



**T.C. İSTANBUL T CARET
 NİVERSİTESİ**

FEN B LİMLERİ ENSTİT S 

** RET M S STEMLERİNDE MAKİNE   RENMESİ İLE KESTİRİMCİ
BAKIM UYGULAMASI VE MODELLEMESİ**

Hakan CEYHAN

Danışman

Doç. Dr. Mustafa Cem KASAPBAŐI

**Y KSEK LİSANS TEZİ
BİLGİSAYAR M HENDİSLİ İ ANABİLİM DALI
İSTANBUL – 2022**

KABUL VE ONAY SAYFASI

Hakan Ceyhan tarafından hazırlanan "**Üretim Sistemlerinde Makine Öğrenmesi İle Kestirimci Bakım Uygulaması Ve Modellemesi**" adlı tez çalışması 02/02/2022 tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman **Doç. Dr. Mustafa Cem KASAPBAŞI**
İstanbul Ticaret Üniversitesi

Jüri Üyesi **Doç. Dr. Buket DOĞAN**
Marmara Üniversitesi

Jüri Üyesi **Dr. Öğr. Üyesi Arzu KAKIŞIM**
İstanbul Ticaret Üniversitesi

Onay Tarihi : 10.02.2022

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsünün 10.02.2022 tarih ve 2022/339 numaralı Yönetim Kurulu Kararının 2. maddesi gereğince, ders yüklerini ve tez yükümlülüğünü yerine getirdiği belirlenen Hakan CEYHAN adlı öğrencinin mezun olmasına oy birliği ile karar verilmiştir.

Prof. Dr. Necip ŞİMŞEK
Enstitü Müdürü

AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

10.02.2022

Hakan CEYHAN

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR.....	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ.....	3
3. ENDÜSTRİYEL DEVRİMLER	6
4. ENDÜSTRİYEL VERİ TOPLAMA SİSTEMLERİ	8
4.1. PLC (Programlanabilir Lojik Kontrolör).....	8
4.1.1. PLC programlama dilleri.....	9
4.1.2. PLC haberleşme yöntemleri	12
4.1.2.1. Profinet (Process Field Net).....	12
4.1.2.2. Profibus (Process Field Bus).....	12
4.1.2.3. Modbus.....	12
4.1.2.4. Modbus Rtu.....	13
4.1.2.5. Modbus Tcp/Ip.....	14
4.1.2.6. Teleservis haberleşme	14
4.2. Endüstriyel Haberleşme Standartları.....	14
4.2.1. OPC Classic	16
4.2.1.1. OPC DA (Data Access).....	17
4.2.1.2. OPC A/E (Alarm/Event)	17
4.2.1.3. OPC HDA (Historical Data Access).....	18
4.2.1.4. OPC Security	18
4.2.1.5. OPC XML DA	19
4.2.2. OPC UA (Unified Architecture).....	19
5. BAKIM YAKLAŞIMLARI	22
5.1. Arızı (Düzeltilici) Bakım (Reactive Maintenance).....	23
5.2. Periyodik Bakım.....	24
5.3. Duruma Dayalı Bakım (CBM).....	25
5.4. Önleyici Bakım (Proaktif Bakım)	25
5.5. Kestirimci Bakım (Predictive Maintenance)	26
6. KESTİRİMCİ BAKIMDA MAKİNE ÖĞRENMESİ	28
6.1. Rastgele Orman (Random Forest).....	32
6.2. Temel Bileşenler Analizi (Principal Component Analysis)	36
7. MATERYAL VE YÖNTEM	37
7.1. Veri Toplama	37
7.1.1. Veri toplama mimarisi.....	38
7.1.2. Veri toplama sistemi donanım özellikleri.....	39
7.1.3. Veri toplama sistemi uygulama özellikleri	40
7.1.3.1. TIA portal	41
7.1.3.2. OPC UA client veri toplama servisi.....	43
7.1.3.3. Operatör duruş bilgileri giriş uygulaması	44

7.2. Veri Seti	45
7.3. Kalan Faydalı Ömür	47
7.4. Makine Öğrenmesi Aşaması	49
8. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	52
8.1. Rastgele Orman İle Tahminleme Sonucu	52
8.2. Temel Bileşen Analizi İle Tahminleme Sonucu	54
9. SONUÇ VE ÖNERİLER.....	56
KAYNAKLAR	58
ÖZGEÇMİŞ.....	62

ÖZET

Yüksek Lisans Tezi

ÜRETİM SİSTEMLERİNDE MAKİNE ÖĞRENMESİ İLE KESTİRİMCİ BAKIM UYGULAMASI VE MODELLEMESİ

Hakan CEYHAN

**İstanbul Ticaret Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Mustafa Cem KASAPBAŞI

2022, 62 sayfa

Üretim sistemlerinin verimlilikleri söz konusu olduğunda bakım yaklaşımları son derece önemli bir role sahiptir. Geleneksel bakım yaklaşımları kısıtlı bir başarı sağlamış olsa da günümüz endüstriyel teknolojilerinin özellikle de endüstri 4.0'ın itici gücü ile birlikte makinelerden belirli standartlar ile veriler gerçek zamanlı okunabilmekte ve bu verilerle makine öğrenmesi (machine learning-MÖ) aracılığı ile bakım zamanları optimize edilebilmektedir. Böylece kestirimci bakım anlayışı ile üretim sürecindeki herhangi bir bakım gerektiren arıza önceden öngörülerek bu durum yaşanmadan önüne geçilebilmektedir. Bu çalışmada bir döküm fabrikasında bulunan polimer döküm makinesinde, makine öğrenmesi ile kestirimci bakım uygulamasını gerçekleştirebilmek amacıyla akım, sıcaklık, titreşim, motor çalışma durumu, motor hızı, basınç gibi veriler 5 ay boyunca toplanmıştır. Elde edilen veriler ile temel bileşen analizi (principal component analysis-TBA) ve rastgele orman (random forest-RO) makine öğrenmesi yöntemleri kullanılarak, sırasıyla denetimsiz ve denetimli olarak bakım zaman tahminleri saat bazında kategorize edilerek %85,17 başarı oranı ile gerçekleştirilmiştir.

Anahtar Kelimeler: Endüstri 4.0, kestirimci bakım, makine öğrenmesi.

ABSTRACT

M.Sc. Thesis

PREDICTIVE MAINTENANCE APPLICATION AND MODELING WITH MACHINE LEARNING IN PRODUCTION SYSTEMS

Hakan CEYHAN

**İstanbul Commerce University
Graduate School of Applied and Natural Sciences
Department of Computer Engineering**

Supervisor: Assoc. Prof. Dr. Mustafa Cem KASAPBAŞI

2022, 62 pages

Maintenance approaches have an extremely important role when it comes to efficiency in production systems. Although traditional maintenance approaches have had limited success, with the driving force of today's industrial technologies, especially industry 4.0, all maintenance data generated on production machines can be collected in real time, and maintenance times can be optimized through machine learning. Thus, with the predictive maintenance approach, any maintenance-required breakdown in the production process can be foreseen and prevented before this situation occurs. This study collected data such as current, temperature, vibration, engine working state, engine speed, and pressure for 5 months to apply predictive maintenance with machine learning on a polymer casting machine located in a casting factory. Using principal component analysis and random forest machine learning methods with procured data, first unsupervised then supervised maintenance predictions respectively were obtained with an accuracy rate of %85,17 categorizing hour-basis.

Keywords: Industry 4.0, machine learning , predictive maintenance.

TEŞEKKÜR

Bu araştırma boyunca beni bilgi ve tecrübesi ile yönlendiren, karşılaştığım güçlükleri aşmamda yardımcı olan değerli danışman hocam Doç. Dr. Mustafa Cem KASAPBAŞI'na ve desteğini benden esirgemeyen sevgili eşim Gülizar CEYHAN'a teşekkürlerimi sunarım.

Hakan CEYHAN
İSTANBUL, 2022

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Endüstriyel devrimler.....	6
Şekil 4.1. Siemens marka S7-1200 model PLC	9
Şekil 4.2. PLC entegre edilebilir modüller.....	9
Şekil 4.3. Ladder logic ve fonksiyon blok diyagram	10
Şekil 4.4. SCL.....	10
Şekil 4.5. STL.....	11
Şekil 4.6. Tia portal.....	12
Şekil 4.7. Modbus haberleşme	13
Şekil 4.8. Modbus rtu veri paketi.....	14
Şekil 4.9. Modbus tcp/ip veri paketi.....	14
Şekil 4.10. OPC klasik haberleşme şeması	16
Şekil 4.11. OPC DA	18
Şekil 4.12. OPC A/E	18
Şekil 4.13. OPC UA mimarisi.....	20
Şekil 4.14. OPC UA haberleşme standardı.....	21
Şekil 4.15. OPC UA katman mimarisi	22
Şekil 5.1. Bakım türleri	24
Şekil 5.2. Bakım türleri ve uygulama zamanları	28
Şekil 6.1. Makine öğrenmesi teknikleri.....	30
Şekil 6.2. Denetimli öğrenme akış diyagramı	31
Şekil 6.3. Denetimsiz öğrenme akış diyagramı	32
Şekil 6.4. Pekiştirmeli öğrenme akış diyagramı.....	33
Şekil 6.5. Rastgele orman.....	33
Şekil 6.6. Rastgele orman makine öğrenmesi	34
Şekil 6.7. Rastgele orman algoritması.....	36
Şekil 6.8. PCA	37
Şekil 7.1. Saha seviyesi veri toplama mimarisi	39
Şekil 7.2. Uygulama çalışma şablonu	40
Şekil 7.3. IBOX endüstriyel panel.....	41
Şekil 7.4. TIA portal platformunda S7-1200 üzerine alınmış verilerin gösterimi.....	42
Şekil 7.5. S7 bağlantı protokolü.....	43
Şekil 7.6. OPC UA erişim adresleri.....	44
Şekil 7.7. Veri toplama uygulaması.....	44
Şekil 7.8. Belirsiz duruş seçim ekranı	45
Şekil 7.9. Belirsiz duruş nedeni seçim ekranı	46
Şekil 7.10. Belirsiz duruş açıklaması giriş ekranı.....	46
Şekil 8.1. Gerçek/tahmin KFÖ grafiği (saniye)	53
Şekil 8.2. Gerçek/tahmin KFÖ grafiği (kategorik)	53
Şekil 8.3. PC1/PC2 dağılım grafiği.....	54

ÇİZELGELER

	Sayfa
Çizelge 7.1. Veri seti özellikleri ve açıklamaları.....	46
Çizelge 8.1. Rastgele orman öznitelik sayısına göre doğruluk oranları	53
Çizelge 8.2. SPE eşik belirleme yöntemine göre doğruluk oranları	54
Çizelge 8.3. Alternatif çalışmalar ile doğruluk değerlerinin karşılaştırılması ...	55

SİMGELER VE KISALTMALAR

AGV	Automated Guided Vehicle
CART	Classification and Regression Tree
CBM	Condition Based Maintenance
CBM	Duruma Dayalı Bakım
COM	Component Object Model
CRC	Cyclic Redundancy Check
CRM	Customer Relationship Management
DCOM	Distributed Component Object Model
DHCP	Dynamic Host Configuration Protocol
EDDL	Electronic Device Description Language
ERP	Enterprise Resource Planning
FDT	Filed Device tool
GBM	Gradient Boosting Machine
HMI	Human Machine Interface
IoT	Internet Of Things
KFÖ	Kalan Faydalı Ömür
LSTM	Long Short Term Memory
M2M	Machine to Machine
MC PdM	Multiple Classifier Predictive Maintenance
MES	Manufacturing Execution System
ML	Machine Learning
MÖ	Makine Öğrenmesi
OEE	Overall Equipment Effectiveness
OLE	Object Linking and Embedding
OPC	OLE for Process Control
OPC UA	OLE for Process Control Unified Architecture
OPC DA	OLE for Process Control Data Access
OPC AE	OLE for Process Control Alarm Event
OPC HDA	OLE for Process Control Historical Data Access
PCA	Principal Component Analysis
PdM	Predictive Maintenance
PdM	Kestirimci Bakım
PvM	Preventive Maintenance
PLC	Programmable Logic Controller
RF	Random Forest
RMSE	Kök Ortalama Kare Hatası
RMSE	Root Mean Squared Error
RNN	Recurrent Neural Network
RO	Rastgele Orman
RPM	Revolution Per minutes
RPM	Dakikadaki Devir Sayısı
RUL	Remaining Useful Life
SCL	Structured Control Language
SDK	Software Development Kit
SFC	Sequential Function Chart

SOAP	Simple Object Access Protocol
SPE	Squared Prediction Error
SPE	Kare Tahmin Hatası
STL	Statement List language
SVM	Support Vector Machines
TBA	Temel Bileşen Analizi
TCP	Transmission Control Protocol
TIA Portal	Totally Integrated Automation Portal

1. GİRİŞ

Endüstri 4.0 çağında yapay zeka imalat endüstrisini dönüştürüyor. Nesnelerin interneti (internet of things - IoT) ve makine öğrenimi yöntemlerinin ortaya çıkmasıyla birlikte üretim sistemleri, insanlar, makineler, sensörler vb. ile gerçek zamanlı iletişim ve iş birliği yoluyla fiziksel süreçler izlenebilir ve akıllı kararlar alınabilir. Yapay zeka, üreticilerin deneyimlerden öğrenen makine öğrenimi teknolojilerini kullanarak ekipman arıza süresinin azaltılmasına, üretim hatalarının tespit edilmesine, minimum duruş süresi sağlayabilmesine ve tedarik zincirini iyileştirebilmesine olanak tanır (Angelopoulos vd., 2020). Bu teknolojilerin son uygulamalarından biri de kestirimci bakım (predictive maintenance) sistemleridir. Tahmine dayalı bakım, üretim ekipmanının bakıma ihtiyaç duyacağı tam zamanı tahmin etmek için endüstriyel IoT teknolojilerini makine öğrenimi ile birleştirerek sorunların çözülmesine ve uyarlanabilir kararların zamanında alınmasına olanak tanır (Carvalho vd., 2019).

Yeni teknolojileri adapte etme ve kullanma ihtiyacı, endüstriyi yeni bir çağa doğru evrimleştirdi. Veri miktarı, yeni cihazlar, bağlantı teknolojileri, kişiselleştirme ve kontrollü üretim endüstri 4.0 olarak adlandırılan süreci doğurdu. Almanya'da endüstri alanında yenilik ve değişim taleplerini karşılayabilmek için oluşturulan terimin adı "dördüncü sanayi devrimi" olarak ilan edildi (Zonta vd., 2020).

Geçmişten günümüze yaşanan endüstriyel devrimler iş süreçlerinin verimliliğini artırmıştır. Büyük bir işgücü ve dolayısıyla düşük üretkenlik gerektiren görevleri yerine getirmede insanın kapasitesini artıran gelişmelere "Endüstri Devrimi" denir (Martins vd., 2020).

Bu çalışmada bir döküm fabrikasındaki döküm makinesinde gerçekleşebilen arızalardan biri olan mikser motor arızası için kestirimci bakım benzer modeli ile denetimli ve denetimsiz makine öğrenmesi yöntemleri uygulanarak bir erken uyarı sistemi oluşturulması amaçlanmıştır. Mikser motor arızası planlı çalışma süresi içerisinde alındığında 1,5 - 2 saat aralığında plansız bir bakım oluşmasına

sebepe olmaktadır. Bu da üretim verimliliğini düşürdüğü gibi ekstra bakım maliyetlerine de sebebiyet verebilmektedir.

Bu çalışmanın ana amacı, kestirimci bakım benzer modeli ile makine öğrenmesi metodolojisi kullanılarak makinenin sağlık durumunu tespit edebilmektir. Bu sayede makine arızalanmadan önce bir erken uyarı sistemi oluşturarak bakım sayısı ve zamanı optimize edilebilecektir.

Bu çalışma 9 bölümden oluşmaktadır. 2. bölümde literatürde yapılmış benzer çalışmalara, 3. bölümde endüstriyel devrimlere değinilmiştir. 4. bölümde veri toplama gereksinimleri ve alt yapı bilgilerine, 5. bölümde bakım yaklaşımlarına yer verilmiştir. 6. bölümde makine öğrenmesi algoritma çeşitleri ve projede kullanılan makine öğrenmesi algoritmaları hakkında genel bilgiler yer almaktadır. 7. bölümde projede kullanılan materyaller ve metotlar açıklanmaktadır. 8. bölümde uygulanan projenin sonuçları irdelenmektedir. 9. bölümde ise nihai sonuç açıklanmış ve çalışmanın geliştirilmesi ile ilgili tavsiyelere yer verilmiştir.

2. LİTERATÜR ÖZETİ

Yapay zeka destekli kestirimci bakım ile ilgili birçok çalışma bulunmaktadır. Mathew ve arkadaşları turbofan jet motorlarının kalan faydalı ömürlerini (KFÖ-RUL) hesaplamak amacıyla doğrusal regresyon, karar ağaçları, SVM, rastgele orman, KNN, k ortalamalar, gradient boost, ada boost, derin öğrenme, anova gibi makine öğrenmesi yöntemlerini karşılaştırmıştır. Bu çalışma sonucunda rastgele orman (RO) yönteminin diğerlerinden daha iyi bir performans sağladığı ortaya konulmuştur (Mathew vd. 2017).

Ayvaz ve arkadaşları tarafından yapılan çalışmada üretim hatları için veriye dayalı kestirimci bakım sistemi geliştirilmiştir. IoT sensörlerden elde edilen veriler makine öğrenmesi modelleri ile gerçek zamanlı olarak kullanılmış ve en başarılı sonuçların elde edildiği modellerin rastgele orman ve xgboost olduğu gözlemlenmiştir (Ayvaz ve Alpay, 2021).

2017’de Tahan ve arkadaşları tarafından yapılan gaz türbini için geliştirilen motor performansı izleme, teşhis ve prognostik tekniklerin sistematik bir incelemesini sunar. Arıza teşhisinin algılanabilmesi için performansa dayalı bir durum izleme çalışmasını kapsar (Tahan vd., 2017).

Erkan Caner Özkat’ın 2021’de yapmış olduğu çalışmada kalan faydalı ömür tahmininde kullanılmak üzere makine öğrenmesi metodolojisi kullanılarak titreşim verilerinden makine sağlığı göstergesi belirlenmeye çalışılmıştır. Tahmin başarısı belirlenirken determinasyon katsayısından (R^2) ve kök ortalama kare hatasından (RMSE) faydalanılmıştır (Özkat, 2021). Test veri seti için R^2 ve RMSE değerleri sırasıyla 0.9897 ve 2.2025 olarak bulunmuştur.

Cline Brad ve arkadaşları tarafından yapılan çalışma, petrol ve gaz ekipmanı servis departmanının operasyonlarını geliştirmeye yönelik, makine öğrenimi tekniklerinin kullanıldığı kestirimci bakım yaklaşımlarının benzer uygulamalarda etkin olarak kullanılabilme potansiyelini göstermesi açısından önemli bir çalışmadır (Cline vd., 2017).

Ürün numarası, ortam sıcaklığı, işlem ortamı sıcaklığı, dönüş hızı (rpm), tork, takım aşınması parametreleri içeren bir veri seti ile yapılan çalışmada, açıklayıcı arayüz (explanatory interface) ve açıklanabilir model (explainable model) kullanılmış ve sonuçları karşılaştırılmıştır. Her iki yöntemin de güçlü ve zayıf yönlerine rağmen açıklayıcı arayüz ile daha kararlı sonuçlar elde edilmiştir (Matzka, 2020).

Olcak Öztanır ve arkadaşları tarafından 2018'de gerçekleştirilen çalışmada derin öğrenme tekniğinin bakım planlamasında kullanımı ve diğer makine öğrenme tekniklerine göre başarı oranı kıyaslaması yapılmıştır. Turbofan jet motoru veri seti ile çalışılmış, uygulanan diğer metotlara göre daha başarılı sonuç verdiği gözlemlenen modelin bir RNN türeviden LSTM kullanılarak oluşturulan model olduğu gözlemlenmiştir (Öztanır, 2018).

Oğuzhan Çömlekçi'nin 2020 yılında yapmış olduğu çalışmada rastgele orman (random forest - RF) , gradient boosting (GBM) ve bir yapay sinir ağı algoritması kullanılarak sistem arızaları sınıflandırılmış ve sonuçlar karşılaştırılmıştır. Her bir metot için mikro ortalama ve makro ortalama yöntemine göre doğruluk oranları hesaplanmıştır. Mikro ortalama doğru tahmin edilen örneklerin oranı, makro ortalama sınıf düzeyindeki ortalama doğruluktur. Çalışma kapsamında RF için mikro doğruluk oranı 0,8521, makro doğruluk oranı 0,7388, sinir ağı algoritması mikro doğruluk oranı 0,6454, makro doğruluk oranı 0,5488, GBM için mikro doğruluk oranı 0,8732, makro doğruluk oranı 0,7628 bulunmuş olup en ideal öğrenme metodunun GBM olduğu sonucuna ulaşılmıştır. Bunun sonucunda makine öğrenimi teknikleri kullanılarak endüstriyel otomasyon sistemlerinde oluşan arızaların tespitinde kullanılabileceği görülmüştür. (Çömlekçi, 2020).

2020 yılında David Kimera ve arkadaşları tarafından yapılan çalışmada gemi tamir sahalarındaki balast pompalarının makine öğrenimi ile kestirimci bakımı konusu ele alınmış ve bu pompaların arızalanması ile ilgili bir erken uyarı sistemine yönelik bir kestirimci bakım yaklaşımı sağlamayı amaçlamıştır. Basınç, akış hızı, akım, motor dönüş hızı (rpm) ve emme basıncı parametreleri kullanılarak 40 hafta boyunca bu parametreler izlenmiştir. Temel bileşen analizi

kullanılarak arıza tespitinde etkili parametreler saptanmıştır. Oluşturulan modelin gerçek arıza zamanından %13,85'lik bir sapma ile başarı sağlandığı gözlemlenmiştir (Kimera vd., 2020).

2020 yılında JPS Martins' in yapmış olduğu çalışmada bir makine arızasının önceden kestirilebilmesi amacıyla bir test tezgahında bir tahmin modeli uygulayarak bakım algoritmalarına katkıda bulunmak için metodoloji önerisi sunmaktadır (Martins vd., 2020).


2020 yılında Zeki Murat Çınar ve arkadaşları tarafından yapılan çalışmada sürdürülebilir akıllı üretime yönelik kestirimci bakım çalışmalarına temel oluşturabilmek adına son gelişmelerin kapsamlı bir incelemesini sunulmuştur.

2015 yılında Gian Antonio Susto ve arkadaşları tarafından yapılan çalışmada kestirimci bakım için çoklu sınıflandırıcı bir makine öğrenimi metodolojisi kullanılmaktadır. Önerilen MC PdM (Multiple Classifier Predictive Maintenance) yaklaşımında modül üzerinde farklı sınıflandırıcı çalışır. Çalışma sonucu önerilen MC PdM modelinin 97.08 doğruluk oranı ile klasik PvM ve tek bir SVM sınıflandırmaya göre çok daha iyi performans sağladığı görülmüştür (Susto vd., 2014).

Literatürde ilgili çalışmalar incelendiğinde halihazırda var olan bir veri seti ile çalışılabildiği gibi endüstriyel ortamdan elde edilen özgün veri setleri ile de çalışıldığı görülmüştür. Mevcut çalışmada endüstriyel ortamdan elde edilen veri seti toplama aşaması diğer çalışmalardan farklı olarak detaylıca ele alınmıştır. Bununla birlikte mevcut çalışmada denetimli ve denetimsiz olmak üzere iki farklı yaklaşım ayrı ayrı ele alınmıştır.

3. ENDÜSTRİYEL DEVRİMLER

Endüstri, insan gücüne dayalı üretimden, üretim hızlarının ve kalitesinin arttığı çok daha kontrollü olduğu bugünün şartlarına ulaşırken aşağıdaki dönemlerden geçmiştir (Şekil 3.1).



Şekil 3.1. Endüstriyel devrimler (Agrawal, 2017)

Endüstri 1.0 (18. yüzyıl): Su ve buhar enerjisi ile çalışan mekanik üretim sistemlerinin ilk örnekleri ortaya çıkmıştır.

Endüstri 2.0 (20. yüzyıl başlangıcı): İlk üretim hatlarının, iş bölümüne dayalı, su ve buhar enerjisinin yerini elektrik enerjisinin aldığı kitlesel üretimin devreye alınmaya başladığı dönemdir.

Endüstri 3.0 (1970'lerin başı): Otomasyon dönemini başlatan, ilk programlanabilir mantıksal denetleyicilerin (PLC) kullanıldığı, bilgi teknolojileri ve elektronğin devreye girişi bu yıllardan sonra başlamıştır.

Endüstri 4.0 (21. yüzyıl): Otonom makineler, yatay ve dikey entegrasyonlar, nesnelerin interneti, makine öğrenimi, büyük veri ve analitiği, artırılmış gerçeklik, siber güvenlik, siber fiziksel sistemler, bulut teknolojileri, 3 boyutlu yazıcılar bu son endüstriyel devrimin ürünleri olarak gösterilebilir.

Özellikle günümüzde endüstri 4.0 ile birlikte çeşitli alanlarda benzeri görülmemiş teknolojik ve bilimsel gelişmeler yaşanmaktadır. Bu gelişmeler ile birlikte nihai amaç iş süreçlerinin verimliliğini artırmaktır. Bilgiye erişim şekillerinde de değişiklik olmuş, çok çeşitli kaynaklardan (sensörler, akıllı kontrol sistemleri, giyilebilir teknolojiler vb.) çok daha hızlı bir şekilde veri toplanabiliyor olmasına rağmen artık daha karmaşık bir yapıya bürünmüştür. Bu karmaşık ve büyük verinin anlamlı bir hale getirilebilmesi amacıyla işlenmesi, günümüzde verimliliği artırmak için gerekli olan önemli parametrelerden biri haline gelmiştir. Özellikle sensör teknolojilerinin gelişmesi, makine-makine (M2M), makine-insan (HMI) haberleşmesi ve standartlarının olgunlaşması (OPC UA), nesnelerin interneti, yapay zeka ve büyük veri analitiği ile karmaşık sorunların üstesinden gelinebilmesi sağlanmıştır. Geleneksel bakım süreçleri de bu gelişmelerden nasibini almış, arıza bakım ve koruyucu periyodik bakım dışında makine verilerinin analizinden yola çıkarak arıza oluşmadan önceki sürecin tahmin edilmesiyle kestirimci bakım yapılabilmesi olanaklı hale gelmiştir.

Endüstriyel devrimler, endüstriyel üretkenliği ve karmaşıklığı artırmıştır. Mühendisler, belirli algoritmalarla kontrol edilebilen makineleri performansını iyileştirebilmek amacıyla kendi kendine öğrenebilen ve her geçen gün daha iyiye giden makinelere dönüştürmeyi amaçlarlar. Bu amaç doğrultusunda da öncelikle fabrikadaki hatlardan/makinelerden makine-makine ve makine-insan arabirimleri aracılığı ile sağlıklı bir şekilde verilerin toplanması çalışma kapsamındaki ilk adımlardan biridir.

4. ENDÜSTRİYEL VERİ TOPLAMA SİSTEMLERİ

Fabrika üretim sahalarında bulunan üretim ekipmanları PLC, hareket, nümerik kontrolör gibi çeşitli marka ve modeldeki programlanabilir kontrolcüler ile yönetilmektedir. Otomasyonu sağlanmış bir üretim ekipmanından veri toplama çalışması yapılabilmesi için bu kontrolcüler ile haberleşmeyi sağlayacak standartlara ihtiyaç vardır.

4.1. PLC (Programlanabilir Lojik Kontrolör)

PLC (programmable logic controller) endüstriyel alanlarda faaliyet gösteren ve üretim hatlarını oluşturan robot, üretim bandı, pnömatik (hava basıncını mekanik harekete çeviren) ekipman gibi çeşitli makinelerin kontrolünü ve programlanabilmesini sağlayan, günümüzde karmaşık röle sistemlerinin yerini almış olan özelleştirilmiş bir bilgisayara verilen isimdir.

General Motors firmasının 1968 yılında kendi üretim sahasında yer alan karmaşık röle sisteminin yerini alacak bir ürün talebinde bulunmasıyla birlikte Bedford Associates firması bu talebi karşılamak amacıyla MODICON (Modular Digital Controller) adındaki ürününü ortaya koymuştur. Projede yer alan Dick Morley günümüzde PLC'nin ilk örneğini ortaya atmış kişi olarak anılmaktadır.


PLC'ler de bilgisayarın sahip olduğu RAM ve ROM bellekler, işlemci, giriş ve çıkış birimleri ve haberleşme modülleri gibi bileşenlere sahiptir.

PLC gerçekleştirmesi gereken işlevi sahip olduğu modül üzerindeki giriş ve çıkışları değiştirecek şekilde programlar oluşturarak sağlamaktadır. Günümüzde çoğu mikro kontrolcü 3.3V veya 5V giriş/çıkış gerilimi kullanırken PLC'lerde bu değer 24V'tur.



Şekil 4.1. Siemens marka S7-1200 model PLC

S7-1200 model PLC'nin sol tarafına farklı haberleşme protokollerini destekleyen 3 adet modül takılabilir. Sağ tarafına ise PLC üzerindeki input ve output sayıları yetersiz kalması durumunda maksimum 8 adet olmak üzere sinyal modülü takılabilmektedir (Şekil 3.2).




Şekil 4.2. PLC entegre edilebilir modüller

4.1.1. PLC programlama dilleri

PLC'ler sahadaki çeşitli makine ve cihazlar üzerinden gelen bilgileri girişleri üzerinden okuduktan sonra yazılan programa göre bu girişleri milisaniyeler

mertebesinde yorumlar ve çıkışları üzerinden yine çevre birimlere iletir. PLC programlamada ladder (Şekil 4.3), fonksiyon blok diyagram, SCL (structured control language) (Şekil 4.4), STL (statement list language) (Şekil 4.5), SFC (sequential function chart) gibi birçok dil kullanılmaktadır.



Şekil 4.3. Ladder logic ve fonksiyon blok diyagram

```

2  #tmpI := 2;
3  #tmpJ := 5;
4  #tmpDBNo := 20;
5
6  FOR #tmpI := 2 TO 8 DO
7      %EW(#tmpI) := 0;
8      %AB(#tmpI) := %MB(#tmpI);
9      %AW(#tmpI + 1) := %MW(#tmpI + 1);
10 END_FOR;
11 #statBool := %MX(IDX := #tmpI,
12                 BIT := #tmpJ);
13 %EX(IDX := #tmpI,
14     BIT := #tmpJ) := %MX(IDX := #tmpI,
15                           BIT := #tmpJ);
16


```

Şekil 4.4. SCL

Network 1:					
Comment					
				RLO	Value
1	A	"Motor_1_Enabled"		1	1
2	AN	"Motor_1_EmergencyStop"		0	1
3	JC	n_OK		1	
4	=	"Motor_1_Start"		1	1
5	AN	"Motor_1_SpeedOK"		0	1
6	AN	"Motor_1_BreakesEnabled"		0	0
7	=	"Motor_1_Stop"		0	0
8	JU	End			
9	n_OK: SET				
10	AN	"Motor_1_BreakesEnabled"			
11	=	"Motor_1_Stop"			

Şekil 4.5. STL

Röle tabanlı sistemlerin yerini alan PLC'lerin programlanmasında sıklıkla ladder logic adı verilen açık/kapalı anahtar sembollerinden oluşan ve özellikle elektrik teknisyenlerinin çok üst düzey programlama bilgisine sahip olmasını gerektirmeden basit bir şekilde PLC programlayabilmesini sağlayan bir dil kullanılır (Şekil 4.3). Daha üst seviye kullanıcılar için C diline benzer olan SCL gibi diller kullanmak mümkündür (Şekil 4.4). Ayrıca yeni nesil PLC'ler ile birlikte yüksek seviye (C++, C#) dillerle de PLC programlanabilmektedir. Bununla birlikte farklı marka PLC'ler için programlama arayüzleri farklılık gösterir. Örneğin Mitshubishi MT Work, Siemens TIA Portal (Şekil 4.6).



Şekil 4.6. TIA portal

4.1.2. PLC haberleşme yöntemleri

4.1.2.1. Profinet (Process Field Net)

- Uluslararası PROFIBUS ve PROFINET konsorsiyumu tarafından geliştirilmiştir.
- Endüstriyel kontrol sistemlerinde TCP/IP standartlarını kullanan üst düzey açık ağ haberleşme protokolüdür.
- Profinet Profibus ile TCP/IP ve ilişkili olduğu OPC, DHCP ve HTTP açık bilgi teknolojilerini birleştirir.
- Hızı 100Mbit/s'dir.


4.1.2.2. Profibus (Process Field Bus)

- Büyük endüstriyel otomasyon sistemlerini de kapsayabilen haberleşme standardıdır.
- Bu haberleşme sistemi birçok PLC üretici firma ve Alman Eğitim ve Araştırma departmanı (BMBF) tarafından 1989 yılında geliştirilen ve standart olarak kabul edilen bir ağ sistemidir.
- Bu yapıda bir ana (master) cihaz ve bunlara bağlı yardımcı (slave) çevre birimleri mevcuttur. Bir ana cihaz için en fazla 32 adet yardımcı cihaz bağlanabilir. En fazla 4 adet olmak üzere sinyal tekrarlayıcı (repeater) kullanıldığı takdirde yardımcı cihaz sayısı 126'ya kadar çıkartılabilir.
- Profibus-PA doğrudan Profibus-DP'ye bağlanmak için geliştirilmiştir ve kendinden güvenli uygulamalarda kullanılabilir.
- DP, RS485 fiziksel katmanını kullanırken PA, esas olarak proses uygulamaları için tasarlanmış IEC 61158-2 fiziksel katmanını kullanır.
- Hızı 12Mbit/s'dir.

4.1.2.3. Modbus

- 1979 yılında Modicon tarafından geliştirilmiştir. Seri port ve internet protokollerini kullanır (Şekil 4.7).

- PLC, sürücü, sensörler ve diğer çevre ekipmanlar ile haberleşmede kullanılır.
- Bu yapıda bir ana cihaza en fazla 247 adet yardımcı cihaz bağlanabilir.
- Kısa ve uzun mesafeler için sırasıyla RS232 ve RS485 seri haberleşme arayüzü kullanılır.



Şekil 4.7. Modbus haberleşme

4.1.2.4. Modbus Rtu


- Kullanım kolaylığı ve güvenilirliği sebepleriyle yaygın olarak kullanılan Modbus Rtu protokolü ana-yardımcı mimarisine göre düzenlenmiş seri haberleşme protokollerini kullanır.
- İki bitlik veriler halinde yollanan mesajlar 6 bitlik CRC (hata kontrol mekanizması) ile kullanılarak bir güvenlik altyapısına kavuşur. CRC ile gönderilen verilerin tamamı denetlenir (Şekil 4.8).
- RS485 sıklıkla kullanılan haberleşme protokolüdür.
- Modbus Rtu için belirlenen veri aktarım hızları 9.600-19.200 baudrate'dir.

Başlangıç	Adres	Fonksiyon	Veri	CRC Kontrol	Bitiş
≥ 3.5 char	8 bits	8 bits	N x 8 bits	16 bits	≥ 3.5 char

Şekil 4.8. Modbus Rtu veri paketi

4.1.2.5. Modbus Tcp/Ip

- Modbus Tcp/Ip klasik internet ağı protokolünü baz alır (Şekil 4.9). Cihazlardaki işlemci ve internet kartlarına bağlı olarak 100 Mbps hıza kadar veri aktarımı yapabilir. Sunucu/istemci mantığı ile çalışır. Ağda birden fazla sunucu ve istemci olmasına olanak tanır.
- TCP/IP protokolünde verilerin iletim hızı cihazlarda kullanılan işlemci ve internet kartı türüne bağlı olarak değişmektedir.



Şekil 4.9. Modbus Tcp/Ip veri paketi

4.1.2.6. Teleservis haberleşme

- Anten ve sim kart aracılığı ile kablosuz bağlantı sağlar.

4.2. Endüstriyel Haberleşme Standartları

Bu çalışmada bahsi geçen döküm fabrikasındaki verileri toplamak için OPC UA haberleşme standardı kullanılmıştır. OPC UA (OLE for process control unified architecture), ham verilerin ve önceden işlenmiş bilgilerin üretim sahasından üretim planlama sistemlerine güvenilir şekilde taşınabilmesi için geliştirilmiş bir OPC Foundation teknolojisidir (Cavalieri ve Cutuli, 2010).

Günümüzde endüstriyel alanda her türden makinelerin farklı marka ve model adı altında makine-makine, makine-insan ve CRM (customer relationship management) sistemleri ile sürekli iletişim sağlayabilmeleri gerekmektedir. Gelişen endüstri ortamında sahada kullanılan makinelerin, cihazların gelişmesiyle birlikte bu sistemler arasında haberleşme sağlanması da gittikçe karmaşık hale gelmeye başladı. Aynı marka ve model ürünlerin kendi kapalı

devre çözümleri bulunsa da farklı marka ve modeller söz konusu olduğunda özel haberleşme standartlarına ihtiyaç duyulmaktaydı. Mevcut çözüm ise sadece ilgili marka ve model için geçerli olmaktaydı. Marka ve modellerden biri bile değişirse aynı çözümün tekrarlanması gerekliliği doğmaktaydı. Bununla birlikte oluşturulan çözümü içeren marka ve modellerin sürücüleri güncellendiği takdirde bu çözümün de güncellenmesi gerekliliği oluşabilmekteydi. Tüm bu oluşan mühendislik maliyetlerinden ve zaman kaybından kaçınabilmek amacıyla 1995 yılında Fisher-Rosemount, Rockwell Software, Opto 22, Intellution ve Intuitive Technology şirketleri önderliğinde bir vakıf kuruldu (Schwarz ve Börösök, 2013).


Vakfın amacı, otomasyon verilerine standartlaştırılmış erişim sağlayan aygıt sürücüleri için bir tak ve çalıştır standardı tanımlamaktır. Sonuç olarak 1996 yılında OPC (OLE for process control) adıyla bir standart duyuruldu. Önemli özelliklere ve temel Windows teknolojilerinin kullanımına odaklanmak, ele alınan kullanım durumu için standardın hızlı bir şekilde benimsenmesini sağladı.

OPC bir protokol değildir. Microsoft'un OLE/COM (object linking and embedding/component object model) modeline dayanan, farklı uygulamalar arası haberleşmeyi hedefleyen, nesneye yönelik teknolojiye sahip bir haberleşme standardıdır. Önemli özelliklere ve temel Windows teknolojilerinin kullanımına odaklanması, ele alınan kullanım durumu için standardın hızlı bir şekilde benimsenmesini sağladı.

Derneğin oluşturduğu bu yeni standart ile birlikte birçok yazılım, donanım ve endüstriyel kontrol cihazları üreten firmaların kendi bünyelerindeki kapalı devre çözümlerine esnek yapıda bir alternatif sağlanmış oldu. Bu sonuçlar ile birlikte OPC foundation'ın Classic OPC ve OPC UA standartları, makineler arası iletişimi marka, modelden bağımsız hale getiren standartlar olarak kabul görmüştür.

4.2.1. OPC Classic

OPC veri kaynağı ile veri depolama birimleri arasında köprü vazifesi görür. Bu görevi gerçekleştirirken de her iki birimin birbirlerinin iç yapıları hakkında bilgi sahibi olmaları gerekliliğini ortadan kaldırır. Bununla birlikte donanımlar arasındaki haberleşmeler için de üreticilere olan bağımlılığa son vermiş olur. Kısaca OPC standardını destekleyen ürünler birbirleri ile doğrudan haberleşme imkanı bulmuştur.



Şekil 4.10. OPC klasik haberleşme şeması

OPC Classic standartları ele alınırken OPC server/client yapısının üzerinde durulmalıdır (Şekil 4.10). OPC sunucular (server) cihazların kendisine ait kapalı devre haberleşme sistemleri ile OPC ortamının iletişim kurabilmesini sağlayan tercümanlar olarak düşünülebilir. OPC sunucusunun görevi, OPC istemcinin istekleri doğrultusunda cihazdan aldığı bilgiyi istemciye ulaştırmak veya istemcinin göndermiş olduğu bilgiyi cihaza iletmektir.


OPC istemciler ise ilgili SDK ile tasarlanmış uygulamalar ve uygun OPC sunucular arasındaki iletişimden sorumludur. OPC istemci istekleri sunucuya gönderir ve sunucudan dönen dataları ise uygun formatta ilgili uygulamaya aktarır. Platform bağımlıdır. Microsoft altyapısı kullandığı için farklı işletim sistemlerine uyumlu değildir.

Zamanla, OPC bir standartlar bütünü haline almıştır. Bu standartlar;

- OPC DA (Data Access)
- OPC AE (Alarm/Event)
- OPC HDA (Historical Data Access)
- OPC Security
- OPC XML

4.2.1.1. OPC DA (Data Access)

Gerçek zamanlı veri akışından sorumludur. Verilerin okunmasını, yazılmasını ve izlenmesini sağlar. İzleme için tercih edilen yol sunucudaki değer değişikliklerinin izlenmesidir (Şekil 4.11).




Şekil 4.11. OPC DA

4.2.1.2. OPC A/E (Alarm/Event)

Cihazda oluşabilecek alarm ve tetiklenmelerin tespitinden ve değişikliklerinden sorumludur. Bildirimleri almak için, OPC Alarm/Event istemcisi sunucuya bağlanır, bildirimlere abone olur ve sunucuda tetiklenen tüm bildirimleri alır. Bildirim sayısını sınırlamak için, OPC istemcisi belirli filtre ölçütlerini belirtebilir.

OPC istemcisi, ilk adımda Alarm/Event sunucusunda bir OPCEventServer nesnesi oluşturarak ve ikinci adımda olay mesajlarını almak için kullanılan bir OPCEventSubscription oluşturarak bağlanır (Şekil 4.12). Bu olay iletileri için filtreler her abonelik için ayrı ayrı yapılandırılabilir.



Şekil 4.12. OPC A/E

4.2.1.3. OPC HDA (Historical Data Access)

OPC DA gerçek zamanlı datalarla ilgilenirken, OPC Historical Access geçmişe ait verilerin okunması işlemlerinden sorumludur. OPC istemcisi, HDA sunucusunda bir OPCHDAServer nesnesi oluşturarak bağlanır. Bu nesne, geçmiş verileri okumak ve güncellemek için tüm arabirimleri ve yöntemleri sunar. HDA sunucusunun adres alanına göz atmak için bir OPCHDABrowser nesnesi tanımlanır. 3 farklı şekilde okuma yapabilir.

- Tek bir tarih veya tarih aralığı ile,
- Tarih aralığı ve bir veya daha fazla değişken değeri aracılığı ile,
- Tarih aralığı, bir veya birden fazla değişken değeri aracılığı ile çekilen geçmiş verilerin toplam değerleri ile,

OPC HDA, okuma yöntemlerine ek olarak, geçmiş veri tabanına veri ekleme, değiştirme ve silme işlemlerini de gerçekleyebilir.

4.2.1.4. OPC Security

Bağlantı güvenliğinden sorumludur. OPC Classic, Microsoft tabanlı bir iletişim protokolü olan ve güvenlik özellikleri bulunan DCOM/COM aktarımının üzerine


kurulmuştur. OPC Classic standardı kısacası Windows işletim sistemleri ailesinin sağladığı güvenliğe güvenir.

4.2.1.5. OPC XML DA


COM/DCOM yerine HTTP/SOAP ve web service teknolojileri kullanan ilk platformdan bağımsız OPC spesifikasyonudur. Ancak yüksek kaynak tüketimi nedeniyle beklenildiği kadar başarılı olamamıştır.

4.2.2. OPC UA (Unified Architecture)

Klasik OPC'nin önde gelen halefi olan OPC UA, 2004 yılında yolculuğuna başladı ve ilk endüstri uygulamaları 2009 yılında kullanıma sunuldu. Birleşik mimari adı, farklı OPC teknik özelliklerini tek bir çatı altında birleştirmek anlamına gelir. OPC UA, bilgi güvenliği, platform bağımsızlığı ve gelişmiş bilgi modelleme açısından OPC Classic'in bir evrimidir. Geleneksel Windows tabanlı bilgisayarlardan Linux sistemlerine veya mobil platformlara kadar farklı işletim sistemlerine ve ortamlara dağıtılabilir. Dolayısıyla platformlar arası bir protokoldür ve bu nedenle herhangi bir işletim sistemine veya programlama diline bağlı değildir. Bu da çok hızlı bir şekilde benimsenmesini sağlayan önemli faktörlerden biridir. OPC-UA mevcut OPC sunucularının tüm standartlarını bünyesinde bulundurur ve bunların üstüne geliştirilmiştir. Yeni ve büyük başarısı, basit veri türü bilgilerinin ötesinde daha üst düzey bir veri modelidir. İyi bilinen OPC COM ve XML spesifikasyonlarının evrimi olan bu yapı yeni teknolojileri ve konseptleri endüstriyel uygulamalara entegre etmek için önemli bir araçtır. Güçlü meta modeli, açık ve standartlaştırılmış hizmet odaklı mimari ve farklı türdeki OPC sunucularını birleştirme yeteneği yeni uygulama alanlarının kapısını açma potansiyeli taşır (Şekil 4.13).



Şekil 4.13. OPC UA mimarisi (Mahnke vd., 2009)



Şekil 4.14. OPC UA haberleşme standardı

Mevcut haliyle, OPC UA uygulamaları otomasyon verilerine erişmek için çoğunlukla ikili kodlama ve UA TCP adı verilen TCP aktarım protokolünü kullanmaktadır.

Yazılımın kimlik doğrulaması ve verilerin şifrelenmesi yoluyla gelişmiş bilgi güvenliği artık süreç kontrolünde kritik gereksinimlerdir ve OPC UA bu özelliklere sahiptir. Güvenliğin arttırılmasına yönelik olarak sertifika modeli uygulanmıştır. Bu sertifika aracılığı ile kimliği belirli uygulamaların belirli portlardan kontrollü olarak erişimlerine izin verilir (Şekil 4.14).



Şekil 4.15. OPC UA katman mimarisi

FDT (filed device tool) ve EDDL (electronic device description language) gibi diğer standartlar OPC UA'dan yararlanacak ve OPC UA üzerinden erişilebilen etki alanına özgü bilgi modeli için tamamlayıcı özellikleri tanımlayacaktır (Şekil 4.15). Classic OPC'ye kıyasla OPC UA'yı bir uygulamaya entegre etmek nispeten daha kolaydır. Klasik OPC ile protokolün kullanılması gereken her özelliği (DA, AE, HDA) için yeni bir sunucu veya istemci geliştirilmek zorundayken, OPC UA'da bunların hepsi birleştirilmiş durumda. Böylece OPC UA'da sadece bir defa nesne oluşturmak yeterli olmaktadır. Bu da uygulama kullanılabilirliğini arttırmakta ve OPC UA'yı bir ürüne entegre etmek için gereken süreyi kısaltmaktadır. Öte yandan OPC UA uygulamaları, akıllı alan sensörlerindeki küçük gömülü sunuculardan, büyük ölçekli bilgisayar sistemlerine kadar çok farklı ortamlarda çalışabileceğinden, kapsamı ve işlevleri bakımından çok farklı görevler üstlenebilir. Dolayısı ile problem bazlı olarak ölçeklenebilir bir yapıya sahiptir.

5. BAKIM YAKLAŞIMLARI

Üretim sistemlerinde verimliliği artırmanın en önemli koşullarından biri üretim sisteminin durmaksızın stabil olarak çalışmasını sağlamaktan geçer. Bu amaçla bakım yaklaşımları hayati öneme sahiptir. Beklenmedik anlarda oluşan arızaların bakımları plansız bakım, arıza oluşmadan önce yapılan ve arızanın önüne geçmeyi amaçlayan bakımlar ise planlı bakımlar olarak ele alınır. Şekil 5.1’de bakım yaklaşımları ve bu yaklaşımların verimliliğe etkileri gösterilmiştir.

Şekil 5.1’de gösterilen OEE (Overall Equipment Effectiveness) üretim verimliliğini ifade eder. OEE, herhangi bir ekipmanın veya tüm süreçlerin performans etkinliğini ölçmek için kullanılabilirlik, performans ve kalite unsurlarına dayalı nicel bir ölçüm sağlar (Tsarouhas, 2019).

Kullanılabilirlik (Availability – A) belirlenmiş zaman periyodu içerisinde (vardiya süresi, gün, ay, yıl) makine arızalarından kaynaklı duruşlar çıkarıldıktan sonraki toplam çalışma süresini ifade eder. Kısaca fiili çalışma süresinin toplam süreye oranını ifade eder (Denklem 5.1).

$$A = \frac{\text{Toplam Süre} - \text{Arıza Süreleri Toplamı}}{\text{Toplam Süre}} \quad (5.1)$$

Performans (Performance – PE) Makinenin/hattın net çalışma süresince gerçekleştirdiği üretimin ürünün çevrim süresi göz önünde bulundurularak üretebileceği üretime oranı olarak ifade edilebilir (Denklem 5.2).


$$PE = \frac{\text{Net Üretim Süresi}}{\text{Üretim Süresi}} = \frac{\text{Çevrim Süresi} \times \text{Üretim Miktarı}}{\text{Üretim Süresi}} \quad (5.2)$$

Kalite (Quality – Q) belirlenen zaman aralığındaki üretilmiş olan ürün içerisindeki hatalı üretimlerin, hurdaya ayrılanların toplam üretimden çıkarılması ile elde edilen net üretim sayısının toplam üretim sayısına oranı olarak ifade edilir (Denklem 5.3).

$$Q = \frac{\text{Üretim Adedi} - \text{Kusurlu üretim}}{\text{Üretim Adedi}} \quad (5.3)$$

Toplam Ekipman Etkinliği (Overall Equipment Effectiveness – OEE) kullanılabilirlik, performans ve kalite değerlerinin çarpımı olarak ifade edilir (Denklem 5.4).

$$\text{OEE} = \text{Kullanabilirlik} \times \text{Performans} \times \text{Kalite} = A \times PE \times Q \quad (5.4)$$



Şekil 5.1. Bakım türleri (Çınar vd., 2020)

5.1. Arızı (Düzeltilici) Bakım (Reactive Maintenance)

Arızı bakımında sistem arızalandıktan sonra tekrar çalışır hale gelebilmesi için onarımlar yapılır (Özgür-Ünlüakın vd., 2019). Beklenmedik bir anda oluşan arızadan hemen sonra sistemin tekrar eski durumuna dönebilmesi amacıyla yapılan tamirat ve onarım çalışmalarıdır (Oktar, 2014). Sistemde öncelikle bir arıza veya performans düşüşü beklenir. Bu gerçekleştikten sonra yapılan bakıma arızı veya reaktif bakım denir. Plansız bir bakım türüdür. Bakım maliyeti düşük olsa da yapılan üretime göre meydana gelen arıza süresi göz önüne alındığında genel verimliliği düşürebilir. Arıza oluştuğunda bakıma müdahale ve bakım

süresi önemlidir. Tespiti zor bir arıza veya tecrübesiz bakımcıların elinde bakım süresinin uzaması verimliliği olumsuz etkiler. Ayrıca yedek parça ihtiyacı söz konusu olduğunda depoda bu parça bulunmuyor ise tedarik süreci ile birlikte bu süre daha da uzayabilir. Bununla birlikte oluşan arızanın başka arızaları tetikleyebilme ihtimali de vardır. Tüm bu potansiyeller göz önünde bulundurulduğunda arıza bakımların maliyetlerinin yüksek olduğu söylenebilir.

5.2. Periyodik Bakım

Bu yaklaşımın amacı, arıza oluşmadan önce makinenin arızalanmasına sebep olabilecek bileşenlerinin bakımının yapılmasıdır (Gedikli vd.,2021). Çok sık yapılırsa işletme maliyetlerini artıran gereksiz bakımlara yol açabilir.

Üretim alanlarında bakım planlama biriminin belirlemiş olduğu, yağlama, parça değişimi gibi sistemin genel kontrollerinin yapıldığı düzenli olarak gerçekleştirilen bakımlardır. Sağlıklı bir planlama yapıldığı takdirde endüstride kullanılabilecek uygunlukta ve üretimin sürekliliğini artıran bir yaklaşımdır (Calayır vd.,2021).

Endüstriyel ortamlarda en sık görülen bakım stratejilerindendir. Bakımı yapılacak ekipmanın belirli zaman veya üretim periyoduna göre düzenli olarak bakıma alınması esasına dayanır. Bu zaman dilimi hesaplanırken optimum zaman periyodunun belirlenebilmesi için ekipmanın iyi tanınması gerekir. Burada zaman periyodları belirlenirken minimum plansız bakım oluşmasının sağlanmasına gayret edilir. Periyodik koruyucu bakımın uzun aralıklarla yapılması plansız duruşlara neden olacağı gibi, kısa aralıklarla yapılması da bakım maliyetlerinin artmasına sebebiyet verecektir.

Ekipman veya ekipman parçalarında belirli zaman periyodlarında kullanımdan bağımsız oluşabilen bozulmalar söz konusu olduğunda zamana dayalı periyodik bakım uygulanabilirken, makinenin sadece çalıştığı süre baz alınarak yapılan zamana dayalı periyodik bakımlar da söz konusudur. Böylece ekipmanın çalışmadığı süre periyodik bakım için kalan süreyi etkilemez. Bu yöntemin uygulanabilmesi için ekipmanın çalıştığı ve duruşta olduğu durumları takip edip

kayıt altına alma gerekliliği mevcuttur. Bununla birlikte üretim adetleri bilgileri kayıt altında tutulduğunda ise üretim adedine dayalı olarak belirli bir üretim adedine ulaşıldığında periyodik bakım gerçekleştirilebilir.

5.3. Duruma Dayalı Bakım (CBM)

Duruma dayalı bakımın (CBM) makine bakım stratejisini geliştirmek için etkili bir yöntem olduğu genel olarak kabul edilmektedir. Klasik bir yaklaşım olan arızalandıktan sonra bakım yapılan uygulamalardan, arıza gerçekleşmeden önce önleme yaklaşımına geçiş için etkili bir yöntem olduğu genel olarak kabul edilmektedir. Arızı bakım, sistemde arıza meydana geldiğinde yapılırken, kestirimci bakım, sistemde beklenmeyen arızaları önlemek amacıyla ardışık revizyonları planlamak için istatistiksel makine bilgisini ve operasyonel deneyimi kullanır (Tahan vd., 2017).

Duruma dayalı bakımda makine sürekli izlenir. Belirli parametreler için eşik değerler aşıldığı takdirde bakım yapılır. Periyodik bakımdaki gibi düzenli aralıklarla bakım yapılmaz. Uygulanabilmesi için kritik olan parametreler belirlenir ve takibi yapılır. İlgili parametreler belirlenmiş olan üst ve alt eşik değerlerini aştığı takdirde bakım uygulanır. Aksi halde herhangi bir bakım çalışması yapılmaz.

5.4. Önleyici Bakım (Proaktif Bakım)

Arızaların kök nedenlerini tespit etmek ve ortadan kaldırmak için gerçekleştirilen bakım faaliyetidir. Kestirimci bakım ve önleyici bakım tanımları göz önünde bulundurulduğunda, kestirimci bakımın veri odaklı bir strateji olduğu, önleyici bakımın ise model tabanlı bir çözüme odaklandığı söylenebilir (Wang vd., 2020).

Önleyici bakımın amacı arızaya sebebiyet veren etkenleri mümkün olduğunca ortadan kaldırmaya yöneliktir. Tüm arızaların ortadan kalkması pek mümkün olmasa da plansız bakımların sayısını minimuma indirmeye yardımcı olur. Bu tür

bir bakımda da önleyici bakımın uygulanabilmesi için yine ekipmanın iyi tanınması gerekmektedir. Örneğin nemden kaynaklı bir arıza oluşması söz konusu ise ekipmanların nemden arındırılması veya çalışma ortamının nem oranının kontrol altına alınması önleyici bakım kapsamındadır. Bu sayede nemden kaynaklı arızaların gerçekleşmesinin önüne geçilmiş olur.

5.5. Kestirimci Bakım (Predictive Maintenance)


Kestirimci bakım, sistemlerin en olası arıza sonucunu tahmin etmek için verilerin, makine öğrenme tekniklerinin ve istatistiksel algoritmaların kullanılması olarak adlandırılır (Kimera ve Nangolo, 2020). Kestirimci bakım, bir makinenin sağlıklı çalışıp çalışmadığını tahminleme ve sensörler veya akıllı kontrol cihazları ile elde edilen verileri makine öğrenimi algoritmalarıyla modelleyerek, bakım çalışmaları ile ilgili en iyi kararı verme süreci olarak tanımlanır (Özkat, 2021). Kestirimci bakımın özü, bir sonraki arızayı, arıza meydana gelmeden önce tahmin etmektir (Ayvaz vd.,2021).

Bir ekipmanın sağlık durumuna ilişkin tahmine dayalı olarak bakımının yapıldığı kestirimci bakım sistemleri, geçmiş veriler, tanımlanmış sağlık faktörleri, istatistiksel çıkarım yöntemleri ve mühendislik yaklaşımlarına dayalı tahmin araçları sayesinde, arızaların önceden tespit edilmesine ve arıza öncesi müdahalelere olanak tanır (Çınar vd., 2020).

Periyodik bakımın dezavantajlarından biri ekipmanlar daha uzun süre arızalanmadan işleyişine devam edebilecek ve sistem çalışmasını sürdürebilecek durumda olsa bile bakım yapılmasıdır. Bu da bakım maliyetlerini artırır. Bununla birlikte bakım esnasında üretim yapması gereken hat, bu süreyi bakımda geçirdiği için bu hattın verimliliği düşer.

Endüstri 4.0 kavramı ile birlikte makinelerin/hatların gerçek zamanlı olarak izlenebilirliği sağlanabilmektedir. Sensörler aracılığı ile hattın çeşitli bilgileri gerçek zamanlı olarak izlenerek bakım yapılması gerekip gerekmediği öngörülebilir (Bektaş O., 2020). Kestirimci bakımın amacı sensörler aracılığı ile

sistemin çeşitli bileşenlerini takip ederek, kalan faydalı ömrü tespit edip bakımın gerekip gerekmediğini öngörmektir. Şekil 5.2’de sistem şartlarına göre uygulanabilecek bakım türleri ve zamanları gösterilmiştir.




Şekil 5.2. Bakım türleri ve uygulama zamanları (Sirvio, 2015)

6. KESTİRİMCİ BAKIMDA MAKİNE ÖĞRENMESİ

Yapay zekanın bir alt dalı olan makine öğrenmesi, doğrudan programlama yapmadan, bunun yerine verilerden sisteme öğrenme ve öğrendiklerini geliştirebilme becerilerini kazandıran bir disiplindir.

Makine öğrenimi verilerin yapısını keşfetmek, kullanıcılar tarafından anlaşılabilen ve kullanılabilecek modellere uyum sağlamak için kullanılan örüntü tanıma algoritmalarıdır. Geçmiş verileri kullanarak bir bilgisayar programının nasıl oluşturulacağı, verilen bir sorunun nasıl çözüleceği ve programın verimliliğinin otomatik olarak nasıl iyileştirileceği sorusuna deneyimle cevap verir. Son yıllarda astronomide yapıları sınıflandırmak, bankacılık ile ilgili dolandırıcılık girişimlerini tespit etme, kullanıcıların okuma ve izleme alışkanlıklarının tespiti, nörobiyolojik çalışmalar, şoförsüz olarak gidebilen araç geliştirilmesi gibi alanlarda makine öğreniminden faydalanılmaktadır (Shobha ve Rangaswamy, 2018).

Her gün büyük miktarda veri üretilir ve paylaşılır. Anlamlı sonuçlar elde etmek için bu kadar büyük miktarda veriyi analiz etmek zahmetli bir iştir ve manuel olarak uygulamaya çalışmak imkansızdır. Verileri analiz ederek geliştirilen yöntemler ile kalıplar bulup buradan anlamlı sonuçlara ulaşmak herhangi bir uygulama alanının bilinçli kararlar alabilmesi için gereklilik arz eder. Ancak daha iyi tahminler yapmak için rastgele orman, lojistik regresyon, destek vektör makinesi ve kümeleme algoritması gibi denetimli veya denetimsiz çeşitli makine öğrenme algoritmalarını uygulamak mümkündür (Chazhoor vd., 2020).



Şekil 6.1. Makine öğrenme teknikleri (Shobha ve Rangaswamy, 2018)


Makine öğrenme teknikleri;

- Denetimli (Supervised) Öğrenme
- Denetimsiz (Unsupervised) Öğrenme
- Yarı-Denetimli (Semi-Supervised) Öğrenme
- Pekiştirmeli (Reinforcement) Öğrenme

olarak gruplandırılır (Şekil 6.1).


Denetimli (Supervised) Öğrenme; makine öğrenimi etiketli veriler kullanılarak gerçekleştirilir. Denetimli makine öğreniminde bağımsız verilerle birlikte bağımlı değişken de verilerek eğitim sağlanır (Şekil 6.2). Oluşturulan bu model daha sonra verilen bağımsız değişkenleri kullanarak hedef değişkeni tahmin eder. Sınıflandırma ve regresyon amaçlı kullanılır. Doğrusal regresyon (linear regresyon), karar ağaçları (decision tree), naïve bayes, lojistik regresyon (logistic regression), destek vektör makineleri (support vector machines) gibi denetimli makine öğrenmesi algoritmaları mevcuttur. Popüler uygulama alanlarından bazıları banka kredisi puanlandırma, konuşma tanıma uygulamaları, kanser teşhis çalışmaları, tıbbi görüntüleme teknolojileri, el yazısı tanıma, harf ve rakam tanıma, e-posta güvenlik uygulama çalışmalarıdır.

Sınıflandırmada verilen bir örneğin model eğitiminden sonra öğrenilen sınıflanlardan hangisine ait olduğunu tahmini söz konusudur. Regresyon ise gözlemlenen verilerle bir denklem uydurarak iki değişken arasındaki korelasyonu modellemeyi amaçlamaktadır.



Şekil 6.2. Denetimli öğrenme akış diyagramı


Denetimsiz (Unsupervised) Öğrenme; etiketlenmemiş, belirsiz veriler üzerinde çalışır. Veriler etiketli olmadığından bu verileri kümeleyerek anlam çıkarmayı amaçlar (Şekil 6.3). Bu yöntemde algoritma verilerdeki dikkat çekici yapıyı keşfetmek için kendi icraatlarını bir denetim olmadan uygular (Mahesh, 2020). K-ortalamlar (k-means), k-en yakın komşu (k-nearest neighbour), apriori algoritması, temel bileşenler analizi (principal component analysis) birer denetimsiz makine öğrenme algoritmalarıdır.



Şekil 6.3. Denetimsiz öğrenme akış diyagramı

Yarı-Denetimli Öğrenme; denetimli ve denetimsiz öğrenme tekniklerini içerisinde barındırır. Etiketlenmemiş büyük miktarda veri ile birlikte etiketlenmiş küçük miktarda veriyi kullanan bir yaklaşımdır. Belirli bir veri seti için az sayıda etiketli veri kullanılmış ise uygulanabilir. Etiketlenmemiş olan veri sayısı etiketli veri sayısından önemli ölçüde büyük olması durumundaki senaryolarda kullanılması makuldur. Aksi halde bu problem doğrudan denetimli öğrenme yöntemi ile çözülebilir. Bu yöntemin amacı etiketlenmiş verilerden yola çıkarak etiketlenmemiş olan verilerin bir kısmını sınıflandırmaktır.


Pekiştirmeli (Reinforcement) Öğrenme; deneme yanılma yolunu benimseyerek başarıya ulaşmayı hedefleyen bir yöntemdir. Bu öğrenme biçiminde ajan çevresini ölçebilir ve buna göre bir aksiyon alabilir. Bu aksiyona karşılık bir tepki bekler ve bu tepkiler ödül sistemi içerisinde değerlendirilir. Kazanılan ödül baz alınarak ajan eğitilmiş olur. Ödül-ceza sistemini baz alan bir yaklaşımdır (Şekil 6.4).



Şekil 6.4. Pekiştirmeli öğrenme akış diyagramı

6.1. Rastgele Orman (Random Forest)

Bu yöntem, birçok özelleşmiş karar ağacının birleşimi olarak ifade edilebilir. Girdi-çıkı ilişkisi, makine tarafından deneysel veriler yardımıyla belirli güven aralıklarında öğrenilir. Tahmin modelinin başarısı, makine tarafından yeterli öğrenme sağlandıktan sonra doğrulama verilerinin test edilmesiyle belirlenir.




Şekil 6.5. Rastgele orman

Şekil 6.5'te gösterilen her ikili düğüm tek bir özelliğe göre belirlenir ve her dal tahminin sağlandığı bir terminal düğümde biter. Düğümden sonraki dallanmalar

ormandaki ağaçları temsil eder. Bu yapıdaki verilen test veri setine göre yapılan nihai tahmin tüm tek ağaçların tahminlerinin ortalamasına dayanır (Sarica vd., 2017).

Breiman tarafından önerilen rastgele orman yaklaşımı, birçok karar ağacına sahip bir makine öğrenme algoritmasıdır. Torbalama ve rastgele alt uzaylar yöntemlerinin bir birleşimidir. Bu yöntem son yıllarda hem regresyon hem de sınıflandırma problemlerinde başarısını kanıtlamış ve birçok farklı alanda kullanılan en iyi makine öğrenmesi algoritmalarından biridir. RO algoritmasında veri seti öncelikle, öğrenme eğitim verisi (in-Bag) ve öğrenme düzeyini test etmek için test verisi (out of bag) olmak üzere rastgele iki kısma ayrılır. Daha sonra, veri setinden rastgele birçok karar ağacı oluşturulur. Her ağacın dallanması, düğüm noktalarında rastgele seçilir. RO nihai tahmini, her bir ağaçtan elde edilen tüm sonuçların ortalamasıdır. Bu nedenle, her bir ağaç belirli ağırlıklarda RO tahminini etkiler. Bu yöntemde her ağaç tek tek incelenmez. RO algoritması, alt kümelerden rastgele eğitim verisi alma ve rastgele algoritma ile ağaç oluşturma özelliğinden dolayı diğer makine öğrenmesi algoritmalarından daha güçlüdür (Yeşilkanat, 2020).



Şekil 6.6. Rastgele orman makine öğrenmesi (Verikas vd., 2016)

Toplu sınıflandırıcılar arasında en yaygın kullanılan algoritmalarından olan RO, aynı zamanda hızlı çalışma yeteneğine sahiptir ve aşırı öğrenme problemine karşıdayanıklıdır. Çalışılacak ağaç sayısı belirlenebilir.


RO algoritmasında en iyi bölünmeyi tespit edebilmek için her bir düğümde kullanılan değişkenlerin sayısı “m” ve oluşturulacak ağaç sayısı için “N” olmak üzere 2 parametre seçimi yapılır. Her bir düğüm noktasında “m” değişkeni rastgele olarak belirlenir ve bunlar arasındaki en iyi dal belirlenmiş olur (Şekil 6.7). RO ağaç üretmek için CART (Classification and Regression Tree) algoritmasından faydalanır. Her bir düğümde dallar bu algoritmanın kriterleri (örneğin GINI indexsi) baz alınarak oluşturulur. (Akar ve Güngör, 2012).

Rastgele orman algoritması adımları;

Adım 1: Veri setinden rastgele örnekler seçilir.

Adım 2: Seçilen her örnek için bir karar ağacı oluşturulur. Ardından oluşturulan her bir karar ağacı tek tek ele alınarak bir tahmin sonucu elde edilir (Şekil 6.6).

Adım 3: Eğer problem bir sınıflandırma problemi ise mod , regresyon problemi ise ortalama kullanılarak hesaplama yapar.



Şekil 6.7. Rastgele orman algoritması (Lin vd., 2017)

Rastgele orman algoritmasını tıp, bankacılık, tarım, e-ticaret gibi alanlarda sıklıkla kullanılmaktadır. Bankacılık sektöründe müşterilerin ödeme alışkanlıkları baz alınarak risk teşkil eden müşterilerin tespitinde kullanılabilmektedir. Tıbbi alanda ilaç endüstrisindeki ilaç etken maddelerin doğru kombinasyonlarını tespit edebilmek amacıyla kullanılabilmektedir. Bununla birlikte hastalık tanımlama alanında da sıklıkla kendisine yer bulabilmektedir. Hisse senetlerinin davranışlarının tespiti ve olası kar zarar tahminleri alanlarında kullanılabilmektedir. E-ticaret alanında ise müşteri davranışları gözlemlenerek tavsiye edilecek ürünlerin müşterilerin beğenisini kazanıp kazanamayacağı hakkında fikir oluşturabilmektedir.

Rastgele orman algoritması kullanılarak eğitim veri seti içerisindeki en önemli özellikler tanımlayabilmek de bu yöntemin yetenekleri arasındadır.


6.2. Temel Bileşenler Analizi (Principal Component Analysis)

Birçok özelliğe sahip büyük veri kümelerinde bilgilerin çoğunu korurken bir dizi boyut küçültme tekniği kullanılarak değişkenlerin sayısını azaltmak mümkün olabilmektedir. Bunlar arasında en yaygın kullanılanı temel bileşenler analizidir (TBA) (Lauro ve Palumbo, 2000).

Karl Pearson'un 1901 yılında yaptığı temel bileşenler analizi çalışmaları, Hotelling tarafından 1933 yılında geliştirilmiştir (Yazar vd., 2009).

Temel bileşenler analizi, birçok değişkenden oluşan bir veri setinde bulunan bilgiyi daha az değişkenle ve minimum bilgi kaybıyla ifade etmeye çalışan bir tekniktir. Büyük boyutlu veri setleri içindeki boyutsallığı azaltır. Böylece minimum kayıpla boyut indirgenmiş olur. Üç amacı vardır; verilerin boyutunu azaltma, tahminleme, veri seti boyutunu küçülterek analiz yapılması amacıyla görüntülemektir.

PCA hesaplaması esnasında elde edilen eigen (öz) vektör anomali tespiti için kullanılabilir. Bunun için test verisinin eigen vektörlerinin temel bileşenler düzlemi üzerindeki mesafeleri dikkate alınır. Belli bir sınır değerinin üzerindeki mesafeler anomali olarak değerlendirilebilir.



Şekil 6.8. PCA

7. MATERYAL VE YÖNTEM

Teknolojik gelişmeler ile son yıllarda veriye erişim şekillerinde de değişiklikler meydana gelmektedir. Geçmişte sınırlı cihazlardan veri alınabiliyorken, nesnelerin interneti kavramının hayatımıza girişiyle birlikte bugün çok çeşitli cihazlardan veri alınabilmektedir. Sadece kullanıcı girişleri ile elde edilen bilgiler değil, cihazlarla doğrudan haberleşerek gerçek zamanlı bilgiler elde edilebilmektedir. Bununla birlikte cep telefonları, giyilebilir teknolojiler (akıllı saatler, akıllı gözlükler, sensör teknolojileri...) de günlük hayatın vazgeçilmez bir parçası haline gelmiştir. Özellikle endüstriyel ortamlarda sensörler aracılığı ile alınabilen veriler bize geniş bir çalışma alanı sunabilmektedirler.

Bir kestirimci bakım uygulaması yapılabilmesi için öncelikle ilgili makinenin verileri sensörler ve diğer akıllı kontrol sistemlerine erişim aracılığıyla alınabilmelidir. Bu uygulamada döküm makinesinin verilerinin toplanabilmesi için bir Siemens PLC S7-1200 kullanılmıştır.

7.1. Veri Toplama


PLC aracılığı ile makinenin bilgileri anlık olarak kaydedildi ve veri seti olarak hazırlandı. Bu çalışmada makineden, çalışma durumu, üretim sayısı (adet), üretim miktarı (kg), ürün üretim süresi, mikser motor durumu, reçete yükleme numarası, mikser motor titreşim, mikser sıcaklık, mikser hızı (rpm), mikser basınç, akım faz1, akım faz2, akım faz3, belirlenmiş 8 adet alarm durumu, tarih/saat gibi bilgiler alınmıştır. Aynı anda birden fazla alarm gelebildiğinden dolayı her alarm tipi için farklı bir alan belirlenmiştir.

Çalışma kapsamında geliştirilmiş olan veri toplama sistemi, üretim ve bakım süreçlerini kapsayan anahtar performans göstergeleri dahil olmak üzere belirlenen veri setlerinin Endüstri 4.0 mimarisine uygun şekilde OPC UA protokolü ile gerçek zamanlı olarak makine kontrol sistemlerinden (PLC) toplanmasını sağlar. Bu bağlamda veri toplama ekipmanları IBOX akıllı veri toplama mimarisi oluşturulmuş ve hedef veri kaynaklarına çevrim içi bağlantı

kurarak verilerin merkezi olarak arşivlenmesi gerçekleştirilmiştir. Ayrıca oluşturulan bu veri setinde ihtiyaç duyulan ve PLC içerisinde yer almayan duruş tipleri KIOSK aracılığı ile operatörler tarafından girişi yapılarak alınması sağlanmıştır (Şekil 7.2).

7.1.1. Veri toplama mimarisi


Veri toplama mimarisinde IBOX veri toplama pano ekipmanları ile gerçek zamanlı endüstriyel haberleşme özelliklerine sahip akıllı bir veri toplama sistemi kurgulanmıştır. Donanım bileşenleri endüstriyel ekipmanlardan oluşturularak gerçek zamanlı haberleşmeyi destekleyen ürünler tercih edilmiştir.



Şekil 7.1. Saha seviyesi veri toplama mimarisi

Döküm makinesinin verileri Siemens S7-300 PLC içerisindeki datablock yapılarında mevcutken bu PLC ve OPC-UA standardı ile haberleşme şansı olmadığından hali hazırda bünyesinde OPC-UA desteği ile gelen S7-1200 model PLC IBOX içerisine yerleştirilmiş ve S7-300 ile S7-1200 model PLC'ler arasında bağlantı sağlanarak bilgilerin bu yeni nesil PLC'ye aktarımı sağlanmıştır. S7-1200 PLC ile endüstriyel PC üzerinde çalışan veri toplama servisi de OPC-UA standardı ile haberleşerek verilerin sunucuya kaydedilmesini sağlamıştır.

Sistemin otomasyon teknolojileri tarafındaki kontrolünden sorumlu cihaz olan PLC S7-300 ile OPC UA aracılığı ile doğrudan haberleşme sağlanamayacağından PLC S7-300 ile PLC S7-1200 arasında S7 bağlantı protokolü ile haberleşme sağlanmıştır. Bu çalışma için ihtiyaç duyulabilecek veriler PLC üzerinden bu haberleşme protokolü ile PLC S7-1200'e taşınmıştır. Şekil 7.1'de de görüldüğü üzere elde edilen veriler PLC-1200 üzerinde toplanmış ve OPC UA destekli bu PLC (S7-1200) ile haberleşen endüstriyel bir bilgisayar üzerinde çalışan veri toplama servisi aracılığı ile saniyede bir bu veriye erişecek şekilde kodlanarak merkezi sunucu üzerindeki veri tabanına yazılmıştır.



Şekil 7.2. Uygulama çalışma şablonu

7.1.2. Veri toplama sistemi donanım özellikleri

Veri toplama sistemi Endüstri 4.0 konseptindeki yeni nesil veri toplama donanım bileşenlerinden oluşturulmuştur.

- S7-1200 PLC,
- Endüstriyel PC (Data Collection Box PC) Intel® Pentium® N4200 2.5 GHz, 2 HDMI, 2 GbE LANs, 6 USB 12V/36W AC/DC adapter and EU power cord, Win 10 IoT OS,

- Endüstriyel Güvenlik Duvarı,
- 5 x port endüstriyel ethernet switch,
- 5A endüstriyel güç kaynağı,

birimleri tek bir panelde toplanmış ve IBOX olarak adlandırılmıştır. Bunun dışında döküm makinesine ait kontrol sistemi olan Siemens S7-300 PLC ve toplanan verilerin kaydedildiği bir sanal sunucu kullanılmıştır.



Şekil 7.3. IBOX endüstriyel panel

Bu IBOX'lar ile ethernet tabanlı kablolu veya kablosuz olarak, Profinet ve TCP/IP bağlantı ile bağlantı kurulabilir. Bu proje kapsamında döküm makinesinin kontrol sistemi ile mevcut IBOX içerisindeki veri toplama sistemi arasında profinet ile bağlantı sağlanmıştır.


7.1.3. Veri toplama sistemi uygulama özellikleri

Veri toplama mimarisi Endüstri 4.0 temelinde bulunan haberleşme ve uygulama özelliklerini taşıyan platformlar ile geliştirilmiştir. 2 Farklı PLC'nin haberleşmesinde kullanılmak üzere günümüz endüstriyel otomasyon teknolojilerinde en uygun seçeneklerden biri olan Siemens TIA Portal V16 STEP 7 PLC yazılım geliştirme mühendislik platformu kullanılmıştır. Endüstriyel PC ile S7-1200 arasındaki veri akışı için de .NET tabanlı bir uygulama çalışmaya özel olarak yazılmıştır.

7.1.3.1. TIA Portal


TIA (Totaly Integrated Automation) portal platformu Siemens'in PLC kontrol sistemlerini HMI panellerinin yazılım projelerinin geliştirilmesi için kullanılan bir mühendislik portalıdır. Projede en güncel versiyon olan V16 TIA portal sürümü kullanılarak veri toplama PLC S7-1200 kontrol ünitesi ile üretim hattında mevcut bulunan S7-300 PLC kontrol ünitesi haberleşmesi sağlanmış, makine sensör verilerine erişim için programlanmıştır. Ayrıca S7-1200 PLC kontrol ünitesine entegre olarak çalışan OPC UA sunucu aktifleştirilerek client olarak geliştirilecek OPC UA veri toplama servisinin erişimine açılmıştır (Şekil 7.4).

TIA portal platformu kullanılarak PLC kontrol üniteleri programlanarak istenen uygulama senaryosuna göre makine ve hatların kontrol edilmesi sağlanabilmektedir. Projede yer alacak sensör verileri veri blokları içinde istenen veri tipleri olarak tanımlanarak TIA portal donanım ve haberleşme için uygun olan ekipmanların tanımlanan veri blokları ile programlanmış ve PLC hafıza alanına programın yüklenerek devreye alınması sağlanmıştır. Sahada makinelere bağlı bulunan sensörlerin dijital veya analog sensör bağlantı tiplerini algılayabilen PLC kontrol ünitelerinde gelen sinyalleri sayısallaştırarak algılanması, istenen uygulama senaryosunda veri olarak gerçek zamanlı okunabilmesi ve arşivlenebilmesi amacıyla bu verilere erişilmesi sağlanmıştır.



Şekil 7.4. TIA portal platformunda S7-1200 üzerine alınmış verilerin gösterimi

Projede tüm veri kaynakları S7-300 makine PLC kontrol ünitesine bağlı olarak çalışmakta olup çalışan sisteme müdahale etmemek ve Endüstri 4.0 mimarisine uygun bir altyapı kurgusu oluşturmak adına yeni bir S7-1200 PLC kontrol ünitesi devreye alınmak suretiyle iki PLC haberleştirilerek, verilerinin toplanması ve arşivlenmesi sağlanmıştır.



Şekil 7.5. S7 Bağlantı protokolü

PLC S7-300 ile PLC S7-1200 arasında S7 bağlantı protokolü ile haberleşme sağlanmıştır. İhtiyaç duyulabilecek veriler PLC üzerinden bu haberleşme protokolü ile PLC S7-1200'e taşınmıştır (Şekil 7.5).


Bu sayede OPC UA teknolojisini desteklemeyen mevcut S7-300 PLC kontrol ünitesindeki mevcut sensör verileri OPC UA teknolojinin sahip yeni nesil bir S7-1200 PLC kontrol sistemi kullanılarak Endüstri 4.0 mimarisine uygun şekilde veri toplama sistemi kurulmuştur. S7-1200 PLC kontrol ünitesi üzerinde bulunan OPC UA sunucu özelliği açılarak haberleşmeye hazır hale getirilmiştir. TIA Portal OPC UA sunucu arayüzünde haberleşmek istenilen veri setleri tanımlanarak OPC UA adresleri tespit edilmiştir (Şekil 7.6). Böylece bu adreslerin OPC UA veri toplama client servisi ile okunup veri tabanına gerçek zamanlı olarak kaydedilmesi sağlanmıştır.

OPC UA server interface			
	Browse name	Node type	Local data
69	▼ Status_Data	"AI_DB"."Status_Dat..	
70	Machine_Started	BOOL	"AI_DB"."Status_Data"."Machine_Started"
71	Machine_Auto	BOOL	"AI_DB"."Status_Data"."Machine_Auto"
72	Machine_Stopped	BOOL	"AI_DB"."Status_Data"."Machine_Stopped"
73	Production_Count	DINT	"AI_DB"."Status_Data"."Production_Count"
74	Production_Amount	REAL	"AI_DB"."Status_Data"."Production_Amount"
75	Worktime	INT	"AI_DB"."Status_Data"."Worktime"
76	Motor_Status	BYTE	"AI_DB"."Status_Data"."Motor_Status"
77	Charge	WORD	"AI_DB"."Status_Data"."Charge"
78	▼ Sensor_Data	"AI_DB"."Sensor_Da..	
79	Mixer_Vibration	REAL	"AI_DB"."Sensor_Data"."Mixer_Vibration"
80	Mixer_I	REAL	"AI_DB"."Sensor_Data"."Mixer_I"
81	Mixer_Temp	REAL	"AI_DB"."Sensor_Data"."Mixer_Temp"
82	Mixer_Speed	INT	"AI_DB"."Sensor_Data"."Mixer_Speed"
83	Mixer_Pressure	REAL	"AI_DB"."Sensor_Data"."Mixer_Pressure"
84	▼ Energy_Data	"AI_DB"."Energy_Da..	
85	I_1	REAL	"AI_DB"."Energy_Data"."I_1"
86	I_2	REAL	"AI_DB"."Energy_Data"."I_2"
87	I_3	REAL	"AI_DB"."Energy_Data"."I_3"
88	Max_I_1	REAL	"AI_DB"."Energy_Data"."Max_I_1"
89	Max_I_2	REAL	"AI_DB"."Energy_Data"."Max_I_2"
90	Max_I_3	REAL	"AI_DB"."Energy_Data"."Max_I_3"
91	KW_H	REAL	"AI_DB"."Energy_Data"."KW_H"
92	Alarm	"AI_DB"."Alarm"	

Şekil 7.6. OPC UA erişim adresleri

7.1.3.2. OPC UA client veri toplama servisi

Veri toplama yazılımı, S7-1200 PLC kontrol ünitesinden OPC UA standardını kullanarak gerçek zamanlı veri okuma ve bu verileri veri tabanına arşivleme görevini gerçekleştirmek üzere geliştirilmiştir.




Şekil 7.7. Veri toplama uygulaması

Veri toplama yazılımı .NET Framework 4.7.2 kullanılarak .NET Windows Form olarak C# ile Visual Studio 2015 platformu üzerinde yazılmıştır (Şekil 7.7). Endüstriyel PC içerisinde Windows 10 işletim sistemi üzerinde koştan veri toplama programını veri kaybını engellemek amacıyla endüstriyel PC çalıştığı müddetçe işlevini yerine getirilebilmesi için Windows servis olarak çalıştırılmaktadır. Bu sayede beklenmedik durumlarda endüstriyel veri toplama PC'si kapanıp açıldığı takdirde veri toplama servisimiz otomatik olarak aktif edilmiş olur. Program üzerindeki device alanı veri toplama programı ile döküm makinesi arasındaki bağlantısı durumunu göstermektedir. Server alanı ise veri toplama programımız ile SQL Server 2017 veri tabanımızın bulunduğu sunucu arasındaki bağlantı durumunu ifade eder. Details alanında anlık olarak değişen bağlantı durumları ve data toplama esnasında oluşabilecek sorunlar görüntülenmektedir.

7.1.3.3. Operatör duruş bilgileri giriş uygulaması

Arıza oluştuğu takdirde makine arıza sebebi sistem tarafından otomatik olarak tespit edilemediyse belirsiz arıza bilgisi bir arayüz aracılığı ile operatörlere iletilir (Şekil 7.8). Bu arayüz hem izleme hem de arıza bilgilerinin girişlerinin yapılabilmesini sağlayabilmektedir. Gelen uyarı ile operatörden bu arızanın sebebinin girilmesi talep edilir (Şekil 7.9). Böylece oluşan duruşların sebepleri de kiosk aracılığı ile operatör tarafından belirlenmiş olur (Şekil 7.10).



ID #	Başlangıç	Bitiş	Süre (Dakika)	Seç
621373	24.01.2022 16:33:02	24.01.2022 16:37:02	4	Seç
621345	24.01.2022 16:01:27	24.01.2022 16:23:44	22.28	Seç
621312	24.01.2022 15:39:37	24.01.2022 15:43:45	4.13	Seç
621304	24.01.2022 14:59:49	24.01.2022 15:33:01	33.2	Seç

Şekil 7.8. Belirsiz duruş seçim ekranı

PLANLI	0
PLANSIZ	19
☐ HAT HAZIRLAMA	P0001
☐ ELEKTRİK ARIZA	P0008
☐ MEKANİK ARIZA	P0009
☐ KALIP BEKLEME	P0010
☐ POLYESTER AAP KOBALT İLAVE	P0011
☐ HAMMADDE NEM SORUNU	P0012
☐ OPERATÖR EKSİKLİĞİ	P0013
☐ HAMMADDE YOK	P0014
☐ MALZEME SIKIŞMASI	P0015
☐ AAP GELMEMESİ-KAÇAĞI	P0016
☐ KOBALT GELMEMESİ-KAÇAĞI	P0017
☐ TEMİZLEME SUYU GELMEMESİ-KAÇAĞI	P0018
☐ MİKSER MOTOR ARIZASI	P0019

Şekil 7.9. Belirsiz duruş nedeni seçim ekranı

Geri

☆ BELİRSİZ DURUŞ BİLGİ GİRİŞİ

Makine *

RESPECTA POLIMER

Vardiya *

Vardiya

Duruş ID *

612152

Başlangıç *

14.01.2022 17:47

Bitiş *

14.01.2022 18:00

Duruş Sebebi *

ELEKTRİK ARIZA

Açıklama *

Kaydet

İptal

Şekil 7.10. Belirsiz duruş açıklaması giriş ekranı

7.2. Veri Seti

16/04/2021-15/09/2021 tarihleri arasında gerçekleşen 3.801.250 satır veriden oluşur. Veri seti özellikleri Çizelge 7.1’de gösterilmiştir.

Çizelge 7.1. Veri seti özellikleri ve açıklamaları

Öznitelik	Açıklama	Veri Türü
Machine working	Çalışma durumu	Boolean
Production count	Üretim sayısı (adet)	Integer
Production amount	Üretim miktarı (kg)	Float
Worktime	Ürün üretim süresi (sn)	Integer
Engine status	Mikser motor durum	Boolean
Charge	Reçete yükleme numarası	Integer
Mixer vibration	Mikser motor titreşim	Float
Mixer actual temperature	Mikser sıcaklık	Float
Mixer working speed	Mikser hızı (RPM)	Integer
Mixer actual pressure	Mikser basınç	Float
Current-1	Akım bilgisi faz-1	Float
Current-2	Akım bilgisi faz-2	Float
Current-3	Akım bilgisi faz-3	Float
Alarm-1	Acil stop	Boolean
Alarm-2	Termik attı	Boolean
Alarm-3	Mikser motoru sürücü arızası	Boolean
Alarm-4	Hava basıncı düşük	Boolean
Alarm-5	Konveyör arızası	Boolean
Alarm-6	Malzeme sıkışması	Boolean
Alarm-7	Kalıp bekleme	Boolean
Alarm-8	Mekanik arıza	Boolean
Datetime	Tarih/saat	DateTime

Veri setimize öncelikle veri ön işleme adımları uygulandı. NULL değer içeren az sayıdaki veri, veri setinden çıkarıldı. Farklı tarih formatları düzenlendi. Makine çalışma saatleri ile uyumsuzluk gösteren veriler kirli veri olarak nitelendirilip veri setinden çıkarıldı. Elde edilen veri setinde, makinenin sağlıklı çalışmaya başladığı durumdan öngörmek istediğimiz arıza verisi gelene kadar ki veri blokları kullanıldı.

7.3. Kalan Faydalı Ömür

Kestirimci bakım, makinenin/ekipmanın belirli bir periyottaki sağlık durumunu tahmin etme süreci olarak tanımlanabilir. Bu tahmini yaparken de makineden sensörler vasıtası ile alınan sıcaklık, basınç, gürültü, titreşim, çekilen akım, ortam sıcaklığı gibi çeşitli verilerin analizinden elde ettiği sonuçları kullanır.

Arıza oluştuktan sonra yapılan bakımlarda arıza tespiti, bakım süresinin uzayabilmesi, oluşan arızanın bir takım farklı arızaları tetikleyebilmesi unsurlarından dolayı verimliliği olumsuz etkileyebilmektedir. Buna karşılık arıza bakımı en aza indirmek amacıyla arıza oluşmadan önce yapılan periyodik bakımların sıklaştırılması ise toplam bakım süresini artırmakta ve verimliliği düşürebilmektedir. Kestirimci bakım tam da bu noktada yapılması gereken bakımın zamanını tespit etmeyi amaçlamaktadır.

Kestirimci bakımın amacı “Kalan Faydalı Ömür”ü (Remaining Useful Life - RUL - KFÖ) tahmin etmektir. Bu sayede makinenin sağlık durumu tespit edilebilir ve oluşabilecek arızalar önceden tahmin edilebilir. Bunun sonucunda da bakım planlaması yapılarak gereksiz bakımların önüne geçilmiş ve dolayısı ile makine verimliliğine ciddi ölçüde katkı sağlanmış olur. KFÖ tahmini, makinelerin gelecekteki performansını tahmin etmek ve makinelerin arıza durumuna geçmeden önceki kalan süreyi elde etmek için tahmin yöntemlerini kullanan bir süreçtir (Lei vd., 2016).

KFÖ tahmininde genel olarak 3 model mevcuttur;

- Hayatta Kalma Modeli: Tam olarak arıza olduğu sıradaki veriler bilindiği takdirde,
- Bozulma Modeli: Elde arıza verileri yoksa ancak arızayı işaret eden bir eşik değeri bilindiği takdirde,
- Benzer Modeli: Makinenin/ekipmanın sağlıklı çalıştığı bilinen bir “t” zamanından itibaren arıza oluşuncaya kadar ki süreçte tüm veriler bilindiği takdirde uygulanır (Özkat, 2021).

Bu çalışmada bir döküm fabrikasında bulunan döküm makinesi verileri üzerinde izleme yapılarak elde edilen veriler üzerinde çalışılmıştır. Makinede 8 duruş tanımı mevcuttur.

- 1- Acil Stop
- 2- Termik Attı
- 3- Mikser Motoru Sürücü Arızası*
- 4- Hava basıncı düşük
- 5- Konveyör Arızası
- 6- Malzeme Sıkışması
- 7- Kalıp Bekleme
- 8- Mekanik Arıza

Mikser motoru sürücü arızası dışındaki duruş tanımlarının bir kısmı sistem dışından gelen müdahaleler, bir kısmı da ani oluşan üretim bandı duruşlarından kaynaklanmaktadır. Mikser motoru sürücü arızası karışım materyallerinin zaman içinde mikser ve bağlantı ekipmanlarının içinde akışkanlığını kaybetmesi sonucu oluşmaktadır. Mikser motoru sürücü arızası oluştuğunda arıza bakım süresi hem uzun olabilmekte hem de başka mekaniksel arızalara sebebiyet verebilmektedir. Bu da verimliliği ciddi anlamda olumsuz etkilemektedir. Bu

yüzden mevcut çalışmada yalnızca mikser motoru sürücü arızasının önceden tespit edilebilmesi amaçlanmıştır.

7.4. Makine Öğrenmesi Aşaması

Kestirimci bakımda makinenin “t” anında yalnızca çalıştığı ya da arızalı olduğu bilgisini tahmin edebilmek yeterli değildir. Önleyici tedbirlerin zamanında alınabilmesi için o üretim sisteminin ihtiyaç duyduğu arızaya kalan süreyi doğru tahmin edebilmek gereklidir. Bu nedenle bu problem bir sınıflandırma probleminden ziyade bir regresyon problemi olarak ele alınabilir.

İlgili veri seti hem denetimli hem de denetimsiz makine öğrenmesi algoritmalarından birine ayrı ayrı uygulanmıştır. Literatür taraması sonucu regresyona uygulanabilir olan ve tahmin gücünün yüksek olduğu bilinen denetimli makine öğrenmesi algoritmalarından rastgele orman, denetimsiz makine öğrenmesi tarafında temel bileşen analizi kullanılmasına karar verilmiştir.

Makine çalışma parametreleri 5 ay boyunca izlendi. Bu arızalar gerçekleşinceye kadar ki sağlıklı makine çalışma parametreleri üzerinde çalışıldı.

16 özellik ile 16 bağımsız değişken ve 1 bağımlı değişken (RUL) kullanılarak elde edilen modelin doğruluk oranı (Çizelge 8.1) istenen başarıyı sağlayamadığından motor arızasının tahminiyle en çok ilgili olan özellikler ile çeşitli denemeler yapılmış ve doğruluk oranı en yüksek olan vibrasyon, akım ve sıcaklık öznitelikleri ile yola devam edilmesinde karar kılınmıştır.

Rastgele orman modeli ile kullanılan metodolojide, arızanın oluştuğu zaman bilindiği için bu arızaya kadar ki kalan zamanı kalan faydalı ömür olarak hesaplayıp yeni bir sütun olarak veri setimize ekledik. Veri setimizi %54 eğitim (77.487 adet), %46 test (66.052 adet) veri seti olarak ikiye ayırdık. Denetimli makine öğrenmesi algoritmalarından rastgele orman algoritması ile modelimizi oluşturduk. Kalan faydalı ömrü bulmaya odaklı çalışma, alarm tespitine bir

regresyon problemi olarak yaklaşılabilmemizi sağlamıştır. Böylelikle arızaya ne kadar süre kaldığının tahmini yapılabilmektedir. Model oluşturulurken $n_estimators$ (ağaç sayısı) parametresi olarak 1000 değeri alınmıştır.

Temel bileşen analizi modeli ile kullanılan metodolojide, temel bileşen analizi yardımıyla çalışma koşullarını belirleyen en etkili bileşenler tespit edildi. Burada veriyi en iyi açıklayan bileşenleri bulmak amaçlanmıştır. Bu yaklaşımın belirlenmesi aşamasında David Kimera ve arkadaşlarının yapmış olduğu çalışma da göz önünde bulundurulmuştur (Kimera vd., 2020).

Veri seti öznelik mühendisliği (feature engineering) uygulamak amacıyla pencerelere ayrılır ve her pencere düzeyinde alanların kısa vadeli dağılımını tanımlayan bir dizi istatistiksel nicelik hesaplanır. Bu nicelikler, daha önce Metallinou ve ekibi tarafından sürekli izleme için başarıyla kullanılmış olan 11 fonksiyon; ortalama (mean), standart sapma (standard deviation), çarpıklık (skewness), basıklık (kurtosis), yayılma aralığı (range), minimum, maksimum (maximum), ilk çeyrek (first quantile), üçüncü çeyrek (third quantile), ortanca çeyrek (median quantile) ve çeyrekler arası aralık (inter-quantile range)'den oluşur (Turker vd., 2017).

Veri üzerinde her bir kayıt için kendisinden önce gelen 12 saatin verisine dair istatistikler hesaplanarak mevcut özelliklerde zenginleştirilmeye gidilmiştir. ortalama, standart sapma, çarpıklık, basıklık, yayılma aralığı, minimum, maksimum, ilk çeyrek, üçüncü çeyrek, ortanca çeyrek ve çeyrekler arası aralık istatistikleri veri setinin özellik bilgilerine ilave edilerek özellik sayısı 3'den 36'ye çıkarılmıştır.

Denetimsiz makine öğrenme algoritmalarında etiketli datalardan bahsedilemediği için veri seti %80 eğitim, %20 test olarak ayrılmış, metrik olarak da denklem (1)'deki formül ile ifade edilen kare tahmin hatası (squared prediction error - SPE) kullanılmıştır.

36 özellik arasından TBA uzayında %99 anlamlılık teşkil eden özellik sayısı 3 olarak tespit edilmiştir. TBA hesaplamasında çıkartılan öz vektörler büyükten küçüğe sıralanarak ilk 3 temel bileşen arasından her bir satır için SPE hesaplaması yapılmıştır.

$$SPE = \sqrt{\left\{ \frac{\sum (y - y_i)^2}{n} \right\}} \quad (7.1)$$

Eğitim verisi içerisindeki SPE değerlerinin ortalaması üzerinden bir üst sınır belirlenmiş, bu üst sınır test veri setinde alarm üst sınırı olarak kullanılmıştır.

8. ARAŞTIRMA SONUÇLARI VE TARTIŞMA


8.1. Rastgele Orman ile Tahminleme Sonucu

Denetimli makine öğrenmesi algoritmalarından rastgele orman kullanılarak önce regresyon uygulanıp daha sonra KFÖ tahminlerini sınıflandırarak kategorik sonuçlar elde edilmiştir. Belirlenen kategoriler işletmenin ihtiyaçlarına göre farklılık gösterebilir. Mevcut işletmede bakım uyarı sistemi içerisinde makinenin arızalanmasına kalan süre için 3 kategori belirlenmiştir.


- Normal Çalışma (Arızaya kalan süre 10 saatten fazla)
- Uyarı (2 ile 10 saat arası)
- Alarm (2 saatten az)

Normal çalışma kategorisi; makinenin çalışma parametrelerinde herhangi bir anormallik olmadığını ve bakım gerektirmediğini, uyarı; bakımın yakında gerekli olabileceğini, alarm ise bakımın acilen gerekli olduğunu aksi takdirde mikser motor sürücü arızasının gerçekleşebileceğini belirtir.

Şekil 8.1’de saniye bazında tahmin edilen KFÖ değerleri ile gerçek KFÖ değerleri grafik üzerinde gösterilmiştir. Saniye bazında elde edilen doğruluk değeri (accuracy) %58,02 olmuştur. Bununla birlikte Şekil 8.2’de gösterildiği üzere tahmin ve gerçek KFÖ değerleri belirlenen kategorilere göre sınıflandırıldığında ise elde edilen doğruluk değeri %85,17’dir.



Şekil 8.1. Gerçek/tahmin KFÖ grafiği (saniye)



Şekil 8.2. Gerçek/tahmin KFÖ grafiği (kategorik)


Çizelge 8.1. Rastgele orman öznitelik sayısına göre doğruluk oranları

Öznitelik Sayısı	Doğruluk Oranı
16 Öznitelik	%15,69
3 Öznitelik	%58,02

Çizelge 8.1’deki çizelge 16 özniteliğin tamamının kullanılması durumundaki ve 3 öznitelik kullanıldığı takdirde (akım, vibrasyon ve sıcaklık) elde edilen doğruluk oranlarının kıyaslamasını içermektedir.

8.2. Temel Bileşen Analizi ile Tahminleme Sonucu

Test veri seti modele uygulandığında modelin başarı tespiti için kare tahmin hatası (SPE) metriği kullanılmıştır. Eğitim verisi üzerinde elde edilen SPE değerlerinden oluşan dizinin normal dağılım grafiğine oturtulmuş halinden birinci ve üçüncü quantile değerleri ile bir hata eşiği belirlenmiştir. Bu hata değeri üzerinden elde edilen doğruluk oranı %67,75 olarak bulunmuştur. Buna karşılık SPE değerlerinin ortalaması alınarak elde edilen üst sınır değeri ile test verilerinin %73,4'ünde anomali tespit edilmiştir (Çizelge 8.2). Şekil 8.3 arızanın gerçekleştiği ana tekabül eden kayıtların PC1 (Principal Component 1), PC2 (Principal Component 2)'ye göre dağılım grafiğini ifade etmektedir.



Şekil 8.3. PC1/PC2 dağılım grafiği

Çizelge 8.2. SPE eşik belirleme yöntemine göre doğruluk oranları

Eşik Belirleme Yöntemi	Doğruluk Oranı
Quantile Bazlı SPE Eşiği	%67,75
Ortalama Bazlı SPE Eşiği	%73,40

Bu çalışmada kullanılan veri seti, bir veri toplama sistemi ile döküm fabrikasından elde edildiğinden başka çalışmalarla doğrudan bir kıyaslama yapmak mümkün olmamıştır. Buna rağmen aşağıdaki tabloda bu çalışma ile benzer çalışmalarda elde edilmiş olan doğruluk değerlerinin karşılaştırmasına yer verilmiştir.

Çizelge 8.3. Alternatif çalışmalar ile doğruluk değerlerinin karşılaştırılması

Çalışmalar	Yöntem	Doğruluk Oranı
Mevcut çalışma	RO	%85,17
Çalışma 1 (<i>Çınar vd., 2020</i>)	RO	%98,8
Çalışma 2 (<i>Tessaro vd., 2020</i>)	RO	%88,75

9. SONUÇ VE ÖNERİLER

Geleneksel arızı, periyodik ve önleyici bakımlar, üretim endüstrilerinde hala yaygın olarak kullanılan bakım yöntemleridir. Arıza gerçekleşikten sonra arıza tespit süresinin uzun olması, yedek parça gereksinimi söz konusu olduğunda parça işletmede mevcut değilse tedarik süresinin uzayabilmesi, oluşan arızanın zincirleme olarak başka arızaları tetikleme ihtimali gibi unsurlar, bakım maliyetlerini artıran unsurlardır. Bununla birlikte periyodik olarak yapılan bakımların periyotları uzun tutulduğunda arıza bakımının artmasına sebep olduğu gibi, kısa tutulduğunda ise sistem uzun süre sorunsuz çalışabilecekken gereksiz bakımlara ve bu nedenle de üretim verimliliğinin düşmesine sebebiyet vermektedir. Mevzu bahis bakım yaklaşımlarının eksikliklerini gidermek ve bu çalışmada üretim endüstrisinde bakımı optimize edebilmek amacıyla makine öğrenmesi yöntemleri kullanılarak kestirimci bakım yaklaşımı uygulandı. Kestirimci bakım makineye ait verileri sürekli bir şekilde gerçek zamanlı olarak takip ederek değişen koşullara rağmen verimliliği en üst düzeyde tutacak şekilde makine bakımı için en uygun zamanı belirler. Böylece arıza oluşmadan önlem alınabilir ve gereksiz bakımların önüne geçilebilir.

Bu çalışmada, endüstriyel ortamda üretim yapan bir döküm makinesi üzerinde mikser motor sürücü arıza zamanı tahmini için kestirimci bakım uygulaması gerçekleştirildi. Uygulanan modellerin çıktıları göz önüne alındığında, denetimli makine öğrenme modeli rastgele orman ile nispeten daha başarılı sonuçlar elde edildiği gözlemlendi. Bu kapsamda kestirimci bakım uygulamamızın mikser motor sürücü arızasını gerçekleşmeden önce belirlenen kriterlere göre tahmin etme konusunda etkili olduğu söylenebilir. Bu sayede belirtilen arıza gerçekleşmeden önce önlem alınarak arızanın ve üretim verimliliğinin bu durumdan olumsuz etkilenmesinin önüne geçilebilir.

Kestirimci bakım için çalışma yapılacak olan alan ile ilgili veri setleri ve beklentilere göre farklı yaklaşımlar söz konusudur. Dolayısıyla tüm kestirimci bakım uygulamaları için tek bir yaklaşım söz konusu değildir. Bu çalışmada tek bir ürün tipi için farklı duruş sebeplerinden sisteme olumsuz etkileri ve maliyeti

çok daha büyük olan mikser motor sürücü arızası gerçekleşme zamanı tahminlemesi üzerinde durulmuştur. Sonraki aşamada veri seti zenginleştirilerek farklı ürün tiplerinde ve farklı arıza tiplerini de tahmin edebilecek makine öğrenmesi modelleri geliştirilebilir.

KAYNAKLAR

- Agrawal, G., 2017. Should India Stay Away From The Fourth Revolution?. Available at SSRN 3084256. <https://doi.org/10.2139/ssrn.3084256>
- Akar, Ö., Güngör, O., 2012. Rastgele Orman Algoritması Kullanılarak Çok Bantlı Görüntülerin Sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 1(2), 139-146. <https://doi.org/10.9733/jgg.241212.1t>
- Angelopoulos, A., Michailidis, E. T., Nomikos, N., Trakadas, P., Hatziefremidis, A., Voliotis, S., & Zahariadis, T., 2020. Tackling Faults in The Industry 4.0 Era—a Survey of Machine-Learning Solutions and Key Aspects. *Sensors*, 20(1), 109. <https://doi.org/10.3390/s20010109>
- Ayvaz, S., Alpay, K., 2021. Predictive Maintenance System for Production Lines in Manufacturing: A Machine Learning Approach Using IoT Data in Real-Time. *Expert Systems with Applications*, 173, 114598. <https://doi.org/10.1016/j.eswa.2021.114598>
- Bektaş, O., 2020. Kestirimci Bakım için Döner Mekanizma Bozulma Eğrisinin Tanımlanması. *Avrupa Bilim ve Teknoloji Dergisi*, (19), 420-428. <https://doi.org/10.31590/ejosat.708257>
- Calayır, G. N., Kabak, M., 2021. Bakım için Makine Öğrenme Tekniklerinin Analizi ve Bir Uygulama. *Journal of Turkish Operations Management*, 5(1), 662-675.
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. 2019. A Systematic Literature Review of Machine Learning Methods Applied to Predictive Maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Cavalieri, S., Cutuli, G. 2010, September. Performance Evaluation of OPC UA. In 2010 IEEE 15th Conference on Emerging Technologies & Factory Automation (ETFA 2010) (pp. 1-8). IEEE. <https://doi.org/10.1109/ETFA.2010.5641184>
- Chazhoor, A., Mounika, Y., Sarobin, M. V. R., Sanjana, M. V., Yasashvini, R., 2020, October. Predictive Maintenance Using Machine Learning Based Classification Models. In *IOP Conference Series: Materials Science and Engineering* (Vol. 954, No. 1, p. 012001). IOP Publishing. <https://doi.org/10.1088/1757-899X/954/1/012001>
- Cline, B., Niculescu, R. S., Huffman, D., Deckel, B., 2017, January. Predictive Maintenance Applications for Machine Learning. In 2017 Annual Reliability and Maintainability Symposium (RAMS) (pp. 1-7). IEEE. <https://doi.org/10.1109/RAM.2017.788679>


- Çınar, Z. M., Abdussalam Nuhu, A., Zeeshan, Q., Korhan, O., Asmael, M., & Safaei, B., 2020. Machine Learning in Predictive Maintenance Towards Sustainable Smart Manufacturing in Industry 4.0. Sustainability, 12(19), 8211. <https://doi.org/10.3390/su12198211>
- Çömlekçi, O., 2020. Endüstriyel Otomasyon Sistemlerinde Yapay Zeka Yöntemleri İle Arıza Tespiti (Master's thesis, Bursa Uludağ Üniversitesi).
- Gedikli, T., ERVURAL, B. Ç., ŞEN, D. T., 2021. Bulanık TOPSIS ve Bulanık AHP Yaklaşımlarıyla En Uygun Bakım Stratejisinin Belirlenmesi: Bir Gıda İşletmesinde Uygulama. Avrupa Bilim ve Teknoloji Dergisi, (22), 212-225. <https://doi.org/10.31590/ejosat.838168>
- Kimera, D., Nangolo, F. N., 2020. Predictive Maintenance for Ballast Pumps on Ship Repair Yards via Machine Learning. Transportation Engineering, 2, 100020. <https://doi.org/10.1016/j.treng.2020.100020>
- Lauro, C. N., Palumbo, F., 2000. Principal Component Analysis Of Interval Data: a Symbolic Data Analysis Approach. Computational Statistics, 15(1), 73-87. <https://doi.org/10.1007/s001800050038>
- Lei, Y., Li, N., Gontarz, S., Lin, J., Radkowski, S., Dybala, J. (2016). A Model-Based Method for Remaining Useful Life Prediction of Machinery. IEEE Transactions on Reliability, 65(3), 1314-1326. <https://doi.org/10.1109/TR.2016.2570568>
- Lin, W., Wu, Z., Lin, L., Wen, A., Li, J., 2017. An Ensemble Random Forest Algorithm for Insurance Big Data Analysis. Ieee Access, 5, 16568-16575. <https://doi.org/10.1109/ACCESS.2017.2738069>
- Mahesh, B., 2020. Machine Learning Algorithms-A Review. International Journal of Science and Research (IJSR).[Internet], 9, 381-386. <https://doi.org/10.21275/ART20203995>
- Mahnke, W., Leitner, S. H., Damm, M., 2009. OPC Unified Architecture. Springer Science & Business Media. <https://doi.org/10.1007/978-3-540-68899-0>
- Martins, J. P. S., Rodrigues, F. M., Henriques, N., 2020. Modeling System Based on Machine Learning Approaches for Predictive Maintenance Applications. KnE Engineering, 2020, 857-871. <https://doi.org/10.18502/keg.v5i6.7105>
- Masani, K. I., Oza, P., Agrawal, S., 2019. Predictive Maintenance and Monitoring of Industrial Machine Using Machine Learning. Scalable Computing: Practice and Experience, 20(4), 663-668. <https://doi.org/10.12694/scpe.v20i4.1585>

- Mathew, V., Toby, T., Singh, V., Rao, B. M., Kumar, M. G., 2017, December. Prediction of Remaining Useful Lifetime (RUL) of Turbofan Engine Using Machine Learning. In 2017 IEEE International Conference on Circuits and Systems (ICCS) (pp. 306-311). IEEE. <https://doi.org/10.1109/ICCS1.2017.8326010>
- Matzka, S., 2020, September. Explainable Artificial Intelligence for Predictive Maintenance Applications. In 2020 Third International Conference on Artificial Intelligence for Industries (AI4I) (pp. 69-74). IEEE. <https://doi.org/10.1109/AI4I49448.2020.00023>
- Oktar, Ş., 2014. Demiryollarında Araç Bakım ve Onarımı. Demiryolu Mühendisliği, (1), 38-40.
- Özgür-Ünlüakın, D., Türkali, B., Karacaörenli, A., Aksezer, S. Ç., 2019. A DBN Based Reactive Maintenance Model for A Complex System in Thermal Power Plants. Reliability Engineering & System Safety, 190, 106505. <https://doi.org/10.1016/j.ress.2019.106505>
- Özkat, E. C., 2021. Makine Öğrenmesi Metodolojisi Kullanılarak Yüksek Hızlı Rulmanlarda Sağlık Göstergesinin Belirlenmesi. Avrupa Bilim ve Teknoloji Dergisi, (22), 176-183. <https://doi.org/10.31590/ejosat.869285>
- Öztanır, O., 2018. Makine Öğrenmesi Kullanılarak Kestirimci Bakım.
- Sarica, A., Cerasa, A., Quattrone, A., 2017. Random Forest Algorithm for The Classification of Neuroimaging Data in Alzheimer's Disease: a Systematic Review. Frontiers in Aging Neuroscience, 9, 329. <https://doi.org/10.3389/fnagi.2017.00329>
- Schwarz, M. H., Börcsök, J., 2013, October. A Survey on OPC and OPC-UA: About the Standard, Developments and Investigations. In 2013 XXIV International Conference on Information, Communication and Automation Technologies (ICAT) (pp. 1-6). IEEE. <https://doi.org/10.1109/ICAT.2013.6684065>
- Shobha, G., Rangaswamy, S., 2018. Machine Learning. In Handbook of Statistics (Vol. 38, pp. 197-228). Elsevier <https://doi.org/10.1016/bs.host.2018.07.004>
- Sirvio, K. M., 2015. Intelligent Systems in Maintenance Planning and Management. In Intelligent Techniques in Engineering Management (pp. 221-245). Springer, Cham. https://doi.org/10.1007/978-3-319-17906-3_10
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., Beghi, A., 2014. Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. IEEE Transactions on Industrial Informatics, 11(3), 812-820. <https://doi.org/10.1109/TII.2014.2349359>

- Tahan, M., Tsoutsanis, E., Muhammad, M., Karim, Z. A., 2017. Performance-Based Health Monitoring, Diagnostics and Prognostics for Condition-Based Maintenance of Gas Turbines: A Review. *Applied Energy*, 198, 122-144. <https://doi.org/10.1016/j.apenergy.2017.04.048>
- Tessaro, I., Mariani, V. C., Coelho, L. D. S., 2020. Machine Learning Models Applied to Predictive Maintenance in Automotive Engine Components. In *Multidisciplinary Digital Publishing Institute Proceedings* (Vol. 64, No. 1, p. 26). <https://doi.org/10.3390/IeCAT2020-08508>
- Tsarouhas, P., 2019. Improving Operation of The Croissant Production Line Through Overall Equipment Effectiveness (OEE): A Case Study. *International Journal of Productivity and Performance Management*. <https://doi.org/10.1108/IJPPM-02-2018-0060>
- Turker, B. B., Yemez, Y., Sezgin, T. M., Erzin, E., 2017. Audio-Facial Laughter Detection in Naturalistic Dyadic Conversations. *IEEE Transactions on Affective Computing*, 8(4), 534-545. <https://doi.org/10.1109/TAFFC.2017.2754256>.
- Wang, Q., Bu, S., He, Z., 2020. Achieving Predictive and Proactive Maintenance for High-Speed Railway Power Equipment with LSTM-RNN. *IEEE Transactions on Industrial Informatics*, 16(10), 6509-6517. <https://doi.org/10.1109/TII.2020.2966033>
- Verikas, A., Vaiciukynas, E., Gelzinis, A., Parker, J., Olsson, M. C., 2016. Electromyographic Patterns During Golf Swing: Activation Sequence Profiling and Prediction of Shot Effectiveness. *Sensors*, 16(4), 592. <https://doi.org/10.3390/s16040592>
- Yazar, İ., Yavuz, H. S., Çay, M. A., 2009. Temel Bileşen Analizi Yönteminin ve Bazı Klasik ve Robust Uyarlamalarının Yüz Tanıma Uygulamaları. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 22(1), 49-63.
- Yeşilkanat, C. M., 2020. Spatio-Temporal Estimation of The Daily Cases of COVID-19 in Worldwide Using Random Forest Machine Learning Algorithm. *Chaos, Solitons & Fractals*, 140, 110210. <https://doi.org/10.1016/j.chaos.2020.110210>
- Zonta, T., da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S., Li, G. P., 2020. Predictive Maintenance in The Industry 4.0: A Systematic Literature Review. *Computers & Industrial Engineering*, 106889. <https://doi.org/10.1016/j.cie.2020.106889>

ÖZGEÇMİŞ

Adı Soyadı : Hakan CEYHAN



Eğitim Durumu

Lise : Beyoğlu Fındıklı Lisesi, 2000

Lisans : Trakya Üniversitesi,
Mühendislik Fakültesi,
Bilgisayar Mühendisliği, 2006

Yüksek Lisans : İstanbul Ticaret Üniversitesi,
Fen Bilimleri Enstitüsü,
Bilgisayar Mühendisliği, 2022

İş Tecrübeleri

Yayınları

Kayar, A., Öztürk, F., Ceyhan, H., 2021, March. Increasing Productivity and Quality with IoT Technologies in Industrial Treatment Systems. In European, Asian, Middle Eastern, North African Conference on Management & Information Systems (pp. 181-188). Springer, Cham.

Ceyhan, H., KASAPBAŞI, M. C., 2022. Üretim Sistemlerinde Makine Öğrenmesi ile Kestirimci Bakım Uygulaması ve Modellemesi. Avrupa Bilim ve Teknoloji Dergisi, (33), 167-175.