

Filo Tabanlı Veri Odaklı Hata Teşhis Sistemi Geliştirilmesi

Metin Yılmaz

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Kasım 2020

Development of Fleet-Based Data-Driven Fault Diagnosis System

Metin Yilmaz

MASTER OF SCIENCE THESIS

Computer Engineering Department

November 2020

Filo Tabanlı Veri Odaklı Hata Teşhis Sistemi Geliştirilmesi

Metin Yılmaz

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Donanımı Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Doç. Dr. Ahmet Yazıcı

Bu tez, TÜBİTAK tarafından 118C252 no'lu proje çerçevesinde desteklenmiştir.

Kasım 2020

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Ahmet Yazıcı danışmanlığında hazırlamış olduğum “**Filo Tabanlı Veri Odaklı Hata Teşhis Sistemi Geliştirilmesi**” başlıklı tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davranışımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğim ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim.

04/11/2020

Metin Yılmaz

ÖZET

Üretim ve bilgisayar teknolojilerinin birleşimi ile verimliliği üst düzeye çıkarmak, yapay zekâ yaklaşımları ile hataları en aza indirmek hatta makine öğrenmesi ile oluşabilecek hataları önceden tahmin edebilmek önem kazanmıştır. Veri odaklı hata teşhis sistemi bu konulara çözüm olarak ortaya çıkmıştır. Sistemdeki veriler kullanılarak hata teşhisi yapılarak olası arıza durumları önceden tespit edilebilmektedir. Benzer işi yapan birden fazla araç veya makinenin olduğu sistemlerde ise, hata teşhisi için filo tabanlı anomali durum tespit yönetim yaklaşımı geliştirilmiştir.

Bu çalışmada, veri odaklı hata teşhis sistemi konusunda yapılan Filo Tabanlı Durum İzleme uygulaması geliştirilmiştir. Yapay zekâ tabanlı tekniklerin çoğunda bir makine üzerinde analiz yapılmaktadır. Analiz teknikleri için geçmişe yönelik büyük veri kümelerine ihtiyaç duyulmaktadır. Veri kümesi ihtiyacı için makine uzun süre çalıştırılıp veri toplanması veya test platformlarından veri alınması gerekmektedir. Bu yüzden veri seti oluşturma işlemi oldukça maliyetlidir. Ancak elde birbirine benzer özellikte ve benzer işi yapan sistemler varsa, bir filo tabanlı izleme sistemi kurulabilir. Böyle bir filo yönteminde geçmişe ait büyük veri setlerine ihtiyaç duyulmamakta olup filodaki benzer sistemlerin aynı çalışma koşullarında benzer veriler üretmesi gereksinimi dikkate alınarak farklılıklar tespit edilmektedir. Filo yönetimi için geliştirilen uygulama web tabanlı olarak geliştirilmiş, test platformları ve deneyler ile dişli kutusu, iyon dejirmeni, şaft ve şanzıman makineleri ve içindeki rulmanlar için oluşturulmuş dört farklı veri seti için başarılı sonuçlar alınmıştır. Çalışmada Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) ve Dinamik Zaman Çarpıtma (Dynamic Time Warping, DTW) gibi dönüşüm yöntemleriyle verilerdeki ani yükselmeler, harmonik ve gürültü gibi istenmeyen değişimler giderilmiştir. Filodaki sistemler arası benzerlikler Öklid, Kare Öklid, Manhattan Mesafesi vb. metrikler ile tespit edilerek, birbiriyle benzerlik gösteren sistemler, Hiyerarşik Kümeleme algoritması ile kümelenmiştir. Kümeleme sonucunda her bir bileşen için anomali puanları bulunmuştur. Uygulama sonucunda filodaki diğer üyelerden farklılık gösteren makine ya da rulmanın hatalı olduğu gözlemlenmiştir.

Anahtar Kelimeler: Filo Tabanlı Durum İzleme, Veri Odaklı Hata Teşhis, Verimlilik, Prognostik


SUMMARY

With advancement of production and computer technologies, maximizing productivity, minimizing errors , and even predicting them before they occur with machine learning technologies gained an attraction. Data-Driven Fault Diagnosis approaches have emerged as a solution to these issues. By using sensor data acquired from monitored system, possible malfunctions can be predicted and diagnosed in advance. In manufacturing systems with more than one component performing a similar task, fleet-based management approaches have been developed for anomaly detection and fault diagnosis.

In this study, a fleet-based condition monitoring approach and an application has been developed for a data-driven fault diagnosis system. Most of the artificial intelligence-based techniques for fault detection are implemented locally on a machine. For data-driven supervised fault prediction and diagnosis techniques most of the time large historical data sets are needed for high accuracy and performance. Due to this requirement, the machine must be operated for a long time to collect data. Therefore, the process of creating a data set might be costly. However, a fleet-based monitoring system approach based on similarity comparisons can be established if there are similar systems at hand. In such a fleet method, there is no need for large historical data sets, and anomalies are determined by taking into account the need for similarities of the machine components in the fleet when operating under similar conditions. The work developed for fleet management in this thesis is developed as web-based, and promising results are obtained on four different test data that include machinery and bearings faults. In this study, based on the nature of sensor signal being examined data is pre-processed utilizing different transforming techniques such as Fast Fourier Transform (FFT) and similarities of the signals among each other are compared via Dynamic Time Warping (DTW) utilizing different measurement metrics such as Euclidean, Square Euclidean, Manhattan Distance etc. By obtaining distance based metric information, similar systems are clustered via Hierarchical Clustering algorithm. Anomaly scores are calculated for each component utilizing the results of clustering. Our results show that , faulty machines or bearing differs from healthy members of the fleet can be detected utilizing this approach.

Keywords: Fleet-based Condition Monitoring, Data-Driven Fault Diagnosis, Productivity, Prognostic

TEŞEKKÜR



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	4
2.1. Bakım ile İlgili Temel Kavramlar	4
2.2. Hata Teşhis, Anomali Tespiti ve Filo Yönetimi	7
2.3. Karşılaştırma ve Kümeleme Teknikleri	14
2.4. Veri Setleri	19
2.4.1. PHM 2012 Data Challenge	20
2.4.2. PHM 2018 Data Challenge	21
2.4.3. IMS Bearing Data	22
2.4.4. PHM 2009 Data Challenge	23
3. MATERİYAL VE YÖNTEM	25
3.1. Materyal	25
3.2. Yöntem	26
4. BULGULAR VE TARTIŞMA	31
4.1. Uygulamada Kullanılan Veri Setleri	31
4.1.1. Titreşim verisi tabanlı filo yönetimi ile hata tespiti	33
4.1.2. Sıcaklık verisi tabanlı filo yönetimi ile hata tespiti	43
4.1.3. Basınç verisi tabanlı filo yönetimi ile hata tespiti	47
4.2. Tartışma	52

İÇİNDEKİLER (devam)

5. SONUÇLAR VE ÖNERİLER	54
KAYNAKLAR DİZİNİ	55

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1 Bakım Maliyeti ve Bileşen Güvenilirliği Arasındaki İlişki (Werner, 2011)	5
2.2 ISO 13381-1'e Göre Prognostik Adımları (Kozlov vd., 2018)	5
2.3 Veri Odaklı Yaklaşım (Werner, 2011)	8
2.4. Anomali Tespit Yöntemleri Sınıflandırılması (Basora vd., 2019)	9
2.5. Proaktif Bir Filo Yönetimi İçin Hiyerarşik Yaklaşım (Monnin vd., 2014)	11
2.6. Kule Vinci Filosunun Sistem Mühendisliği Uygulama İzleme Sistemi (Zheng vd., 2010)	12
2.7. Tahmin Performansının Doğruluğu ve Güncelliliği (Saxena vd., 2014)	13
2.8. Filo Tabanlı PHM Süreçleri (Wagner ve Hellingrath, 2017)	14
2.9. Centroid Tabanlı Kümeleme Örneği (Developers, 2020)	16
2.10. Yoğunluk Tabanlı Kümeleme Örneği (Developers, 2020)	17
2.11. Dağıtım Tabanlı Kümeleme Örneği (Developers, 2020)	17
2.12. Hiyerarşik Kümeleme Örneği (Developers, 2020)	18
2.13. Grup Dağılımı ve Dendogram Grafiği (Seker, 2012)	18
2.14. PHM Araştırma Grupları (Jia vd., 2018)	19
2.15. PHM 2012 Data Challenge Pronostia Test Platformu (Challenge, 2012)	21
2.16. PHM 2018 Data Challenge Devre Levhası Üreten Bir İyon Değirmeni (Challenge, 2018)	22
2.17. IMS Bearing Test Platformu (Lee vd., 2007)	23
2.18. PHM 2009 Data Challenge Dişli Kutusu (Challenge, 2009)	24
 3.1. Uygulama Web Arayüzü	26
3.2. Uygulama Akış Diagramı	27
3.3. Uygulama Blok Diyagramı (Hendrickx vd., 2019)	27
 4.1. PHM12 Titreşim Zaman Alanı Sinyali (X : Zaman ve Y : Titreşim Eksenleridir)	34
4.2. PHM12 Titreşim FFT Frekans Alanı Sinyali (X : Frekans ve Y : Genlik Eksenleridir)	34
4.3. PHM12 Titreşim DTW Sinyali	34
4.4. PHM12 Titreşim Benzemezlik Matrisi	35
4.5. PHM12 Titreşim Nokta Grafiği	36
4.6. PHM12 Titreşim Dendogram Grafiği	36
4.7. IMS Titreşim Zaman Alanı Sinyali (X : Zaman ve Y : Titreşim Eksenleridir)	38
4.8. IMS Titreşim FFT Frekans Alanı Sinyali (X : Frekans ve Y : Genlik Eksenleridir)	38
4.9. IMS Titreşim DTW Sinyali	39

ŞEKİLLER DİZİNİ (devam)

4.10. IMS Titreşim Nokta Grafiği	40
4.11. IMS Titreşim Dendogram Grafiği	40
4.12. PHM09 Titreşim Zaman Alanı Sinyali (X : Zaman ve Y : Titreşim Eksenleridir)	41
4.13. PHM09 Titreşim FFT Frekans Alanı Sinyali (X : Frekans ve Y : Genlik Eksenleridir)	41
4.14. PHM09 Titreşim DTW Sinyali	42
4.15. PHM09 Titreşim Nokta Grafiği	43
4.16. PHM09 Titreşim Dendogram Grafiği	44
4.17. PHM12 Sıcaklık Nokta Grafiği	45
4.18. PHM12 Sıcaklık Dendogram Grafiği	46
4.19. Soğutma Pompası Basınç Düşüsü Nokta Grafiği	48
4.20. Soğutma Pompası Basınç Düşüsü Dendogram Grafiği	48
4.21. Aşırı Basınç Soğutma Pompası Nokta Grafiği	50
4.22. Aşırı Basınç Soğutma Pompası Dendogram Grafiği	50
4.23. Soğutma Pompası Sızıntı Nokta Grafiği	51
4.24. Soğutma Pompası Sızıntı Dendogram Grafiği	52

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
2.1 Prognostik ve Sağlık Yönetimi (Prognostic and Health Management, PHM) Avantaj ve Dezavantajları (Gao vd., 2015)	6
2.2 Arızalı Rulmanların RUL Tahmini İçin Kullanılan Yöntemlerin Avantajları ve Dezavantajları (Jammu ve Kankar, 2011)	7
2.3 PHM 2008-2017 Veri Araştırma Görevleri (Jia vd., 2018)	20
4.1 PHM12 Titreşim Kümeleme ve Anomali Puanı	37
4.2 IMS Titreşim Benzemezlik Matrisi	39
4.3 IMS Titreşim Kümeleme ve Anomali Puanı	41
4.4 PHM09 Titreşim Benzemezlik Matrisi	42
4.5 PHM09 Titreşim Kümeleme ve Anomali Puanı	44
4.6 PHM12 Sıcaklık Benzemezlik Matrisi	45
4.7 PHM12 Sıcaklık Kümeleme ve Anomali Puanı	46
4.8 Soğutma Pompası Basınç Düşüsü Benzemezlik Matrisi	47
4.9 Soğutma Pompası Basınç Düşüsü Kümeleme ve Anomali Puanı	49
4.10 Aşırı Basınç Soğutma Pompası Benzemezlik Matrisi	49
4.11 Aşırı Basınç Soğutma Pompası Kümeleme ve Anomali Puanı	50
4.12 Soğutma Pompası Sızıntı Benzemezlik Matrisi	51
4.13 Soğutma Pompası Sızıntı Kümeleme ve Anomali Puanı	52

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar	Açıklama
CNC	Bilgisayarlı Sayısal Kontrol (Computer Numerical Control)
CSV	(Comma Separated Values)
D3.js	(Data Driven Document)
DTW	Dinamik Zaman Çarpıtma (Dynamic Time Warping)
FFT	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
IMS	Akıllı İmalat Sistemleri (Intelligent Manufacturing Systems)
JSON	(JavaScript Object Notation)
PHM	Prognostik ve Sağlık Yönetimi (Prognostic and Health Management)
RPM	Dakika Başına Dönüş Hızı (Revolutions Per Minute)
RUL	Kalan Faydalı Ömür (Remaning Useful Life)
SIR	Sıralı Önem Yeniden Örnekleme (Sequential Importance Resampling)
TSP	Tahmine Başlama Zamanı (Time to Start Prediction)

1. GİRİŞ VE AMAÇ

Günümüzde dijital dönüşüm ile bakım süreçleri gelişmiş, erken hata tespiti oldukça önemli hale gelmiştir. Fabrika ve üretim tesislerinde kullanılan elektrikli makinelerde hata teşhisini, arızanın büyüp, hasar yayılmadan önlenmesinde oldukça etkilidir. Makinelerde hatanın önceden tespiti ve analizi iş gücü ve üretim kayıpları, enerji maliyetleri ve verimlilik açısından önem arz etmektedir. Elektrik makinelerinde durum izlenmesi, olası arızaların erken tespit edilmesine imkan tanımaktadır. Bu bakım maliyetini ve beklenmeyen arıza riskini önemli ölçüde azaltmaktadır. Çalışma durumunun izlenmesiyle hatalar önceden tespit edilebilir, ihtiyaç halinde müdahale edilerek daha önemli arızaların önüne geçilebilir. Riskler ve bakım maliyetleri düşürülür. Dolayısıyla hataların erken tespiti, ani arızaların önüne geçerek, bakım maliyetlerini düşürür ve ürün kalitesini yükseltir.

Arızalar, verimliliğin yanı sıra makine güvenliği için de oldukça önemli bir durumdur. Arızalanmış bir makine iş gücü bakımından ciddi problemlere yol açabilmekle birlikte; operatör ve çevrelerinde bulunan diğer insanlar için de bir tehdit haline gelebilmektedir. Makinelerin sebep olduğu iş kazaları ciddi yaralanmalara ve ölümlere yol açabilmektedir. İşletmeler iş güvenliği kurallarına uysalar bile, çalışılan makinelerde oluşan arızalar, önlenemeyecek kazalara sebep olabilmektedir. Çernobil Nükleer Santral Kazası gibi daha büyük ölçekli makine ve işletmelerde olabilecek hasarlar, kilometrelerce uzaklıktaki yaşamı olumsuz etkilemeyecektir (TAEK, 2020).

Tüm bu konular ışığında; can ve mal kaybını, arızadan kaynaklanarak yetiştiremeyen üretim ve sevkiyatlar sebebiyle oluşacak ekonomik ve itibar kayıplarını önlemek ve sistemlerin devamlılığını sağlamak için makine ve teçhizatların arızaya yol açacak anormal durumların tespiti çok önem arz etmektedir. Üretimdeki araç ve gereçlerin çalışma durumunun izlenmesi, bu araçların istikrarlı çalışmasını sağlamak, güvenilirlik ve kaliteyi artırmak amacıyla kullanılan çok etkili bir yöntemdir. Arızaların bütümeden erken tespiti, makinelerin ömrünü artırabildiğinden, bu yöndeki veri odaklı hata teşhisini gibi çalışmalar; hızlı, kolay yorumlanabilir, uygulanması rahat ve kullanışlı teknikler üzerinde yoğunluk kazanmıştır. Veri odaklı hata teşhis sistemleri, önceki kayıtlara ve makine anomalilerinin istatistiksel durumlarına dayanarak tahminlerde bulunur. İzleme sistemi tarafından sağlanan bilgilere güvenilmesi gerekmektedir. Bu sebeple kararlı bir izleme sistemi kurulması anomali tespiti için önemlidir.

Son dönemde kullanılan prognostik sistemlerin çoğu tek bir makine üzerinde analiz yapmaktadır (Hendrickx vd., 2019). Bu analiz için geçmişe ait büyük veri setlerine ihtiyaç duyulmaktadır. Bu veriler benzer özellikte makinelerin uzun süre çalıştırılmasıyla veya daha önceden yapılmış çalışmalardan faydalananarak elde edilebilir. Uygulamada bu işlemler maliyetli olabilmektedir. Ayrıca analiz yapabilmek için ciddi alan bilgisi uzmanlığı gerekmektedir. Büyük geçmiş yönelik veri setleri; arıza ve sağlık durumlarının tamamını içerecek şekilde olmalıdır ve sistem buna göre öğretilmelidir. Yeni oluşacak arıza durumları bilinemediğinden burada problemler gözlemlenemeyecektir. Her hata koşulunu endüstriyel ortamda oluşturmak mümkün değildir. Farklı çalışma koşulları, çevresel etkenler ve makine ömürleri göz önüne alındığında oluşacak hata varyasyonlarının sayısı tahmin edilemeyecek boyutlara gelmektedir. Makineler çalışmaya devam ettikçe çalışma durumları değişecek bu da en başta sağlıklı koşullarda alınan hata bilgileri ile kıyaslanacağı için zamanla gelişen normal çalışma koşullarını da hata olarak değerlendirebilecektir. Ancak benzer özellikte çalışan makinelerden oluşan bir filo varsa, bu filoya ait filo tabanlı bir izleme sistemi kurulabilir. Bir organizasyonda, aynı çalışma koşullarında aynı işleri yapan makine ve teçhizatlar için bir filo tanımı yapılabilir ve bu filo üzerinden karşılaştırma yöntemleri ile anomali durumu gözlenir. Aynı özellikteki makinelerin farklı çalışma durumları bir arıza göstergesi olabilmektedir. Bunun tespiti için kurulan bu filo tabanlı sistem ile bu arızalar tespit edilebilir.

Lee vd. (2014) çalışmasında; birbiriyle bağlantılı makinelerde büyük veri uygulamalarıyla, akıllı analitik bir yöntem kurmuştur. Matthews vd. (2014); sivil havacılıkta, yerleşik uçuş ve veri kaydedicileri kullanarak, anormal hava güvenliği olaylarını incelemek için filo üzerinde veri madenciliği algoritmaları uygulamıştır. Siegel (2013), rüzgar türbinleri üzerine çalışarak, rüzgar hızı sensöründen alınan verilerle, kümleme yaklaşımları ile prognostik ve sağlık durumu izlemesi geliştirmiştir. Uçak motorlarındaki benzerlik özelliklerinden faydalananlarak, Jacobs vd. (2018) iki motor arası farklılıklardan anormal davranışları gözlemlemiştir. Demiryolu endüstrisinde çalışan parçaların birbiri ile uyumunu inceleyen Hodge vd. (2015), Kalan Faydalı Ömrü (Remaning Useful Life, RUL) tahmini yapmıştır. Filo yaklaşımlarında yalnızca bir özellik için değil birden fazla özellik için, birden fazla anamoli analiz edilebilir. Farklı özelliklerin kendi içlerinde birbirleriyle karşılaştırılmasıyla, filodaki herhangi bir makinede olan sapma bir hata göstergesi olduğu düşünülebilir.

Bu çalışmada benzer özellik gösteren benzer işi yapan filoları incelemek amacıyla, ortak bir yapı üzerinde, tüm adımları gerçekleştirecek şekilde, bir uygulama geliştirilmiştir. Uygulama bloklar halinde kurgulanmıştır. Her bir blok inceleme kolaylığı açısından görselleştirilen çıktılar oluşturacak şekilde tasarlanmıştır. Böylelikle bir filodaki tüm üyeleri aynı anda analiz imkanı sunulmuştur. İlk olarak birinci blokta verilerle ilgili ön

işleme adımları gerçekleştirilmiştir. Verinin türüne göre ön işleme yöntemleri uygulanmıştır. Örneğin titreşim gibi çok fazla değişkenlik gösteren özelliklerdeki verilerde DTW uygulanarak filo üye çiftleri arasındaki zaman hizalanması sağlanmıştır. FFT yöntemiyle anlık tepe değerlerini gidermek için 0-1 arası min/max normalizasyonu yapılmıştır. Bu veri ön işlemlerinden sonra üye çiftleri alternatif yöntemlerle karşılaştırılarak birbirleri arasında mesafe ve benzemezlikler bulunmuştur. İkinci blokta karşılaştırılan üye çiftleri arasında kümeleme (clustering) işlemi uygulanmıştır. Üçüncü blokta da kümeleme durumlarına göre, üye sayıları oranlanarak anomali puanları belirlenmiştir. Tüm çalışma dört veri seti üzerinde; toplamda yedi ayrı özellik verileri ile test edilmiş ve sonuçlar alınmıştır. Filo yaklaşımında esas olan üyelerin çögünün sağlıklı olduğu koşuldur. Bozulma gösteren üyeler diğerlerinden farklı özellik gösterecektir. Ayrıca üyeleri benzer çalışma koşullarında çalıştığı, benzer işi yaptığı ve çevresel koşulların da aynı olduğu varsayılmaktadır.

Takip eden bölümde problem ve yöntemler ile ilgili literatür araştırması, bakım ile ilgili temel kavramlar, yaklaşımlar aktarılmaktadır. Filo yönetimiyle ilgili literatür araştırmaları belirtilmektedir. Çözüm yöntemleriyle ilgili literatürde yapılan çalışmalar detaylandırılmaktadır. Uygulamada kullanılan veri kümeleri tanıtılmaktadır. Üçüncü bölümde; kullanılan materyal ve yöntem tanıtılmaktadır. Problem ile ilgili mimari ve araçlar yazılarak, alternatif yöntemler tartışılmaktadır. Bu kapsamdaki iş akışı ve diyagramları, metriklerden bahsedilmektedir. Dördüncü bölümde bulgular ve tartışmalar bölümündür. Uygulamanın içeriği bu bölümde anlatılmaktadır. Her bir blok bu bölümde tanıtılmaktadır. Blok çıktılarının grafikleri gösterilip, sonuçlar aktarılmaktadır. Deneysel sonuçlar gösterilmektedir. Beşinci bölümde sonuçlar tartışılmaktadır. Çalışmanın ana hatları ile ilgili açıklamalar yapılmaktadır. Çalışmayla ilgili genel bir değerlendirme yapılarak gelecek çalışmalar için önerilerde bulunulmaktadır.

2. LİTERATÜR ARAŞTIRMASI


Üretim ve imalat fabrikalarında kullanılan CNC gibi elektrik makinelerinde hata teşhisleri son dönemlerde oldukça hızlı araştırılarak geliştirme sağlanmıştır. Ayrıca, fabrikalardaki makinelerin karmaşıklığı sebebiyle, veri odaklı hata teşhisin doğruluk ve güvenilirliğini artırmaya yönelik çalışmalar da önemli hale gelmiştir. Diğer taraftan, bir hatanın erken teşhisini, arızanın büyümeyi ve önemli problemlere dönüşmesini engelleyebilir. Bu sebeple endüstriyel ortamlarda hata teşhisine gösterilen ilgi artmıştır (Li vd., 2017).

2.1. Bakım ile İlgili Temel Kavramlar

Avrupa standarı EN 13306: 2010'a göre bakım "Bir nesnenin yaşam döngüsü boyunca kendisinden beklenen işlevlerini yerine getirebileceği durumu muhafaza etmek veya geri yüklemek için gerekli tüm teknik, idari ve yönetimsel eylemlerin kombinasyonu" olarak tanımlanır. Bakım türleri; düzeltici bakım, önleyici bakım ve kestirimci bakım olmak üzere üç bölüme ayrılmıştır. Bu çalışmada, kestirimci bakım yöntemlerinden biri olan prognostik yöntem ile filo tabanlı yönetim ile hata teşhisini uygulanmıştır.


Kestirimci Bakım (Predictive Maintenance); araç gereçlerin teknik durumuna göre tahmin edilen ömrünü hesaba katarak, arıza riskini arttırmadan kalan ömrünün artırılması için uygun bakım görevlerini yerine getirmektir (Oztanır, 2018). Bu bakım türü; bir sistemde kullanılan araçların sağlık durumunu belirlemek için sistemin ve makinenin koşullarını izleyen araçları kullanır. Bu araçlar makine öğrenmesi algoritması ile geçmiş ve şu anki durumu göz önüne alarak matematiksel ve fiziksel modeller geliştirir. Böylece termal görüntüleme, ultrasonik, titreşim ve yağ analizi gibi yöntemler ile bileşenlerin sağlığını izleyerek gelecekteki arıza durumu hakkında tahminde bulunmaya çalışır. Bu sayede periyodik bakım planlarına ihtiyaç azalır, arıza zamanı tahminine göre önceden bakım planlaması yapılabilir. Bakım planları yaparken bakım maliyeti ve güvenilirlik arasındaki denge de dikkate alınmalıdır. Şekil 2.1'te bu ikili arasındaki ilişki görülmektedir. T_0 anında kullanılan bir makinada, ilk anda bakım maliyetleri yüksek olduğu gibi güvenilirlik de yüksektir. Makine kullanıldıkça bu iki eksen birbirine yaklaşır. Birbirine en yakın olduğu zaman, bakım için en uygun zamandır. Örneğin otomobil lastik dişlerinin izlenmesi, lastik değişim zamanı hakkında bilgi verir, böylece lastik dişlerinin en

uygun zamanda değiştirerek lastik patlama ve kayma gibi riskleri ortadan kaldırır. Kestirimci bakım sayesinde sistemlerin yaşam döngüleri üst düzeye çıkar ve bakım maliyetleri en aza indirilir (Werner, 2011).



Şekil 2.1 Bakım Maliyeti ve Bileşen Güvenilirliği Arasındaki İlişki (Werner, 2011)

Kestirimci bakım yöntemleri ile arıza tespiti yapılmaktadır. Bu yöntemlerden prognostik (tanı); sistemin gerçek durumu, bu durumun izdüşümü ve arızadan önce kalan sürenin tahminidir. Prognostik daha sonra ISO 13381-1 standartı ile yeniden tanımlanmıştır. Bu tanıma göre; “prognostik arızadan önceki çalışma süresinin tahmini ve gelecekteki var olma veya birkaç arıza modunun ortaya çıkma riskidir.” Prognostik standartı ile prognostığın ana hatları belirlenir ve prognostığı gerçekleştirmek için ihtiyaç duyulan veriler tanımlanır. Alt ve üst çalışma koşulu limitleri için kalibrasyon durumu da yine bu standart ile belirlenir. Standardın tanımladığı şekilde prognostik adımları Şekil 2.2’te gösterilmiştir (Kozlov vd., 2018).



Şekil 2.2 ISO 13381-1’e Göre Prognostik Adımları (Kozlov vd., 2018)

Bakım ile ilgili kavramlardan bir diğeri; Prognostik ve Sağlık Yönetimi (Prognostic and Health Management, PHM); endüstriler için geliştirilmiş kalite, azaltılmış duruş süresi, artan sistem güvenliği ve daha düşük üretim maliyetlerine ulaşmak amacıyla; yaklaşan arıza

ve RUL tahmini için kullanılan bakım yöntemidir (Gao vd., 2015). Çizelge 2.1'de PHM yönteminin avantaj ve dezavantajları gösterilmiştir.

Çizelge 2.1 Prognostik ve Sağlık Yönetimi (Prognostic and Health Management, PHM) Avantaj ve Dezavantajları (Gao vd., 2015)

Avantaj	Dezavantaj
Farklı veri kaynaklarının entegrasyonu,	Karşılıklı bağımsız olduğu varsayılan başarısızlık zamanları,
Hata olasılığının ölçümü	Kapsamlı ortak değişkenlerin gerekli olması

Cosme vd. (2018), çalışmalarında arıza prognostiği için gürültü ölçümlerinde parçacık filtrelerinin etkili bir yöntem olduğunu göstermiştir. Ölçüm için alınan örneklerin yeterli miktarda olamaması sebebiyle örnek yoksunluğu ile karşılaşılmıştır. Bu örnek azlığı gürültü ölçümlerinde karşılaşılan ciddi sorunlardandır. Bu sorunu aşmak için, durum uzayından örneklenen rastgele bağımsız değişkenler üreten, diferansiyel denklem tabanlı parçacıkfiltresi (Particle Filter based on Differential Evolution, PF-DE, called IPF), ardışık gelişim filtresi (sequential evolutionary filter, SEF) yaklaşımı ile PRONOSTIA (Rulman arızası belirtisine yönelik tezgâh testi) platformundan çalışma koşulları altında rulmanların daha hızlı bozulması, bir CNC makinesi üzerinde gerçekleştirilebilir (Cosme vd., 2018).

Takım tezgâhlarında arıza durumları oluşması, bu durumların kayıt altına alınması gibi durumlar söz konusu olduğunda gerçek hayatı yeterli veriye ulaşmakta problem yaşanabilmektedir. Tezgâh performansını değerlendirmek için gerekli veri setini oluşturmak amacıyla yeniden yapılandırılabilir prognostik bir yaklaşım tasarlanabilir. Bu tasarımda; The Watchdog Agent Toolbox'ı ile takım tezgâhlarının performansını değerlendirmek ve tahmin etmek için kolay ve etkili bir şekilde kullanılabilen hem donanım hem de yazılımın bir entegrasyonu olan Prognostik Platformu (Reconfigurable Prognostic Platform, RPP) yapılabilir (Liao ve Lee, 2010).

RUL makineler için önemli bir değerdir. Rulman elemanları yataklarında da böyle bir RUL değeri çıkarımı ve yaklaşılan arıza tahmini, rulmanın gelecekteki kullanımı ile ilgili fikir verebilmektedir. Ahmad vd. (2018), sağlık göstergesi eğilimini öğrenmek için regresyona dayalı bir yaklaşım, Tahmine Başlama Zamanı (Time to Start Prediction, TSP) belirlemek için gradyan bazlı bir yöntem önermektedir. TSP; verilerin analizinin doğru yapılması rulman bozulmalarının ilk aşamalarında, ciddi bir bozulma olmadığından, daha doğru bir RUL tahmini yapmaya katkı sağlar (Ahmad vd., 2018).

Tüm bu prognostik koşullarının yanında, prognostik ve RUL tahmini için kullanılan yöntemlerin avantaj ve dezavantajları da vardır. Çizelge 2.2'de Jammu ve Kankar (2011)'ın RUL tahmini için yaptığı çalışmada avantaj ve dezavantajlar görülmektedir.

Çizelge 2.2 Arızalı Rulmanların RUL Tahmini İçin Kullanılan Yöntemlerin Avantajları ve Dezavantajları (Jammu ve Kankar, 2011)


Çözüm Yöntemi	Avantaj	Dezavantaj
Titreşim	Güvenilir ve standart yöntem, değişime anında tepki verir, arızalı bileşeni belirleme yeteneği.	Pahalı, müdahaleci, sensör hatalarına bağlı.
Yağ / Enkaz Analizi	Yatak kolaylığı karakterizasyonu kolaylığı, kusurun türünü ve yerini tespit etmek mümkündür.	Yağ besleme sistemine sahip rulmanlar ile sınırlıdır.
Sıcaklık	Anormal çalışma alanlarını tespit etme yeteneği, standart yöntem.	Yaklaşan arızayı tespit etmek zordur.
Akustik Emisyon	Yaklaşan arıza tespit edilebilir, büyük sinyal / gürültü oranı.	Örneklemeye frekansı yüksek olmalıdır.

Laddada vd. (2017) çalışmalarında, kesici takım tezgâhlarının PHM ve RUL tahmini probleminin çözümünde, performans düşüşü değerlendirmesi için Dalgacık Paket Dönüşümü (Wavelet Package Transform, WPT) ve Ekstrem Makine Öğrenmesi (Extreme Learning Machine, ELM) algoritmalarına dayanan prognostik veri güdümlü bir yöntem geliştirilmiştir. İki aşamalı olan bu yöntem; ilk olarak özellik çıkarımı kesme aletinin aşınma davranışının temsilini gösteren bir model oluşturmak için ELM girdileri olarak kullanılır. Oluşturulan model; kesici aletin PHM ve RUL için kullanılır.

Bakım yöntemi stratejisi olarak veri odaklı yaklaşım; veriler arasındaki kalıpları veya ilişkileri kullanarak bu verileri işlemek anlamına gelmektedir. Şekil 2.3 'te veri odaklı yaklaşım yöntemlerinin kategorileri görülmektedir (Werner, 2011).

2.2. Hata Teşhis, Anomali Tespiti ve Filo Yönetimi

Li vd. (2017) çalışmalarında, Endüstri 4.0'da sistematik bir yaklaşım formülü oluşturmak ve kestirimci bakım için bilgi edinmek için, veri madenciliği yaklaşımına




Şekil 2.3 Veri Odaklı Yaklaşım (Werner, 2011)

dayanan makine merkezlerinde hata teşhisini sağlayan; sensör seçimi, veri toplama, veri ön işleme, veri madenciliği, karar destek ve bakım uygulama modullerini içeren bir uygulama geliştirmiştirlerdir.

Anomali durumları sistemlerin olması gereki̇gi gibi çalışmadi̇gi ve arızaya yol açtı̇gi koşulları belirtmektedir. Örneğin Değirmenci'ye (2019) göre; özel günlerde kredi kartı kullanımının normal harcamaların üzerine çıkması anomali olarak tanımlanmazken, normal bir günde normal harcamaların üzerinde bir harcama anomali olarak değerlendirilmektedir. Anomali durumları iş gücünün aksamasına ve kayıplar yaşanmasına sebep olmaktadır. Bu sebeple anomali tespiti önemli bir çalışma konusu haline gelmiştir. Bu bölümde akıllı hata tespitine yönelik yöntemler, prognostik yaklaşımalar ve bu yöntemlerden biri olan filo tabanlı yönetim ile ilgili bilimsel çalışmalara dėrinilmektedir. Şekil 2.4.'te anomali tespit yöntemleri gösterilmiştir. Genel olarak; yeniden yapılandırma, alan, topluluk, mesefa tabanlı ve istatistiksel olmak bėş yönteme ayrılan anamoli tespit yöntemleri, kendi içerisinde alt dallara da ayrılmıştır (Basora vd., 2019).

Günümüzde kullanılan prognostik sistemlerin çoğu tek bir makine üzerinde analiz yapmaktadır (Hendrickx vd., 2019). Bu analiz için geçmişe ait büyük veri setlerine ihtiyaç duyulmaktadır. Bunun için de ya benzer özellikte makinelerin uzun süre çalıştırılarak veri elde edilmesi ya da daha önceden çalışılmış veri setlerine ihtiyaç vardır. Uygulamada bu



Şekil 2.4. Anomali Tespit Yöntemleri Sınıflandırılması (Basora vd., 2019)

işlemler maliyetli olabilmektedir. Ancak benzer özellikte çalışan makinelerden oluşan bir filo varsa, bu filoya ait filo tabanlı bir izleme sistemi kurulabilir. Aynı özellikteki makinelerin farklı çalışma durumları bir arıza göstergesi olabilmektedir. Bunun tespiti için kurulan bu filo tabanlı sistem ile bu arızalar tespit edilebilir.

Hendrickx vd. (2019) çalışmalarında, filoyu oluşturan makinelerin durumlarını izlemek için bir anomali tespit uygulaması geliştirilmiştir. Bu uygulama ile filo yönetimindeki temel avantajları kullanarak kararlı bir yapı kurulmuş olur. Makine karşılaştırması ile geçmişte ait büyük bir veri kümeseine ihtiyaç duymaması, kullanıcı tanımlı karşılaştırma yöntemleri sayesinde alan uzmanlığının dahil edilmesi ve diğer yapay zekâ tekniklerinin aksine, kolay yorumlanabilirlik ve bir alan uzmanının uygulama tahminlerini doğrulamasına olanak tanımışı gibi avantajları sayesinde filo yönetimi ile iyi bir anomali tespiti alt yapısı kurulmuş olur. Filo tabanlı yönetimde makine çiftlerinin karşılaştırılması, filoyu kümelemek ve anomali tespiti yapmayı mümkün kılar. Gerçekleştirilen her adımda işlemler görselleştirilerek arıza tespiti gözlemlenebilir. Karşılaştırma yöntemi için yapay zekâ ve makine öğrenmesi teknikleri kullanılır. Filo tabanlı yaklaşımda makine çiftleri arasında çevrim için karşılaştırma kullanılır. Filodaki diğerlerinden farklılık gösteren

makine arıza gösteriyor olabilir. Titreşim, sıcaklık, akım, gerilim, x-y-z yükleri ve nem gibi farklı özelliklerinde karşılaşılmasına olanak tanıyan bu sistem ile etkili bir analiz yöntemi geliştirilir (Hendrickx vd., 2019).


Hodge vd. (2015) çalışmalarında demiryolu endüstrisinde durum izleme için kullanılan Kablosuz Sensör Ağları (Wireless Sensor Networks, WSNs) ile ilgili genel bir inceleme yapılmıştır. Sistemlerin, yapıların, araç ve makinelerin analizi için kablosuz sensör ağının kullanım durumu, kullanım amacı, sensör konfigurasyonları ve ağ topolojileri incelenmiştir. Bu yöntemle koşul izleme durumu ile insan denetim gereksinimlerinin azalması, arızaların oluşmadan önce tespit edilerek bakım maliyetlerinin düşmesi ve güvenilirliğin arttırılması hedeflenmektedir.

Jacobs vd. (2018) çalışmalarında havacılık ve uzay gaz türbini motorlarında sağlık durumunu izlemek için birbirinin kardeşi iki motor arası sistem davranışları ve dış bozukluklardaki benzerlikten yararlanılarak, varyasyon analizi yöntemi geliştirmiştir. Kardeş motor gözlemlenen motor için temel bir tanım sağlar ve motorlar arası normal varyasyon ile anormal davranışlar birbirinden ayrılır. Önceden iki motordan da gelen sağlıklı veriler ile model eğitilerek, motorlardaki farklar tespit edilir. Böylece anormal davranışındaki motor gösterilmiş olur.

Siegel (2013) çalışmasında rüzgar hızı sensörü sağlık izleme vaka çalışması ve PHM Data Challenge 2011 verileri üzerinde artık kümeleme yöntemi uygulamıştır. Artık kümeleme yaklaşımı; ölçülen sinyal özelliklerindeki doğrusal olmayan korelasyon ilişkisi modeli ve tahmini sinyal özellikleri ile çoklu sistem izleme durumunu sağlar. Kümeleme kısmı sisteme bağlı imza yönünü inceleyerek, sağlık değerini bozulma imzasının değeri ile karşılaştırır. Rüzgar hızı verilerini benzeterek, otomatik ilişkisel sınır ağı regresyon analiz yöntemi ile karşılaştırıldığında en yüksek doğrulukla tahmin sağlamıştır. Kullanılan bu yöntemin mevcut yöntemlerin çoğundan daha iyi performans gösterdiği ve sinyallerde nominal bir korelasyon oluştduğunda uygun bir izleme algoritması olduğu gözlemlenmiştir.

Matthews vd. (2014) çalışmalarında daha önceden bilinmeyen havacılık güvenliği olaylarını keşfetmek amacıyla, aşınmaya dayalı analizi tamamlamak için; ölçeklenebilir veri madenciliği algoritmalarını kullanmıştır. Uçaklardaki uçuş veri kaydedicilerinde bulunan; uçuş kontrol sistemleri, aktuatörler, motorlar, iniş takımı, aviyonik ve pilot komutları gibi verileri kullanarak, büyük ölçekli dağıtılmış veri madenciliği teknikleri aracılığıyla anomali tespitini yapmak için çok çekirdekli öğrenme kullanılmıştır. Yapılan çalışma neticesinde tespit edilen tüm anormallikler alan uzmanları tarafından da doğrulanmıştır.

Armendia vd. (2010) çalışmalarında, ikiz kontrol takım tezgâhını ve işleme performansını etkileyen pek çok parametreyi bir araya getiren bir simulasyon geliştirmiştir. Bu sayede enerji tüketimi ve bileşenlerin kullanım ömrü gibi işleme performanlarının tahmini hedeflenmektedir. Filo çapında veri toplayarak, farklı sistem ve ekipmanların uzmanlıklarını bir araya getirmektedir. Gerçek işleme verileri ile işleme süreçleri ve makine durumları izlenmektedir. İzleme sistemi ile makine takımındaki hasarlı bilgilendirici için uyarı sistemi geliştirilmiştir. Ayrıca sistem ile filo düzeyinde bir sağlık yönetimi sağlar ve bakım işlemlerini optimize eder. Bu sayede Şekil 2.5.'te gösterilen proaktif bir varlık yaşam yönlendirme metodolojisi inşa edilmiştir. Teşhis, pronostik ve uzmanlığı destekleyen veri modelleri birleştirilerek bir anomalî tespit uygulaması geliştirilmiştir.



Şekil 2.5. Proaktif Bir Filo Yönetimi İçin Hiyerarşik Yaklaşım (Monnin vd., 2014)


Lee vd. (2014) çalışmalarında büyük veri ortamlarındaki imalat dönüşümü ve verileri yönetmeye yönelik akıllı kestirimci bilişim araçlarının üretime katkısı incelenmiştir. Endüstri 4.0 ile fabrikalardaki birbirine bağlı makineler ortak bir topluluk haline gelmiştir. Bu makinelerin yönetimi için Siber-Fiziksnel sistem tabanlı üretim ve hizmet yeniliklerinin imalat sanayilerindeki yeri incelenmiştir.

Bagheri vd. (2015) çalışmalarında makine ağını siber düzeyde yöneten ve analiz eden bir metodoloji oluşturmuştur. Siber katmanı mimarının bilgi merkezi olup, filodaki makinelerden verinin aktarıldığı yerdır. Filo karşılaştırma teknikleri ile makine performansının analiz edilmesini sağlar. Makinenin geçmiş bilgileri ile benzerlikler ölçülerek gelecek durumu hakkında tahminlerde de bulunabilir.

Said vd. (2016) çalışmalarında ekipman filoları yönetimi, kullanım değerlendirmesi ve ekipman sağlığının izlenmesi için telematik olarak çalışan (gerçek zamanlı veri aktarma

ve izleme yeteneği sunan) hesaplama yöntemlerinin olduğu bir uygulama geliştirmiştir. Çalışmada ölçüm hesaplama algoritmaları ve yaşam analiz teknikleri anlatılmıştır. Bu algoritma ve tekniklerden faydalananarak ekipmandaki arıza durumlarını tahmin etmek amacıyla sağlık izleme uygulaması oluşturulmuştur. Sistemin güvenilirliğini test etmek ve doğrulamak için de iki farklı filodan alınan telamatik veri setleri üzerinde uygulanmıştır.

Zheng vd. (2010) çalışmalarında; sistem mühendisliği esas alınarak kule vinçleri filosunun yararlı ömrü incelenmiştir. Filodaki kule vinçlerinden çalışma verileri toplanarak Radyal Temel İşlev Ağrı (Radial Basis Function Network, RBF) algoritması ile yapısal stres elde edilmiştir. Daha sonra RUL hesaplanarak, kalan ömrün optimizasyonu için parametre toplama, geri bildirim, kontrol ve yapısal yararlı ömrü gibi bilgiler ışığında ömür izleme optimizasyon kontrolü ve yönetimi gerçekleştirilmiştir. Bu izleme sistemi sonlu elemanlar, sinir ağı ve yorulma yoğunluğu gibi teknikleri kullanır. Sistem mühendisliği temel alınarak gerçekleştirilen bu uygulama, yapısal yararlı ömrü stresin eşdeğer döngü süresine göre hesaplamaktadır. Böylece kule vincinin yararlı ömrünün optimum tasarımını ve çalışma verilerinin çevrim içi olarak izlenmesini sağlar. Şekil 2.6.'da sistemin optimum tasarım, kontrol ve yönetimi blok diyagram halinde gösterilmiştir.




Şekil 2.6. Kule Vinci Filosunun Sistem Mühendisliği Uygulama İzleme Sistemi (Zheng vd., 2010)

Le ve Geramifard (2014) çalışmalarında, filo içindeki ekipmanların durumunun izlenmesi ve sağlık değerlendirmesi için geçmiş veri kullanımı incelenerek bir bakım

yöntemi geliştirilmiştir. Freze makinelerinin keyfi çalışma koşullarında takım aşınmasını tahmin etmek için Sıralı Önem Yeniden Örneklemeye (Sequential Importance Resampling, SIR) algoritması ile bir yaklaşım geliştirilmiştir. Bu yaklaşım; aynı çalışma koşullarında bulunan geçmiş veriye dayanan tahmin yöntemlerinden farklı olarak, geçmiş veri eksikliği olduğu durumlar için çözüm olarak sunulmaktadır. SIR algoritmasına uygun bir model oluşturmak amacıyla, birbirine en çok benzeyen çalışma koşulları tanımlanarak bu koşullardaki geçmiş veriler birleştirilir. Bu sayede takım aşınması tahmini sağlanır.

Saxena vd. (2014), filo ve birim tabanlı prognostik yöntemler için performans değerlendirmesi yapmıştır. Çalışmada metrik önermekten ziyade prognostik yönteminin hangi hususları kapsadığı açıklanmıştır. Öncelikli olarak prognostik yaklaşım diğer tahmin yöntemlerinden ayrılarak, hangi faktörlerin performansları etkilediği belirtilmiştir. Performans değerlendirmesinde kullanılması gereken teknikler, arıza durumu yorumları ve algoritma tahmin karşılaştırımları aktarılmıştır. Prognostik yaklaşımının uygulanabilirlik ve sınırlarına da bu çalışmada yer verilmiştir. Şekil 2.7.'de tahmin performansına dair bir akış diyagramı görülmektedir.



Şekil 2.7. Tahmin Performansının Doğruluğu ve Güncelliliği (Saxena vd., 2014)

Wagner ve Hellingrath (2017) çalışmalarında, filo tabanlı bir PHM için benzer özellikteki filodan alınan veriler kullanılarak değerlendirme yaklaşımı incelenmiştir. Teşhis ve prognostik için filonun özelliklerine göre farklı adımlar uygulanır. Şekil 2.8.'de bu adımlar gösterilmektedir. İlk olarak filo özellikleri analiz edilir ve uygun PHM yaklaşımının seçimi için alt yapı oluşturulur. Sonraki adımda veriler ön işleme tabi tutularak uygun format dönüşümü yapılır. Filo özelliklerine göre benzer alt filolara ayırmak gerekebilir. Daha sonra filo özelliklerine göre; avantaj ve dezavantajları göz önüne alınarak, uygun bir yaklaşım seçilir. Son olarak seçilen yaklaşımın performansı değerlendirilir. Performans istenen kriterde değilse, önceki adımlar tekrarlarak uygun hale getirilir.



Şekil 2.8. Filo Tabanlı PHM Süreçleri (Wagner ve Hellingrath, 2017)

2.3. Karşılaştırma ve Kümeleme Teknikleri

Filo yönetiminde makine karşılaştırma ve kümeleme önemli yöntemlerdir. Bu yöntemler için kullanılacak tekniklerde metriklerinden bazıları şu şekildedir;

Öklid mesafesi; “ n uzunluğundaki iki dizinin arasındaki düz çizgi mesafesidir ve Eşitlik 2.1’deki formülle verilir” (Hendrickx vd., 2019):

$$s(x, y) = \sqrt{\sum_{i=1}^n c(x_i, y_i)^2} \quad (2.1)$$

“ $c(x_i, y_i)$ iki m boyutlu veri noktası arasındaki Öklid normudur”. Bu norm Eşitlik 2.2’de görülmektedir (Hendrickx vd., 2019):

$$\begin{aligned} c(x_i, y_i) &= \|x_i\|_2 - \|y_i\|_2 \\ &= \sqrt{x_{i1}^2 + \dots + x_{im}^2} - \sqrt{y_{i1}^2 + \dots + y_{im}^2} \end{aligned} \quad (2.2)$$

Kare öklid mesafesi ile şekil çiftleri arasındaki mesafe matrisi Eşitlik 2.3’teki gibi bulunabilir.

$$\Delta_{ij} = dist(x_{test}^i, x_{train}^j) = \sum_{k=0}^{d-1} (x_{test}^i[k], x_{train}^j[k])^2 \quad (2.3)$$

Maximum Benzerlik Metriği ise; “aradaki benzerliğinin maximum değeridir” Eşitlik 2.4’te bu benzerlik verilmiştir (Chan ve Tou, 2008).

$$sim-score = \frac{1}{|s|} \sum_{a=1}^{|s|} \frac{1}{N} \sum_{n=1}^{NF_{means,n}} (2.4)$$

Manhattan mesafesi; “şehir bloğu olarak adlandırılır ve iki vektör arasındaki mesafedir. Bu yöntem, binalardan geçilemediğinde iki nokta arasındaki mesafeyi hesaplamada kullanılabilir”. Bu formül Eşitlik 2.5’té verilmiştir (Lüthe, 2019).

$$manhattandistance = \sum_{i=1}^{|i|} |x_i - y_i| (2.5)$$

Jaccard Paul tarafından bulunan (katsayı) kümeler arasındaki benzerlikleri ölçen Jaccard benzerliği; kesişim büyülüğünün iki kümenin birleşim büyülüğüne bölünmesiyle Eşitlik 2.6’daki gibi tanımlanır.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} (2.6)$$

Kosinüs benzerliği; n -boyutlu bir uzayda, iki n -boyutlu vektör arasındaki açının kosinüsüne eşittir. Bu benzerlik, alınan iki vektörün nokta çarpımının, iki vektörün uzunluk veya büyülüklüklerinin çarpımına bölümü ile bulunur. Eşitlik 2.7’de bu denklem görülmektedir.

$$similarity(A, B) = \frac{A \cdot B}{\|A\| \cdot \|B\|} = \frac{\sum_{i=1}^n (A_i \cdot B_i)}{\sqrt{\sum_{i=i}^n A_i^2} \cdot \sqrt{\sum_{i=i}^n B_i^2}} (2.7)$$


Pearson benzerliği; iki n -boyutlu vektörün standart sapmalarının, bu vektörlerin çarpımına bölünmesidir. Eşitlik 2.8’de bu benzerlik verilmiştir.

$$similarity(A, B) = \frac{cov(A, B)}{\sigma_a \sigma_b} = \frac{\sum_{i=1}^n (A_i - \bar{A})(B_i - \bar{B})}{\sqrt{\sum_{i=i}^n (A_i - \bar{A})^2} \cdot \sqrt{\sum_{i=i}^n (B_i - \bar{B})^2}} (2.8)$$

Overlap benzerliği; iki kümenin kesişiminin, iki kümenin minimumuna bölümündür. Eşitlik 2.9'da bu formül gösterilmiştir.

$$O(A, B) = \frac{|A \cap B|}{\min(|A|, |B|)} \quad (2.9)$$

“Yaklaşık en yakın komşular algoritması, Jaccard Benzerliği, Kosinüs Benzerliği, Öklid Uzaklılığı veya Pearson Benzerliği temel alınarak, sağlanan benzerlik algoritmasına dayanan bir nesne kümesi için k -En Yakın Komşular Grafiği oluşturur.” (Neo4j, 2020). Kümeleme algoritmalarından centroid tabanlı kümelemede, “veriler hiyerarşik olmayan kümeler halinde düzenlenir.” Centroid tabanlı algoritmaların etkili olmasının yanında başlangıç koşullarına ve aykırı değerlere duyarlı olması gibi dezavantajları vardır. Bu yaklaşımada en yaygın kümeleme algoritması K -Means'dir. Şekil 2.9.'da geometrik merkez şeklinde kümelerin dağılımı gözükmemektedir. Merkezin her bir bölümünde bulunan elemanlar o kümeye aittir.



Şekil 2.9. Centroid Tabanlı Kümeleme Örneği (Developers, 2020)


Yoğunluk tabanlı kümelemede ise; Örnek yoğunluğuna göre gruplanan kümeler, keyfi şekillerde dağılabilirler. Bu algoritmalar, değişen yoğunluklara ve yüksek boyutlara sahip verilerle güçlük çekmekte ve kümelere aykırı değer atanamamaktadır. Şekil 2.10.'da bu yoğunluk dağılımı görülmektedir.

Dağıtım tabanlı kümeleme yönteminde, Gauss gibi dağılımlardanoluştugu varsayıılır. Dağıtım tabanlı kümelemede bir nokta, dağılım merkezinden uzaklaştıkça, o dağılıma ait



Şekil 2.10. Yoğunluk Tabanlı Kümeleme Örneği (Developers, 2020)


olma olasılığı azalmaktadır. Şekil 2.11.'de görüldüğü gibi içe görünen bantlar dağılımlarda olasılık düşüşünü göstermektedir. Bu algoritmanın da zayıf noktası, verilerdeki dağılım türü biliniyorsa kullanılabilirnessidir.



Şekil 2.11. Dağıtım Tabanlı Kümeleme Örneği (Developers, 2020)


Hiyerarşik kümeleme, genel olarak hiyerarşik verilerde kullanılır. Bu algoritmada kullanılan küme ağaçları doğru seviyede kesilerek herhangi bir sayıda kümeyi seçilebilir. Bu algoritmada küme sayısını önceden bilmeye gerek olmadığından, küme sayısı bilinmediği durumlarda daha kullanışlıdır. Şekil 2.12.'de canlıların sınıflandırması ile ilgili hiyerarşik grafik görülmektedir.

Hiyerarşik gösterimde dendrogram grafiği önemli bir grafiktir. Ağaç grafiği anlamına gelen dendrogram; hesaplamalı biyolojide genler arası ilişkisi veya veri madenciliğinde veri



Şekil 2.12. Hiyerarşik Kümeleme Örneği (Developers, 2020)

grupları arasındaki ilişkiyi göstermek gibi çeşitli alanlarda kullanılır. Örneğin A, B, C, D ve E şeklinde 5 üyeden oluşan bir veri grubu olsun. Bu gruptaki mesafeyi Öklid Mesafesi ile hesaplayarak, A ve B ile C ve D birbirine en yakın, E ise en uzak olduğunu varsayıyalım. Bu durumda Şekil 2.13.'teki gibi bir grafik elde edilecektir. Birbirine yakın üyeler önce gruplanmış ve en uzaktaki üye grubu en son katılmıştır (Seker, 2012).



Şekil 2.13. Grup Dağılımı ve Dendogram Grafiği (Seker, 2012)

Filo halinde gelen veriler zaman ekseninde aynı hızada olmadığı durumlarda ön işleme yöntemleri kullanılabilir. DTW, zaman serisi analizinde, zaman serisini temsil eden bir diziyi hizalayan başarılı bir algoritmadır. Amaç, minimum toplam mesafeye sahip X ve Y dizilerinin bir hizalamasını bulmaktır. X ve Y arasındaki benzerlik daha sonra şu şekilde ifade edilir (Hendrickx vd., 2019): Filo yönetiminde veriler zaman bakımından aynı hızada olmadığı durumlarda ön işleme yöntemlerine ihtiyaç duyulmaktadır. DTW zaman serisini temsil eden bir diziyi hizalayan kullanışlı bir algoritma olduğundan, zaman serisi


analizlerinde oldukça kolaylık sağlar. X ve Y dizilerindeki benzerlik Eşitlik 2.10'daki gibi gösterilir. Buradaki amaç minumum toplam mesafede X ve Y dizilerini hizalamaktır (Hendrickx vd., 2019).

$$s(x, y) = \sqrt{\sum_{i=1}^L c(x_{i0}, y_{i1})^2} \quad (2.10)$$

Bu alanda yapılan çalışmalara katkı sağlamak ve mevcut çalışmaları genişleterek filo yönetimine önem kazandırılması hedeflenmektedir.

2.4. Veri Setleri

Bu bölümde literatürde uygulama için kullanılan veri setleri aktarılmıştır. Ağırlıklı olarak PHM Challenge veri setleri kullanılmıştır. Çizelge 2.3'te geçmiş yıllara ait PHM yayınları için görev tanımları gösterilmiştir. Şekil 2.14.'te de PHM yayınlarının hangi kategorilere ait olduğu gösterilmektedir.



Şekil 2.14. PHM Araştırma Grupları (Jia vd., 2018)

Çizelge 2.3 PHM 2008-2017 Veri Araştırma Görevleri (Jia vd., 2018)


Kuruluş - Yıl	Sistem	Tasks
PHMS2015	Enerji Santrali	Denetimli arıza tespiti ve teşhis
PHMS2017	Boji	Denetimli arıza tespiti ve teşhis
PHMS2016	Yarı İletken CMP	Sanal Ölçüm
PHMS2014	Bilinmeyen	Denetimli risk değerlendirmesi ve arıza tespiti
IEEE2014	Yakıt Pilleri	Belirti ve sağlık değerlendirmesi
PHMS2013	Bilinmeyen	Denetimli arıza tespiti ve teşhis
PHMS2012	Rulman	Belirti
PHMS2011	Anemometre	Denetimsiz arıza tespiti ve teşhis
PHMS2010	Freze Makinesi	Belirti
PHMS2009	Bilinmeyen	Denetimsiz arıza tespiti ve teşhis
PHMS2008	Uçak	Belirti

2.4.1. PHM 2012 Data Challenge

PHM 2012 Data Challenge; PRONOSTIA platformuyla oluşturulmuş, motor ve rulman arızaları için prognostik yaklaşımları test etmek amacıyla toplanmış bir veri setidir. “PRONOSTIA, rulmanların hata tespiti, teşhis ve prognostik yaklaşımlarını test etmek ve doğrulamak için tahsis edilmiş bir deney platformudur”. FEMTO-ST2 enstitüsünün AS2M1 bölümünde tasarlanmış platform, bilya yataklarının çalışma ömürleri boyunca bozulmasını karakterize eden deneysel verileri oluşturur. Rulman için bozulmaları hızlı bir şekilde gerçekleştirmeyi sağlar. Bu sayede kısa süre içerisinde çok fazla sayıda test yaparak veri toplamak mümkündür (Nectoux vd., 2012).

Şekil 2.15.’te görünen bu test platformunda bir test yatağı üzerinde 250 W gücündeki bir motordan, dişli kutusu (Gearbox) aracılıyla motor belirli RPM dönüş hızlarına çıkartılarak çeşitli rulmanlar test işlemine tabi tutulmuştur. Shaft üzerine monte

edilen rulmanlar alüminyum plakalar arasında üzerlerine yerleştirilen 90 derece aralıklı ivmeölçerler, thermocouple, sıcaklık sensörü ve güç sensörlü bulunmaktadır. Motora yük silindir basınçlı bir apartla verilmektedir.




Şekil 2.15. PHM 2012 Data Challenge Pronostia Test Platformu (Challenge, 2012)

17 adet ayrı rulmandan 3 çeşit operasyon şartı altında veri toplanmıştır. Bunlar motorun dönme hızı RPM ve rulmana uygulanan güç değerleri olup şu şekildedir; 1800 RPM - 4000N, 1650 RPM - 4200 N ve 1500 RPM – 5000N. Titreşim sinyalleri, dikey ve yatay ivmeölçerler ile 25,6 kHz de her 10 sn de bir 0,1 sn uzunluğunda toplanıp kaydedilmiştir. Sıcaklık değeri bir thermocouple aracılığıyla 10Hz örneklemeyle her dakikadaa 600 örnek şeklinde kaydedilmiştir (Challenge, 2012).

2.4.2. PHM 2018 Data Challenge

PHM 2018 Data Challenge; Ion Mill Etch Tool – Devre levhası üreten bir iyon dejirmeni gravür aletindeki hataları tahmin etmek için toplanmış veri setidir. Bu veri seti, bir devre levhası imalat işleminde kullanılan bir iyon dejirmeni aşındırma aracının hata davranışını incelemektedir. Bu sistemde, akış soğutucu ve iyon dejirmen odaları arasındaki elektrik kaçağı, elektrik şebekesi aşınması, iyon odası aşınması vb. özellikleri sağlamaktadır. Bu arızaların nerede ve ne zaman olacağını tahmin etmek ve bu iyon dejirmenlerinin arıza sürelerini bakım işlemleri için planlamak faydalı olacaktır. Şekil 2.16.'da bu iyon dejirmeni şeması görülmektedir. Beş farklı araç için sensörlerden 24 farklı veri alıp bu üç hata durumunu çıkartmaktadır: soğutma sistemi ile ilgili basınç düşüşü, çok yüksek kontrol soğutma pompası basıncı ve sızıntı. Alınan hata verileri dörder saniyelik zaman periyotları ile gelmektedir. Bir araç için 1.713.515 satır veri bulunmaktadır.

Toplamda 6.854.060 saniyelik (114.234 dk) zaman periyodunda veri toplanmış bulunmaktadır (Challenge, 2018).




Şekil 2.16. PHM 2018 Data Challenge Devre Levhası Üreten Bir İyon Değirmeni (Challenge, 2018)

2.4.3. IMS Bearing Data

IMS Bearing Veri seti Cincinnati Üniversitesi Akıllı İmalat Sistemleri (Intelligent Manufacturing Systems) tarafından sağlanmış rulman deneyleridir. Bir şaft üzerine dört rulman monte edilmiştir. Dönme hızı, sürtünme kayışları aracılığıyla mile bağlanan bir AC motor tarafından 2000 RPM'de sabit tutulmuştur. Şafta ve yatağa bir yay mekanizması ile 6000 lbs radyal yük uygulanır. Rexnord ZA-2115 çift sıralı rulmanlar Şekil 2.17.'de gösterildiği gibi şafta monte edilmiştir. (Kuvars İvmeölçer (ICP) ivmeölçerleri, birinci veri seti için yatak muhafazasına, her rulman için iki ivmeölçer; x- ve y-ekseni, ikinci ve üçüncü veri setleri için her yatak için bir ivmeölçer).

Veri paketine üç veri seti dahil edilmiştir. Her veri kümesi bir test-hata verisi vardır. Her veri seti, belirli aralıklarla kaydedilen bir saniyelik titreşim sinyali anlık görüntüleri olan ayrı dosyalardan oluşur. Her dosya 20.480 noktadan oluşur ve örneklemeye hızı 20 kHz olarak ayarlanır (Lee vd., 2007).



Şekil 2.17. IMS Bearing Test Platformu (Lee vd., 2007)

2.4.4. PHM 2009 Data Challenge

PHM 2009 Data Challenge; ivmeölçer verilerini ve yatak geometrisi hakkında bilgileri kullanarak genel bir şanzıman için arıza tespiti ve büyülüklük tahmini için toplanmış veri setidir. Şekil 2.18.'de gösterildiği gibi iki geometrili; biri düz dişliler, diğer螺旋 kesimli (helisel) dişliler kullanılır. Mahmuz geometrisi:

- * Giriş mili: 1-Giriş Pinyon: 32 diş
- * Avara mili: 1. avara dişlisi: 96 diş
- * Avara mili: 2. (çıkış) avara dişlisi: 48 diş
- * Çıkış mili: çıkış dişlisi: 80 diş

Girişten çıkışa dişli redüksiyon oranı: $16/48 * 24/40$ veya 5'e 1 redüksiyon. Endevco 10mv / g Hızlanma,


$\pm\% 1$ hata, Rezonans > 45 KHz.

Üç Kanal:

- * Kanal 1, giriş tarafı Ivmeölçerdir
- * Kanal 2 çıkış tarafı Ivmeölçerdir
- * Kanal 3, Takometre Sinyali: Devir başına 10 darbe

Örneklemme Hızı: 66,666,67 Saniyede Örnek (200 KHz / 3).

Veriler, hem giriş hem de çıkış mili tespit plakalarına monte edilen ivmeölçerlerden senkronize olarak örneklenmiştir. Takılı bir takometre, çok hassas sıfır geçiş bilgisi sağlayan devir başına on darbe üretir. Veriler yüksek ve düşük yükleme altında 30, 35, 40, 45 ve 50 Hz şaft hızında toplanmıştır. Buna ek olarak, çalışma süresi ve yük önemli hata iletmesini indüklemek için yeterli olmamasına rağmen, verilere farklı tekrarlanan çalışmalar dahil edilmiştir. Sınıflandırılacak toplam 560 örnek vardır (Challenge, 2009).



Şekil 2.18. PHM 2009 Data Challenge Dişli Kutusu (Challenge, 2009)


3. MATERİYAL VE YÖNTEM

Bu çalışmada önerilen veri odaklı hata teşhis yöntemi, benzer özellikte rulman veya makinelerden oluşan; titreşim, sıcaklık ve basınç tiplerinde veri üreten, bir sisteme uyarlanması üzere tasarlanmıştır. Bu yöntem; CNC vb. makine ve rulmanlardan gelen verilerin işlenmesine uygun bir yaklaşımdır. Sistemdeki tüm makinelerin anlık olarak izlenmesi ve olası anomali durumlarının grafiksel olarak gösterilmesine ihtiyaç vardır. Bu ihtiyaçların karşılanması için filo tabanlı izleme sistemi önerilmektedir.

3.1. Materyal

Uygulama bloklar halinde tasarlanmıştır. Her bir bloğun çıktısı grafikleştirilerek görsel dinamiklik sağlanmıştır. Bu sistem; C# ile MVC uygulaması ile hazırlanmıştır. Sistem geçmişe yönelik veri setleriyle beslenecek şekilde hazırlanmış ancak uyarlama yapılarak anlık veri ile çalışacak hale getirilebilir. Sistemde kullanılan formül ve algoritmalar tüm veri setlerine uygulanarak her blok için çıktı oluşturacak duruma getirilmiştir. Bloklar birbirini besler niteliktedir. Grafik gösterimleri için (Data DrivenDocument, D3.js) kullanılmıştır (D3, 2020). Grafik beslemeleri için de (JavaScript ObjectNotation, JSON) ve CSV (Comma Separated Values) dosyaları oluşturulmuştur. Sistem dört ayrı veri setindeki titreşim, basınç düşüşü, aşırı basınç, basınç sızıntısı ve sıcaklık parametreleri için ayrı ayrı çalıştırılmış ve her bloktaki çalışmalar gözlemlenmiştir.

Şekil 3.1.'de arayüzü gösterilen uygulama içerisinde çok katmanlı bir yapı oluşturulmuştur. Service katmanında verilerle ile ilgili işlemler, dosya analizleri ve grafik için dosya oluşturma, algoritma türetme ve formül uyarlama, benzerlik, karşılaştırma, anomali puanı oluşturma gibi fonksiyonlar tanımlanmıştır. Controller katmanında ise service katmanında yazılan kodlar çağrılarak sistemin web üzerinden çalıştırılması sağlanmıştır. Son olarak view katmanında verileri oluşturulan grafiklerin D3.js ile görselleştirilmesi sağlanmıştır. Bu grafiklerden anlık olarak tüm sistemin takibi yapılmaktadır (D3, 2020).



Şekil 3.1. Uygulama Web Arayüzü


3.2. Yöntem

Filo tabanlı hata teşhis sistemi için önerilen yöntemin genel akış diyagramı Şekil 3.2.’de görülmektedir. Yöntem; veri ön işleme, karşılaştırma, kümeleme ve hata tespiti üzere dört temel adımdan oluşmaktadır. Şekil 3.3.’te aktarılan bloklar gösterilmiştir.


Bu bölümde uygulama bloklarında yapılan işlemler anlatılmıştır.

Veri ön işleme adımda; okunan, sıcaklık, titreşim ve basınç verileri, zaman alanında grafiksel olarak gösterilir. Veriler ortalamaları alınarak grafikte hangi bölgelerde olduğu belirtilir. Frekans alanında incelemek amacıyla zaman alanı sinyali, FFT ile frekans alanına dönüştürülür, 0-1 normalizasyonu ve 300 Hz üzeri sinyaller atılarak, anlık değerler düzelttilir. FFT çıktısı frekans grafiği olarak gösterilir. Titreşim verisi için DTW uygulanarak frekans alanındaki sinyaller karşılaştırılır. DTW sinyali grafiksel olarak gösterilir.

Filodaki üye çiftlerinin X ve Y eksenlerinde nasıl karşılaşılacağına karar vermek ilk adımdır. Karşılaştırmak için ilk olarak makine veya araçtan alınan veriler istenilen sinyal alanına dönüştürülür. Daha sonra filo üyeleri bu sinyal alanlarında karşılaşılır.



Şekil 3.2. Uygulama Akış Diagramı



Filodaki üye bir makineye eğer, makineden ilgili veriler anlık ölçümleri yakalayan sensörler ya da makine istemcilerine bağlı olarak çalışan MT Connect ile alınmaktadır (Yılmaz ve Gürel, 2019). Alınan ham verileri başka bir sinyal alanına dönüştürmek veriler üzerinde işlem yapmayı kolaylaştırmaktadır. Bu veriler farklı alanlara dönüştürülebilir. Bunlar zaman, frekans, zaman/frekans ve özellik alanlarıdır.

Verileri frekans alanında incelemek, zaman alanında incelemekten daha kullanışlıdır. Zaman alanındaki bir sinyali frekans alanına dönüştürmek için FFT kullanılabilir.

Her filo üyesi, ardışık olarak elde edilen FFT dizileri ile temsil edilir. Uygulamada, veriler frekans ölçegine dönüştürülür ve her üye için benzer bir değer aralığına sahip olması için min / maks ölçeklcmc FFT kullanılarak normalleştirilir. Düşük frckanstaki alçak geçiren filtre, alakasız yüksek frekans içeriğini kaldırır.

Titreşim gibi yüksek frekanslarda değişim gösterebilecek özellikleri barındıran verilerde zaman uyuşmazlığı etkisini azaltmak için DTW (Eşitlik 2.10) ve frekans alanı dönüşümü tercih edilebilir. Toplanan verilerin hızı değişkenlik gösterdiğinde DTW, spektrumları en uygun şekilde hizalayacaktır. Bu durumda veri, boyutları ve bölme sayısındaki sıklıkları eşit olan zaman serileri olarak kabul edilebilir.

Karşılaştırma adımda; Manhattan, Öklid, Kare Öklid ve Maksimum Benzerlik metrikleri kullanılarak filo üye çiftleri arasında benzemezlik bulunur ve benzemezlik matrisi oluşturulur. Benzemezlik matrisinden yola çıkılarak ikili üye çiftleri halinde dendogram grafiği çizdirilir.

Verileri karşılaştırmak için benzemezlik ölçülerini bilmek gerekmektedir. Böylece benzemezlik oranları bulunabilir. Elde edilen veriler arasındaki benzemezliği bulmak için kullanılan alternatif yöntemler arasında Bölüm 2'de bahsedilen metriklerden Öklid Mesafesi, Kare Öklid Mesafesi, Menhattan ve Maksimum Benzerlik Metriği bulunmaktadır.

Elde edilen veriler sıralı çiftler halinde 1'den n 'e kadar tek tek karşılaştırılır ve filodaki tüm üyelerin birbirleri ile benzemezlik (dissimilarity) matrisi oluşturulur. İki üye arasındaki benzemezlik oranı 0 ile 1 arasında bir değer almaktadır. Benzemezlik oranı sıfıra ne kadar yakınsa iki üye o kadar benzerdir denilir. Aynı filo üyelerinin benzemezlik değeri sıfırı göstermektedir.

Kümeleme adımda benzemezlik oranları bulunan filo üyeleri hiyerarşik olarak kümelenir, benzer olan üyeler aynı kümede toplanır. Oluşan kümeleme sonucunda, kümedeki üye sayısına göre anomali puanları hesaplanır.

Benzer davranışları üyeleri grublamak için kümeleme algoritmaları kullanır. Kümeleme, üyeleri ikişerli olarak, seçilen iki eksende (X, Y) karşılaştırmak için bir kümeleme algoritması kullanarak, benzer şekilde davranışları aynı grup içinde tanımlar.

Kümeleme için benzerlik bloğundan elden edilen benzemezlik matrisi kullanılır. Bir küme içerisinde ne kadar çok üye varsa, doğruluğu o kadar yüksektir.

Bu çalışmada kümeleme algoritmasında kullanılan yöntem hiyerarşik kümeleme yöntemidir. Kütle Merkezi (Centroid) tabanlı algoritmalar hiyerarşik kümeleme yöntemine göre daha etkili olabilir ancak başlangıç koşullarına ve anlık değişimlere karşı duyarlı olabilmektedir. Yoğunluk tabanlı kümeleme, değişen yoğunluklara ve yüksek boyutlara sahip verilerle çalışırken güçlük çekmektedir. Dağıtım tabanlı kümeleme ise, ancak verilerin dağıtım türü biliniyorsa kullanılabilir. Diğer taraftan hiyerarşik kümelemede küme sayısını önceden belirlemeye gerek yoktur. Tüm bu durumlar göz önünde bulundurulduğunda, kümeleme algoritması için hiyerarşik kümeleme seçilmiştir.

Hyerarşik kümelemede kümeler hiyerarşisi oluşturulur. Bu hiyerarşî yaygın olarak aşağıdan yukarı ya da yukarıdan aşağıya da yapılmaktadır. Hiyerarşî yaklaşımı, her bir öğeyi kendi alt kümese atar ve bir kümeye kalana kadar en yakın ya da en benzer iki alt kümeyi yinelemeli olarak birleştirir. Alt kümeler arasındaki mesafeyi ölçek kümeleme parametresi olarak kullanılmaktadır. Alt kümelerin öğeleri arasındaki minimum mesafeyi kullanan tek bağlantı ve öğeleri arasındaki maksimum mesafeyi kullanan tam bağlantı, kullanılan iki yaygın seçenektedir.

Hata tespiti adımda ise anomali puanlarına göre hata olma ihtimali bulunan filo üyeleri gösterilir.

Sistemdeki üyelerde anomali skoru atamak için oluşturulan kümeler kullanılır. Benzer davranışa sahip üyelerin aynı kümeye olması beklenir ve bir kümeye üye sayısının büyülüklüğü, sağlıklı davranış gösterme olasılığı ile doğru orantılıdır. Üyelerin anomali puanını bulmak için; kendi kümese olmayan üyelerin toplam üyelere oranı hesaplanır. Bu sebeple arıza ihtimali yüksek üyelerin anomali puanı bire yakındır. Her üyeyi sağlıklı veya arızalı olarak sınıflandırmak için 0 ile 1 arasındaki bu puanı eşleştirmek, filonun büyülüklüğü ve hatalı üyelerin beklenen oranın hakkında bilgi vermektedir.

Filodaki üyeler pencerelerden elde edilen bir dizi FFT spektrumu ile gösterilir. Günlük ölçüye dönüştürülen veriler, her bir üye benzer değer aralığına sahip olması için, min-max ölçeklendirme FFT'yi kullanarak normalleştirir. 300 Hz'de alçak geçiren filtre alakasız yüksek frekans içeriğini kaldırır.

Aktarma sisteminin hızı dalgalandığı durumda, öklid mesafesine göre farklılık ölçüsü olarak DTW spektrumları en uygun şekilde hizalayacaktır. Bu durumda veriler n adet frekans

bölümü olan, n boyutlu zaman serileri olarak kabul edilir. Kullanıma göre istenirse farklı ağırlıklara sahip olabilse de, frekans bölmelerinin her bir bölümü eşit ağırlıktadır.

Her bloğun sonuçlarını görselleştirmek, üyenin sağlık koşulları ve uygulamanın tahminleri hakkında fikir verebilir. Basit bir görselleştirme ile her bloğun sonuçları gösterilir. Filo yönetiminde zaman ve frekans alanı sinyalleri, DTW sinyalleri, benzemezlik matrisi, dendogram grafiği, nokta grafiği, kümeleme grafiği görselleştirme için güçlü araçlardır.

Bu yöntemde her bir bloktaki veriler görselleştirilerek alan uzmanlığına gerek kalmadan arıza gözlemlenebilir ve uyarılar oluşturulabilir. Büyük veri setine ihtiyaç duyulmadığından yaklaşık 10 dakikalık aralıklarla toplanan veriler ile etkili bir analiz, her bir makine için anlık olarak yapılabilir.

Arayüzde görülen source alanında oluşturulan veri setleri (PHM 2012 titreşim, PHM 2012 sıcaklık, PHM2018 basınç düşüşü, PHM 2018 soğutma pompası basıncı, PHM 2018 sızıntı, IMS titreşim, PHM 2009 titreşim) listelenmektedir. Distance measure alanında ise, karşılaştırma için kullanılacak metrikler (Öklid, Kare Öklid, Menhattan, Maximum) listelenmiştir. Calculate butonu ile ilgili alanlardaki seçimlere göre, seçilen veri setine, seçilen metriğe göre filo yönetimi uygulanmaktadır ve grafikler hazırlanmaktadır. İşlem sonucunda şekilde görülen bağlantılar ile ilgili grafiklere erişilebilir. Point Graph nokta grafiği bağlantısı, Signal Raw, ham veri sinyal grafiği, Signal FFT (uygulanmışsa) FFT çıktısı grafiği, Signal DTW (uygulanmışsa) DTW çıktısı grafiği, Matrix seçilen mesafe metriğine göre oluşturulan benzemezlik matrisi grafiği, Dendrogram oluşturulan ağaç grafiği, Cluster, kümeleme ve anomali puanları için oluşturulan grafik bağlantılarıdır.

4. BULGULAR VE TARTIŞMA

Önerilen yöntem PHM 2009, PHM2012, PHM2018 ve IMS veri setlerine uygulanmış ve anomali sonuçları alınmıştır. Bu bölümde tüm veri setleri için alınan sonuçlar açıklanmıştır.

4.1. Uygulamada Kullanılan Veri Setleri

PHM 2012 Data Challenge veri seti; Pronostia Platformundan, motor ve rulman arızaları için prognostik yaklaşımı test etmek amacıyla toplanmış bir veri setidir. Bu setteki 17 rulman için titreşim ve sıcaklık sensörlerinden alınan veriler önerilen yöntemle incelenmiştir. Veri setindeki her bir rulman, bir makine filosu içerisinde farklı makinelerden gelen bir makine bileşeni olarak da düşünülebilir. Veri seti için rulman isimlendirmeleri Bearing ile başlatılıp çalışma koşuluna Bearing_1_4 gibi göre numaralandırılmıştır.

Titreşim verileri için 17 rulman verisinden 14'ünün birbirine yakın zamanlardaki kısımları alınmıştır. B_1_4, B_3_3, ve B_2_7 rulmanlarından ise daha sonraki zamanlarda veri parçaları alınmıştır. Her bir rulmandan 40 milisaniye aralıklarda 2.500 veri alınmıştır.

Bu setteki her bir rulman ivme değeri 20 g'yi geçikten sonra arızalı olarak kabul edilip, RUL değerleri de veri seti dökümanlarında bildirilmiştir.

Veri setinin dosya organizasyonu: CSV dosyaları halinde kaydedilen veri setleri her bir sütuna titreşim verisi için [saat, dakika, saniye, microsaniye, yatay ivme değeri, dikey ivme değeri] şeklinde organize edilip kaydedilmiştir. Sıcaklık değeri ise [Saat, Dakika, Saniye, 0.x sn, Sıcaklık değeri] olarak kaydedilmiştir.

Filo yönetimine adapte edilebilir senaryo: Aynı şartlar altında ve aynı zaman diliminde çalıştırılan, birbirinden bağımsız 17 adet rulmandan alınmış titreşim ve sıcaklık verileri değerlendirilebilir böylece ilk arıza göstermeye başlayan rulmanın anomali/arıza skoru diğerlerine göre çok daha fazla olarak çıkacaktır. Örneğin bu veri setinde 1. çalışma koşulunda çalışan 7 adet rulman, 2. çalışma koşulunda çalışan 7 adet rulman bulunmaktadır (Challenge, 2012).

IMS Bearing Data Rulman deneyleri veri seti; Cincinnati Üniversitesi Akıllı İmalat Sistemleri (Intelligent Manufacturing Systems - IMS) tarafından sağlanmıştır. 4 rulman için 20 KHz örneklemme hızında setler oluşturulmuştur. Veriler rulman tanımından Bearing olarak adlandırılmış ve yerlestiği yere göre isimlendirilmiştir. Burada B_1_4 gibi kısaltma kullanılmıştır. 4 rulman için aynı çalışma koşullarından B_1_4, B_1_5 ve B_1_6 aynı zaman aralığından, B_1_7 ise farklı zaman aralığından 2.500 örnek alınarak uygulamaya girdi olarak sağlanmıştır.

Tüm arızalar, yatağın 100 milyon devirden fazla olan kullanım ömrünü aşından sonra meydana gelmiştir.

Veri setinin dosya organizasyonu: Veri dosyasındaki her kayıt (satır) bir veri noktasıdır. Daha büyük zaman damgaları aralıkları dosya adlarında gösterilir, deneyin bir sonraki iş gününde yeniden başlatılmasını gösterir. Örneğin veri seti 1'de 4 rulman için x ve y eksenlerindeki titreşim değerleri gösterilmiştir. [Bearing 1 – Ch 1&2, Bearing 2 – Ch 3&4, Bearing 3 – Ch 5&6, Bearing 4 – Ch 7&8.]

Filo yönetimine adapte edilebilir senaryo: Bir veri seti içerisindeki titreşim verileri 4 rulman için karşılaştırılarak anomali puanları tespit edilebilir (Lee vd., 2007).

PHM 2009 Data Challenge Veri Seti; ivmeölçer verilerini ve yatak geometrisi hakkında bilgileri kullanarak genel bir şanzıman için arıza tespiti ve büyülüklük tahminidir. Farklı zamanlarda çalıştırılan setler ile 30 Hz, düşük yük ve Spur dişli tipi ile çalıştırılmış 14,428, 431,490 setleri ile farklı çalışma koşullarında sistemin tepkisini test amaçlı farklı frekans ve yükteki 376 çalışmaları uygulamaya dahil edilmiştir.

İvmeölçer verilerinin değerlerine Fourier dönüşümü uygulanması tavsiye edilmiştir. DTW işlemine tabi tutularak hassas sonuçlar elde edilebilir.

Veri setinin dosya organizasyonu: CSV dosyaları halinde kaydedilen veri setleri her bir sütuna titreşim verisi için [giriş voltajı, çıkış voltajı, takometre.] şeklinde organize edilip kaydedilmiştir.

Filo yönetimine adapte edilebilir senaryo: Farklı Hz değerleri için 560 defa çalıştırılmış veriler mevcuttur. Aynı Hz, yük ve tip değerleri için farklı çalışmalar alınarak bir filo oluşturulup karşılaştırma yapılabilir (Challenge, 2009).

PHM 2018 Data Challenge; Ion Mill Etch Tool – Devre levhası üreten bir iyon dejirmeni gravür aletindeki hataları tahmin etmek için toplanmış veri setidir. Bu veri seti

üzerinden alınan parçalar sisteme uyarlanmış ve aynı koşullarda çalışan 5 farklı araç için soğutma pompası üzerinden soğutma sistemi ile ilgili basınç düşüşü, çok yüksek kontrol soğutma pompası basıncı ve sızıntı verisi alınmıştır. Tek bir bölge üzerinde 3 veri de yanyana gösterilmektedir. Kolon numaları sisteme tanıtılarak 3 veri üzerinden de analizler gerçekleştirılmıştır. Bu araçlar üzerinden alınan veriler de tek bir özellik içerdiginden DTW uygulanmamış, ön işleme için FFT ile 0-1 normalizasyonu yapılmıştır. Veriler aracın yerine göre isimlendirilmiş ve burada kısaltma ile gösterilmiştir. T_1_4 gibi.

Veri setinde 24 farklı veri üzerinde işlem yapılarak 3 adet arıza durumu ortaya çıkarılmıştır. Bu arıza değerleri için alınan basınç verilerinin zamanla düşüğü gözlemlenmiştir. Veri alınamadığı andan itibaren aracın arıza durumuna geçtiği görülmüştür.

Veri setinin dosya organizasyonu: CSV dosyaları halinde kaydedilen hata veri setleri her bir sütuna [zaman, soğutma sistemi basınç düşüşü, soğutma sistemi çok yüksek kontrol soğutma pompası basıncı, soğutma sistemi sızıntı] şeklinde organize edilip kaydedilmiştir. Her rulman için farklı dosyalar halinde kaydedilmiştir.


Filo yönetimine adapte edilebilir senaryo: 5 rulman için farklı zamanlarda alınan veri parçaları için veri blokları oluşturularak gruplama yapılabilir. Daha ileri zamanlardan alınan verilerin bozulma gösterdiği gözlenebilir (Challenge, 2018).

4.1.1. Titreşim verisi tabanlı filo yönetimi ile hata tespiti


PHM 2012 Data Challenge veri setinden, uygulama blok diyagramındaki veri bloğunda gösterilen, uygulamaya aktarılan titreşim verileri ile sonuçlar alınmış ve grafiksel olarak gösterilmiştir. Şekil 4.1.'de bir rulman için, ham titreşim verilerinin zaman alanı üzerinde, tepe değerleri ve verinin zamana göre akışı gösterilmiştir.

Şekil 4.2.'de zaman alanındaki titreşim sinyaline FFT uygulanarak sinyal frekanslarına çevrilmiş ve 0-1 min/max normalizasyonu sağlanmıştır. Kesim frekansı da 300 Hz olarak belirlenmiş ve bunun üzerindeki sinyaller atılmıştır.


FFT'den üretilen frekans alanındaki verilere DTW işlemi uygulanarak Şekil 4.3.'deki sinyal alınmıştır.



Şekil 4.1. PHM12 Titreşim Zaman Alanı Sinyali (X : Zaman ve Y : Titreşim Eksenleridir)



Şekil 4.2. PHM12 Titreşim FFT Frekans Alanı Sinyali (X : Frekans ve Y : Genlik Eksenleridir)



Şekil 4.3. PHM12 Titreşim DTW Sinyali


Karşılaştırma bloğunda DTW sinyali üzerinden makine çiftleri ikili olarak mesafe hesaplanarak, çeşitli mesafe metrikleri ile (öklid, kare öklid, manhattan, maximum) Şekil 4.4.'teki benzemezlik matrisi bulunmuştur. Benzemezlik oranı 0,5 ve altı olduğunda iki makine benzer varsayılmıştır. Burada 0,5 altındaki değerler yeşil renk ile işaretlenerek benzer makine çiftleri gösterilmiştir. Şekil 4.4.'teki matriste görüldüğü üzere; B_1_4, B_3_3 ve B_2_7 rulmanları diğer rulmanlara benzemezlik oranları daha yüksektir. Diğer hiçbir rulmanla benzemezlik oranı 0,5 değerinin altında olmadığı için yeşil bölgesi yoktur.

	B_1_3	B_1_4	B_1_5	B_1_6	B_1_7	B_2_3	B_2_4	B_2_5	B_2_6	B_2_7	B_3_3	B_1_1	B_1_2	B_2_1	B_2_2	B_3_1	B_3_2
B_1_3	0	0.5155	0.2801	0.3066	0.2979	0.2680	0.2579	0.2643	0.2676	0.6571	0.9740	0.3205	0.3287	0.2578	0.2647	0.2879	0.2742
B_1_4	0.5155	0	0.5136	0.5087	0.5131	0.5193	0.5205	0.5179	0.5172	0.6451	0.5170	0.5059	0.5064	0.5284	0.5174	0.5148	0.5159
B_1_5	0.2801	0.5136	0	0.2981	0.2946	0.2737	0.2597	0.2664	0.2622	0.6582	0.9720	0.3226	0.3130	0.2653	0.2629	0.2861	0.2749
B_1_6	0.3066	0.5087	0.2981	0	0.3157	0.3033	0.2944	0.2983	0.2943	0.6554	0.9549	0.3371	0.3333	0.2956	0.2901	0.3127	0.3017
B_1_7	0.2979	0.5131	0.2946	0.3157	0	0.2866	0.2827	0.2888	0.2822	0.6566	0.9610	0.3334	0.3336	0.2868	0.2813	0.3054	0.2916
B_2_3	0.2680	0.5193	0.2737	0.3033	0.2866	0	0.2454	0.2514	0.2552	0.6589	0.9903	0.3167	0.3179	0.2365	0.2579	0.2754	0.2630
B_2_4	0.2579	0.5205	0.2597	0.2944	0.2827	0.2454	0	0.2394	0.2421	0.6605	0.9989	0.3162	0.3131	0.2213	0.2364	0.2680	0.2521
B_2_5	0.2643	0.5179	0.2664	0.2983	0.2888	0.2514	0.2394	0	0.2489	0.6600	0.9902	0.3106	0.3151	0.2378	0.2487	0.2757	0.2547
B_2_6	0.2676	0.5172	0.2622	0.2943	0.2822	0.2552	0.2421	0.2489	0	0.6596	0.9828	0.3147	0.3090	0.2401	0.2435	0.2775	0.2596
B_2_7	0.6571	0.6451	0.6582	0.6554	0.6566	0.6589	0.6605	0.6600	0.6596	0	0.6464	0.6534	0.6528	0.6642	0.6600	0.6573	0.6589
B_3_3	0.9740	0.5170	0.9720	0.9549	0.9610	0.9903	0.9989	0.9902	0.9828	0.6464	0	0.9434	0.9471	0.5066	0.9874	0.9787	0.9816
B_1_1	0.3205	0.5059	0.3226	0.3371	0.3334	0.3167	0.3162	0.3106	0.3147	0.6534	0.9434	0	0.3453	0.3285	0.3151	0.3232	0.3147
B_1_2	0.3287	0.5064	0.3130	0.3333	0.3336	0.3179	0.3131	0.3151	0.3090	0.6528	0.9471	0.3453	0	0.3320	0.3119	0.3310	0.3212
B_2_1	0.2578	0.5284	0.2653	0.2956	0.2868	0.2365	0.2213	0.2378	0.2401	0.6642	0.5066	0.3285	0.3320	0	0.2294	0.2734	0.2532
B_2_2	0.2647	0.5174	0.2629	0.2901	0.2813	0.2579	0.2364	0.2487	0.2435	0.6600	0.9874	0.3151	0.3119	0.2294	0	0.2755	0.2553
B_3_1	0.2879	0.5148	0.2861	0.3127	0.3054	0.2754	0.2680	0.2757	0.2775	0.6573	0.9787	0.3232	0.3310	0.2734	0.2755	0	0.2745
B_3_2	0.2742	0.5159	0.2749	0.3017	0.2916	0.2630	0.2521	0.2547	0.2596	0.6589	0.9816	0.3147	0.3212	0.2532	0.2553	0.2745	0

Şekil 4.4. PHM12 Titreşim Benzemezlik Matrisi


Rulmanların X ve Y düzlemi üzerinde konumunu göstermek amacıyla, nokta grafiği makinelerin titreşim verilerinin ham değerleri ile oluşturulur. Her bir rulman için gelen tüm değerlerin ortalaması alınarak Şekil 4.5.'teki gibi gösterilmektedir. Rulmanların durumlarına göre grafik üzerinde yerleri belirlenmiş ve oluşan filoda farklılık gösteren rulmanlar farklı bölgelerde konumlanmıştır. İşlemler sonucunda benzemezlik oranları farklı olduğu tespit edilen üç rulmanın (B_1_4, B_3_3 ve B_2_7) bu grafikte farklı bölgelerde olduğu görülmektedir. Ancak ham veriler üzerinde işlem yapıldığından, anlık değişimler gibi sebeplerden dolayı sonuçlar güvenilir olmayıabilir. Bu grafik sadece karşılaştırma maksatlı verilmiştir.

İkili makine çiftlerinden benzerliği düşük olandan yüksek olana doğru dendrogram grafiği çizdirilir. Bu işlem için benzemezlik matrisinden faydalananır. Benzemezlik oranı en düşük olandan en yüksek olana doğru ikişerli kümeler belirlenir. Bir makine başka bir makine çiftinin içinde bulunuyorsa, bu yeni makine bu makine çiftine yeni bir değer olarak



Şekil 4.5. PHM12 Titreşim Nokta Grafiği

eklenir. Örneğin Şekil 4.6.'te B_2_1 ve B_2_4 makine çifti oluşturulmuştur ve B_2_2 makinesi de bu ikili çifte yeni bir benzerlik olarak eklenmiştir. Sonrasında gelen B_2_3 ve B_2_5 makineleri de önceki çiftlerle benzerlik gösterdiginden, önceki benzerliklere eklenmiştir. Bu döngü tüm makineler sisteme dahil olana kadar devam etmektedir. Oluşturulan JSON dosyasından beslenecek şekilde D3.js yardımı ile Şekil 4.6.'teki dendogram grafiği çizdirilir (D3, 2020).



Şekil 4.6. PHM12 Titreşim Dendogram Grafiği

Kümeleme bloğunda, benzemezlik matrisi kullanılarak hiyerarşik kümeleme ile kümeler oluşturulmuş ve her bir kümedeki makinenin anomali puanı bulunmuştur. Çizelge 4.1'de bu kümeleme ve anomali puanları görülmektedir.

Çizelge 4.1 PHM12 Titreşim Kümeleme ve Anomali Puanı


Bearing	Cluster	Anomaly Point
B_1_1, B_1_2, B_1_3, B_1_5, B_1_6, B_1_7, B_2_1, B_2_3, B_2_4, B_2_5, B_2_6, B_3_2, B_3_1	0	0,17
B_1_4	1	0,94
B_3_3	2	0,94
B_2_7	3	0,94

Hata tespiti沼ında da, tüm görsel grafikler ve kümeleme sonuçlarında görüleyeceği üzere; yeşil alanda gösterilen rulmanlar 0-17 anomali puanı aynı kümede olduğu gözlemlenmiştir. Mavi alandaki B_1_4, kırmızı alandaki B_3_3 ve sarı alandaki B_2_7 rulmanları 0,94 anomali puanı diğerlerinden farklılık göstermektedir. Bu rulmanlar arızalı kabul edilebilir. Veriler incelendiğinden bu rulmanlar için veri setlerinden alınan parçaların diğerlerine göre farklı zamanlarda alındığı için farklılık olduğu gözlemlenmiştir.


Veriler incelendiğinde de bu üç rulmandaki titreşim değerleri diğer rulman gruplarına göre farklılık göstermektedir. Dolayısıyla kümelemede farklı bir kümede yer almıştır. Genel olarak rulmanlarda aşınmadan dolayı iç yüzükte yıpranma, bilyelerin esnemesi nedeniyle dönme problemleri, yorulma sebebiyle pullanma gibi arıza oluşabilmekte ve bunlar titreşim verisi değerlerine yansiyabilmektedir. Böyle durumlarda aynı çalışma şartlarında hareket ettiği varsayılan bu rulman parçaları anomali durumu gösterdiğinde hata vardır diye kabul edilebilir.

IMS Bearing Veri Setinde rulmandaki ham titreşim verileri, veri沼ında, zaman alanı sinyali olarak Şekil 4.7.'de gösterilmiştir. 3000 saniye süresince gösterilen değerler 0,20 ve -0,40 Acc arasında değiştiği görülmektedir.

Titreşim verisine FFT uygulanarak 0-1 normalizasyonu yapılmış ve 300 Hz üzeri atılmıştır. Şekil 4.8.'de frekans alanındaki grafik görülmektedir. Bu sinyal de 300 Hz'e kadar olan değerler, 0,20 ve -0,25 arasında değişmektedir.



Şekil 4.7. IMS Titreşim Zaman Alanı Sinyali (X : Zaman ve Y : Titreşim Eksenleridir)




Şekil 4.8. IMS Titreşim FFT Frekans Alanı Sinyali (X : Frekans ve Y : Genlik Eksenleridir)

Bu FFT sinyalinden üretilen frekans alanındaki değerlere DTW uygulanmış ve Şekil 4.9.'teki DTW sinyali bulunmuştur.

Karşılaştırma blogunda; DTW üzerinden öklid benzerliği uygulanarak Çizelge 4.2'deki benzemezlik matrisi üretilmiştir. Bu matriste B_1_4, B_1_5 ve B_1_6 rulmanları 0,5 benzemezlik oranının altında olduğundan benzer kabul edilerek yeşil renk ile işaretlenmiştir.

Rulmanlardan alınan titreşim verileri ortalama olarak Şekil 4.10.'daki nokta grafiğinde gösterilmiştir. Ham verilerden alınan ortalama değerlere göre benzerlik gösteren



Şekil 4.9. IMS Titreşim DTW Sinyali


Çizelge 4.2 IMS Titreşim Benzemezlik Matrisi

	B_1_4	B_1_5	B_1_6	B_1_7
B_1_4	0	0,3835	0,4152	0,5697
B_1_5	0,3835	0	0,4182	0,554
B_1_6	0,4152	0,4182	0	0,5884
B_1_7	0,5697	0,554	0,5884	0


B_1_4, B_1_5 ve B_1_6 rulmanları yakın bölgelerde görülmektedir. B_1_7 rulmanı ise daha uzak bir bölgededir.

Benzemezlik matrisinden dendogram grafiği üretilerek Şekil 4.11.'deki gibi hiyerarşik olarak gösterilmiştir. Benzemezliği düşük olan B_1_4 ve B_1_5 rulmanları öncelikli olarak kümelenerek grafiğe eklenmiştir. Daha sonra benzemezliği düşük B_1_6 rulmanı eklenmiştir. Son olarak da benzemezlik oranı en yüksek olan B_1_7 rulmanı eklenerek hiyerarşik dendogram grafiği tamamlanmıştır.

Kümeleme blogunda, Çizelge 4.3'teki kümeleme çizelgesi oluşturulur. Çizelgedeki yeşil alandaki B_1_7, B_1_5 ve B_1_6 rulmanları 0,25 anomalî puanı ve mavi alandaki B_1_7 rulmanı ise 0,75 anomalî puanı ile bağımsız birer kümedir. Hata tespiti blogunda, buradan yola çıkarak anomalî puanı yüksek olan B_1_7 rulmanında hata vardır denilebilir.



Şekil 4.10. IMS Titreşim Nokta Grafiği




Şekil 4.11. IMS Titreşim Dendogram Grafiği

PHM 2009 Data Challenge Veri Setinde, veri blogunda, bir çalışmadan alınan ham verileri zaman alanı sinyali olarak Şekil 4.12.'da gösterilmiştir. 3000 saniye olarak toplanan titreşim verileri 0,018311 ve 4,9475 Acc aralığında ani değişimlerle gerçekleştiği görülmektedir.


Çizelge 4.3 IMS Titreşim Kümeleme ve Anomali Puanı

Bearing	B_1_4	B_1_5	B_1_6	B_1_7
Cluster	0	0	0	1
Anomaly Point	0,25	0,25	0,25	0,75




Şekil 4.12. PHM09 Titreşim Zaman Alanı Sinyali (X : Zaman ve Y : Titreşim Eksenleridir)

Titreşim verisine FFT uygulanarak 0-1 normalizasyonu yapılmış ve Şekil 4.13.'te gösterilmiştir. Normalizasyon grafiği 300 Hz 0,0030518 ve 0,49479406 Acc aralığından anlık değişimlerle gerçekleştiği görülmektedir.



Şekil 4.13. PHM09 Titreşim FFT Frekans Alanı Sinyali (X : Frekans ve Y : Genlik Eksenleridir)

Bu FFT sinyalinden üretilen frekans alanındaki değerlere DTW uygulanmış ve Şekil 4.14.'teki DTW sinyali bulunmuştur.



Şekil 4.14. PHM09 Titreşim DTW Sinyali


Karşılaştırma blogunda; DTW üzerinden öklid benzerliği uygulanarak Çizelge 4.4'teki benzemezlik matrisi üretilmiştir. Burada Run_14, Run_428, Run_431 ve Run_490 daki çalışmalarada rulmanlar 0,5 benzemezlik oranından düşük olduğundan yeşil renk ile belirtilerek benzer olduğu gösterilmiştir.

Çizelge 4.4 PHM09 Titreşim Benzemezlik Matrisi

	Run_14	Run_376	Run_428	Run_431	Run_490
Run_14	0	0,5211	0,5911	0,5903	0,0104
Run_376	0,5211	0	0,5303	0,5497	0,5286
Run_428	0,5911	0,5303	0	0,0122	0,7238
Run_431	0,5903	0,5497	0,0122	0	0,6888
Run_490	0,0104	0,5286	0,7238	0,6888	0

Sanzıman dışlilerindeki titreşim verileri ortalama olarak Şekil 4.15.'te görüldüğü üzere nokta grafiğinde gösterilmiştir. Öncelikli olarak Run_14 ve Run_490 benzerlik oranları en düşük olduğundan ikili küme olarak grafiğe eklenmiştir. Daha sonra kendi içinde benzerliği düşük olan Run_428 ve Run_431 çalışmalarındaki rulmanlar ikili küme olarak grafiğe eklenmiştir. Run_376 çalışmasındaki rulman, Run_14 ve Run_490 kümese

benzemezlik oranı düşük olduğundan o kümeye eklenmiştir. Sonrasında gelen benzemezlik oranı ile diğer kümeye de bağlanmıştır.




Şekil 4.15. PHM09 Titreşim Nokta Grafiği

Bu benzemezlik matrisinden de dendogram grafiği üretilerek Şekil 4.16.'daki gibi hiyerarşik olarak gösterilmiştir.

Kümeleme沼ında, Çizelge 4.5'teki kümeleme çizelgesi oluşturulur. Çizelgede yeşil alandaki Run_14 ve Run_490 çalışmaları ile mavi alandaki Run_428 ve Run_431 çalışmaları bağımsız birer kümedir. Farklı yükte ve frekansta alınan kırmızı alandaki Run_376 ise farklı bir kümedir. Hata tespiti沼unda, birbiri ile aynı anomali puanına sahip ikili rulman çiftlerin hatalı olma ihtimali vardır.

4.1.2. Sıcaklık verisi tabanlı filo yönetimi ile hata tespiti

PHM 2012 Data Challenge Veri setinden, veri沼unda, 9 rulmandan 6 rulman için veriler yakın zaman aralıklarından alınmıştır. B_2_6 ve B_3_3 rulmanları da kendi arasında



Şekil 4.16. PHM09 Titreşim Dendogram Grafiği

Çizelge 4.5 PHM09 Titreşim Kümeleme ve Anomali Puanı

Bearing	Run_14	Run_490	Run_428	Run_431	Run_376
Cluster	0	0	1	1	2
Anomaly Point	0,6	0,6	0,6	0,6	0,8

yakın zamandan, B_2_7 rulmanı içinse daha farklı bir zaman aralığından 2.500 veri 40 milisaniye aralıklarla alınmıştır. Veri setindeki sıcaklık verileri de sisteme uygulanmış ve sonuçlar alınmıştır.


Başlangıçtan itibaren 300 sn'ye kadar sıcaklığının düşüğü ve bir müddet sonra yükselişi görülmektedir. 71.8 C olan başlangıç değeri 71.40 C arasında değiştiği anlaşılmaktadır. Sıcaklık verisi genel anlamda yüksek frekanslı değişen bir sinyal özelliği taşımadığından DTW ön işlemine gerek duyulmamaktadır. Burada yalnızca 0-1 arası normalizasyon yapılmıştır.

Karşılaştırma blogunda, Çizelge 4.6'da ön işleme tabi tutulan verilere benzerlik algoritması (öklid) uygulanarak bulunan benzemezlik matrisi görülmektedir. Yeşil ile gösterilen alanlar benzemezlik oranının 0,5'in altında olanlar, birbirine benzer makineler olarak değerlendirilir. Diğerleri ile bu oranın altında benzerlik göstermeyen B_2_6 ve B_2_7 rulmanları ve sadece bu rulmlara düşük oran gösteren B_3_3 diğerlerine benzemezdir.

Çizelge 4.6 PHM12 Sıcaklık Benzemezlik Matrisi

	B_1_4	B_1_5	B_1_6	B_1_7	B_2_4	B_2_5	B_2_6	B_2_7	B_3_3
B_1_4	0	0,0545	0,3125	0,1275	0,3901	0,2191	0,8155	0,9854	0,869
B_1_5	0,0545	0	0,1585	0,2792	0,5195	0,3721	0,8458	0,9845	0,888
B_1_6	0,3125	0,1585	0	0,5274	0,6848	0,5917	0,8852	0,9827	0,9135
B_1_7	0,1275	0,2792	0,5274	0	0,1484	0,0213	0,7473	0,9866	0,8279
B_2_4	0,3901	0,5195	0,6848	0,1484	0	0,0679	0,6291	0,9878	0,7593
B_2_5	0,2191	0,3721	0,5917	0,0213	0,0679	0	0,712	0,9871	0,8072
B_2_6	0,8155	0,8458	0,8852	0,7473	0,6291	0,712	0	0,9907	0,1832
B_2_7	0,9854	0,9845	0,9827	0,9866	0,9878	0,9871	0,9907	0	0,9915
B_3_3	0,869	0,888	0,9135	0,8279	0,7593	0,8072	0,1832	0,9915	0


Şekil 4.17.'de sıcaklık için ortalama nokta grafiği görülmektedir. Grafikten görüleceği üzere yakın ya da uzak bölgede toplanan noktalar benzerlik ile ilgili fikir vermemektedir. Böylelikle ham veriler üzerinde işlem yapmanın her zaman sağlıklı sonuçlar veremeyeceği görülmektedir.



Şekil 4.17. PHM12 Sıcaklık Nokta Grafiği

Şekil 4.18.'de benzemezlik matrisinden oluşturulan dendrogram grafiği görülmektedir. Benzemezlik matrisi incelendiğinde benzemezlik oranı 0,0213 ile en düşük olan B_1_7 ve B_2_5 rulmanları dendrogram grafiğine ilk kümeye olarak eklenmiştir.

Sonrasında B_2_4 rulmanı bu kümeye eklenmiştir. Kendi aralarındaki benzemezlik oranı düşük olan B_1_4 ve B_1_5 rulmanları, kendi içlerinde ikili küme oluşturarak önceki gruba eklenmiştir. Daha sonra B_1_6 rulmanı, birbirleri ile kümelenen B_2_6 ve B_3_3 rulmanları ve B_2_7 rulmanı dendrogram grafiğine eklenerek tüm üyeleri grafikte görüntülenmiştir.



Şekil 4.18. PHM12 Sıcaklık Dendogram Grafiği

Kümeleme bloğunda, Çizelge 4.7'deki sonuçlar bulunmuştur. Sıcaklık sonuçlarında görüldüğü gibi, yeşil alandaki rulmanlar 0,33 anomali puanı ile aynı kümededir, mavi alandaki B_2_6 ve B_3_3 rulmanları kendi aralarında 0,77 anomali puanı ile kümelenmekteyken kırmızı alandaki B_2_7 rulmani ise 0,88 anomali puanı ile ayrı bir kümededir. Hata tespiti bloğunda verilerden yola çıkılarak anomali puanları yüksek olan bu 3 rulmanda hata vardır denilebilir.

Çizelge 4.7 PHM12 Sıcaklık Kümeleme ve Anomali Puanı

Bearing	B_1_4	B_1_5	B_1_6	B_1_7	B_2_5	B_2_4	B_2_6	B_3_3	B_2_7
Cluster	0	0	0	0	0	0	1	1	2
Anomaly Point	0,33	0,33	0,33	0,33	0,33	0,33	0,77	0,77	0,88

4.1.3. Basınç verisi tabanlı filo yönetimi ile hata tespiti

PHM 2018 Data Challenge Veri Setinde, veri blogunda, basınç düşüşü makine karşılaştırma için, zaman alanı sinyali bir araç için ham veriler ile oluşturulmuştur. Basınç düşüşünün kademeli olarak azaldığı ve 1000,1600, 2300 saniye civarında ise ani düşüş yaşandığı görülmektedir. Zaman sinaline 0-1 normalizasyonu yapılmıştır. Değişen çok fazla özellik barındırmadığından DTW uygulanmamıştır.

Karşılaştırma blogunda, elde edilen değerler araç çiftleri için karşılaştırılarak öklid benzerlik algoritması uygulanarak Çizelge 4.8'deki benzemezlik matrisi elde edilmiştir. Grafikte benzemezlik oranı 0,5 altındaki yeşil ile işaretli alanlardan görüleceği üzere; T_1_6, T_1_7 ve T_2_4 araçları birbirlerine göre benzemezlik oranları düşüktür. Bu sebeple bu araçlar birbirine benzerdir.


Çizelge 4.8 Soğutma Pompası Basınç Düşüsü Benzemezlik Matrisi

	T_1_4	T_1_5	T_1_6	T_1_7	T_2_4	T_2_5
T_1_4	0	0,8151	0,9719	0,9714	0,9712	0,9077
T_1_5	0,8151	0	0,9824	0,9821	0,982	0,7639
T_1_6	0,9719	0,9824	0	0,0055	0,0115	0,9807
T_1_7	0,9714	0,9821	0,0055	0	0,0011	0,9803
T_2_4	0,9712	0,982	0,0115	0,0011	0	0,9801
T_2_5	0,9077	0,7639	0,9807	0,9803	0,9801	0


Basınç düşüşü ortalama olarak alınarak Şekil 4.19.'daki nokta grafiği oluşturulmuştur. Grafikte benzemezlik oranları düşük olan makine çiftleri aynı bölgelerde olduğu görülmektedir.

Benzemezlik matristen yararlanılarak dendogram grafiği çizdirilmiş ve Şekil 4.20.'de gösterilmiştir. Grafikte T_1_6, T_1_7 ve T_2_4 araçları benzer olduğundan öncelikli olarak eklenmiştir. Sonrasında birbiri arasındaki benzemezlik oranı düşük olan T_1_5, T_2_5 ve bu makine ikilisine de T_1_4 makinesi eklenmiştir. Daha sonra oluşan kümeler birbirne eklerek grafik tamamlanmıştır.

Kümeleme blogunda; Çizelge 4.9'daki sonuçlar bulunmuştur. Grafikte görüldüğü gibi, yeşil alandaki T_1_7, T_2_4 ve T_1_6 0,5 anomalî puanıyla araçları ve mavi alandaki



Şekil 4.19. Soğutma Pompası Basınç Düşüşü Nokta Grafiği



Şekil 4.20. Soğutma Pompası Basınç Düşüşü Dendogram Grafiği

T₁_5 ve T₂_5 araçları 0,66 anomalî puanıyla kendi aralarında bir küme iken kirmizi alandaki T₁_4 aracı 0,83 anomalî puanıyla bağımsız bir kümedir. Hata tespiti bloğunda, buradan yola çıkarak anomalî puanı yüksek olan T₁_4 aracında hata vardır denilebilir.

PHM 2018 Data Challenge Veri Setinde Aşırı basınç soğutma pompasında alınan veriler ile, veri bloğunda, zaman alanı sinyali bir araç için oluşturulmuştur. Zaman alanı sinyaline 0-1 normalizasyonu uygulanmıştır. 300 Hz üzerindeki sinyaller atılmıştır.

Çizelge 4.9 Soğutma Pompası Basınç Düşüsü Kümeleme ve Anomali Puanı

Bearing	T_1_7	T_2_4	T_1_6	T_1_5	T_2_5	T_1_4
Cluster	0	0	0	0	1	2
Anomaly Point	0,5	0,5	0,5	0,66	0,66	0,83

Karşılaştırma blogunda, elde edilen değerler araç çiftleri için karşılaştırılarak oklid benzerliği uygulanarak Çizelge 4.10'daki benzemezlik matrisi elde edilmiştir. Burada T_1_6, T_1_7 ve T_2_4 araçlarının benzemezlik oranları yeşil alanda görüleceği üzere oldukça düşüktür. Bu sebeple bu üç makine birbirine benzerdir.


Çizelge 4.10 Aşırı Basınç Soğutma Pompası Benzemezlik Matrisi

high	T_1_4	T_1_5	T_1_6	T_1_7	T_2_4	T_2_5
T_1_4	0	0,9602	0,9721	0,9716	0,9714	0,9247
T_1_5	0,9602	0	0,9876	0,9876	0,9876	0,9856
T_1_6	0,9721	0,9876	0	0,0055	0,0115	0,9793
T_1_7	0,9716	0,9876	0,0055	0	0,0011	0,9789
T_2_4	0,9714	0,9876	0,0115	0,0011	0	0,9787
T_2_5	0,9247	0,9856	0,9793	0,9789	0,9787	0


Aşırı Basınç Soğutma pompası için ham verilerin ortalaması alınarak Şekil 4.21.'deki nokta grafiği oluşturulmuştur. Burada benzer olan makineler aynı bölgelerde yer almıştır.

Benzemezlik matristen yararlanılarak dendogram grafiği çizdirilmiş ve Şekil 4.22.'de gösterilmiştir. Burada birbirine benzer makineler yakın bölgelerde olduğu görülmektedir.

Kümeleme blogunda, Çizelge 4.11'deki sonuçlar bulunmuştur. Çizelgede görüldüğü gibi, yeşil alandaki T_1_7, T_2_4 ve T_1_6 araçları 0,5 anomali puanıyla ve mavi alandaki T_1_4 ve T_2_5 araçları 0,66 anomali puanıyla kendi aralarında bir küme iken kırmızı alandaki T_1_5 aracı 0,83 anomali puanıyla bağımsız bir küme olduğu görülür. Hata tespiti admımda, buradan yola çıkarak anomali puanı yüksek olan T_1_4 aracında hata vardır denilebilir.



Şekil 4.21. Aşırı Basınç Soğutma Pompası Nokta Grafiği



Şekil 4.22. Aşırı Basınç Soğutma Pompası Dendogram Grafiği

Çizelge 4.11 Aşırı Basınç Soğutma Pompası Kümeleme ve Anomali Puanı

Bearing	T_1_7	T_2_4	T_1_6	T_1_4	T_2_5	T_1_5
Cluster	0	0	0	1	1	2
Anomaly Point	0,5	0,5	0,5	0,66	0,66	0,83


PHM 2018 Data Challenge Veri Setinde Soğutma pompası sızıntılarından alınan ham veriler üzerinden, veri bloğunda, zaman alanı sinyali bir araç için oluşturulmuştur. Ham verilerden oluşan zaman alanı sinyaline 0-1 normalizasyonu uygulanmıştır.

Karşılaştırma bloğunda, elde edilen değerler araç çiftleri için karşılaştırılarak oklid benzerliği uygulanarak Çizelge 4.12'deki benzemezlik matrisi elde edilmiştir. T_1_6, T_1_7 ve T_2_4 makineleri anomali puanları 0,5'ten düşük olduğundan benzerdir ve yeşil ile işaretlenmiştir.

Çizelge 4.12 Soğutma Pompası Sızıntı Benzemezlik Matrisi


leak	T_1_4	T_1_5	T_1_6	T_1_7	T_2_4	T_2_5
T_1_4	0	0,9615	0,2971	0,31	0,3174	0,9563
T_1_5	0,9615	0	0,9694	0,9697	0,9699	0,9859
T_1_6	0,2971	0,9694	0	0,0055	0,0115	0,9538
T_1_7	0,31	0,9697	0,0055	0	0,0011	0,9523
T_2_4	0,3174	0,9699	0,0115	0,0011	0	0,9516
T_2_5	0,9563	0,9859	0,9538	0,9523	0,9516	0

Basınç düşüşü ortalaması olarak alınarak Şekil 4.23.'teki nokta grafiği oluşturulmuştur. Burada benzer makineler; T_1_6, T_1_7 ve T_2_4 aynı bölgede toplanmıştır.



Şekil 4.23. Soğutma Pompası Sızıntı Nokta Grafiği

Benzemezlik matristen yararlanılarak dendogram grafiği çizdirilmiş ve Şekil 4.24.'de gösterilmiştir.



Şekil 4.24. Soğutma Pompası Sızıntı Dendogram Grafiği

Kümeleme bloğunda; sizıntıya bakıldığından ise yeşil alandaki T_1_7, T_2_4, T_1_6 ve T_1_4 araçları 0,33 anomali puanıyla bir kümedir. Mavi alandaki T_2_5 aracı 0,83 anomali puanıyla ve kırmızı alandaki T_1_5 aracı da 0,83 anomali puanıyla bağımsız birer kümedir. Çizelge 4.13'deki çizelgeden yola çıkarak, hata tespit bloğunda, anomali puanı yüksek olan T_2_5 ve T_1_5 araçlarında hata vardır denilebilir.

Çizelge 4.13 Soğutma Pompası Sızıntı Kümeleme ve Anomali Puanı

Bearing	T_1_7	T_2_4	T_1_6	T_1_4	T_2_5	T_1_5
Cluster	0	0	0	0	1	2
Anomaly Point	0,33	0,33	0,33	0,33	0,83	0,83

4.2. Tartışma

Genel olarak anomali tespiti ve filo yönetimi ile ilgili çalışmalar tek bir veri seti üzerinden çalışılırken; bu çalışmada dört veri seti üzerinde; titreşim, sıcaklık ve basınç özelliklerini incelenmiş ve filo elemanlarında bu özelliklerden alınan değerler öklid, kare öklid, manhattan ve maximum yöntemleri ile karşılaştırılmıştır. Tüm sonuçları FFT

döndüşümü ile frekans alanında incelemek daha verimli olmuştur. Titreşim verisi yüksek frekanslarda değişken özellik barındırdığından, zaman uyuşmazlığı etkisini azaltmak için DTW işlemine tabi tutulmuştur. DTW uygulanmadığında karşılaşmadan düzgün sonuç alınamadığı gözlemlenmiştir. Uygulama için en verimli sonuçlar titreşim özelliği için alınmıştır. Üye sayısı fazla olan filolarda daha net sonuçlara ulaşılmıştır.

Uygulama çıktıları ve grafikler sayısal olarak incelendiğinde; sağlıklı makineler veya rulmanlar, çoğunluk oluşturacak şekilde kümelenmiştir. Uygulanmak istenen sistemde ne kadar çok üye varsa yapı o kadar başarılı olur. Ancak makineler genel olarak sağlıklı varsayıldığından, sağlık kurallarına uymayan üyeleri, kurulan yapının alacağı sonuçlar için problem teşkil eder. Ayrıca sistemdeki üye sayısının az olması kümelenmede düşük anomalî puanları göstereceği için de bir problemdir. Üyelerin özdeş ve aynı koşullarda aynı işi yapma şartı da uygulamanın çalışma alanlarını sınırlar. Aksi durumda yorumlanamayacak sonuçlar elde edilebilir. Uygulamada test edilen farklı koşullarda alınmış verilerin karşılaştırma sonucunda farklı değerler aldığı gözlemlenmiştir.

Gözlemlenen dezavantajlarının yanı sıra, filo izleme tabanlı denetim sistemlerinde, geleneksel izleme yaklaşımlarına göre sağladığı avantajlar şunlardır: Öncelikli olarak anlık makine durum izlemesi imkânı sağlar, bu sebeple makine durumundaki sapmayı algılayabildiğinden, tüm olası makine hatalarını daha önceden sisteme öğretmeye ihtiyaç yoktur. Böylece veri odaklı bir uygulama için daha az veriye ihtiyaç duyar. Filo izleme yaklaşımlarında makinelerin gerçek sağlık durumları bilgisini içeren yüksek boyutlu geçmiş veri setlerine ihtiyaç duyulmaz. Bir diğer avantaj ise makinelerin çalıştığı ve üretimin devam ettiği koşullarda analiz yapılabilmesidir. Anlık karşılaşmalar daha önceden rastlanmayan ya da gözden kaçan koşullarda bile herhangi bir makinedeki sapma durumlarını tespit edebilir. Ayrıca grafiksel görselleştirmeler sistemin okunabilirliğini üst düzeye çıkardığından alan bilgisi uzmanlığı olmadan da arıza tahminlerine olanak tanır. Uygulamada bu avantajlar gözlemlenmiştir.

Sisteme ilave uyarı yapıları ile hata durumlarında ilgili kişiler bilgilendirilebilir. Arıza olasılığı olan makineler önceden tespit edilerek olası bozulmaların önüne geçilebilir, böylece üretim planlaması daha verimli hale getirilebilir. Acil durum yedek parça ihtiyacı en aza indirilebilir ve üzerinde işlem yapılan parçalarla ilgili sıkıntılar olmadan önlenebilir. Sahadaki görüşmeler neticesinde bir özelliği kullanmaktan ziyade, sisteme etki edecek; sıcaklık, titreşim, personel, akım, gerilim ve ortam ısisı gibi çalışma koşullarına etki eden özelliklerin çoğunluğu kullanılarak, sistem iyileştirilebilir.

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada filo tabanlı bir hata tespit sistemi geliştirilmiştir. Geliştirilen bu sistemde; filodaki bütün makinelerden veriler alınarak birbirleriyle karşılaştırılır ve bu karşılaştırmaya göre makineler kümelenir. Uygulama dört blok halinde tasarılmıştır: veri ön işleme, filo üyelerinin karşılaşılması, filo kümelenmesi ve hata tespiti.

Verilerin sonuçları incelenmek istendiğinde, her bir blokta oluşturulan grafikler yol gösterecektir. Sıcaklık ve titreşim için farklı değerler ile işlem yapıldığı için farklı sonuçlar alınmıştır. Veri setinin içeriği de benzer durumu söylemektedir. Filo üyelerinin geneli sağlam varsayıldığından büyük olan kümelerde anomali puanı düşüktür. Bazı üyeleri kendi içinde küçük bir küme oluştursa da diğerlerinden farklı bölgelerde, farklı kümelerde ve yüksek anomali puanlarında olduğu durumlarda arıza olma ihtimali yüksektir.

Çalışma benzer özellikte benzer koşullarda benzer işi yapan makinelerin olduğu filolarda uygulanabilir. Arıza durumları için uyarılar oluşturulabilir. Makine müdahalesına izin verilen durumlarda makineler durdurulabilir. Farklı yapay zekâ algoritmalarına veri kaynağı sağlayarak hibrit bir kestirimci bakım geliştirilebilir.

Bir üye için geçmiş verileri parçalar haline ayıralarak, her bir parça bir filo üyesi olarak sisteme dahil edilebilir, böylece bir makine kendi içinde bir filo yaklaşımı ile analiz edilebilir. Zamanla oluşan çalışma koşulları değişimleri artacağı için, bu değişimi karşılaştırmak, arıza şiddeti konusunda bilgi verebilir. Sistemdeki diğer üyeleri ve kendi içerisinde kurulan filo yönetimi yaklaşımı birleştirilerek, hatalı olan üyelerin fazla kümede olma problemi giderilmiş olur.

KAYNAKLAR DİZİNİ

- Ahmad, W., Khan, S. ve Kim, J., 2018, A hybrid prognostics technique for rolling element bearings using adaptive predictive model, *IEEE Transactions on Industrial Electronics* 65.2, 1577–1584. DOI: 10.1109/TIE.2017.2733487. URL: <https://ieeexplore.ieee.org/document/7995072>.
- Armendia, M., Peysson, F. ve Euhus, D., 2010, Twin-control: a new concept towards machine tool health management, *Industrial Instrumentation & Automation* 1.
- Bagheri, B., Yang, B., Kao, H. ve Lee, J., 2015, Cyber-physical systems architecture for self-aware machines in Industry 4.0 environment, *IFAC-PapersOnLine* 48, 1622–1627. DOI: 10.1016/j.ifacol.2015.06.318. URL: <https://www.sciencedirect.com/science/article/pii/S2405896315005571>.
- Basora, L., Olive, X. ve Dubot, T., 2019, Recent advances in anomaly detection methods applied to aviation, *Aerospace* 6.117. DOI: 10.3390/aerospace6110117. URL: <https://www.mdpi.com/2226-4310/6/11/117>.
- Challenge, P., 2009, PHM09 challenge data set gearbox fault detection data set, *PHM Society*. URL: <https://www.phmsociety.org/competition/PHM/09>.
- Challenge, P., 2018, PHM18 challenge data set the fault behavior of an ion mill etch tool, *The Prognostics and Health Management Society*. URL: <https://www.phmsociety.org/events/conference/phm/18/data-challenge>.
- Challenge, P., 2012, PHM2012, FEMTO bearing data set, NASA ames prognostics data repository, *IEEE International Conference on Prognostics and Health Management, Denver, CO, USA*. URL:

KAYNAKLAR DİZİNİ (devam)

<https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#femto>.

Chan, Y. ve Tou, N., 2008, MAXSIM: A maximum similarity metric for machine translation evaluation, *Department of Computer Science National University of Singapore Law Link, Singapore 117590*, 55–62. URL: https://www.researchgate.net/publication/220874863_MAXSIM_A_Maximum_Similarity_Metric_for_Machine_Translation_Evaluation.

Cosme, L., D'Angelo, M., Caminhas, W. M., Yin, S. ve Palhares, R., 2018, A novel fault prognostic approach based on particle filters and differential evolution, *Springer Science+Business Media, LLC* 48, 834–853. DOI: 10.1007/s10489-017-1013-1. URL: <https://link.springer.com/article/10.1007/s10489-017-1013-1>.

D3., 2020, *JavaScript library for manipulating documents based on data*. URL: <https://d3js.org>.

Developers., 2020, *Clustering algorithms*. URL: <https://developers.google.com/machine-learning/clustering/clustering-algorithms>.

Değirmenci, E., 2019, Fabrika Ortamındaki Otonom Taşıyıcı Araçlar için Durumsal Farkındalık Yöntemi Geliştirilmesi, *Osmangazi Üniversitesi*.

Gao, R., Wang, L., Teti, R., Dornfeld, D. ve Kumara, S., 2015, Cloud-enabled prognosis for manufacturing, *CIRP Annals - Manufacturing Technology* 64.2, 749–772. DOI: 10.1016/j.cirp.2015.05.011. URL: <https://www.sciencedirect.com/science/article/abs/pii/S000785061500150X>.

KAYNAKLAR DİZİNİ (devam)

- Hendrickx, K., Meert, W., Mollet, Y., Gyselinck, J., Cornelis, B., Gryllias, K. ve Davis, J., 2019, A general anomaly detection framework for fleet-based condition monitoring of machines, *Mechanical Systems and Signal Processing* 139.106585. ISSN: 0888-3270. DOI: 10.1016/j.ymssp.2019.106585. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0888327019308064>.
- Hodge, V. J., O'Keefe, S., Weeks, M. ve Moulds, A., 2015, Wireless sensor networks for condition monitoring in the railway industry: a survey, *IEEE Transactions On Intelligent Transportation Systems* 16.3, 1088–1106. DOI: 10.1109/TITS.2014.2366512. URL: <https://ieeexplore.ieee.org/document/6963375>.
- Jacobs, W., Edwards, H., Kadirkamanathan, V. ve Mills, A. R., 2018, Inter-engine variation analysis for health monitoring of aerospace gas turbine engines, *European PHM*. URL: <https://www.phmpapers.org/index.php/phme/article/view/444>.
- Jammu, N. ve Kankar, P., 2011, A review on prognosis of rolling element bearings, *International Journal of Engineering Science and Technology* 3.10, 7497–7503. ISSN: 0975-5462. URL: https://www.researchgate.net/publication/267236273_A_Review_on_Prognosis_of_Rolling_Element_Bearings.
- Jia, X., Huang, B., Feng, J., Cai, H. ve Lee, J., 2018, Review of PHM data competitions from 2008 to 2017: methodologies and analytics, *PHM Society Conference, At Philadelphia, US*. URL: https://www.researchgate.net/publication/327872068_A_Review_of_PHM_Data_Competitions_from_2008_to_2017.
- Kozlov, A., Al-jonid, K., Kozlov, A. ve Antar, S., 2018, Product quality management based on CNC machine fault prognostics and diagnosis, *IOP Conf. Series: Materials Science and Engineering* 327.022067. DOI: 10.1088/1757-899X/327/2/022067. URL: <https://doi.org/10.1088/1757-899X/327/2/022067>.

KAYNAKLAR DİZİNİ (devam)

https://www.researchgate.net/publication/324461099_Product_quality_management_based_on_CNC_machine_fault_prognostics_and_diagnosis.

Laddada, S., Benkedjouh, T., Si-Chaib, M. O. ve Drai, R., 2017, A data-driven prognostic approach based on wavelet transform and extreme learning machine, *5th International Conference on Electrical Engineering - Boumerdes (ICEE-B)*, 1–4. DOI: 10 . 1109 / ICEE - B . 2017 . 8192142. URL: <https://ieeexplore.ieee.org/document/8192142>.

Le, T. ve Geramifard, O., 2014, Fleet-based approach for tool wear estimation using sequential importance sampling with resampling, *13th International Conference on Control Automation Robotics & Vision (ICARCV)*, 1467–1472. DOI: 10 . 1109 / icarcv . 2014 . 7064532. URL: <https://ieeexplore.ieee.org/abstract/document/7064532>.

Lee, J., Kao, H. ve Yang, S., 2014, Service innovation and smart analytics for industry 4.0 and big data environment, *Product Services Systems and Value Creation. Proceedings of the 6th CIRP Conference on Industrial Product-Service Systems* 16, 3–8. DOI: 10 . 1016 / j . procir . 2014 . 02 . 001. URL: <https://www.sciencedirect.com/science/article/pii/S2212827114000857>.

Lee, J., Qiu, H., Yu, G., Lin, J. ve Rexnord Technical Services., 2007, IMS, bearing data set, NASA ames prognostics data repository, *University of Cincinnati, NASA Ames Research Center, Moffett Field, CA*. URL: <http://ti.arc.nasa.gov/project/prognostic-data-repository>.

Li, Z., Wang, Y. ve Wang, K., 2017, Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario, *Shanghai University and Springer-Verlag GmbH Germany, part of Springer Nature* 5, 377–387. DOI: 10 . 1007 / s40436-

KAYNAKLAR DİZİNİ (devam)

017-0203-8. URL: <https://link.springer.com/article/10.1007/s40436-017-0203-8>.

Liao, L. ve Lee, J., 2010, Design of a reconfigurable prognostics platform for machine tools, *Expert Systems with Applications* 37, 240–252. DOI: 10.1016/j.eswa.2009.05.004. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0957417409004242>.

Lüthe, M., 2019, *Calculate similarity—the most relevant metrics in a nutshell*. URL: <https://towardsdatascience.com/calculate-similarity-the-most-relevant-metrics-in-a-nutshell-9a43564f533e>.

Matthews, B., Das, S., Bhaduri, K., Das, K. ve Martin, R., 2014, Discovering anomalous aviation safety events using scalable data mining algorithms, *Journal of Aerospace Information Systems* 11.10, 482–482. DOI: 10.2514/1.I010080. URL: <https://arc.aiaa.org/doi/10.2514/1.I010080>.

Monnin, M., Leger, J. ve Morel, D., 2014, Proactive fleet health monitoring and management, 313–320. DOI: 10.1007/978-1-4471-4993-4_28.

Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E. ve Morello, B., 2012, PRONOSTIA: an experimental platform for bearings accelerated degradation tests, *Conference on Prognostics and Health Management.*, 1–8. URL: https://www.researchgate.net/publication/258028751_PRONOSTIA_An_experimental_platform_for_bearings_accelerated_degradation_tests.

Neo4j., 2020, *Similarity algorithms*. URL: <https://neo4j.com/docs/graph-algorithms/current/labs-algorithms/similarity>.

KAYNAKLAR DİZİNİ (devam)

Oztanır, O., 2018, Makine Öğrenmesi Kullanılarak Kestirimci Bakım, *Hacettepe Üniversitesi*.

Said, H., Nicoletti, T. ve Perez-Hernandez, P., 2016, Utilizing telematics data to support effective equipment fleet-management decisions: utilization rate and hazard functions, *Journal of Computing in Civil Engineering* 30.1, 04014122. DOI: 10 . 1061 / (ASCE) CP . 1943 - 5487 . 0000444. URL: <https://ascelibrary.org/doi/abs/10.1061/8ASCE/9CP.1943-5487.0000444>.

Saxena, A., Sankararaman, S. ve Goebel, K., 2014, Performance evaluation for fleet-based and unit-based prognostic methods, *Second European conference of the Prognostics and Health Management society*, 8–10.

Seker, S., 2012, *Öbekağacı (dendrogram)*. URL: <http://bilgisayarkavramlari.sadievrenseker.com/2012/04/10/obekagaci-dendrogram/>.

Siegel, D., 2013, Prognostics and health assessment of a multi-regime system using a residual clustering health monitoring approach, *University of Cincinnati*.

TAEK., 2020, *Çernobil Nükleer Santral Kazası*. URL: <https://www.taeck.gov.tr/tr/2016-06-09-00-44-19/154-cernobil-dosyasi/1038-cernobil-nukleer-santral-kazasi.html>.

Wagner, C. ve Hellingrath, B., 2017, Fleet knowledge for prognostics and health management – identifying fleet dimensions and characteristics for the categorization of fleets, *Annual Conference of the Prognostics and Health Management Society 2017*.

KAYNAKLAR DİZİNİ (devam)

Werner, A., 2011, An early warning monitoring system for CNC spindle bearing failure, *Clemson University*. URL: https://tigerprints.clemson.edu/all_theses/1235/.

Yılmaz, M. ve Gürel, U., 2019, CNC tezgâhlarından MT Connect verileri ile duruş ve çalışma analizi, *ISAS 2019 3rd International Symposium on Innovative Approaches in Scientific Studies. SETSCI Conference Proceedings* 10.4, 21–25. URL: http://www.set-science.com/manage/uploads/ISAS2019-ENS_0042/SETSCI_ISAS2019-ENS_0042_007.pdf.

Zheng, X., Zhuan-zhenb, L. ve Xie, Z., 2010, Study on structural effective life of tower crane and monitoring system for tower crane fleet based on systems engineering, *IEEE International Conference on Intelligent Computing and Intelligent Systems* 3, 254–257. DOI: 10.1109/icicisys.2010.5658540. URL: <https://ieeexplore.ieee.org/document/5658540>.