Stator Arızaları

Stator Sargılarının Önemi ve Yalıtım Kalitesi:

Stator sargıları, asenkron motorun elektromanyetik yapısının temelini oluşturur. Üç fazlı sargılar, döner manyetik alan yaratarak rotorun dönmesini sağlar. Bu sargıların yalıtım kalitesi, motorun uzun vadeli güvenilirliği, dayanıklılığı ve verimliliğini doğrudan etkiler. Ancak yalıtım malzemesinin zamanla yaşlanması, sıcaklık, nem, kimyasallar, titreşimler ve mekanik zorlamalar sonucu yalıtım özelliklerinde bozulmalar meydana gelir [21,22].

Nedenler, Sonuçlar ve Riskler:

Stator arızaları çoğu zaman sargılar arasındaki kısmi deşarjların ilerleyip faz-faz veya faz-toprak kısa devrelere dönüşmesiyle ortaya çıkar. Aynı faz içindeki komşu sargıların kısa devre olması başlangıçta lokal bir ısınma bölgesi yaratır. Bu sıcak bölge, yalıtımı daha da zayıflatarak sargılar arasında yayılır, sonunda motoru tamamen çalışmaz hale getirir. Faz-toprak kısa devreleri ise motor koruma elemanlarını tetikleyerek beklenmedik duruşlara neden olur. Dengesiz akımlar, verimlilikte düşüş, aşırı ısınma, gürültü ve titreşim artışı stator arızalarının tipik belirtileridir.

Tespit, Önleme ve Gelişmiş Yöntemler:

Stator arızalarının erken tespiti, motor akım imzası analizi (MCSA), titreşim ölçümleri, kısmi deşarj testleri, sıcaklık sensörleri ve sürekli çevrimiçi izleme sistemleri aracılığıyla gerçekleştirilir. Gelişmiş sinyal işleme teknikleri, makine öğrenmesi, derin öğrenme tabanlı sınıflandırma algoritmaları, harmonik analizler ve özellik seçme yöntemleri stator arızalarının karmaşık yapısında dahi tanınmasına yardımcı olmaktadır.

Periyodik bakım, iyi yalıtım materyali kullanımı, nem ve toz kontrolü, uygun soğutma, inverter besleme koşullarının iyileştirilmesi ve titreşim izleme uygulamaları stator arızalarının oluşumunu geciktirir veya engeller. Bu önlemler, büyük üretim kayıplarına ve maliyetli bakım operasyonlarına yol açan tam sargı yanmalarını önleyerek işletmenin uzun vadeli başarısına katkıda bulunur.

3.4. Kapsamlı Bakış, Uygulama Yöntemleri ve Geleceğe Dönük Yaklaşımlar

Asenkron motorların endüstriyel süreçlerde karşılaştığı başlıca sorunlar arasında rulman, rotor ve stator arızaları yer almaktadır. Her bir arıza türü

farklı nedenlere, belirtilere ve tespit yöntemlerine sahip olmakla birlikte, ortak sonuç üretim süreçlerinin kesintiye uğraması, verimlilikte azalma, enerji kaybı ve maliyet artışıdır.

Arıza Yönetimi ve Kestirimci Bakım:

Geleneksel periyodik bakım yaklaşımları, arızaların önlenmesinde her zaman yeterli olmamaktadır. Bu nedenle kestirimci bakım stratejileri son yıllarda önem kazanmıştır. Çevrimiçi durum izleme teknikleri, sensör verilerinin sürekli kaydı, titreşim ve akım imzası analizleri, yapay zeka ve makine öğrenmesi tabanlı örüntü tanıma yöntemleri, rulman, rotor ve stator arızalarının erken tespitini mümkün kılarak planlı duruşlarla bakım yapılmasını sağlar. Bu yaklaşımlar, arızaların ciddi boyutlara ulaşmasını engelleyerek işletmelere rekabet avantajı sunar [23].

İleri Teknolojiler ve Otomasyon:

Gelişmiş sensör teknolojileri, kablosuz veri aktarımı, bulut tabanlı veri işleme, FPGA/DSP tabanlı yüksek hızlı hesaplama ortamları, derin öğrenme algoritmaları, geniş veri kümelerinde karmaşık özellik çıkarma yöntemleri gibi teknolojiler arıza tespiti ve bakım optimizasyonunu daha da geliştirecektir. Özellikle düşük yük seviyelerinde veya farklı arızaların aynı anda meydana geldiği çoklu arıza durumlarında bile bu yöntemler hızlı, doğru ve güvenilir teşhis olanağı sunacaktır.

Arıza yönetimi sadece motor düzeyinde değil, sistem bütünlüğü ile ele alınmalıdır. Üretim hattında bulunan diğer makineler, redüktörler, pompalar, kompresörler, fanlar ve konveyörler arasındaki etkileşimlerin anlaşılması, titreşim ve gürültü kaynaklarının lokalize edilmesi, şebeke geriliminin temizlenmesi (harmonik filtreler, aktif güç düzenleyiciler), inverter kontrol stratejilerinin iyileştirilmesi, malzeme kalitesinin artırılması gibi önlemler de motor arızalarının oluşumunu azaltacaktır.

Enerji Verimliliği ve Sürdürülebilirlik:

Arızaların önlenmesi ve hızlı tespiti, enerji verimliliğini artırarak işletmelerin karbon ayak izini de düşürür. Arıza kaynaklı kayıplar azaldığında işletme kârlılığı ve rekabet gücü yükselir, sürdürülebilir üretim hedeflerine daha kolay ulaşılır. Bu bakımdan rulman, rotor ve stator arızalarının yönetimi, sadece teknik bir sorun olmaktan çıkarak stratejik bir yaklaşım haline gelir.

4. Akıllı Sınıflandırma Yöntemleri

Asenkron motorlar, endüstriyel tesislerde kullanılan enerji dönüştürücülerinin %70'inden fazlasını oluşturmaktadır. Ancak yapılan araştırmalara göre, rulman, rotor ve stator arızaları, bu motorlarda meydana gelen arızaların %80'inden fazlasını oluşturmaktadır. Bu arızalar, üretim hatlarında beklenmeyen duruşlara neden olarak saatte ortalama %15 üretim kaybına yol açmakta ve enerji tüketimini %10'a kadar artırabilmektedir. Ayrıca, bu tür arızaların giderilmesi için yapılan bakım maliyetleri, yıllık işletme giderlerinin %20'sine ulaşabilmektedir. Bu nedenle, arızaların erken tespiti ve etkin yönetimi hem üretim sürekliliği hem de maliyet kontrolü açısından kritik bir öneme sahiptir [24].

Geleneksel analiz yöntemleri (akım veya titreşim verilerinin izlenmesi, frekans analizi, istatistiksel ölçütler) çoğu zaman karmaşık ve gürültülü endüstriyel ortamlarda yeterince esnek ve hassas olmamaktadır. Özellikle birden fazla arıza türünün aynı anda ortaya çıkması, yük koşullarının sürekli değişmesi, besleme geriliminin dengesizliği ve invertör tabanlı sürücülerin yarattığı ek gürültü, klasik yaklaşımların performansını kısıtlamaktadır. Bu noktada akıllı sınıflandırma yöntemleri, karmaşık örüntüleri ortaya çıkarma ve veriyi anlamlandırma kabiliyetleri sayesinde, arıza teşhisinde ön plana çıkmaktadır [25].

Örüntü tanıma ve makine öğrenmesi temelli akıllı sınıflandırma yöntemleri, elde edilen ham verilerden (akım, titreşim, akustik, manyetik, sıcaklık vb.) anlamlı özellikler çıkararak, bu özelliklerin istatistiksel ve matematiksel ilişkilerine dayalı olarak veriyi önceden tanımlanmış sınıflara (arızalı/arızasız, arıza türü A/B/C gibi) atar. Böylece, anormal durumlar standart referans koşullardan hızlıca ayrıştırılır. Literatürde Naive Bayes, Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve C4.5 Karar Ağacı, bu alanda en sık karşılaşılan yöntemlerdendir. Ayrıca K- En Yakın Komşu (KNN), RIPPER, Rastgele Orman, ANFIS, GA tabanlı optimizasyon gibi yöntemler de farklı çalışmalarda öne çıkmaktadır [25-29].

Aşağıdaki alt başlıklarda, örüntü tanıma kavramının temellerinden başlayarak, Naive Bayes, SVM, ANN, C4.5 ve diğer yöntemlerin asenkron

motor arıza teşhisindeki kullanım alanları, avantajları, dezavantajları, veri ön işleme ihtiyaçları, deneysel bulgular ve endüstriyel uygulamalara yönelik örneklerle sunulacaktır [30-33].

4.1. Örüntü Tanıma Tekniklerinin Tanıtımı

Örüntü tanıma, büyük ve karmaşık veri içinden anlamlı örüntüleri ortaya çıkarma sürecidir. Bu süreçte hedef, elde edilen çok boyutlu verinin (sensör okumaları, sinyal işleme sonucu elde edilen özellikler vb.) belirli sınıflara doğru bir şekilde atanmasıdır. Asenkron motor arıza teşhisinde örüntü tanıma yaklaşımı, farklı arıza durumlarına (kırık rotor çubuğu, dış bilezik rulman arızası, stator sargı kısa devresi gibi) ait veriler üzerinden bir model eğitmeyi ve yeni gelen verilerdeki arıza durumunu doğru tahmin etmeyi amaçlar [3, 4, 26,27].

Burada başarının anahtarı, özellik çıkarımı ve seçimi, uygun sınıflandırıcı algoritmanın belirlenmesi, doğru eğitim-doğrulama stratejilerinin kullanılması ve modelin genelleme kabiliyetinin sağlanmasıdır. Özellik çıkarımı aşamasında, istatistiksel ölçütler (RMS, tepe faktörü, basıklık, çarpıklık), frekans tabanlı ölçümler (FFT tabanlı harmonik analiz, dalgacık dönüşümleri) veya zaman-frekans analizleri (STFT, Hilbert-Huang dönüşümü) kullanılabilir. Elde edilen özellikler, boyut indirgeme teknikleri (PCA, LDA) ile optimize edilebilir. Ardından bu özellik vektörleri akıllı sınıflandırma modellerinin girdisi olarak kullanılır.

Gerçek endüstriyel uygulamalarda, veri gürültülü, karmaşık ve heterojen olabilir. Aynı motorun farklı yük seviyelerinde, farklı sıcaklıklarda, farklı besleme kalitelerinde ve farklı zamanlarda elde edilen veriler, modelin genelleme kabiliyetini sınar. Bu nedenle akıllı sınıflandırma yöntemleri, sadece doğruluk açısından değil, gürültüye dayanıklılık, işlem süresi, parametre hassasiyeti, bellek kullanımı ve yorumlanabilirlik gibi kriterler açısından da değerlendirilmelidir.

4.2. Naive Bayes Sınıflandırıcısı

Naive Bayes, basit bir olasılık modeline dayanmaktadır. Her bir özelliğin sınıf koşullu olasılığı hesaplanır ve Bayes kuralı kullanılarak veri örneğinin hangi sınıfa ait olduğu tahmin edilir. Bu yaklaşım, tüm özelliklerin birbirinden bağımsız olduğunu varsayar. Bu varsayım tam anlamıyla gerçekçi olmasa da pratikte kabul edilebilir sonuçlar sunabilmektedir [37,38].

Kullanım Senaryosu:

- Rulman arızası tespitinde, frekans bantlarındaki RMS değerleri veya titreşim istatistikleri Naive Bayes ile hızlıca sınıflandırılabilir.
- Düşük boyutlu özellik vektörlerinde, basit ve hızlı bir yaklaşım sunar.

Performans ve Sınırlamalar:

- Özellik bağımsızlığı varsayımı her zaman geçerli olmayabilir.
- Karmaşık, yüksek boyutlu verilerde diğer gelişmiş yöntemlerin gerisinde kalabilir.

Naive Bayes, hızlı prototipleme, basit senaryolar veya ilk yaklaşım olarak endüstriyel uygulamalarda değerlendirilebilir [39].

4.3. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri, örüntü tanıma problemlerinde sıkça tercih edilen, istatistiksel öğrenme teorisine dayalı bir yöntemdir. Verileri yüksek boyutlu uzaya eşleyerek, en geniş marjine sahip ayırım hiperdüzlemini bulur. Çekirdek fonksiyonları ile doğrusal olmayan verilerde de etkili sonuçlar elde edilebilir [41, 42].

Kullanım Senaryosu:

- Rotor çubuğu kırıklarını, farklı yük seviyeleri ve gerilim dengesizlikleri altında başarıyla ayırt eder.
- Rulman arızalarında iç/dış bilezik kusurlarını titreşim sinyallerinden elde edilen özelliklerle yüksek doğrulukta sınıflandırır.
- Stator sargı kısa devre yüzdesinin tespitinde, frekans bileşenlerini kullanarak doğru sonuçlar verir.

Avantaj ve Dezavantajlar:

- Yüksek doğruluk, iyi genelleme kabiliyeti.
- Parametre ayarına (C , γ) duyarlıdır.
- Büyük veri setlerinde eğitim süresi uzayabilir, ancak donanım hızlandırma teknikleri (GPU, FPGA) bu sorunu azaltır.

SVM, literatürde ANN ve KNN gibi yöntemlerle kıyaslandığında çoğu zaman dengeli, istikrarlı ve genelleme yeteneği yüksek bir seçenek olarak görülmüştür [43].

4.4. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları, insan beyninden esinlenen yapılarıyla karmaşık ve doğrusal olmayan ilişkileri modelleyebilme kabiliyeti sunmaktadır. Çok Katmanlı Algılayıcı (MLP) türü ağlar, geri yayılım algoritmasıyla eğitilir ve farklı katman ile nöron sayıları sayesinde karmaşık fonksiyonları yüksek doğrulukla modelleyebilir [44, 45].

Kullanım Senaryosu:

- Rulman arızasının derecesini (yarım kırık çubuktan birden fazla kırık çubuğa kadar) sınıflandırabilir.
- Kırık rotor çubuğu, stator kısa devresi ve rulman arızasının aynı anda bulunduğu çoklu arıza durumlarında etkindir.
- Dalgacık analiziyle elde edilen özellikler ANN'e verildiğinde yüksek doğruluk oranları elde edilebilir.

Avantaj ve Dezavantajlar:

- Karmaşık ve doğrusal olmayan ilişkileri modellemede çok başarılıdır.
- Yeterli veri sağlanırsa performansı yükselir.
- Aşırı öğrenme riski, uzun eğitim süreleri, hiperparametre ayar zorluğu gibi sorunlar vardır.

ANN'ler, literatürde farklı arıza tiplerinde %90'ların üzerinde doğruluk oranlarına ulaşmış, özellikle önışlem (feature extraction) adımlarının iyi yapıldığı durumlarda üst düzey performans göstermiştir [45].

4.5. C4.5 Karar Ağacı ve Diğer Yöntemler

C4.5 karar ağacı tabanlı bir sınıflandırma yöntemidir. Veri setini hiyerarşik biçimde bölerek, insan tarafından anlaşılır bir ağaç yapısı oluşturur. Bu sayede hangi özelliğin hangi arıza durumunda kritik olduğuna dair şeffaf bir karar süreci sunar [46, 47].

Kullanım Senaryosu:

- Rulman arızalarında belirli titreşim frekans bantlarında artış gözleniyorsa, C4.5 bunu ağaç yapısında basit testlerle ortaya koyabilir.
- Rotor arızalarında kayma faktörü veya yan bant frekanslarını kullanarak farklı arıza tiplerini ayırabilir.
- Stator kısa devre oranının belirlenmesinde basit eşikler ve mantıksal testlerle karar verilir.

Avantaj ve Dezavantajlar:

- Yorumlanabilirlik: Mühendisler, bakım personeli ağaç yapısını inceleyerek hangi özelliklerin önemli olduğunu anlayabilir.
- Aşırı öğrenme riski vardır, bu nedenle budama stratejileri önemlidir.
- Veri değişimlerine duyarlı olabilir.

KNN, RIPPER, Rastgele Orman, ANFIS gibi diğer yöntemler de literatürde başarılı uygulamalar sunmuştur. Özellikle çoklu arıza durumlarında ansambl yöntemleri (örneğin Rastgele Orman) birden fazla karar ağacını birleştirerek daha yüksek doğruluk ve kararlılık sağlayabilir [46, 47].

4.6. Uygulama Örnekleri, Veri Ön İşleme ve Parametre Seçimi

Gerçek endüstriyel bir senaryoda, asenkron motorun stator akım verisi farklı yüklerde, farklı besleme harmonik seviyelerinde, nemli veya tozlu ortamlarda kaydedilebilir. Dalgacık analiziyle zaman-frekans düzleminde belirli bantlardaki enerjiler çıkarılarak bir özellik vektörü oluşturulur. Bu özellik vektörü SVM, ANN, Naive Bayes ve C4.5 gibi yöntemlere verildiğinde farklı performanslar elde edilir [48].

- Naive Bayes hızlı ve basittir, ancak bazen karmaşık veride düşük doğruluk sunar.
- SVM doğru parametrelerle %95 üzeri doğruluk sağlayabilir.
- ANN, uygun mimari ve yeterli eğitim verisiyle %98-99 doğruluk görebilir.
- C4.5 belki %90-95 arasında kalsa da anlaşılabilir bir model sunar.

Veri ön işleme aşamasında, gürültü filtreleme, istatistiksel normalizasyon, boyut indirgeme (PCA, LDA) yöntemleri kullanılabilir. Parametre ayarı için grid search, genetik algoritmalar veya parçacık sürü optimizasyonu gibi metotlar denenecek en iyi parametre kombinasyonlarını verebilmektedir.

Gerçek zamanlı uygulamalarda hız da önemlidir. SVM veya ANN eğitim süresi uzun olsa da eğitim bir kez yapıldıktan sonra sınıflandırma hızı genellikle yüksektir. C4.5 karar ağacı da hızlı sınıflandırma sunar. Naive Bayes baştan sona hızlıdır, ancak verinin karmaşıklığı arttıkça performans düşebilir.

4.7. Gelecek Yönelimleri ve Derin Öğrenme

Derin öğrenme yöntemleri (CNN, LSTM, RNN) ham veriden otomatik özellik çıkarma yeteneğiyle arıza tespitinde önem arz etmektedir. Özellikle

CNN tabanlı modeller, titreşim sinyallerinden elde edilen spektrogramları veya akım sinyalinin zaman-frekans temsillerini doğrudan girdi olarak insan müdahalesine gerek kalmadan özellik öğrenebilir. Bu durum arıza tespitini daha da güvenilir ve genelleme yeteneği yüksek hale getirmektedir [41- 45].

Ayrıca ansambl yöntemler, farklı sınıflandırıcıları bir araya getirerek daha kararlı ve yüksek doğruluklu sonuçlar üretir. Rastgele Orman veya XGBoost gibi modern teknikler hem belirsizliği azaltır hem de gürültülü verilerde dahi istikrarlı bir performans sunmaktadır.

Bulut tabanlı izleme, IoT sensörleri, kablosuz veri aktarımı, 5G iletişim altyapısı gibi teknolojiler sayesinde farklı tesislerden gelen veriler birlikte işlenerek daha kapsamlı modellerin eğitilmesi sağlanabilir. Bu sayede bakım stratejileri global ölçekte optimize edilerek farklı noktalardaki arızalar tespit edilerek genel durmalar engellenebilir.

Sonuç

Endüstride artan rekabet, enerji verimliliği hedefleri, üretim hatlarının karmaşıklığı ve bakım maliyetlerinin kontrol altında tutulması ihtiyacı, akıllı sınıflandırma yöntemlerinin önemini daha da artırmaktadır. Gelecekte derin öğrenme, ansambl sınıflandırıcılar, bulut tabanlı izleme platformları, gerçek zamanlı kontrol sistemleri ve kestirimci bakım stratejileriyle entegre edilen bu yöntemler, asenkron motorların güvenilir, sürdürülebilir ve yüksek performanslı şekilde işletilmesine kritik katkılar sağlayacaktır.

Önceki bölümlerde ele alınan rulman, rotor ve stator kaynaklı arızalara yönelik teşhis yöntemleri, akıllı sınıflandırma yaklaşımlarıyla geliştirilmektedir. Bu yaklaşımlar, %90'ın üzerinde doğruluk oranlarıyla daha güvenilir ve genellenebilir sonuçlar sunmaktadır. Ayrıca, analiz sürelerini %50 oranında kısaltarak teşhis süreçlerini hızlandırmakta ve verilerin görselleştirilmesiyle daha anlaşılabilir hale getirmektedir. Bu sayede, işletmeler uzun vadede %30'a varan bakım maliyeti tasarrufu, üretim devamlılığının artması ve enerji tüketiminde azalma gibi hedeflere ulaşabilmektedir.

5. Deneysel Yöntemler ve Veriler

Asenkron motor arıza teşhisinde, literatürdeki birçok çalışma deneysel doğrulamanın önemini vurgulamaktadır. Bu doğrulama süreci, geliştirilen akıllı sınıflandırma yöntemlerinin endüstriyel ortamlarda karşılaşılabilecek zorluklar (gürültü, değişken yük, dengesiz besleme gerilimi, farklı güç seviyeleri, nem ve toz gibi) karşısında nasıl performans gösterdiğini değerlendirmek için önemli bir adımdır. Bu bölümde, kullanılan motorun özelliklerinden başlayarak deney düzeneği, sensörler, veri toplama süreci, ön işleme adımları, deneysel koşullar incelenecek ve açıklanacaktır [3].

5.1. Deney Düzeneği ve Asenkron Motor Özellikleri

Deneysel çalışmada kullanılan motorlar, endüstriyel uygulamalarda sıkça kullanılan üç fazlı asenkron motorlar arasından seçilmiştir. Çeşitli güce sahip motorların deneylere dahil edilmesi, farklı performans seviyeleri ve verim sınıfları sunarak geliştirilen yöntemlerin genelleme yeteneğini test etmeye imkanı tanımaktadır. Deneyde kullanılan motorların özellikleri, Tablo 1, Tablo 2 ve Tablo 3'te görülmektedir [3].

Tablo 5.1. 2.2 kW Asenkron motorun teknik özellikleri [3]

Özellik	Değer
Güç	2200W
Gerilim	220/380V Δ /Y
Akım	9.3/5.4A Δ /Y
Frekans	50 Hz
Devir	940 d/d
Cos ϕ	0.76


Tablo 5.2. 3 kW Asenkron motorun teknik özellikleri [3]

Özellik	Değer
Güç	3000W
Gerilim	220/380V Δ/Y
Akım	11.2/6.5A Δ/Y
Frekans	50 Hz
Devir	2870 d/d
Cos ϕ	0.86

Tablo 5.3. 4 kW Asenkron motorun teknik özellikleri [3]

Özellik	Değer
Güç	4000W
Gerilim	380/660V Δ/Y
Akım	8.7/5A Δ/Y
Frekans	50 Hz
Devir	1440 d/d
Cos ϕ	0.83



Asenkron motorun arıza teşhisine yönelik deneysel çalışmalarda, motorun gerilim, akım, hız, tork ve sıcaklık gibi temel büyüklüklerinin yüksek hassasiyetle ölçülmesi gerekmektedir. Deney düzeneğinde kullanılan akım, gerilim, hız, tork ve sıcaklık sensörleri ile veri toplama kartı tanıtılmaktadır (Şekil 5.1). Bu ölçüm altyapısı sayesinde, önceki bölümlerde bahsedilen arıza tespit yöntemlerinin uygulanabilmesi için gerekli veriler elde edilmektedir [3].



Şekil 5.1. Asenkron motor deney düzeneği [3]

5.1.1. Akım Sensörü (LA 55-P)


LEM firmasının üretmiş olduğu LA 55-P akım sensörü, motora ait üç faz akım bilgisinin ölçümü için kullanılmıştır (Şekil 5.2). Bu sensör 0-50 A aralığındaki akımları ölçebilmektedir. Sensörün nüvesinden geçen akım, 1000 kat küçültülerek sensörün çıkışına aktarılmaktadır. Elde edilen düşük genlikli sinyal, deney düzeneğinde kullanılan yükselteç devresi ile 21 kat yükseltilir ve bu sayede sensör çıkışı, veri toplama kartının analog girişlerine uygun seviyeye getirilmiş olur. Böylece üç faz akım bilgisi yüksek doğrulukla dijital ortama aktarılır [3,49]



Şekil 5.2. LA 55-P akım sensörü

5.1.2. Gerilim Sensörü (LV 25-P)

Motora ait üç faz gerilim bilgisinin ölçümünde yine LEM firmasının üretimi olan LV 25-P gerilim sensörü (Şekil 5.3) kullanılmıştır. Bu sensör, 10-500 V aralığındaki gerilimleri ölçebilmektedir. Sensör, manyetik alan etkisiyle gerilimi 2500:1000 oranında düşürür. Elde edilen bu düşük genlikli sinyal, yazılım ortamında (LabVIEW veya Matlab) uygun ölçeklendirme yapılarak tekrar asıl değere çevrilir, böylece faz gerilimlerinin etkin değeri elde edilir. Bu yöntem yüksek gerilimlerin güvenli ve doğru bir şekilde ölçülmesini sağlamaktadır [3,50]



Şekil 5.3. LV 25-P gerilim sensörü

5.1.3. Hız Sensörü (Artımlı Dönel Enkoder ARS H 58)

Motor hız bilgisi, Atek firmasının ürettiği ARS H 58 artımlı dönel enkoder ile elde edilmektedir (Şekil 5.3). Bu enkoder, motor milinin her tam devrinde 1024 puls üretmekte ve 6000 devire kadar ölçüm yapabilmektedir. Enkoderden gelen pulsalar veri toplama kartının sayıcı girişine aktarılır. Bu sayede elde edilen puls sayısı, motor milinin anlık hızını hesaplamada kullanılır [3, 51].




Şekil 5.4. Hız sensörü (enkoder)

5.1.4. Tork Sensörü

Deney düzeneğinde tork ölçümü, güç üreten asenkron motor ile güç tüketen manyetik toz fren arasına seri olarak yerleştirilen torkmetre aracılığıyla gerçekleştirilir (Şekil 5.5). Tork sensörü 0-50 Nm aralığında ölçüm yapabilmekte ve çıkış olarak 0-5 V arası lineer bir gerilim sinyali vermektedir. Bu sinyal doğrudan veri toplama kartının analog girişine uygulanarak gerçek zamanlı olarak motor tork değeri ölçülmektedir. Böylece yük değişkenliği altında motorun tork üretme kapasitesi ve arıza durumlarında tork dalgalanmaları incelenebilmektedir [3].



Şekil 5.5. Tork sensörü



Şekil 5.7. PCI-6221 veri toplama kartı

5.2. Veri Toplama ve İşleme Yöntemleri

Veri toplama aşaması deneysel çalışmanın temelini oluşturmaktadır. Akım sinyali, tork, hız ve gerilim ölçümleri belirli bir örnekleme hızıyla (örneğin 6 kHz) kaydedilir. Bu örnekleme hızı, çalışma frekansını (50 Hz) ve potansiyel arıza frekans bantlarını doğru şekilde temsil edecek düzeyde seçilmelidir. Toplanan veriler Matlab /LabVIEW yazılımıyla anlık olarak işlenir ya da daha sonra işlenmek üzere kaydedilir. Rulman, rotor ve stator arızalarına ilişkin sinyaller, motor sabit bir hız ve yük altında çalışırken akım örnekleri alınarak analiz edilir. Eğer deneysel verilerde farklı yük seviyelerine (%25, %50, %75, %100 gibi) ilişkin bir inceleme gerekiyorsa, her test için standart bir örnekleme süresi (örneğin 3 saniye) belirlenir. Bu süre boyunca elde edilen sinyallerden, istatistiksel ve frekans tabanlı özellikler çıkarılarak analiz gerçekleştirilir [3, 52].

Ön işleme aşamasında gürültü filtreleme, normalizasyon ve dalgacık dönüşümü gibi teknikler uygulanabilir. Örneğin, her faz akımının yarım dalga periyotlarına ayrılması, sinyalin anlamlı özellik noktalarına bölünmesini sağlar. Bu tür ön işleme adımları, akıllı sınıflandırma yöntemlerinin doğruluğunu artırırken, arıza bileşenlerinin gizlenmesini önler.

Örnek Veri İşleme Akışı:

- 1) **Veri toplama:** Üç faz akımı (I_a , I_b , I_c), tork ve hız sinyalleri DAQ kartı aracılığıyla elde edilir.
- 2) **Önişlem:** Gürültü filtreleme, DC bileşen çıkarma, normalizasyon ve istenirse dalgacık ayrışması yapılır.

- 3) **Özellik çıkarımı:** RMS, tepe faktörü, basıklık, çarpıklık gibi istatistiksel özellikler; belirli frekans bantlarındaki enerji dağılımları, yan bant bileşenlerin genliği gibi bilgiler hesaplanır.
- 4) **Boyut indirgeme:** PCA veya LDA ile özellik uzayının boyutu azaltılarak sınıflandırıcıya daha odaklı bilgi sunulur.
- 5) **Sınıflandırma:** Elde edilen özellik vektörleri, önceki bölümde incelenen Naive Bayes, SVM, ANN, C4.5 vb. yöntemlere aktarılır.

5.3. Gerilim ve Yük Değişkenliğinin Etkileri

Gerçek endüstriyel ortamlarda motorlar her zaman nominal gerilim ve nominal yük altında çalışmazlar. Gerilim dalgalanmaları, fazlar arası dengesizlikler, invertör beslemeli sürücüler ve değişken yük koşulları arıza tespit sürecini zorlaştırır. Bu nedenle deneylerde farklı gerilim ve yük senaryoları oluşturularak yöntemlerin bu koşullara dayanıklılığı test edilir.

Yük Değişkenliği: Yük, motorun tahrik ettiği makineye veya sisteme göre sürekli değişkenlik gösterebilir. Üretim hattında hızla değişen talepler, proses dalgalanmaları torkun nominalin altında veya üzerinde hareket etmesine neden olur. Bu durum, akım imzasındaki harmoniklerin genliğini, titreşim sinyalinin istatistiksel özelliklerini ve diğer ölçütleri değiştirerek arıza teşhisini zorlaştırmaktadır.

DeneySEL aşamada, motor farklı tork seviyelerinde çalıştırılarak (örneğin nominal torkun %25, %50, %75'inde) arıza belirtilerinin bu koşullarda nasıl değiştiği gözlemlenir. Bazı arıza tipleri düşük yükte fark edilmesi zor belirtiler verirken, bazıları yüksek yük altında daha net sinyaller üretebilir. Dolayısıyla, akıllı sınıflandırma yöntemlerinin her bir yük durumunda performansı incelenerek modelin genelleme kabiliyeti değerlendirilmektedir.

5.4. Arıza Oluşturma ve Test Senaryoları

DeneySEL çalışmada, rulman, rotor ve stator arızaları yapay olarak oluşturularak kontrol altındaki koşullar altında test edilir [53]. Örneğin:

- **Rulman Arızası:** Rulmanın dış bileziğinde mikro çentikler oluşturulması, bilyelerde oyuklar açılması veya rulmanın iç bileziğinde yatak deformasyonlarının yaratılmasıyla farklı şiddette arızalar elde edilir. Bu arızaların titreşim ve akım sinyaline yansıyan frekans bileşenleri incelenerek her arıza seviyesi ayrı ayrı test edilir.
- **Rotor Arızası:** Rotor kafesindeki çubuklar delinerek 1 ila 4 kırık çubuk senaryosu oluşturulur. Kırık sayısının artmasıyla arıza belirti-

si (yan bant frekans bileşenleri) belirginleşir. Bu sayede sınıflandırma yöntemlerinin rotor arızası yoğunluğuna verdikleri tepki incelenebilir.

- **Stator Arızası:** Stator sargısında yalıtım malzemesi kontrollü şekilde zayıflatılarak %1, %3, %5, %10, %15 ve %20 oranlarında kısa devre senaryoları oluşturulur. Kısa devre oranı arttıkça motorun akım imzasındaki asimetrikler, faz dengesizlikleri daha belirgin hale gelir ve yöntemlerin arıza şiddetine duyarlılığı ölçülebilir.

Gerçekleştirilen arıza senaryoları, literatürdeki çalışmalarla da uyumludur. Gerçek endüstriyel durumda arızalar genellikle yavaş gelişse de deneysel olarak hızlandırılmış aşınma veya kontrollü zarar verme teknikleriyle belirtiler daha kısa sürede yakalanmaktadır. Elde edilen veriler laboratuvar ortamında kaydedilirken, endüstriyel uygulamaların simülasyonu için farklı yük, gerilim ve hız koşulları da birleştirilerek karmaşık test kombinasyonları oluşturulur.

5.5. Doğrulama, Eğitim-Doğrulama Stratejileri ve Model Genellemesi

Toplanan veriler, akıllı sınıflandırma yöntemlerinin eğitimi ve doğrulanması için kullanılır. Veriler genellikle iki kümeye ayrılır: eğitim verisi ve test (doğrulama) verisi. Eğitim verisi modelin öğrenmesi için kullanılırken, test verisi modelin genelleme kabiliyetini ölçer. Bu amaçla çapraz geçirme (k-katlı) veya benzeri yöntemler benimsenir. Bu sayede modelin farklı veri alt kümelerindeki performansı değerlendirilerek aşırı öğrenme riski minimize edilir [36,41,43,45].

Ayrıca, 4 kW'lık motorlar üzerinde eğitilen bir modelin 3kW'lık motorun arızalarını ne ölçüde genellebildiği de araştırılabilir. Böylece, modelin üretici, verimlilik sınıfı, güç değeri veya motor tipindeki farklılıklara karşı dayanıklılığı test edilir. Benzer şekilde, farklı gerilim dengesizlikleri veya yük değişkenlikleri altındaki performans analizleri, modelin endüstriyel sahada gerçek anlamda kullanılabilirliğini gösterir.

Sonuç

Bu bölümde, asenkron motor arıza teşhisinde kullanılan deneysel yöntemler ve veriler incelenmiştir. Motorun temel özellikleri, deney düzeneği, sensör seçimi, veri toplama hızı, ön işleme adımları, arıza oluşturma yöntemleri, gerilim ve yük varyasyonları konuları ele alınarak akıllı sınıflandırma yöntemlerine uygun bir veri seti oluşturmanın gerekliliği vurgulanmıştır.

Elde edilen deneysel veriler, önceki bölümlerde tanıtılan Naive Bayes, SVM, ANN, C4.5 gibi akıllı sınıflandırıcıların test edilmesinde kullanılır. Bu sayede teorik yaklaşımın endüstriyel gerçekliğe yansması gözlemlenir. Gerçekçi test koşulları, arızalı koşulların laboratuvarında oluşturulması, veri ön işleme tekniklerinin uygulanması ve farklı çalışma senaryolarının incelenmesiyle elde edilen bulgular, ilerleyen bölümlerde sunulacak deney sonuçları, tartışma ve değerlendirmelerin temelini oluşturur [37,38,46,47].

6. Akıllı Sınıflandırıcılarla Arıza Tespiti

Geleneksel arıza teşhis yöntemlerinde temel sinyal analizi tekniklerine veya fiziksel parametrelerin ölçümüne dayanır. Ancak bu yöntemler, karmaşık sistemlerde arızaların erken ve hassas bir şekilde tespit edilmesinde yetersiz kalmaktadır. Örneğin, geleneksel yöntemlerde sinyallerdeki düşük seviyeli değişiklikler gözden kaçabilir, farklı arıza tipleri arasında doğru bir ayırım yapılamayabilir ve yüksek gürültü koşullarında performans düşüşü yaşanabilir. Ayrıca, operatör bağımlılığı, insan hatası riskini artırır ve teşhis süreci zaman kaynına neden olur. Akıllı sınıflandırıcılar ise bu sorunları aşmak için güçlü bir alternatif sunmaktadır. Makine öğrenimi ve derin öğrenme algoritmalarını kullanan bu yaklaşımlar, büyük hacimli ve çok boyutlu verilerden öğrenme kabiliyetine sahiptir. Geleneksel yöntemlerle tespit edilmesi zor olan karmaşık ilişkileri ve örüntüleri analiz edebilir. Özellikle gürültülü sinyallerde arıza bileşenlerini ayrıştırma, farklı yük koşullarında yüksek doğrulukla teşhis yapma ve arıza tiplerini genellenebilir bir şekilde sınıflandırma imkanı sunar. Akıllı sınıflandırıcılar, sadece mevcut arızaları belirlemekle kalmaz, aynı zamanda gelecekteki olası arızaların öngörülmesine de katkıda bulunarak üretim süreçlerinin durmasını engelleyecektir [32-41].

Önceki bölümlerde, bu arıza türlerinin temel özellikleri, veri toplama yöntemleri, sensör seçimi (akım, titreşim, sıcaklık, akustik vb.), veri ön işleme ve özellik çıkarma teknikleri üzerinde durulmuştur. Akıllı sınıflandırıcılar (Naive Bayes, K-En Yakın Komşu [KNN], Destek Vektör Makineleri [SVM], Yapay Sinir Ağları [ANN veya MLP], RIPPER ve C4.5 Karar Ağacı) [54, 55] gibi yöntemlerin teorik temellerine, avantaj ve dezavantajlarına yer verilmiştir. Bu bölümde ise tüm bu parçalar bir araya getirilerek, akıllı

sınıflandırıcıların asenkron motor arıza tespitinde nasıl uygulandığı, hangi senaryolarda hangi yöntemlerin öne çıktığı ve sonuçların nasıl yorumlanması gerektiği incelenecektir [38, 43].

Arıza türü (rulman, rotor, stator), arıza şiddeti (düşük veya yüksek), motor gücü (4 kW, 3kW vb.), besleme tipi (şebekeden veya invertör beslemesi), veri kalitesi, gürültü düzeyi, sensör sayısı ve çeşidi, gerçek zamanlı izleme gereksinimleri, kestirimci bakım stratejileri, IoT destekli veri toplama altyapısı ve bulut tabanlı analiz olanakları gibi etkenler bir araya geldiğinde ortaya çıkan karmaşık tablo, sabit bir yanıt yerine duruma göre en uygun stratejiyi gerektirir.

6.1. Veri Hazırlama, Ön İşleme ve Özellik Seçimi

Akıllı sınıflandırıcıların doğruluk, güvenilirlik ve genelleme kapasitesi, veri hazırlama sürecinin titizlikle yürütülmesine bağlıdır. Asenkron motor arıza teşhisi için kullanılan ham veriler genellikle motorun normal çalışması, arıza öncesi ve arıza sonrası durumlarında toplanan akım, titreşim, sıcaklık ve akustik sinyallerden oluşmaktadır. Ancak bu sinyaller, çevresel gürültüler, non-lineer etkiler ve invertör kaynaklı harmoniklerle birlikte alınmış olabilir. Bu durum doğrudan analiz yapılmasını engelleyerek yanlış sınıflandırma sonuçlarına yol açmaktadır. Ham verilerin sınıflandırma algoritmaları tarafından doğru bir şekilde işlenebilmesi için öncelikle belirli ön işleme adımlarının uygulanması gereklidir. Gürültü azaltma işlemleri, düşük kaliteli sinyalleri iyileştirmek için filtreleme teknikleri ile gerçekleştirilir. Sinyal normalizasyonu, farklı ölçüm cihazlarından elde edilen verilerin birbiriyle kıyaslanabilir hale gelmesini sağlar. Bunun yanı sıra, dalgacık dönüşümü gibi yöntemlerle sinyaller zaman-frekans boyutunda analiz edilerek, arızaya özgü bileşenler daha belirgin hale getirilir [56].

Veri ön işleme sürecinin ardından, sinyallerden istatistiksel (ortalama, varyans, tepe faktörü vb.) ve frekans tabanlı (spektral yoğunluk, harmonik bileşenler vb.) özellikler çıkarılarak bu özellikler arasından en etkili olanlar seçilir. Özellik seçimi, hem verinin boyutunu azaltarak işlem maliyetlerini düşürmekte hem de sınıflandırıcıların performansını artırmaktadır. Bu aşamalar, arıza teşhis modellerinin doğruluk, hız ve genelleme kabiliyetlerini doğrudan etkileyen kritik adımlardır.

Gürültü Filtreleme ve Sinyal Dönüşümleri:

Zaman domenindeki ham sinyaller, dalgacık dönüşümü (wavelet), Hilbert-Huang analizi veya STFT (Short-Time Fourier Transform) gibi yöntemlerle zaman-frekans domainine geçirilebilir. Böylece arıza belirteçlerini taşıyan spesifik frekans bantları tespit edilir. Rulman arızaları genelde belirli

frekans harmoniklerinde belirginleşirken, rotor çubuk kırıkları yan bant frekans bileşenleriyle, stator kısa devreleri fazlar arası asimetriyle belirlenir. Bu dönüşümler, akıllı sınıflandırıcıların işini kolaylaştırmaktadır.

Özellik Çıkarma :

Elde edilen sinyallerden RMS, tepe faktörü, basıklık, çarpıklık gibi istatistiksel özellikler; dalgacık enerjileri, belirli frekans bantlarındaki genlikler, harmonik bileşenler ve zaman domenindeki geçici belirteçler çıkarılabilir. Amaç, ham veride gizli olan arıza belirtecini netleştirecek, sınıflandırıcının kolayca ayırt edebileceği bir özellik uzayı yaratmaktır [56].

Boyut İndirgeme ve Normalizasyon:

PCA veya LDA gibi boyut indirgeme yöntemleri, yüzlerce özelliği birkaç temel bileşene indirerek hesaplama maliyetini düşürür, sınıflandırıcıların aşırı öğrenme riskini azaltır. Normalizasyon, özelliklerin benzer ölçeklere çekilmesini sağlayarak, mesafe tabanlı yöntemlerde (KNN gibi) veya gradient tabanlı optimizasyon kullanan ANN, SVM gibi yöntemlerde performans artışı sağlamaktadır [57].

6.2. Farklı Arıza Türlerinde Sınıflandırıcıların Uygulanması

Rulman Arızaları:

Rulman arızalarında (iç bilezik, dış bilezik, bilye arızaları) titreşim sinyalinde belirteç bırakılmaktadır. Örneğin dış bilezik arızası belirli bir frekansta titreşim genliğini artırır. Bu veriler dalgacık enerjisi veya frekans bant genliği formunda sınıflandırıcıya sunulduğunda ANN veya KNN çoğu zaman %90-99 arası doğruluk elde etmektedir. C4.5 veya Naive Bayes gibi yöntemler, bazı senaryolarda daha düşük doğrulukta kalsa da veri ön işleme adımları iyileştirilerek performans artırılabilir.

Rotor Arızaları (Kırık Rotor Çubukları):

Kırık rotor çubuk arızası akım sinyalinin yan bant frekans bileşenleri oluşturmaktadır. ANN ve KNN bu bileşenleri genelde çok iyi tespit etmektedir. SVM de uygun çekirdek fonksiyon ve parametre ayarıyla %95 üzeri doğruluk sağlayabilmektedir. Naive Bayes bu arızada doğruluk oranında SVM göre geride kalsa da basitliği ve hızıyla ilk yaklaşım olarak değerlendirilebilir. C4.5, uygun verilerle beslendiğinde karar ağaçları aracılığıyla hangi frekans bileşenlerinin kritik olduğunu açıklar, bu da bakım personeline anlamlı bir geri bildirim olmuş olur [58-60].

Stator Arızaları (Kısa Devreler):

Stator sargılarında meydana gelen düşük seviyeli kısa devrelerin tespiti, arıza belirtilerinin çok zayıf olması nedeniyle en zor teşhis senaryoları arasında yer almaktadır. Stator arızalarında özellikle KNN (K-En Yakın Komşu) algoritması %90'ın üzerinde doğruluk oranlarıyla sonuçlar verebilmektedir. SVM (Destek Vektör Makineleri) ve MLP (Çok Katmanlı Algılayıcı) gibi yöntemler daha düşük doğrulukta sonuç vermektedir. Arıza şiddeti arttığında (örneğin, sargılarda %10 oranında kısa devre oluştuğunda), MLP ve KNN gibi yöntemlerin doğruluk oranı artmaktadır [61-62].

6.3. Gerçek Zamanlı Uygulamalar, IoT Entegrasyonu ve Bulut Tabanlı Analiz

Arıza tespiti, sadece laboratuvar koşullarında değil, gerçek zamanlı endüstriyel ortamlarda uygulanabilir olmalıdır. Üretim hattı durmaksızın çalışırken sensör verileri anlık olarak toplanır, ön işlenir ve sınıflandırıcıya sunulur. Bu aşamada hız, kaynak optimizasyonu, düşük bellek kullanımı gibi parametreler önem arz etmektedir [63].

- **Gerçek Zamanlı İşleme:** KNN algoritması eğitim aşaması gerektirmediğinden küçük veri setlerinde test aşamasında hızlı olmaktadır. Ancak büyük veri tabanlarında her test örneği için tüm eğitim örneklerini karşılaştırması zaman almaktadır. Naive Bayes algoritması çok hızlı olsa da bazı senaryolarda düşük doğruluk göstermektedir. SVM veya MLP iyi eğitildiklerinde test aşamasında çok hızlı karar verir ve gerçek zamanlı uygulamalara uygundur. C4.5 veya RIPPER, testte çok hızlıdır, çünkü karar ağacı ya da kural kümesi hızlı değerlendirilir. Bu nedenle gerçek zamanlı izleme sistemlerinde C4.5'in yorumlanabilirliği ve hızı avantajlı olmaktadır.
- **IoT ve Uzaktan İzleme:** Modern endüstriyel tesislerde IoT tabanlı sensör ağları, motor verilerini kablosuz olarak toplayıp buluta aktarmaktadır. Bulutta çalışan sınıflandırıcılar veya makine öğrenimi modelleri, farklı noktalardan gelen verileri toplayarak çok daha geniş bir eğitim aşaması kazanır. Bu eğitim aşaması algoritmanın doğruluğu artırır ve arıza tespiti için ortak modeller oluşturulmasına imkân sağlar.

6.4. Kestirimci Bakım ve Dijital İkiz Teknolojisi

Arıza tespiti, sadece gerçekleşen arızaları belirlemekle sınırlı kalmamaktadır. Kestirimci bakım stratejileri, arıza oluşmadan önce makine sağlığını izleyerek bakım zamanlarını optimize etmektedir. Akıllı sınıflandırıcılar bu aşamada makine öğrenimi tabanlı kestirimci modellerle

bütünleşmektedir. Zaman serisi analiziyle ortaya çıkan eğilimler, artan titreşim genliği veya akım asimetrisi gibi göstergeler, MLP ve SVM gibi yöntemler için öğrenme fırsatları sunar ve bu yöntemlerin arıza teşhisindeki doğruluğunu artırmaktadır. Böylece model belirli bir eşığa yaklaşıldığında uyarı vererek planlı bakımın yapılmasını sağlar [64].

Dijital ikiz teknolojisi, fiziksel motorun sanal bir kopyasını (ikizini) oluşturarak sensör verileriyle besler. Bu ikiz, normal çalışma ve arızalı senaryoların simülasyonunu yapar. Akıllı sınıflandırıcılar, bu dijital ikiz üzerinden farklı koşullar, yükler, besleme gerilimleri, gürültü seviyeleri gibi parametreleri deneyebilir. Bu sayede gerçek motor etkilenmeden en uygun yöntemler, parametreler ve bakım stratejileri belirlenmektedir [64].

6.5. Gürültülü Ortamlar, Sensör Füzyonu ve Ansambl Yöntemler

Gerçek endüstriyel ortamlar her zaman ideal koşulları sunmamaktadır. Gürültü, eksik veri, sensör hataları, invertör harmonikleri, şebeke dengesizliği gibi etkenler arıza tespitini zorlaştırmaktadır. Bu noktada sensör füzyonu etkin olmaktadır. Akım verisi zayıf kalıyorsa titreşim veya sıcaklık verileri arıza belirtecini desteklemektedir. Sensör füzyonu, ANN veya SVM'nin daha zengin bir özellik uzayında çalışmasını sağlayarak doğruluğu artırır. Ansambl yöntemler (Rastgele Orman, XGBoost) ise birden fazla basit modelin (karar ağaçları gibi) oy çokluğuna veya ağırlıklı kombinasyonuna dayandığından gürültülü verilerde daha istikrarlı sonuçlar vermektedir. Bu yöntemler, özellikle çoklu arıza durumlarında veya değişen koşullara genelleme kabiliyetinin korunmasında etkilidir [65].

Derin öğrenme yaklaşımları da karmaşık, gürültülü ve yüksek boyutlu veri setlerinde otomatik özellik çıkarma kabiliyetiyle öne çıkmaktadır. CNN tabanlı modeller, titreşim veya akım sinyalinin spektrumlarını işleyerek rulman arızalarını tanıyabilmektedir. LSTM veya GRU tabanlı ağlar, zaman serileri üzerinde çalışarak arızayı tahmin edebilir ve kestirimci bakıma destek olur.

6.6. Performans Ölçütleri ve Karar Alma Süreçleri

Arıza tespiti sistemlerinin başarısını değerlendirmek için doğruluk (%Accuracy) sıkça kullanılır, ancak tek başına yeterli bir ölçüt değildir. Doğruluğun yanı sıra hassasiyet (Precision), duyarlılık (Sensitivity), özgüllük (Specificity), F1 skoru, Kappa istatistiği, ROC eğrisi ve AUC gibi ek metrikler model performansını farklı açılardan değerlendirmesini sağlar. Duyarlılığın yüksek olması, sistemin gerçek arızaları tespit etme kapasitesinin güçlü olduğunu gösterir; ancak özgüllük düşükse yanlış durum

oranı artabilir. Bu nedenle, belirli bir uygulamada hangi ölçütün öncelikli olduğuna karar vermek, arıza tespiti sisteminin etkili şekilde uygulanması için kritik bir adımdır [66].

Karar alma süreçlerini desteklemek için performans ölçütlerinin görselleştirilmesi önemlidir. Özellikle sınıflandırıcıların farklı koşullardaki başarılarını değerlendirmek için tablolar ve grafikler kullanılır. Bu yöntemler, birden fazla modelin doğruluk, Kappa istatistiği, test süreleri ve genelleme kabiliyetini karşılaştırmayı kolaylaştırır. Ayrıca performans analizleri, sistem tasarımında öncelikleri belirlemeye ve sınıflandırıcı seçimini optimize etmeye katkı sunar. Uygulama senaryosuna göre metriklerin ağırlıklandırılması ve karar süreçlerine entegre edilmesi, arıza teşhisinde daha güvenilir ve etkin sonuçlar elde edilmesini sağlar [66].

6.7. Uygulama Örnekleri

Akıllı sınıflandırıcıların performansını değerlendirmek ve endüstriyel ortamlarda kullanım potansiyellerini ortaya koymak önemlidir. İşletmede farklı koşullar ve çeşitli arıza türlerine yönelik senaryo analizleri, sınıflandırıcıların doğruluk, işlem hızı, genelleme kapasitesi ve yorumlanabilirlik gibi kritik performans kriterlerini kapsamlı bir şekilde değerlendirme imkanı sunar.

Birinci senaryoda, orta ölçekli bir üretim tesisinde invertör beslemeli 3 kW motorların rulman arızasına yatkın olduğu bir durum ele alınmıştır. Bu tesis, akım, titreşim ve sıcaklık verilerini toplayarak arıza teşhisini gerçekleştirmektedir. Veriler üzerinde dalgacık dönüşümü uygulanmış ve belirli frekans bantlarındaki enerji artışları özellik olarak çıkarılmıştır. Bu özellikler, MLP, SVM, KNN ve C4.5 gibi çeşitli sınıflandırıcılarla test edilmiş ve sırasıyla %95, %92, %90 ve %85 doğruluk oranları elde edilmiştir [25-29]. Ancak, sınıflandırıcı seçiminde yalnızca doğruluk oranları yeterli olmayabilir. Karar verme sürecinde modelin hız, yorumlanabilirlik ve gerçek zamanlı uygulama gereksinimleri gibi faktörler de dikkate alınmalıdır. Örneğin, C4.5 modeli, daha düşük doğruluğuna rağmen yorumlanabilirlik ve işlem hızındaki avantajları nedeniyle tercih edilebilir [30-33]. Bu tür senaryolarda, karar desteği sağlamak için sensör füzyonu artırılabilir ya da ansambl yöntemler devreye alınabilir.

İkinci bir senaryoda ise stator sargı kısa devre şiddetinin %1'den %10'a kadar artışı incelenmiştir. Bu analizde, MLP ve KNN yöntemlerinin doğruluğunun %90'dan %99'a yükseldiği, diğer yöntemlerin ise benzer bir trend göstermesine rağmen performans artışının daha sınırlı kaldığı gözlemlenmiştir. Bu tür senaryolar, sınıflandırıcı performansının arıza şiddetine duyarlılığını görselleştirerek bakım mühendisleri ve veri analistleri için önemli bilgiler sunmaktadır [46-47].

7. Yöntemlerin Performans Değerlendirmesi

Sınıflandırma algoritmalarının avantajlarını, dezavantajlarını ve performanslarını değerlendirmek, doğru yöntem seçiminde önemli bir rol oynamaktadır. Bu bölümde, farklı sınıflandırma algoritmalarının güçlü ve zayıf yönleri, matematiksel temelleriyle birlikte ele alınacaktır. Ayrıca algoritmaların hangi durumlarda üstün performans sergilediği ve hangi sınırlamalara sahip olduğu detaylı bir şekilde değerlendirilecek, bu doğrultuda sınıflandırıcı seçiminde yönlendirme sağlayacak bilgiler sunulacaktır.

7.1. Sınıflandırma Algoritmalarının Avantaj ve Dezavantajları

Bu bölümde, yaygın kullanılan sınıflandırma algoritmalarının temel özellikleri, uygulama alanları, avantajları ve sınırlamaları ele alınmaktadır.

7.1.1. Naive Bayes (NB)

Naive Bayes (NB), olasılık tabanlı bir algoritmadır ve Bayes Teoremi'ni temel alır. Özelliklerin bağımsız olduğu varsayımıyla çalışır ve bu varsayım nedeniyle “naive” olarak adlandırılır [37-38].

Matematiksel Temel:

Bayes Teoremi şu şekilde ifade edilir:

$$P(CX) = \frac{P(XC) \cdot P(C)}{P(X)}$$

Burada:

- $P(C|X)$: Veri seti X 'in sınıf C 'ye ait olma olasılığı
- $P(X|C)$: X 'in C sınıfında görülme olasılığı
- $P(C)$: C sınıfının önsel olasılığı
- $P(X)$: X 'in genel olasılığı

NB sınıflandırıcı, tüm özelliklerin bağımsız olduğunu varsayar:

$$P(C|X) = \frac{P(C) \prod_{i=1}^n P(x_i|C)}{P(X)}$$

Avantajlar:

- Hızlı ve hesaplama maliyeti düşüktür.
- Küçük veri setlerinde etkili çalışır.
- Eksik verilerle çalışabilme kapasitesine sahiptir.

Dezavantajlar:

- Özellik bağımsızlığı varsayımı, gerçek dünyadaki veriler için genellikle geçerli değildir.
- Karmaşık ilişkileri yakalamakta yetersiz kalabilir.

7.1.2. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (SVM), sınıflar arasındaki en iyi ayrım sınırını bulmayı amaçlar. Çekirdek (kernel) fonksiyonları sayesinde doğrusal olmayan problemleri de çözebilir [41-42].

Matematiksel Temel:

SVM'nin optimizasyon problemi şu şekilde tanımlanır:

$$\min_{w,b} \frac{1}{2} w^2$$

Koşul:

$$y_i (w \cdot x_i + b) \geq 1 - \xi_i \quad \forall_i$$

Burada:

w : Ağırlık vektörü

b : Sabit terim

ξ_i : Hata terimi

y_i : Sınıf etiketi (+1 veya -1)

Çekirdek fonksiyonu ile özellik uzayı genişletilebilir:

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$$

Avantajlar:

- Yüksek boyutlu veri setlerinde etkili çalışır.
- Çekirdek fonksiyonları ile doğrusal olmayan problemleri çözer.
- Aşırı öğrenmeye karşı dayanıklıdır.

Dezavantajlar:

- Parametre seçimi karmaşıktır.
- Büyük veri setlerinde yavaş çalışabilir.

7.1.3. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları (ANN), biyolojik sinir sistemlerinden esinlenerek geliştirilmiş bir algoritmadır. Katmanlı bir yapı kullanarak karmaşık örüntüleri öğrenir ve modelleyebilir [44-45].

Matematiksel Temel:

Sinir ağları, giriş verilerini işleyerek her nöron için ağırlıklandırılmış toplamı hesaplar ve bir aktivasyon fonksiyonu ile sonuçları işler:

$$z_j = \sum_{i=1}^n w_{ji} x_i + b_j$$

Burada:

z_j : j nöronunun çıktısı

w_{ji} : Ağırlıklar

x_i : Giriş değerleri

b_j : Bias terimi

Aktivasyon fonksiyonu (örneğin sigmoid) şu şekilde olabilir:

$$f(z) = \frac{1}{1 + e^{-z}}$$

Hata fonksiyonu ise:

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Avantajlar:

- Karmaşık ve doğrusal olmayan ilişkileri öğrenebilir.
- Çoklu katmanlı yapısı sayesinde genelleme kapasitesi yüksektir.

Dezavantajlar:

- Yüksek hesaplama gücü gerektirir.
- Hiperparametre ayarları zordur.

7.1.4. Rastgele Orman (RF)

Rastgele Orman, birden fazla karar ağacı modeli oluşturarak sonuçları birleştirir. Ağaçlar, rastgele özellik alt kümeleri üzerinde eğitilir [46-47].

Matematiksel Temel:

Her bir ağacın tahmini:

$$h_t(x)$$

Toplam tahmin:

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T h_t(x)$$

Burada T , toplam ağaç sayısını ifade eder.

Avantajlar:

- Gürültülü veri setlerinde dayanıklıdır.
- Ağaçlar arasındaki çeşitlilik aşırı öğrenmeyi önler.

Dezavantajlar:

- Fazla sayıda ağaç olduğunda hesaplama maliyeti artar.
- Model karmaşıklığını artırabilir.

7.1.5. KNN ve XGBoost Algoritmaları**K-Nearest Neighbors (KNN)**

KNN Algoritması özellikle kolay uygulanabilirliği ve sezgisel yapısı sayesinde yaygın bir sınıflandırma yöntemidir. Algoritma yeni bir veri noktasını sınıflandırırken, bu noktaya en yakın k komşunun sınıfına bakar ve çoğunluk kuralına göre sınıflandırma yapar [67].

Avantajlar:

- Uygulaması basittir; karmaşık bir model gerektirmez.
- Herhangi bir parametre optimizasyonu gerektirmez ancak k değeri dikkatlice seçilmelidir.
- Farklı veri türleriyle çalışabilir.

Dezavantajlar:

- Büyük veri setlerinde hesaplama maliyeti yüksektir; her yeni veri için tüm veri setindeki mesafeler hesaplanır.
- Gürültülü verilere karşı duyarlıdır.
- Doğru bir sonuç için k değeri dikkatlice belirlenmelidir.

KNN algoritmasının temel matematiksel adımı, bir veri noktası ile diğer veri noktaları arasındaki mesafeyi hesaplamaktır. En yaygın kullanılan mesafe ölçütü Öklid mesafesidir:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Burada:

x_i ve y_i , x ve y veri noktalarının i -inci özellikleridir.

n , veri noktalarının özellik sayısıdır.

XGBoost (Extreme Gradient Boosting)

XGBoost, gradient boosting algoritmasının optimize edilmiş bir versiyonudur. Özellikle yüksek doğruluk oranı ve hızlı hesaplama yeteneği

ile dikkat çeker. Ağaç tabanlı modellerle çalışan XGBoost, çoğunlukla yarışmalarda veya gerçek dünya problemlerinde öne çıkan bir algoritmadır [68].

Avantajlar:

- Büyük veri setleri üzerinde yüksek doğruluk sağlar.
- Otomatik özellik seçimi ve kayıp fonksiyonu optimizasyonu sunar.
- Gelişmiş parametre ayarlarıyla yüksek esneklik sağlar.

Dezavantajlar:

- Karmaşıklık nedeniyle uygulanması daha zordur.
- Yanlış parametre ayarları, performansı olumsuz etkileyebilir.
- Hesaplama süresi ve kaynak kullanımı yüksektir.

XGBoost, aşağıdaki kayıp fonksiyonunu optimize eder:

$$L(\Theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

Burada:

$l(y_i, \hat{y}_i)$: Tahmin edilen (\hat{y}_i) ve gerçek (y_i) değerler arasındaki kayıp fonksiyonu,

$\Omega(f_k)$: Modelin karmaşıklığını kontrol eden düzenleme terimi,

K : Toplam zayıf öğrenicilerin sayısı.

XGBoost'un düzenleme terimi genellikle şu şekilde ifade edilir:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

Burada:

- T : Karar ağacındaki yaprak sayısı,
- w_j : Her bir yaprak için ağırlık,
- γ : Karmaşıklık parametresi,
- λ : Düzenleme katsayısı.

7.2. Performans Metriklerinin Değerlendirilmesi

Performans metriklerinin doğru bir şekilde değerlendirilmesi, sınıflandırma algoritmalarının güçlü ve zayıf yönlerini anlamak için kritik bir öneme sahiptir. Bu metrikler algoritmaların doğruluğunu, verimliliğini ve genelleme yeteneğini ölçmek için kullanılır. Aşağıdaki alt başlıklarda, her bir metrik detaylı bir şekilde açıklanacak ve formüllerle desteklenecektir [69].

7.2.1. Doğruluk (Accuracy)

Doğruluk genellikle sınıflandırma modellerinin performansını değerlendirmek için kullanılan en temel metriktir. Bir sınıflandırıcının doğru tahmin edilen örneklerin toplam örneklere oranını ifade eder [69].

Formül:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Burada:

- *TP* (True Positive): Doğru pozitif sınıflandırmalar,
- *TN* (True Negative): Doğru negatif sınıflandırmalar,
- *FP* (False Positive): Yanlış pozitif sınıflandırmalar,
- *FN* (False Negative): Yanlış negatif sınıflandırmalar.

Avantajlar:

- Hesaplaması kolaydır.
- Genel performansı hızlı bir şekilde ölçmek için uygundur.

Dezavantajlar:

- Veri setindeki sınıf dengesizliklerini dikkate almaz. Örneğin, sınıfların biri büyük bir çoğunluğu oluşturuyorsa, model bu sınıfı sürekli tahmin ederek yüksek doğruluk elde edebilir.

7.2.2. Hassasiyet (Precision) ve Duyarlılık (Recall)

Hassasiyet ve duyarlılık özellikle dengesiz veri setlerinde doğruluğun yeterli olmadığı durumlarda daha açıklayıcı performans metrikleridir [69].

Hassasiyet (Precision)

Hassasiyet modelin pozitif tahminlerinin ne kadarının doğru olduğunu ölçer.

Formül:

$$Precision = \frac{TP}{TP + FP}$$

Duyarlılık (Recall) veya Tespit Oranı (Sensitivity)

Duyarlılık gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir.

Formül:

$$Recall = \frac{TP}{TP + FN}$$

Avantajlar:

- Hassasiyet yanlış pozitiflerden kaçınılması gereken durumlarda önemlidir (örneğin, spam filtresi).
- Duyarlılık yanlış negatiflerin önlenmesinin kritik olduğu durumlarda daha kullanışlıdır (örneğin, kanser tespiti).

Dezavantajlar:

- Tek başlarına modelin genel performansını değerlendirmek için yeterli değildir.

7.2.3. F1 Skoru ve ROC Eğrisi**F1 Skoru**

F1 skoru hassasiyet ve duyarlılığın dengeli bir şekilde değerlendirilmesini sağlayan bir metriktir. İki metriğin harmonik ortalamasıdır ve özellikle dengesiz veri setlerinde faydalıdır [69].

Formül:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

ROC Eğrisi ve AUC

ROC (Receiver Operating Characteristic) eğrisi, bir sınıflandırma modelinin farklı eşik değerlerinde duyarlılık (sensitivity) ile yanlış pozitif oranı (false positive rate) arasındaki ilişkiyi görselleştirir. Eğri altında kalan alan (AUC - Area Under Curve), modelin genel performansını değerlendiren bir metriktir ve sınıflandırıcının, pozitif ve negatif sınıfları doğru ayırt etme yeteneğini özetler [69].

ROC Eğrisi Eksenleri:

- X Eksen: Yanlış Pozitif Oranı ($FP/(FP+TN)$)
- Y Eksen: Duyarlılık ($TP/(TP+FN)$)

Avantajlar:

- F1 skoru, dengesiz veri setlerinde genelleme yeteneğini ölçmek için faydalıdır.
- ROC eğrisi ve AUC, eşik değerine bağımlı olmadan modelin genel performansını değerlendirmek için idealdir.

7.2.4. Kappa İstatistiği ve İlgili Metrikler

Kappa istatistiği, sınıflandırıcının rastgele tahminlerle karşılaştırıldığında ne kadar iyi performans gösterdiğini ölçen bir metriktir.

Formül:

$$\kappa = \frac{P_0 - P_e}{1 - P_e}$$

Burada:

P_0 : Gözlemlenen doğruluk,

P_e : Rastgele tahminle beklenen doğruluk.

Avantajlar:

- Sınıf dengesizliklerini dikkate alır.
- Rastgele sınıflandırmaya göre iyileşmeyi ölçer.

Dezavantajlar:

- Hesaplaması diğer metriklere göre daha karmaşıktır.

7.3. Algoritmaların Karşılaştırılması

Farklı algoritmalar çeşitli kriterlere göre karşılaştırıldığında farklı güçlü ve zayıf yönleri sahiptir. Bu bölümde, hız ve bellek kullanımı, gürültü ve sensör füzyonu altındaki performans ile eğitim ve test süreleri gibi önemli faktörler detaylı bir şekilde ele alınacak ve bu parametreler ışığında algoritmaların avantajları ve dezavantajları tartışılacaktır [70].

7.3.1. Hız ve Bellek Kullanımı

Makine öğrenmesi algoritmalarının verimliliği özellikle büyük veri setleriyle çalışırken hız ve bellek kullanımı gibi faktörlerle doğrudan ilişkilidir. Algoritmaların bu iki parametre açısından performansı şu şekilde karşılaştırılabilir [70]:

- **Naive Bayes (NB):** Minimal bellek kullanımı ve hızlı sonuç üretme kabiliyeti ile tanınır. Ancak, yüksek boyutlu veri setlerinde doğruluk oranı düşebilir.
- **SVM:** Özellikle doğrusal olmayan problemleri çözerken yüksek doğruluk sağlasa da büyük veri setlerinde bellek kullanımı önemli ölçüde artar ve hız düşer. Çekirdek (kernel) fonksiyonlarının seçimi bu performansı etkiler.
- **ANN:** Büyük miktarda bellek gerektirir ve eğitim süreci genellikle uzun sürer. Ancak karmaşık veri setlerini işleme kapasitesi ile güçlüdür.
- **Rastgele Orman (RF):** Bellek kullanımı, kullanılan ağaç sayısına bağlı olarak artar. Eğitim süresi genellikle uzun olsa da test süresi oldukça kısadır.
- **XGBoost:** Paralel işlem yeteneği sayesinde hız avantajına sahiptir. Ancak, parametre optimizasyonu bellek gereksinimini artırabilir.

Formül ve Ölçütler

Bellek kullanımı genellikle modelin ağırlıkları ve hiperparametreleri ile doğrudan ilişkilidir:

Bellek Kullanımı \propto *Ağaç Sayısı (RF)* + *Ağırlık Matrisi Boyutu (ANN, SVM)*

Hız ise algoritmanın karmaşıklığına bağlıdır:

Zaman Karmaşıklığı (SVM) = $O(n^3)$ (*n*: veri seti büyüklüğü)

7.3.2. Gürültü ve Sensör Füzyonu Altındaki Performans

Veri setlerinin gerçek dünyada genellikle gürültü içerdiği göz önünde bulundurulmalıdır. Gürültü sınıflandırıcıların doğruluğunu etkileyen önemli bir faktördür. Ayrıca, sensör füzyonu gibi yöntemlerle birden fazla veri kaynağı birleştirilerek daha dayanıklı sonuçlar elde edilebilir [70].

- **Naive Bayes:** Gürültüye karşı dayanıklılığı sınırlıdır. Ancak sensör füzyonu ile veri çeşitliliği artırıldığında performans artabilir.
- **SVM:** Çekirdek fonksiyonları sayesinde gürültüyü tolere edebilir ancak çok gürültülü veri setlerinde doğruluğu düşebilir.
- **ANN:** Büyük miktarda veri ve çeşitli özelliklerle çalıştığı için gürültüyü filtrelemede başarılıdır.
- **Rastgele Orman:** Gürültüye oldukça dayanıklıdır. Çoklu sensör verilerini birleştirme yeteneği sayesinde doğruluk oranı yüksektir.
- **XGBoost:** Gürültüyü filtrelemede etkili bir algoritmadır. Özellikle ağırlıklı öğrenme sayesinde zayıf sınıflandırıcıları iyileştirebilir.

Sensör Füzyonu ve Performans Artışı

Birden fazla sensör verisinin birleştirilmesi (örneğin, sıcaklık, titreşim, akustik veriler) sınıflandırıcıların daha sağlam sonuçlar üretmesine yardımcı olur:

$$\text{Sensör Füzyon Performansı} = \text{Birleşik Özellik Uzayı} + \text{Geliştirilmiş Doğruluk}$$

7.3.3. Eğitim ve Test Süreleri

Eğitim ve test süreleri algoritma seçimi sırasında kritik bir faktördür. Büyük ölçekli veri setlerinde özellikle gerçek zamanlı uygulamalarda bu sürelerin optimize edilmesi önemlidir [70].

- **Naive Bayes:** Hem eğitim hem de test süresi oldukça kısadır. Bu özelliği ile gerçek zamanlı uygulamalarda tercih edilir.
- **SVM:** Eğitim süresi veri seti büyüklüğüne bağlı olarak uzar. Ancak, test süresi genellikle kısadır.
- **ANN:** Eğitim süresi katman ve nöron sayısına bağlı olarak uzar. Test süresi eğitim süresine kıyasla daha kısadır.
- **Rastgele Orman:** Eğitim süresi kullanılan ağaç sayısına bağlıdır. Test süresi ise oldukça hızlıdır.

- **XGBoost:** Eğitim süresi parametrik optimizasyon nedeniyle diğer yöntemlere göre daha uzundur. Ancak paralel işlem kapasitesi bu süreyi düşürür.

Eğitim ve Test Sürelerinin Hesaplanması

Eğitim süresi model parametrelerinin öğrenilme sürecini kapsar. Test süresi eğitilmiş modelin yeni veriler üzerinde tahmin yapma sürecidir.

$$\text{Eğitim Süresi (ANN)} = O(n \cdot d \cdot k)$$

Burada:

- n : Eğitim veri sayısı,
- d : Özellik sayısı,
- k : Katman sayısı.

$$\text{Test Süresi (RF)} = O(T \cdot d)$$

Burada T , ağaç sayısını ifade eder.

Bu bölümde, algoritmalar hız, bellek kullanımı, gürültüye dayanıklılık, sensör füzyonu ve eğitim-test süreleri açısından karşılaştırılmıştır. Her algoritmanın güçlü ve zayıf yönleri, belirli uygulama senaryolarına uygun şekilde analiz edilmiştir. Bu analiz mühendislerin ve araştırmacıların gerçek dünya uygulamalarında en uygun yöntemi seçmelerine rehberlik edecektir.

7.4. Uygulama Alanları ve Vaka Analizleri

Sınıflandırma algoritmalarının etkinliğini anlamak ve değerlendirmek için gerçek hayattan uygulama senaryolarını incelemek önemlidir. Bu bölümde enerji santrallerinden otomotiv endüstrisine, petrokimya tesislerinden çeşitli sanayi alanlarına kadar farklı sektörlerdeki arıza tespit yöntemleri ele alınacaktır. Her bir alt başlık altında ilgili sektörün zorlukları, sınıflandırma algoritmalarının katkıları ve örnek vaka analizleri incelenecektir [71].

7.4.1. Enerji Santrallerindeki Arıza Tespiti

Enerji santralleri sürekli ve kesintisiz bir enerji üretimi sağlamak amacıyla kompleks ekipmanlarla donatılmıştır. Jeneratörler, türbinler, pompalar ve elektrik motorları gibi ekipmanların düzgün çalışması sistemin bütünlüğü için hayati önem taşımaktadır. Ancak bu ekipmanlarda meydana gelen arızalar üretim kaybına ve ciddi maliyetlere yol açabilir. Aşağıda enerji santraline ait örnek bir senaryo verilmiştir.

Zorluklar:

- Sürekli değişen yük koşulları,
- Yüksek sıcaklık ve basınç gibi zorlu çalışma ortamları,
- Gürültülü veri setleri ve sensör hassasiyeti.

Çözüm Yaklaşımları:

- Destek Vektör Makineleri (SVM): Türbinlerde meydana gelen dengesizlikleri ve titreşim anormalliklerini tespit etmek için idealdir.
- Rastgele Orman (RF): Gürültülü verilerde dayanıklılık sağlar ve çoklu arıza türlerini eş zamanlı olarak değerlendirebilir.
- Sensör Füzyonu: Titreşim, sıcaklık ve akım verilerinin birleştirilmesiyle daha doğru teşhis sonuçları elde edilir.

Vaka Analizi: Bir enerji santralinde jeneratör rotorunda dengesizlik problemi yaşanmıştır. SVM ile titreşim verileri analiz edilmiş ve kısa sürede arıza teşhis edilmiştir. Rastgele Orman algoritması ile geçmiş veri analizi yapılarak benzer arızaların meydana gelme sıklığı tahmin edilmiştir. Sonuç olarak kestirimci bakım programı optimize edilmiş ve maliyetler %15 oranında azaltılmıştır.

7.4.2. Otomotiv Endüstrisinde Rulman Arızaları

Otomotiv sektörü hem üretim süreçlerinde rulman arızalarını sıkça rastlanmaktadır. Rulman arızaları genellikle titreşim ve sıcaklık verileriyle tespit edilir ve zamanında müdahale edilmezse üretim hattında büyük kesintilere neden olabilir.

Zorluklar:

- Yüksek üretim hızı nedeniyle veri toplama sürecinin kısıtlı olması,
- Tekrar eden titreşim sinyalleri arasında arızayı ayırt etmenin güçlüğü,
- Çalışma ortamından kaynaklanan gürültü.

Çözüm Yaklaşımları:

- Naive Bayes (NB): Küçük veri setlerinde hızlı ve etkili bir çözüm sunar.
- Yapay Sinir Ağları (ANN): Karmaşık rulman arızalarının sınıflandırılmasında başarılıdır.
- F1 Skoru: Arıza tespitinde doğruluk ve hassasiyet dengesini ölçmek için kullanılır.

Vaka Analizi: Bir otomotiv fabrikasında rulman arızalarının sıkça yaşandığı tespit edilmiştir. ANN algoritması farklı hız ve yük koşulları altında çalışarak rulman titreşim verilerindeki anomalileri analiz etmiştir. ROC eğrisi ile performans doğrulanmış ve arıza tespit oranı %98'e çıkarılmıştır. Bu sayede üretim hattındaki kesintiler %25 oranında azalmıştır.

7.4.3. Petrokimya Tesislerinde Çoklu Arıza Senaryoları

Petrokimya tesisleri, genellikle karmaşık süreçler ve çok sayıda ekipman içeren dinamik bir yapıya sahiptir. Bu tür tesislerde aynı anda birden fazla arızanın meydana gelme olasılığı oldukça yüksektir. Örneğin, bir pompada meydana gelen mekanik bir arıza elektrik motorunu da etkileyebilir.

Zorluklar:

- Çoklu arızaların aynı anda meydana gelmesi,
- Çalışma koşullarındaki sürekli değişkenlik,
- Kritik ekipmanların arızalanmasının yüksek maliyetlere yol açması.

Çözüm Yaklaşımları:

- XGBoost: Çoklu arıza türlerini yüksek doğruluk oranıyla sınıflandırabilir.
- KNN: Küçük ve homojen veri kümelerinde etkili bir şekilde çalışır.
- Sensör Füzyonu: Titreşim, basınç ve sıcaklık sensörlerinden gelen verilerin birleşimiyle arıza tespit edilir.

Vaka Analizi: Bir petrokimya tesisinde, bir pompada hem mekanik (mil eğriliği) hem de elektriksel (stator kısa devresi) arıza yaşanmıştır. XGBoost algoritması, sensörlerden gelen verileri analiz ederek bu arızaları eş zamanlı olarak tespit etmiştir. Bu analiz sonucu, bakım ekibi tarafından hızlı müdahale sağlanmış ve tesis duruş süresi %40 oranında azaltılmıştır.

7.4.4. Uygulama Alanlarından Genel Çıkarımlar

Saha analizleri sınıflandırma algoritmalarının farklı sektörlerdeki önemini ve katkılarını açıkça göstermektedir. Algoritma seçimi yapılırken:

- Arıza türü,
- Çalışma koşulları,
- Veri setinin büyüklüğü ve kalitesi,
- Sensör tipleri ve doğruluğu gibi faktörler dikkate alınmalıdır.

Gelecekte bu tür sistemlerin IoT ve bulut tabanlı teknolojilerle entegrasyonu daha akıllı ve otonom arıza tespit sistemlerinin geliştirilmesine olanak tanıyacaktır.

7.5. Karar Alma Süreçleri

Arıza tespiti ve sınıflandırma yöntemleri arasında karar vermek mühendislik projelerinde oldukça kritik bir süreçtir. Algoritma seçimi uygulama koşullarına, veri setinin özelliklerine, sistem gereksinimlerine ve bütçe kısıtlamalarına göre değişiklik göstermektedir. Ayrıca gerçek zamanlı sistemler için yapılan seçimler sistemin performansı ve güvenilirliği üzerinde doğrudan etkiye sahiptir [69-71].

Algoritma seçiminde dikkat edilmesi gereken kriterler ve gerçek zamanlı sistemlerde uygulanabilir yöntemler için öneriler detaylı bir şekilde ele alınacaktır.

7.5.1. Algoritma Seçim Kriterleri

Farklı algoritmalar çeşitli veri türleri ve uygulama senaryolarında farklı performans gösterebilmektedir. Bu nedenle seçim sürecinde aşağıdaki kriterler dikkate alınmalıdır [69-71].

7.5.1.1. Veri Tipi ve Yapısı

Boyut: Büyük veri setlerinde ANN, RF ve XGBoost gibi daha karmaşık algoritmalar tercih edilebilir. Küçük veri setleri için NB ve KNN daha uygundur.

Çok Boyutluluk: Yüksek boyutlu veri setlerinde SVM veya RF gibi algoritmalar genellikle daha iyi performans gösterir.

Eksik Veriler: NB, eksik verilerle başa çıkmada etkili bir algoritmadır.

7.5.1.2. Performans Gereksinimleri

Hassasiyet ve Doğruluk: Kritik uygulamalarda F1 skoru ve ROC eğrisine göre performansı yüksek olan algoritmalar tercih edilmelidir.

Hız ve Bellek Kullanımı: Gerçek zamanlı sistemlerde, düşük bellek kullanımı ve hızlı çalışmasıyla bilinen KNN veya NB gibi algoritmalar öne çıkar.

7.5.1.3. Çalışma Koşulları

Gürültülü Ortamlar: Gürültülü veri setleri için RF ve XGBoost gibi dayanıklı algoritmalar önerilir.

Gerçek Zamanlılık: Anlık işlem gereksinimi olan sistemlerde hız ve bellek verimliliği ön planda olmalıdır.

7.5.1.4. İşlem Maliyeti

Düşük maliyetli sistemler için NB ve KNN gibi basit algoritmalar tercih edilebilirken, bütçe kısıtlamalarının olmadığı durumlarda ANN ve SVM gibi daha karmaşık modeller kullanılabilir.

7.5.1.5. Arıza Türü ve Şiddeti

Düşük Şiddetli Arızalar: Düşük seviyeli anomalileri tespit etmek için ANN ve RF gibi algoritmalar daha uygundur.

Karmaşık ve Çoklu Arızalar: XGBoost ve RF, birden fazla arızayı eş zamanlı olarak tespit etme kapasitesine sahiptir.

Vaka Örneği: Bir fabrikada motor arızalarının tespiti için algoritma seçimi yapılması gerektiğinde veri setinin boyutuna ve gürültü oranına bakılarak ANN veya SVM önerilebilir. Ancak bütçe kısıtlaması veya düşük işlem gücü varsa KNN tercih edilmelidir.

7.5.2. Gerçek Zamanlı Sistemler için Öneriler

Gerçek zamanlı arıza tespit sistemleri sürekli çalışan üretim hatlarında enerji santrallerinde ve diğer kritik altyapılarda yaygın olarak kullanılır. Bu sistemler anlık veri işleme yetenekleri ve hızlı karar alma süreçleri gerektirir.

7.5.2.1. Gerçek Zamanlılık için Optimizasyon

Algoritma Basitliği: NB ve KNN gibi hızlı çalışan algoritmalar gerçek zamanlı uygulamalar için uygundur.

Hafif Modeller: Bellek kullanımı düşük, işlem yükü hafif modeller tercih edilmelidir.

7.5.2.2. Veri Ön İşleme

Gerçek zamanlı sistemlerde veri ön işleme süreci mümkün olduğunca basitleştirilmelidir. Dalga dönüşümü veya temel filtreleme teknikleri kullanılarak gürültü azaltılabilir.

7.5.2.3. IoT ve Bulut Tabanlı Sistemler

IoT cihazlarından gelen veriler bulut tabanlı analiz sistemlerine aktarılabilir.

Bulutta ANN veya RF gibi karmaşık algoritmalar çalıştırılarak yerel cihazların işlem yükü azaltılabilir.

7.5.2.4. Sürekli Öğrenme Yeteneği

Dinamik sistemlerde ANN gibi sürekli öğrenme kapasitesine sahip algoritmalar kullanılabilir. Online eğitim (online learning) teknikleri ile modelin gerçek zamanlı adaptasyonu sağlanabilir.

7.5.2.5. Sistem Geri Bildirimi ve Alarm Mekanizmaları

Arıza tespiti yapıldıktan sonra sistemde gerekli müdahalelerin yapılabilmesi için hızlı bir alarm mekanizması kurulmalıdır. Hatalı alarmları en aza indirmek için duyarlılık ve hassasiyet değerleri optimize edilmelidir.

Vaka Örneği: Bir enerji santralinde jeneratör titreşim verilerinin gerçek zamanlı analizi için SVM tabanlı bir sistem geliştirilmiştir. Veriler önce sensörlerden toplanmış ardından lokal bir sunucuda ön işleme tabi tutulmuş ve bulut tabanlı bir ANN modeliyle analiz edilmiştir. Bu sistem sayesinde arıza meydana gelmeden önce %95 doğruluk oranıyla tahminler yapılmıştır.

7.5.3. Sonuçlar ve Gelecek Yaklaşımları

Algoritma seçim süreçleri her bir uygulamanın özel gereksinimlerine göre optimize edilmelidir. İleriye dönük olarak;

- Daha karmaşık ve kapsamlı IoT sistemlerinin algoritmalarla entegrasyonu,
- Gerçek zamanlı büyük veri analizine olanak tanıyan teknolojilerin geliştirilmesi,
- Düşük maliyetli ancak yüksek doğruluk sağlayan hibrit algoritmaların ortaya çıkışı gibi yenilikler beklenmektedir.

Bu süreçlerin sonunda sistemler daha verimli, güvenilir ve ekonomik hale gelecektir.

7.6. Yöntemlerin Sınırlılıkları ve Gelecek Çalışmalar İçin Öneriler

Makine arızalarının tespitinde kullanılan yöntemler mevcut teknolojilerle birçok avantaj sağlasa da çeşitli sınırlılıkları ve çözülmesi gereken zorlukları da beraberinde getirmektedir. Bu bölümde mevcut sınıflandırma yöntemlerinin sınırları ele alınacak ve bu sınırlamaların üstesinden gelmek için gelecekte yapılabilecek çalışmalar tartışılacaktır [71].

7.6.1. Karmaşık Arıza Türlerinin Zorlukları

1. Çoklu ve Karmaşık Arızalar:

- Birden fazla arızanın eş zamanlı olarak meydana geldiği durumlarda mevcut algoritmaların performansı genellikle düşer. Örneğin, rulman ve stator arızalarının birlikte olduğu durumlarda algoritmaların arızaları doğru şekilde ayırması zorlaşır.
- Ansambl öğrenme yöntemleri özellikle Rastgele Orman ve XGBoost gibi modeller karmaşık veri yapılarında ve yüksek boyutlu problemlerde etkili çözümler sunmaktadır. Bu yöntemlerin uygulama süreci genellikle yüksek hesaplama maliyeti ve önemli düzeyde işlem gücü gereksinimi ile ilişkilidir.

2. Düşük Şiddetli Arızaların Tespiti

- Küçük titreşim veya ses anormallikleri gibi düşük seviyeli arızalar genellikle veri setinin doğal varyasyonları içinde kaybolur. Bu durum özellikle erken teşhis gerektiren senaryolar için kritik bir sorundur.
- Dalga dönüşümleri veya gelişmiş sinyal işleme yöntemleriyle düşük şiddetli arızaların belirgin hale getirilmesi sağlanabilir.

3. Parametre Optimizasyonu ve Genel Zorluklar

- Algoritmaların hiperparametrelerinin (örneğin, SVM için kernel tipi, ANN için öğrenme oranı) doğru bir şekilde seçilmesi performansı doğrudan etkiler.
- Otomatik hiperparametre optimizasyon teknikleri (AutoML) bu süreci iyileştirmek için kullanılabilir.

7.6.2. Büyük Veri ve IoT'nin Rolü

1. Büyük Veri ile Gelen Zorluklar ve Fırsatlar

- Endüstriyel sistemlerde sensörlerden sürekli olarak gelen veriler büyük veri analitiğini gerekli kılar. Bu durum hem depolama hem de analiz süreçlerini zorlaştırır.
- Büyük veri işleme platformları (örneğin, Apache Spark veya Hadoop) ve bu sistemlerle uyumlu algoritmalar bu sorunların üstesinden gelmek için önemli bir çözüm sunar.

2. IoT ile Gerçek Zamanlı İzleme

- IoT cihazları büyük veri akışlarını sürekli olarak sunarak gerçek zamanlı izleme ve tahminci bakım sistemlerine olanak tanır.

- Ancak veri güvenliği ve gizliliği bu sistemlerin en büyük zorluklarıdır. Blockchain tabanlı çözümler veya güvenli iletişim protokolleri IoT ağlarını daha güvenli hale getirmek için kullanılabilir.

3. Veri Etiketleme ve İşaretleme

- Büyük veri setlerinin manuel olarak etiketlenmesi zaman alıcı ve maliyetlidir. Bu durum özellikle derin öğrenme yöntemlerinin başarısını etkileyebilir.
- Yarı denetimli veya zayıf denetimli öğrenme teknikleri etiketleme ihtiyacını azaltmak için kullanılabilir.

7.6.3. Yapay Zeka Tabanlı Çözümler

1. Derin Öğrenme ve Hibrit Modeller

- Derin öğrenme algoritmaları karmaşık örüntüleri tanıma ve genelleme yetenekleri ile öne çıkar. Örneğin, CNN tabanlı modeller arızaların frekans spektrumlarındaki farklılıkları tanımlamak için kullanılabilir.
- Hibrit modeller (örneğin, ANN ve XGBoost'un birleştirilmesi) hem yüksek doğruluk hem de hız gereksinimlerini karşılayabilir.

2. Yapay Zeka ve Açıklanabilirlik

- Özellikle derin öğrenme modelleri çoğu zaman bir "kara kutu" olarak kabul edilir. Bu durum, kritik kararların açıklanmasını zorlaştırır.
- Açıklanabilir yapay zeka (Explainable AI) teknikleri algoritmaların verdiği kararların daha şeffaf hale gelmesini sağlayabilir.

3. Otonom Sistemler ve Edge Computing

- Otonom sistemler yapay zekayı bağımsız olarak karar verme süreçlerine entegre edebilir. Örneğin bir üretim hattında yerel olarak çalışan bir sistem arızayı algıladığı anda düzeltici eylemleri otomatik olarak gerçekleştirebilir.
- Edge computing büyük veri akışlarını IoT cihazlarının yakınında işleyerek gecikme sürelerini ve ağ maliyetlerini azaltır.

8. Endüstriyel Uygulamalar ve Gelecek Perspektifleri

Endüstriyel otomasyon sistemleri üretim süreçlerini daha verimli, güvenli ve sürdürülebilir hale getirmek için yapay zeka ve veri analitiği tabanlı çözümleri giderek daha fazla benimsemektedir. Akıllı arıza tespit sistemleri bu süreçte kritik bir rol oynamakta ve işletmelerin hem zaman hem de maliyet tasarrufu sağlamalarına yardımcı olmaktadır. Bu bölümde akıllı arıza tespiti sistemlerinin mevcut endüstriyel uygulamaları ele alınacak ve gelecekteki potansiyel yönelimler değerlendirilecektir.

8.1. Akıllı Arıza Tespiti Sistemlerinin Endüstrideki Uygulamaları

Akıllı arıza tespiti sistemleri farklı endüstri kollarında etkin bir şekilde kullanılmaktadır. Bu bölümde enerji, otomotiv, petrokimya ve üretim gibi sektörlerden seçilmiş örneklerle bu sistemlerin uygulama alanlarına odaklanılacaktır.

1. Enerji Santrallerinde Akıllı Arıza Tespiti

- **Durum:** Bir enerji santralinde kullanılan türbin motorlarının sürekli izlenmesi, ani arızaların önlenmesi için kritik öneme sahiptir.
- **Örnek:** Türbinlerdeki rotor balanssızlıklarının gerçek zamanlı olarak algılanması için akustik sensörler ve yapay zeka tabanlı sınıflandırıcılar (ANN veya SVM) kullanılmaktadır.
- **Kazanımlar:** Bu sistemler sayesinde türbinlerin arızalanma riski minimize edilmekte ve bakım süreçleri optimize edilmektedir.

2. Otomotiv Endüstrisinde Arıza Tespiti

- **Durum:** Araç motorlarında ve aktarma organlarında oluşabilecek arızaların erken tespiti hem güvenlik hem de verimlilik açısından önemlidir.
- **Örnek:** Tesla gibi üreticiler, elektrik motorlarındaki rulman aşınmalarını tespit etmek için IoT cihazları ve bulut tabanlı analiz platformlarını entegre etmektedir.
- **Kazanımlar:** Bu sistemler bakım süreçlerinin maliyetini düşürmekte ve araçların kullanım ömrünü uzatmaktadır.

3. Petrokimya Tesislerinde Çoklu Arıza Tespiti

- **Durum:** Petrokimya tesislerinde pompalar, kompresörler ve diğer ekipmanlar sık sık arızalanabilir. Bu tür arızaların erken teşhisi operasyonel güvenlik için önem taşır.
- **Örnek:** Vibrasyon sensörleri ve ansambl öğrenme yöntemleri kullanılarak kompresörlerdeki mekanik arızaların tespit edilmesi.
- **Kazanımlar:** Operasyonel kesintilerin azaltılması ve ekipman ömrünün uzatılması.

4. Üretim Tesislerinde Akıllı Sistemler

- **Durum:** Üretim hatlarında çalışan makineler sürekli yük altında olduğundan bu makinelerdeki arızaların izlenmesi önemlidir.
- **Örnek:** Siemens fabrikalarında kullanılan CNC makinelerindeki anormallikleri tespit etmek için derin öğrenme tabanlı sistemler kullanılmaktadır.
- **Kazanımlar:** Üretim hatlarının durma süreleri azaltılmakta ve üretim verimliliği artırılmaktadır.

8.2. Gerçek Zamanlı Sistemler ve Gelecek Perspektifleri

Geleneksel arıza tespiti yaklaşımlarının aksine gerçek zamanlı sistemler anında karar alabilme yetenekleri sayesinde işletmelerin rekabet avantajı elde etmelerine yardımcı olur. Bu tür sistemlerin önemini ve gelecekteki potansiyel yönelimleri aşağıdaki başlıklar altında inceleyebiliriz.

1. Gerçek Zamanlı İzleme ve Önleyici Bakım

- **Durum:** Gerçek zamanlı arıza tespiti özellikle kritik altyapıların korunmasında önemlidir. Bu sistemler ekipman performansını sürekli izleyerek arızaları tahmin edebilir.

- **Gelecek Perspektifi:** 5G teknolojisi ile birlikte daha hızlı ve düşük gecikme süresiyle çalışan sistemlerin kullanımı artacaktır.

2. IoT ve Bulut Entegrasyonu

- **Durum:** IoT cihazları sensörlerden toplanan verileri bulut platformlarına göndererek analiz yapılmasını sağlar.
- **Gelecek Perspektifi:** Bulut tabanlı analiz platformlarının edge computing teknolojisi ile birleştirilmesiyle verimlilik daha da artırılabilir.

3. Otonom Sistemler

- **Durum:** Akıllı arıza tespiti sistemleri otonom karar alma mekanizmalarıyla entegre edilebilir.
- **Gelecek Perspektifi:** Otonom üretim hatlarında makineler kendi kendine bakım yapabilen bir yapıya dönüşecektir.

4. Yapay Zeka ve Makine Öğrenimi ile Gelişim

- **Durum:** Derin öğrenme ve ensemble yöntemler gibi yapay zeka teknikleri karmaşık örüntüleri algılayarak daha hassas arıza tespiti sağlar.
- **Gelecek Perspektifi:** Özellikle endüstri 4.0 ve 5.0 gibi yenilikler yapay zekanın üretim süreçlerindeki önemini artıracaktır.

5. Sürdürülebilirlik ve Çevresel Etkiler

- **Durum:** Arıza tespiti sistemlerinin enerji tüketimi ve çevresel etkileri de göz önüne alınmalıdır.
- **Gelecek Perspektifi:** Çevre dostu ve enerji verimli sistemlerin geliştirilmesi gerekecektir.

9. Sonuç ve Öneriler

9.1 Çalışmanın Ana Bulguları

Bu kitap akıllı sınıflandırıcılarla motor arıza tespiti üzerine yapılan detaylı bir incelemenin yanı sıra hem teorik hem de uygulamalı yaklaşımlar sunmaktadır. Çalışma boyunca kullanılan yöntemlerin performans değerlendirmesi, avantajları, dezavantajları ve endüstriyel uygulamalara yönelik örneklerle geniş bir perspektif oluşturulmuştur. Aşağıda bu çalışmanın temel bulguları detaylı bir şekilde açıklanmıştır:

1. Sınıflandırıcıların Performansı

Akıllı sınıflandırma algoritmalarının farklı arıza türlerinde gösterdiği performans, bu yöntemlerin etkinliğini ortaya koymuştur. Özellikle yapay sinir ağları (ANN), destek vektör makineleri (SVM) ve Rastgele Orman (RF) gibi algoritmalar, yüksek doğruluk oranları ile dikkat çekmiştir:

- Yapay Sinir Ağları (ANN):
 - Karmaşık veri setlerinde bile yüksek doğruluk oranları elde edilmiştir.
 - Örneğin, rulman arızalarının tespitinde %97,8 doğruluk oranı sağlanmıştır. Bu başarı, ANN'nin karmaşık örüntüleri tanımlamadaki üstünlüğünü göstermektedir.
 - ANN'nin çoklu katman yapısı sayesinde, farklı gürültü seviyelerine rağmen genelleme başarısı yüksektir.
- Destek Vektör Makineleri (SVM):

- Özellikle stator arızalarının tespitinde, SVM %99,2 doğruluk oranıyla en başarılı yöntemlerden biri olmuştur.
- Kernel fonksiyonlarının doğru seçimiyle doğrusal olmayan sınıflandırma problemlerinde üstün sonuçlar elde edilmiştir.
- SVM, az veriyle bile yüksek performans sağlayarak küçük veri setleri için uygun bir seçenek olarak öne çıkmıştır.
- Rastgele Orman (RF):
 - Gürültülü veri setlerinde dayanıklılık göstermiş ve %92 doğruluk oranıyla güvenilir bir seçenek olduğunu kanıtlamıştır.
 - Özellikle düşük işlem süresi ve gürültüye karşı toleransı nedeniyle endüstriyel uygulamalarda tercih edilmektedir.

2. Farklı Arıza Türleri Üzerindeki Etkiler

Motor arızaları karmaşıklık derecesine ve doğasına bağlı olarak farklı sınıflandırıcı algoritmaların performansını etkileyebilmektedir. Çalışma, bu bağlamda aşağıdaki bulguları ortaya koymuştur:

- Basit Arıza Türleri: Naive Bayes gibi daha basit algoritmalar düşük karmaşıklıkta arıza türlerinde etkili olmuştur. Örneğin, basit bir stator arızasının tespitinde Naive Bayes %85 doğruluk oranı sağlamıştır.
- Karmaşık Çoklu Arıza Durumları: Çoklu arıza senaryolarında (örneğin, hem stator hem de rotor arızası) basit algoritmaların doğruluk oranı %65'e kadar düşmüştür. Bu durum daha gelişmiş algoritmaların bu tür senaryolarda neden gerekli olduğunu göstermektedir.
- Örnek Uygulamalar: Çalışmada test edilen rulman arızalarının %90'ında ANN ve RF en başarılı sonuçları elde etmiştir.

3. Gürültü ve Sensör Füzyonunun Etkisi

Endüstriyel ortamlar, genellikle yüksek gürültü ve çeşitli çevresel etkenlerle doludur. Bu durum, motor arıza tespiti için kullanılan sınıflandırıcıların performansını önemli ölçüde etkileyebilir. Çalışma, bu bağlamda şu önemli bulguları ortaya koymuştur:

- Gürültüye Karşı Dayanıklılık:
 - Rastgele Orman algoritması gürültülü veri setlerinde %92 doğruluk oranı ile öne çıkmıştır.
 - ANN, gürültü azaltma teknikleri uygulandığında performansını %5'e kadar artırabilmiştir.

- Gürültü toleransı düşük olan algoritmalar (örneğin, Naive Bayes), bu tür senaryolarda doğruluk kaybı yaşamıştır.
- Sensör Füzyonu:
 - Çalışmada birden fazla sensörden gelen verilerin birleştirilmesi (akım, titreşim ve sıcaklık verileri gibi) ile sensör füzyonunun doğruluk oranlarını artırdığı görülmüştür.
 - Örneğin, sadece akım verileriyle yapılan analizlerde %85 doğruluk oranı elde edilirken, titreşim verilerinin eklenmesiyle bu oran %95'e çıkmıştır.
 - Sensör füzyonu sayesinde tek bir veri kaynağına bağımlılık azalmış ve arıza tespitindeki güvenilirlik artmıştır.

9.2. Akıllı Yöntemlerin Geleceği

Motor arıza tespitinde akıllı yöntemler hem mevcut teknolojilerin geliştirilmesi hem de yeni nesil uygulamalara entegrasyon açısından büyük bir potansiyele sahiptir. Gelecekte akıllı sınıflandırıcıların uygulanabileceği alanlar ve bu yöntemlerin endüstriyel süreçlere olası katkıları detaylı bir şekilde ele alınacaktır.

9.2.1. Derin Öğrenme ve Hibrit Modeller

Gelecekte derin öğrenme (Deep Learning) yöntemlerinin motor arıza tespitinde daha etkin bir şekilde kullanılacağı öngörülmektedir. Özellikle karmaşık arıza durumlarında geleneksel yöntemlerin yerini alabilecek şu avantajlar sunmaktadır:

- **Otomatik Özellik Çıkarımı:** Derin öğrenme algoritmaları veri ön işleme ihtiyacını azaltarak karmaşık veri setlerinden otomatik olarak anlamlı özellikler çıkarabilir. Örneğin, konvolüsyonel sinir ağları (CNN), titreşim ve akustik sinyaller gibi zaman serisi verilerinde olağanüstü başarı göstermektedir.
- **Hibrit Modellerin Potansiyeli:** Derin öğrenme yöntemlerinin geleneksel yöntemlerle birleştirilmesi özellikle farklı veri türleriyle çalışırken (örneğin akım, titreşim ve sıcaklık) daha güvenilir sonuçlar elde edilmesini sağlar. Örneğin:
 - CNN ve LSTM'nin bir araya getirilmesiyle zamansal ve uzaysal bilgilerin aynı anda analiz edilmesi.
 - Derin öğrenme tabanlı bir modelin Rastgele Orman gibi ağaç tabanlı bir modelle entegre edilmesiyle karmaşık arızaların sınıflandırılması.

9.2.2. IoT ve Büyük Veri Analitiği

Endüstriyel tesislerde IoT cihazlarının yaygınlaşması büyük miktarda verinin toplanmasını ve analiz edilmesini mümkün kılmaktadır. Akıllı sınıflandırıcılar için benzersiz fırsatlar yaratmaktadır:

- **Kestirimci Bakım Sistemlerinin Geliştirilmesi:** IoT sensörlerinden gelen gerçek zamanlı veriler akıllı sınıflandırıcıların sürekli öğrenmesini ve tahminlerini daha hızlı ve hassas bir şekilde güncellemesini sağlamaktadır. Örneğin:
 - Bir enerji santralinde IoT tabanlı sensörlerin 5 yıllık titreşim ve sıcaklık verilerini analiz ederek planlanmamış duruşların %50'ye kadar azaltılması.
 - Büyük veri analitiği ile bakım maliyetlerinde %30 oranında azalma.
- **Öngörücü Analiz Modelleri:** IoT cihazlarından elde edilen verilerle geçmiş verilerin analizi, yalnızca mevcut arızaların tespitiyle sınırlı kalmayarak gelecekteki potansiyel arızaların da tahmin edilmesini sağlar.

9.2.3. Gerçek Zamanlı Sistemler ve Endüstriyel Uygulamalar

Gerçek zamanlı izleme ve karar verme sistemleri endüstriyel uygulamalarda kritik bir rol oynamaktadır. Akıllı sınıflandırıcıların gerçek zamanlı sistemlere entegrasyonu, makine verimliliğini artırmak ve işletme maliyetlerini azaltmak için önemli bir adım olarak görülmektedir.

- **Gerçek Zamanlı Veri Analizi:** Akıllı sınıflandırıcılar sensörlerden gelen verileri anlık olarak işleyerek arıza tespiti ve önleyici bakım kararlarını hızlandırabilir. Örneğin:
 - Otomotiv sektöründe üretim hattındaki rulman arızalarının anında tespiti hat duruşlarını %40 oranında azaltabilir.
 - Çelik üretim tesislerinde sıcaklık ve titreşim verilerinin gerçek zamanlı analiziyle enerji verimliliği artırılabilir.
- **Edge Computing ve Akıllı Algoritmalar:** Büyük veri yükünün azaltılması için akıllı algoritmaların veri işleme ve analiz işlemlerinin sensörlere yakın bir noktada gerçekleştirilmesi (edge computing) önem kazanmaktadır. Bu özellikle gecikmeye duyarlı sistemlerde kritik bir avantaj sunmaktadır.

9.2.4. Çevresel ve Enerji Verimliliği Yönelimleri

Akıllı sınıflandırıcıların çevresel sürdürülebilirlik ve enerji verimliliği konularında da katkı sağlayacağı öngörülmektedir:

- **Karbon Ayak İzi Azaltma:** Akıllı sınıflandırıcılarla enerji tüketiminin daha verimli hale getirilmesi, karbon salınımını düşürme potansiyeline sahiptir. Örneğin:
 - Endüstriyel motorlarda enerji kayıplarının %10 azaltılmasıyla yıllık karbon emisyonunda önemli düşüş sağlanabilir.
- **Yenilenebilir Enerji Uygulamaları:** Rüzgar türbinleri ve güneş enerjisi sistemlerinde kullanılan motorlarda arıza tespitinin daha hızlı yapılması yenilenebilir enerji kaynaklarının kesintisiz kullanılabilirliğini artırabilir.

Akıllı sınıflandırıcılar endüstrideki motor arıza tespiti uygulamalarında büyük bir dönüşüm yaratma potansiyeline sahiptir. Derin öğrenme, IoT ve büyük veri analitiği gibi teknolojilerin bu yöntemlerle entegrasyonu daha güvenilir, hızlı ve enerji verimli sistemlerin geliştirilmesine olanak tanımaktadır. Bu yönelimler hem akademik araştırmalarda hem de endüstriyel uygulamalarda yeni ufuklar açmaktadır.

Kaynaklar

- [1] Kabul, A., 2022. Asenkron motor arızalarının stator akımı ve titreşim sinyalleriyle analizi ve tespiti. Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, 254s, Kütahya.
- [2] Kabul, A., Ünsal, A., 2021. Diagnosis of simultaneous broken rotor bars and static eccentricity faults of induction motors by analyzing stator current and vibration signals.
- [3] Çakır, E., 2013. Asenkron motor test düzeneği. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, 103s, Isparta.
- [4] Çakır, A., 2004. Asenkron motorlarda robot çubuk hatalarının akım sıfır geçiş anı (SGA) değişimi ile tespiti. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, 132s, Sakarya.
- [5] Çakır, A., Çaliş, H., Turan, G., 2014. Remote controlling and monitoring of induction motors through internet. TELKOMNIKA Indonesian Journal of Electrical Engineering, 12(12), 8051-8059.
- [6] M. Hajian, J. Soltani, G. Markadeh, S. Hosseinnia, Adaptive nonlinear direct torque control of sensorless IM drives with efficiency optimization, IEEE Trans. Ind. Electron. 57 (3) (2010) 975–985.
- [7] T.H. dos Santos, A. Goedel, S.A.O. da Silva, M. Suetake, Scalar control of an induction motor using a neural sensorless technique, Electr. Power Syst. Res. 108 (0) (2014) 322–330.
- [8] A. Bellini, F. Filippetti, C. Tassoni, G.A. Capolino, Advances in diagnostic techniques for induction machines, IEEE Trans. Ind. Electron. 55 (12) (2008) 4109–4126.
- [9] M. Hajiaghajani, H. Toliyat, I.M.S. Panahi, Advanced fault diagnosis of a DC motor, IEEE Trans. Energy Convers. 19 (1) (2004) 60–65.
- [10] J. Wang, S. Liu, R.X. Gao, R. Yan, Current envelope analysis for defect identification and diagnosis in induction motors, J. Manuf. Syst. 31 (4) (2012) 380–387.

- [11] O. Ondel, E. Boutleux, G. Clerc, A method to detect broken bars in induction machine using pattern recognition techniques, *IEEE Trans. Ind. Appl.* 42 (4) (2006) 916–923.
- [12] B. Ebrahimi, M. Javan Roshtkhari, J. Faiz, S. Khatami, Advanced eccentricity fault recognition in permanent magnet synchronous motors using stator current signature analysis, *IEEE Trans. Ind. Electron.* 61 (4) (2014) 2041–2052.
- [13] M. Barzegaran, A. Mazloomzadeh, O. Mohammed, Fault diagnosis of the asyn-chronous machines through magnetic signature analysis using finite-element method and neural networks, *IEEE Trans. Energy Convers.* 28 (4) (2013) 1064–1071.
- [14] Dal, B., 2022. FPGA implementation of 1D convolutional neural network for early detection of bearing faults in induction motors. İzmir Ekonomi Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, 59s, İzmir.
- [15] Çolak, İ., 2008. Asenkron Motorlar. Seçkin Yayıncılık, 174s, Ankara.
- [16] Atiz, İ. (2024). Rulman Yağlama Sistemi Test Otomasyonu ve Arayüzü Geliştirilmesi (Master's thesis, Marmara Üniversitesi (Turkey)).
- [17] Koca, Y.B., Ünsal, A., 2017. Asenkron motor arızalarının değerlendirilmesi. *Teknik Bilimler Dergisi*, 7(2), 37-46.
- [18] Acar, Ç., Soygenç, O. C., & Ergene, L. T. (2018). Endüstriyel Uygulamalarda Kullanılan Asenkron Motorlarda IE2 Verim Sınıfından IE4 Verim Sınıfına Geçiş Amaçlı Bir Çalışma. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 30(3), 59-65.
- [19] Naha, A., Samanta, A.K., Routray, A., Deb, A.K., 2016. A method for detecting half-broken rotor bar in lightly loaded induction motors using current. *IEEE Transactions on Instrumentation and Measurement*, 65(7), 1614-1625.
- [20] Wang, Z., Yang, J., Li, H., Zhen, D., Xu, Y., Gu, F., 2019b. Fault identification of broken rotor bars in induction motors using an improved cyclic modulation spectral analysis. *Energies*, 12(17), 3279.
- [21] Wang, Z., Yang, J., Li, H., Zhen, D., Xu, Y., Gu, F., 2019b. Fault identification of broken rotor bars in induction motors using an improved cyclic modulation spectral analysis. *Energies*, 12(17), 3279.
- [22] Imoru, O., Bhaskar, M.A., Jimoh, A.A.-G., Hamam, Y., 2017. Diagnosis of stator shorted-turn faults in induction machines using discrete wavelet transform. *African Journal of Science, Technology, Innovation and Development*, 9(3), 349-355.
- [23] Aydın, İ., 2011. Gerçek zamanlı durum izleme ve arıza teşhisi için bağışık akıllı hesaplama tekniklerinin geliştirilmesi/Development of immune

- intelligent computing techniques for real-time condition monitoring and fault diagnosis. *Firat Üniversitesi Fen Bilimleri Enstitüsü*, 226s, Elazığ.
- [24] S. Das, P. Purkait, C. Koley, S. Chakravorti, Performance of a load-immune classifier for robust identification of minor faults in induction motor stator winding, *IEEE Trans. Dielectr. Electr. Insul.* 21 (1) (2014) 33–44.
- [25] J. Seshadrinath, B. Singh, B. Panigrahi, Investigation of vibration signatures for multiple fault diagnosis in variable frequency drives using complex wavelets, *IEEE Trans. Power Electron.* 29 (2) (2014) 936–945.
- [26] H.-W. Peng, P.-J. Chiang, Control of mechatronics systems: ball bearing fault diagnosis using machine learning techniques, in: *Control Conference (ASCC), 2011 8th Asian, 2011*, pp. 175–180.
- [27] I. Aydin, M. Karakose, E. Akin, An approach for automated fault diagnosis based on a fuzzy decision tree and boundary analysis of a reconstructed phase space, *ISA Trans.* 53 (2) (2014) 220–229.
- [28] J. Bossio, C. Angelo, G. Bossio, Self-organizing map approach for classification of mechanical and rotor faults on induction motors, *Neural Comput. Appl.* 23 (1) (2013) 41–51.
- [29] M. Seera, C.P. Lim, S. Nahavandi, C.K. Loo, Condition monitoring of induction motors: a review and an application of an ensemble of hybrid intelligent models, *Expert Syst. Appl.* 41 (10) (2014) 4891–4903.
- [30] E. Germen, M. Basaran, M. Fidan, Sound based induction motor fault diagnosis using Kohonen self-organizing map, *Mech. Syst. Signal Process.* 46 (1) (2014) 45–58.
- [31] M. Seera, C. Lim, D. Ishak, H. Singh, Application of the fuzzy min-max neural network to fault detection and diagnosis of induction motors, *Neural Comput. Appl.* 23 (1) (2013) 191–200.
- [32] M. Seera, C.P. Lim, D. Ishak, H. Singh, Offline and online fault detection and diagnosis of induction motors using a hybrid soft computing model, *Appl. Soft Comput.* 13 (12) (2013) 4493–4507.
- [33] J. Zarei, M.A. Tajeddini, H.R. Karimi, Vibration analysis for bearing fault detection and classification using an intelligent filter, *Mechatronics* 24 (2) (2014) 151–157.
- [34] S. Moosavi, A. Djerdir, Y. Ait-Amirat, D. Khaburi, ANN based fault diagnosis of permanent magnet synchronous motor under stator winding shorted turn, *Electr. Power Syst. Res.* 125 (0) (2015) 67–82.
- [35] O. Duque-Perez, L.-A. Garcia-Escudero, D. Morinigo-Sotelo, P.-E. Gardel, M. Perez-Alonso, Analysis of fault signatures for the diagnosis of induction motors fed by voltage source inverters using ANOVA and additive models, *Electr. Power Syst. Res.* 121 (0) (2015) 1–13.
- [36] A.G. Garcia-Ramirez, L.A. Morales-Hernandez, R.A. Osornio-Rios, J.P. Benitez-Rangel, A. Garcia-Perez, R. de Jesus Romero-Troncoso,

- Fault detection in induction motors and the impact on the kinematic chain through thermo-graphic analysis, *Electr. Power Syst. Res.* 114 (0) (2014) 1–9.
- [37] F. Jensen, *Introduction to Bayesian Networks*, Hugin Expert, Denmark, 1993.
- [38] L. Jiang, Y. Guo, Learning lazy naive Bayesian classifiers for ranking, in: 17th IEEE International Conference on Tools with Artificial Intelligence, 2005, pp. 411–416.
- [39] G.H. John, P. Langley, Estimating continuous distributions in Bayesian classifiers, in: *Eleventh Conference on Uncertainty in Artificial Intelligence*, Morgan Kaufmann, San Mateo, 1995, pp. 338–345.
- [40] V.N. Vapnik, *The Nature of Statistical Learning Theory*, Springer-Verlag New York, Inc., New York, NY, USA, 1995.
- [41] P. Kankar, S.C. Sharma, S. Harsha, Fault diagnosis of ball bearings using continuous wavelet transform, *Appl. Soft Comput.* 11 (2) (2011) 2300–2312.
- [42] J. Platt, Fast training of support vector machines using sequential minimal optimization, in: B. Schoelkopf, C. Burges, A. Smola (Eds.), *Advances in Kernel Methods – Support Vector Learning*, MIT Press, 1998.
- [43] T. Hastie, R. Tibshirani, Classification by pairwise coupling, in: *Proceedings of the 1997 Conference on Advances in Neural Information Processing Systems 10*, MIT Press, Cambridge, MA, USA, 1998, pp. 507–513.
- [44] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd ed., Prentice Hall PTR, Upper Saddle River, NJ, USA, 1998.
- [45] V.T. Tran, F. Althobiani, A. Ball, B.-K. Choi, An application to transient current signal based induction motor fault diagnosis of Fourier-Bessel expansion and simplified fuzzy artmap, *Expert Syst. Appl.* 40 (13) (2013) 5372–5384.
- [46] J. Quinlan, Induction of decision trees, *Mach. Learn.* (1) (1986) 81–106.
- [47] R. Quinlan, *C4.5: Programs for Machine Learning*, Morgan Kaufmann Publishers, San Mateo, CA, 1993.
- [48] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, I.H. Witten, The WEKA data mining software: an update, *SIGKDD Explor. Newslett.* 11 (1) (2009) 10–18.
- [49] Lem, 2013. Erişim Tarihi: 20.11.2024. <http://www.lem.com/docs/products/la%2055-p%20e.pdf>
- [50] LEM, 2023. Gerilim Sensörü. Erişim Tarihi: 20.11.2024. https://www.lem.com/sites/default/files/products_datasheets/lv_25-p.pdf.
- [51] Atek, 2023. Rotary Enkoder. Erişim Tarihi: 15.06.2023. <https://www.ateksensor.com/rotary-enkoderler-urunler-9.html>.

- [52] National Instruments, 2013. <http://sine.ni.com/nips/cds/view/p/> , Erişim Tarihi: 10.04.2013
- [53] Ayaz, E., Şeker, S., 2001. Yapay sinir ağlarıyla asenkron makinede rulman arıza tanısı. Mühendislikte Modern Yöntemler Sempozyumu, 129-136.
- [54] J. Fürnkranz, G. Widmer, Incremental reduced error pruning, in: W.W. Cohen, H. Hirsh (Eds.), Proceedings of the 11th International Conference on Machine Learning (ML-94), Morgan Kaufmann, New Brunswick, NJ, 1994, pp. 70–77.
- [55] S. Jiang'hong, X. Xiao'li, Large rotating machinery fault diagnosis and knowledge rules acquiring based on improved RIPPER, in: Second International Conference on Intelligent Computation Technology and Automation, 2009. ICICTA '09, vol. 2, 2009, pp. 549–552.
- [56] Çetin, V., & Yıldız, O. (2022). Veri analizinde veri ön işleme teknikleri üzerine kapsamlı bir inceleme. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 28(2), 299-312.
- [57] Murphy, K. P. (2012). Machine learning: a probabilistic perspective. MIT press.
- [58] Çalış, H., Çakır, A., 2007. Rotor bar fault diagnosis in three phase induction motors by monitoring fluctuations of motor current zero crossing instants. Electric Power Systems Research, 77(5-6), 385-392.
- [59] Çalış, H., Çakır, A., 2008. Experimental study for sensorless broken bar detection in induction motors. Energy Conversion and Management, 49(4), 854-862.
- [60] Çalış, H., Unsworth, P.J., 1999a. Fault diagnosis in induction motors by motor current signal analysis SDEMPED, IEEE, 237-241.
- [61] P. Konar, P. Chattopadhyay, Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs), Appl. Soft Comput. 11 (6) (2011) 4203–4211.
- [62] H. Ertunc, H. Ocak, C. Aliustaoglu, ANN- and ANFIS-based multi-staged decision algorithm for the detection and diagnosis of bearing faults, Neural Comput. Appl. 22 (1) (2013) 435–446.
- [63] Lee, J., Bagheri, B., & Kao, H. A. (2015). A cyber-physical systems architecture for industry 4.0-based manufacturing systems. Manufacturing letters, 3, 18-23.
- [64] Ma, S., Flanigan, K. A., & Bergés, M. (2024). State-of-the-Art Review: The Use of Digital Twins to Support Artificial Intelligence-Guided Predictive Maintenance. arXiv preprint arXiv:2406.13117.
- [65] Çömlekçi, O. (2020). Endüstriyel otomasyon sistemlerinde yapay zeka yöntemleri ile arıza tespiti (Master's thesis, Bursa Uludag University (Turkey)).

- [66] Aydemir, Ö. (2022). Dengesiz Veri Kümelerinin Sınıflandırılmasında Poligon Alan Metriğinin Sınıflandırıcı Performans Değerlendirilmesi İçin Kullanılması. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 27(2), 194-205.
- [67] Taunk, K., De, S., Verma, S., & Swetapadma, A. (2019, May). A brief review of nearest neighbor algorithm for learning and classification. In 2019 international conference on intelligent computing and control systems (ICCS) (pp. 1255-1260). IEEE.
- [68] Guang, Y. (2021). Generalized xgboost method. arXiv preprint arXiv:2109.07473.
- [69] Alan, A. (2020). Makine öğrenmesi sınıflandırma yöntemlerinde performans metrikleri ile test tekniklerinin farklı veri setleri üzerinde değerlendirilmesi (Master's thesis, Fen Bilimleri Enstitüsü).
- [70] Ögüt, G. E. (2019). Makine öğrenmesi ve derin öğrenmede CPU ve GPU tabanlı hızlandırma tekniklerinin karşılaştırılması (Master's thesis, Fen Bilimleri Enstitüsü).
- [71] Çömlekçi, O. (2020). Endüstriyel otomasyon sistemlerinde yapay zeka yöntemleri ile arıza tespiti (Master's thesis, Bursa Uludağ University (Turkey)).

Asenkron Motorlarda Arıza Tespiti ve Akıllı Sınıflandırma Teknikleri

Dr. Eyüp ÇAKI

Editör: Prof. Dr. Abdülkadir ÇAKIR

 ÖZGÜR
YAYINLARI

ISBN 978-625-5958-07-5



9 786255 958075