



**T.C.
YALOVA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
MAKİNE MÜHENDİSLİĞİ BİLİM DALI**

**OTOMOTİV ENDÜSTRİSİNDE KESTİRİMCİ BAKIM SİSTEMLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE BAKIM YÖNETİM SİSTEMİNE
UYGULANMASI**

YÜKSEK LİSANS TEZİ

FURKAN SARISOY

DANIŞMAN: DR. ÖĞR. ÜYESİ MAHMUT BİNGÖL

**YALOVA
ŞUBAT 2024**



T.C.
YALOVA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
MAKİNE MÜHENDİSLİĞİ BİLİM DALI

OTOMOTİV ENDÜSTRİSİNDE KESTİRİMCİ BAKIM SİSTEMLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE BAKIM YÖNETİM SİSTEMİNE UYGULANMASI

YÜKSEK LİSANS TEZİ

FURKAN SARISOY
205121004

DANIŞMAN: DR. ÖĞR. ÜYESİ MAHMUT BİNGÖL

YALOVA
ŞUBAT 2024

ETİK BEYAN

Yalova Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım “Otomotiv Endüstrisinde Kestirimci Bakım Sistemlerinin Makine Öğrenmesi Yöntemleri ile Bakım Yönetim Sistemine Uygulanması ” başlıklı bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksinin tespiti halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi taahhüt ve beyan ederim.

Furkan SARISOY



ÖNSÖZ

Yüksek Lisans eğitimim boyunca sağladığı rehberlik, bilgi birikimi ve cesaretlendirici desteği için danışmanım Dr. Öğretim Üyesi Mahmut Bingöl'e, manevi varlığını her zaman arkamda hissettiğim babama, beni her koşulda destekleyen ve motivasyon kaynağım olan aileme teşekkür ederim. Son olarak, bu tezin gerçekleşmesine katkıda bulunan şirketim Ford Otosan'a ve Gövde Liderliği yöneticilerine ve ekip arkadaşlarıma teşekkür ederim.

Şubat – 2024

Furkan SARISOY





İÇİNDEKİLER

ETİK BEYAN.....	i
ÖNSÖZ.....	iii
İÇİNDEKİLER	v
KISALTMALAR LİSTESİ	vii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ.....	xi
ÖZET	xiii
ABSTRACT.....	xv
1. GİRİŞ	1
1.1. Literatür Özeti.....	2
1.2. Endüstride Bakım Süreçleri.....	4
1.2.1. Periyodik bakım (Planlı Bakım).....	4
1.2.2. Kestirimci bakım (Predictive maintenance).....	5
1.2.3. Düzeltici bakım (Arıza onarımı)	6
1.2.4. Şartlı bakım (Durum bazlı bakım).....	7
1.2.5. Toplam üretken bakım (TPM)	8
1.2.6. Durum bazlı bakım ve kestirimci bakım arasında karşılaştırma	10
2. KALAN FAYDALI ÖMÜR VE EKİPMAN ETKİNLİĞİ.....	13
2.1. Ekipman Etkinlik Oranı.....	14
3. MAKİNE ÖĞRENMESİ METODU	17
3.1. Denetimli Öğrenme (Supervised Learning).....	17
3.2. Denetimsiz Öğrenme (Unsupervised Learning)	19
3.3. Pekiştirmeli Öğrenme (Reinforcement Learning).....	20
4. MATERYAL VE METOT.....	21
4.1. Veri Setleri.....	34
4.1.1. Titreşim verileri.....	34
4.1.2. Akım verileri	36
4.1.3. Sıcaklık verileri	38
5. ARAŞTIRMA BULGULARI	43
6. SONUÇLAR VE ÖNERİLER	51
KAYNAKLAR	55
ÖZGEÇMİŞ	57
TEZDEN TÜRETİLEN YAYIN VE ESERLER.....	57



KISALTMALAR LİSTESİ

ABD	: Amerika Birleşik Devletleri
AI	: Yapay Zekâ (Artificial Intelligence)
CBM	: Durum Bazlı Bakım (Condition-Based Maintenance)
CU	: Kontrol Ünitesi (Control Unit)
DQN	: Derin Q Ağı (Deep Q Network)
EEO	: Ekipman Etkinlik Oranı
EN	: Avrupa Standardı (European Norm)
HMI	: İnsan Makine Arayüzü
IEC	: Uluslararası Elektroteknik Komisyonu
IEEE	: Elektrik Elektronik Mühendisleri Enstitüsü (Institute of Electrical and Electronics Engineers)
I/O	: Girdi-Çıktı (Input-Output)
IoT	: Nesnelerin İnterneti (Internet of Things)
ISO	: Uluslararası Standartlar Organizasyonu (International Standards Organization)
KAİZEN	: Sürekli İyileştirme
KFÖ	: Kalan Faydalı Ömür (Remaining Useful Life)
KY	: Konveyör (Conveyor)
LFT	: Lift
LSTM	: Uzun-Kısa Süreli Bellek (Long Short-Term Memory)
MDX	: Motor Sürücü Kontrolörü (Motor Drive Controller)
MES	: Üretim Yürütme Sistemi (Manufacturing Execution System)
ML	: Makine Öğrenmesi (Machine Learning)
NLP	: Doğal Dil İşleme
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PDA	: Taşınabilir Veri Girişi Cihazı
PdM	: Kestirimci Bakım (Predictive Maintenance)
PID	: Oransal İntegral Türevse (Proportional-Integral-Derivative)
PLC	: Programlanabilir Mantık Kontrol Cihazı (Programmable Logic Controller)
PN	: ProfiNet
PTC	: Pozitif Sıcaklık Katsayısı (Positive Temperature Coefficient)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
RUL	: Kalan Faydalı Ömür (Remaining Useful Life)
SQL	: Yapılandırılmış Sorgu Dili (Structured Query Language)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
TPM	: Toplam Üretken Bakım (Total Productive Maintenance)
QL	: Q-öğrenme (Q-learning)
5S	: Sıralama, Düzenleme, Temizlik, Standardizasyon, Disiplin



TABLÖLAR LİSTESİ

Tablo 4.1. Veri seti örneklemeesi	35
Tablo 5.1. Ekipmanların arıza süreleri ve oranları.....	44
Tablo 5.2. Arıza türleri	45
Tablo 5.3. Çalışma odağına alınan arıza ve ekipmanlar.....	45



ŞEKİLLER LİSTESİ

Şekil 1.1. Endüstrinin gelişim süreci.....	2
Şekil 1.2. Örnek periyodik bakım çizelge görüntüsü	4
Şekil 1.3: TPM metotlarından biri olan 5S uygulamasının diyagramı.....	9
Şekil 2.1. Ekipman etkinlik oranı ve diğer kayıp süreler	15
Şekil 3.1. Denetimli öğrenme akış şeması.....	18
Şekil 3.2. Denetimsiz öğrenme akış şeması.....	19
Şekil 3.3. Yatay transfer sağlayan hareketli konveyör sistemi	21
Şekil 4.1. Titreşim sensörü uygulaması.....	24
Şekil 4.2. Titreşim verisi oluşturma diyagramı.....	25
Şekil 4.3. PLC panosu ve Siemens S7-1500 PLC görseli	27
Şekil 4.4. Python’da kütüphane kurulumu adımı 1	28
Şekil 4.5. Modelin oluşturulması	28
Şekil 4.6. Akım veri setinin görselleştirilmesi.....	29
Şekil 4.7. Akım verilerini tahminleme algoritması	31
Şekil 4.8. Maximo uygulaması üzerinde bir ekipmanın bakım bilgi ekran görüntüsü	32
Şekil 4.9. PDA görüntüsü	32
Şekil 4.10. Veri ve komut akış diyagramı	33
Şekil 4.11. ISO EN 10816-1 Titreşim standardı.....	34
Şekil 4.12. Motor etiketi üzerindeki bilgiler.....	37
Şekil 4.13. Sıralı kayış tahrikli konveyör sistemleri	37
Şekil 4.14. Stator arızası yaşamış bir motor bobini.....	38
Şekil 4.15. Bir sıcaklık sensörü aracılığıyla motor sıcaklığı tespit parametreleri.....	39
Şekil 4.16. Sürücü üzerinden alınan sıcaklık verisi.....	40
Şekil 5.1. Titreşim analizi yapılan bir ekipmanın titreşim grafiği	47
Şekil 5.2. Drop lift motor akım grafiği.....	48
Şekil 5.3. Motor bobini zamana bağlı sıcaklığı.....	48
Şekil 5.4. Arıza sürelerinin zamana bağlı değişimi.....	49
Şekil 5.5. Bakım programının devreye alınması sonrası bakım eforu	49

OTOMOTİV ENDÜSTRİSİNDE KESTİRİMCİ BAKIM SİSTEMLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE BAKIM YÖNETİM SİSTEMİNE UYGULANMASI

ÖZET

Üretim sistemlerinin verimliliği ve sürdürülebilir üretim açısından bakım yaklaşımları kritik bir rol oynamaktadır. Üretim hacmi ve kalitesi kadar, ekipmanların etkinliği de sürdürülebilir üretim için önemli bir performans göstergesidir. Bakım yaklaşımları geleneksel olarak uygulandığında belirli sınırlamalarla karşı karşıya kalmış olsa da günümüz endüstriyel teknolojileri, özellikle Endüstri 4.0'ın etkisi altında, makinelerden belirli standartlarla gerçek zamanlı veriler toplamamıza ve böylece bakım etkinliğinin artmasına izin verir. Toplanan verileri kullanarak makine öğrenimi (Machine Learning) ile bakım süreçlerini optimize etmemize imkân tanır. Bu sayede, kestirimci bakım anlayışıyla üretim sürecindeki muhtemel arızalar önceden tahmin edilebilir ve bu tür sorunlar yaşanmadan önce önlenir.

Planlı bakım programlarının, makine öğrenmesi araçlarıyla tahminlemeye dayalı ihtiyaca göre tekrar planlanabilmesi, bakım etkinliğini artırabilir ve dolayısıyla üretim verimliliğini artırabilir. Bu çalışmada, bir otomotiv fabrikasındaki arızalar, duruş süreleri ve ekipmanların etkinlik oranı incelenerek pareto analizi ile ilgili ekipman grupları ve hedef arızalar seçilmiştir. Çeşitli veri kaynakları toplanarak kategorize edilmiş ve algoritma verisi olarak kullanılabilir hale getirilmiştir.

Algoritmaların oluşturulması ve sebep-sonuç ilişkisinin kurulmasında, tahminlemenin bakım yönetim sistemine değerlendirilerek aktarılmasında yapay zekâ ve makine öğrenmesi araçlarından faydalanılmıştır. Recurrent Neural Network (RNN) makine öğrenme metodları kullanılarak kestirimci bakım tahminleri %81,7 başarı oranıyla gerçekleştirilmiştir.

Anahtar Kelimeler: Endüstri 4.0, Makine öğrenimi, Kestirimci bakım



APPLICATION OF PREDICTIVE MAINTENANCE SYSTEMS TO MAINTENANCE MANAGEMENT SYSTEM WITH MACHINE LEARNING METHODS IN AUTOMOTIVE INDUSTRY

ABSTRACT

The maintenance approaches play a critical role in the efficiency and sustainable production of manufacturing systems. The effectiveness of equipment is an important performance indicator for sustainable production, as much as production volume and quality. While maintenance approaches traditionally faced certain limitations, today's industrial technologies, particularly under the influence of Industry 4.0, allow us to collect real-time data from machines according to specific standards, thereby enhancing maintenance effectiveness. Using the collected data, machine learning enables us to optimize maintenance processes. This way, potential failures in the production process can be predicted in advance and prevented before such issues occur.

The ability to reschedule planned maintenance programs based on the predictive needs using machine learning tools can increase maintenance effectiveness and consequently improve production efficiency. In this study, equipment groups and target failures related to Pareto analysis were selected by examining the downtime, failures, and efficiency rates of equipment in an automotive factory. Various data sources were collected, categorized, and made available as algorithmic data.

Artificial intelligence and machine learning tools were utilized in creating algorithms, establishing cause-and-effect relationships, and transferring the evaluation of predictions to the maintenance management system. Predictive maintenance forecasts were achieved with an 81.7% success rate using Recurrent Neural Network (RNN) machine learning methods.

Keywords: Industry 4.0, Machine learning, Predictive maintenance



1. GİRİŞ

Günümüz endüstrilerinde, üretim süreçlerinin sürekliliği ve etkinliği, makinelerin ideal performansını sürdürmelerine bağlıdır. Bu bağlamda, endüstriyel bakım yönetimi, makinelerin planlı ve etkili bir şekilde bakımını sağlama amacını taşımaktadır. Ancak, geleneksel bakım stratejileri genellikle maliyetli ve reaktif olabilir, bu nedenle kestirimci bakım ve makine öğrenimi gibi yeni yöntemlere olan ilgi artmıştır.

Endüstriyel tesislerdeki makinelerin sürekli ve güvenilir bir şekilde çalışabilmesi, üretkenliği artırmak ve maliyetleri düşürmek adına kritik bir öneme sahiptir. Geleneksel bakım stratejileri genellikle makinelerin arıza yapmasını bekleyen reaktif bir yaklaşımı benimserken, kestirimci bakım ve makine öğrenimi yöntemleri, makinelerin durumunu önceden değerlendirmek ve bakımı optimize etmek için daha proaktif bir yaklaşım sunmaktadır.

Bu çalışmada endüstriyel bakım yönetimi ve geleneksel bakım stratejileri, kestirimci bakım yaklaşımları, makine öğrenimi yöntemlerinin endüstriyel bakım süreçlerine uygulanması ve sonuçları incelenmiştir.

Bu tezin temel amacı, endüstriyel bakım yönetimi, kestirimci bakım ve makine öğrenimi yöntemlerini bütünleştirmek suretiyle makinelerin durumunu daha etkili bir şekilde izlemek, bakım stratejilerini optimize etmek ve üretim süreçlerindeki kesintileri minimize etmektir. Araştırma, belirli bir endüstriyel tesis içinde uygulanacak ve makine öğrenimi algoritmalarının kullanılabilirliği, bakım stratejilerinin etkinliği ve genel operasyonel verimlilik üzerindeki etkilerini değerlendirecektir.

Bu tez kapsamında, endüstriyel bakım yönetimi alanında mevcut olan geleneksel ve yeni yöntemleri bütünleştirerek daha sürdürülebilir ve verimli bir bakım stratejisi önermeyi amaçlamaktadır. Bu önerilen strateji, endüstriyel tesislerin bakım maliyetlerini düşürmelerine ve üretkenliklerini artırmalarına katkıda bulunabilir. Şekil 1.1’de endüstrinin buharlı makinelerden başlayarak otomasyon ve haberleşmenin getirdiği noktanın ardından siber fiziksel sistemlere geçişi gösterilmiştir.



Şekil 1.1. Endüstrinin gelişim süreci

1.1.Literatür Özeti

Tarihsel akışta gerçekleşen endüstriyel devrimler, iş süreçlerinin etkinliğini artırmıştır. "Endüstri Devrimi", işgücünün kapasitesini artıran gelişmeleri kapsar ve daha fazla işgücü gerektiren iş süreçlerini daha verimli hale getirir. (Martins ve diğ., 2020).

Gelişen teknolojilere uyum sağlama ve kullanma gerekliliği ile, endüstri yeni bir çağa evrilmiştir. Veri miktarı, yeni nesil cihaz ve ekipmanlar, haberleşme teknolojileri, kişiselleştirme ve kontrollü üretim, "Endüstri 4.0" olarak adlandırılan bir dönüşüm süreci başlatmıştır. Almanya'da bu dönüşümü ifade etmek için "Dördüncü sanayi devrimi" ifadesi kullanılmıştır. (Zonta ve diğ., 2020).

Endüstride yapay zekâ ve makine öğrenmesi sürecinin temelini oluşturulduğu dönemde, yaygınlaşması devam eden tahmine dayalı bakım yöntemleri üzerine çalışmalarını bir otomotiv fabrikasında test ederek sonuçlandırılan bir araştırmacı, bakım yönetim sistemine müdahale etmeden sadece tahminleme üzerine yaptığı çalışmalarda, transfer sistemler, kaynak robotları ve tabancalarının etkinliğini artırmayı ve arıza sebepli duruş sürelerini azaltmayı başarmıştır. (Acar ve diğ.,2014)

Yapay zekâ ve makine öğrenmesi konusu imalat endüstrisini temelden değiştirmektedir. Nesnelerin İnterneti (IoT) (Internet of Things) ve makine öğrenimi yöntemlerinin gelişmesi, üretim sistemlerinin, insanların, makinelerin ve sensörlerin gerçek zamanlı haberleşme ve iş birliği yapabilmesine imkân sağlamıştır. Böylece üretim ve üretimi etkileyen durumlar anlık olarak izlenebilmekte ve seçeneklerin arasındaki en mantıklı kararlar alınabilmektedir. Yapay zekâ, üreticilere ekipman arızalarının etkilerini minimize ederken üretim hatalarını tespit etme, minimum arıza kaynaklı kayıp süre sağlama ve tedarik zincirini iyileştirme imkânı tanımaktadır. (Angelopoulos ve diğ., 2020).

Bu teknolojilerin son uygulamalarından biri kestirimci bakım olarak da ifade edilen tahmine dayalı bakım sistemleridir. Kestirimci bakım, endüstriyel IoT teknolojilerini makine öğrenimiyle senkronize çalışmasını sağlayarak üretim ekipmanlarının ne zaman bakıma ihtiyaç duyacağını tahmin etmeye yardımcı olur. Bu da arızaların daha etkisi ortaya çıkmadan çözülmesini ve çok sayıda bulunan alternatif kararların etkilerinin hesaplanarak çözüm etkinliğinin belirlenmesini ve zamanında alınmasını sağlar (Carvalho ve diğ., 2019).

Yapılan başka bir çalışmada, makine öğrenmesi tabanlı kestirimci bakım sistemleri için bir uygulamayı paylaşmıştır. Çalışmasında, bir elektrik motorunun durumunu tahmin etmek için destek vektör makineleri (SVM) metodu kullanılmıştır. SVM, veri noktalarını sınıflandırmak veya regresyon analizi yapmak için kullanılan bir makine öğrenimi modelidir. Motor üzerinden alınan anlık veriler SVM algoritmasında kullanılarak yorumlanmış ve ekipmanın olası bir arızaya kalan süresi tahmin edilmeye çalışılmıştır. (Akgül ve diğ.,2020)

Benzer bir çalışmada makine öğrenmesi uygulamalarını sadece arıza tahminlemesinde değil, arıza sonrası bakım operasyonunun karar mekanizması için de kullanmayı amaçlamıştır (Öztürk ve diğ.,).

Yapay zekanın otomotiv endüstrisinde kullanılması ile ilgili 2020 yılında yapılan bir çalışmada yapay zekâ algoritmalarını ürün verilerinin kalitesini ve tutarlılığını iyileştirmek için kullanırken, yapay zekanın kestirimci bakımda uygulanabilirliğini saha çalışmalarında göstermişlerdir. (Lee diğ.2023)

Yakın geçmişte yayınlanan bir makale, AI'nın PdM/de (Predictive Maintenance) kullanılmasını sağlayan bir yaklaşım sunmaktadır. Yaklaşım, doğal dil işleme (NLP- Natural Language Processing) ve makine öğrenimi (ML) tekniklerini kullanmıştır. (H. Zhang ve diğ. 2021)

Endüstride üretime doğrudan veya dolaylı yoldan etki eden tüm makinelerin, makine-makine ve makine-insan sistemleriyle sürekli iletişim kurabilmesi ve karar alabilir hale gelmesi rekabet, kalite ve sürdürülebilirlik başlıklarında ayrı ayrı önemli hale gelmiştir. Ancak, bu ihtiyaç, her marka ve model için özel çözümler geliştirmenin maliyetli olduğu ve bu sebeple uygulanabilirlik için bir fizibilite yapılması gerekliliği göz önünde bulundurulmalıdır.

Bu çalışmayla ulaşılmak istenen nokta ve amaç, makinelerin üzerinden veri toplayarak ve makine öğrenme metodolojisi kullanarak tahmine dayalı bakım yöntemleriyle makine sağlığını tespit etmek ve bakım yönetim sisteminin en verimli halinin oluşmasını insandan

bağımsız şekilde sağlamaktır. Bu sayede, makine arızaları önceden tahmin edilebilir, böylece bakım yönetiminin tüm kararları en verimli haline getirilebilir.

1.2. Endüstride Bakım Süreçleri

Endüstriyel bakım, makinelerin ve ekipmanların düzenli olarak kontrol edilmesi, bakımının yapılması ve işlevselliğini sürdürebilmesi için gerçekleştirilen çeşitli stratejileri içerir. Endüstriyel bakım türleri aşağıdaki gibi kategorize edilebilir.

1.2.1. Periyodik bakım (Planlı Bakım)

Periyodik Bakım, aynı zamanda “Planlı Bakım” olarak da adlandırılır, makinelerin veya ekipmanın belirli aralıklarla, önceden belirlenmiş bir program dahilinde düzenli bakım ve kontrol işlemlerine tabi tutulması anlamına gelir. Bu bakım stratejisi, makinelerin uzun ömürlü olmalarını ve sürekli olarak etkili bir şekilde çalışmalarını sağlamayı hedefler. Periyodik Bakım, belirli bir program dahilinde gerçekleştirildiği için planlı bir şekilde organize edilir. Şekil 1.2 de örnek bir periyodik bakım çizelgesi verilmiştir.

Görev	Açıklama	Süre	Sıra	Periyot	İş Türü
10	BAKIMA BAŞLAMADAN ÖNCE EMNİYET TERTİBATLARININ KONTROLÜ	0:00			MEKANİK
	açın.Yükü kaldırın ve döner sapı "Kaldır" konumuna getirinJumbo vakum hortumlu kaldırma cihazını kapatın. Jumbo vakum hortumlu kaldırma cihazı yavaşça alçalmalı ve yük sadece zemine yakinken çözülmeli, aniden düşmemelidir.	0:03		AYLIK	MEKANİK
21	Vinç temizliği için soguk temizleyiciler kullanın, yıkama benzini veya asitli temizleyiciler kullanmayın.	0:00			MEKANİK
30	VAKUM ÜRETİMİ	0:00			MEKANİK
31	Fan, uygulama valfi kapalıyken ve yük kaçaksız olarak vakumlanmışken gürültüler çıkıyor mu?	0:02		YILLIK	MEKANİK
40	Vakum üreticilerin susturucuları temizlenmiş mi?	0:02		AYLIK	MEKANİK
50	Toz filtresi varsa temiz mi?	0:01		AYLIK	MEKANİK
60	Besleme hortumunun vaziyeti iyi mi? (kırık, kıvrık ve aşınmış kısımları)	0:02		AYLIK	MEKANİK
70	JUMBO VAKUM HORTUMU KALDIRMA CİHAZI	0:00			MEKANİK
80	Kumanda ünitesindeki filitrekeçesi halen duruyor mu ve temizlenmiş mi?	0:01		AYLIK	MEKANİK
90	Kaldırma hortumunun vaziyeti iyi mi? (pürüzlü, aşınmış ve delik kısımları)	0:02		AYLIK	MEKANİK
100	Döner yatak kolay hareket edebiliyor mu?	0:02		AYLIK	MEKANİK
110	Döner sap veya regülasyon kolu rahat işliyor mu?	0:02		AYLIK	MEKANİK

Şekil 1.2. Örnek periyodik bakım çizelge görüntüsü

Periyodik Bakımın temel özellikleri şunlardır:

Belirli zaman aralıkları:

Makine veya ekipmanın bakımı, belirli zaman aralıklarında ve önceden belirlenmiş bir program dahilinde yapılır. Bu aralıklar, üreticinin önerilerine, endüstri standartlarına veya tesis içindeki deneyimlere dayanabilir.

Düzenli kontroller:

Bakım sırasında, belirli bileşenlerin, parçaların veya sistemlerin düzenli kontrolleri gerçekleştirilir. Bu kontroller, makinelerin normal işleyişini değerlendirmek, aşınma veya hasar belirtilerini kontrol etmek ve potansiyel arızaları önceden tespit etmek içindir.

Parça değişimleri ve ayarlamalar:

Periyodik Bakım sırasında, belirli parçaların değişimi, yağlamalar, ayarlamalar ve gerekli diğer bakım işlemleri düzenli olarak gerçekleştirilir.

Bakım takvimleri ve kayıtlar:

Bakım takvimleri ve kayıtları, hangi ekipmanın ne zaman bakım yapılacağını ve hangi işlemlerin uygulanacağını belirler. Bu, bakım süreçlerinin düzenli bir şekilde izlenmesine olanak tanır.

Planlı iş durdurmalarına dayalı:

Periyodik Bakım, planlı iş durdurmalarına dayanabilir. Bu, belirli bir süre içinde tesisin işlemlerini durdurarak bakımın yapılmasını içerir.

Makinelerin ömrünü uzatma:

Planlı bakım, makinelerin ömrünü uzatmayı ve beklenmedik arızaları minimize etmeyi amaçlar.

Periyodik bakım, işletmelerin üretkenliğini artırmaya, maliyetleri düşürmeye ve ekipmanların daha uzun süre sorunsuz çalışmasını sağlamaya yönelik bir stratejidir. Bu bakım türü, önleyici bakım kategorisine girer, çünkü potansiyel arızaları önceden belirleme amacını taşır.

1.2.2. Kestirimci bakım (Predictive maintenance)

Kestirimci bakım, makinelerin durumunu sürekli olarak izleyerek, potansiyel arızaları önceden tahmin etmeyi amaçlar. Bu yaklaşım, sensörler, ölçümler ve diğer izleme yöntemleri aracılığıyla elde edilen verileri kullanarak, makinelerin gelecekteki bakım ihtiyaçlarını belirleme ve planlama üzerine kuruludur.

Kestirimci bakımın temel özellikleri şunlardır:

Sensör ve veri izleme:

Kestirimci bakım, makinelerde sensörler ve ölçüm cihazları kullanarak sürekli veri toplar. Bu sensörler, titreşim, sıcaklık, basınç gibi çeşitli parametreleri izleyebilir.

Büyük veri ve analitik:

Elde edilen veriler, büyük veri analitiği ve makine öğrenimi gibi tekniklerle işlenir ve analiz edilir. Bu sayede makine davranışları anlaşılır ve gelecekteki arızalar tahmin edilir.

Durum değerlendirmesi:

Kestirimci bakım, makinelerin durumunu sürekli olarak değerlendirir. Makinenin normal çalışma durumu ve potansiyel arıza belirtileri, izlenen verilerle karşılaştırılarak değerlendirilir.

Önceden bildirim:

Kestirimci bakım, bir arızanın gerçekleşmeden önce belirlenmesini amaçlar. Bu sayede, planlı bakım faaliyetleri önceden programlanabilir ve iş sürekliliği sağlanabilir.

Optimizasyon ve maliyet düşüşü:

Bakım faaliyetleri, ihtiyaç duyulduğunda ve tam olarak ne zaman gerekiyorsa yapılacağı için daha etkili ve maliyet açısından daha düşük olabilir.

Sürekli iyileştirme:

Kestirimci bakım, sürekli olarak verileri analiz eder ve bakım stratejilerini iyileştirmek için geri bildirim sağlar. Bu, sistemlerin sürekli olarak optimize edilmesini sağlar.

Kestirimci Bakım, beklenmeyen arızaların önüne geçmeyi, bakım maliyetlerini minimize etmeyi ve iş sürekliliğini artırmayı amaçlar. Bu strateji, endüstri 4.0 ve IoT (Nesnelerin İnterneti) gibi teknolojik gelişmelerle birlikte daha yaygın hale gelmiştir, çünkü bu teknolojiler, daha fazla veriyi toplamayı ve analiz etmeyi mümkün kılmaktadır.

1.2.3. Düzeltici bakım (Arıza onarımı)

Düzeltici Bakım, aynı zamanda Arıza Bakımı olarak da adlandırılır, makine veya ekipmanın bir arıza veya işlev kaybı durumunda gerçekleştirilen acil bakım faaliyetlerini ifade eder. Yani, bir ekipman arızalandığında veya istenmeyen bir durum meydana geldiğinde, bu durumu düzeltmek ve normal işleyişi yeniden sağlamak amacıyla yapılan bakım türüdür.

Düzeltici bakımın özellikleri şunlardır:

Beklenmeyen durumlar için:

Düzeltici bakım, bir makinenin beklenmeyen bir şekilde arızalandığı veya işlev kaybına uğradığı durumlar için planlanmamış bir bakım türüdür.

Acil müdahale:

Bu tür bakım, acil durumları ele almayı amaçlar. Bir ekipman arızalandığında, hızlı bir şekilde müdahale edilir ve sorun giderilmeye çalışılır.

Düzeltilici bakım, ekipmanın beklenmeyen duruşlarına neden olan arızalara karşı yapılır. Bu duruşlar, üretim süreçlerinde beklenmeyen kesintilere ve iş duruşlarına yol açabilir.

Bu bakım türü, belirli bir plan veya program dahilinde yapılmaz. Düzeltilici Bakım, gerektiğinde ve acil durumlarda gerçekleştirilir.

Arıza sebebini gidermeye odaklı:

Temel amacı, ekipmanın arıza sebebini tespit etmek ve gidermektir. Makinenin normal işleyişini yeniden sağlamak esas hedeftir.

Düzeltilici faaliyetler:

Arıza tespiti, onarım, parça değişimi ve diğer düzeltilici faaliyetler Düzeltilici Bakımın ana bileşenleridir.

Düzeltilici bakımın birkaç dezavantajı vardır. İlk olarak, beklenmeyen arızaların ve iş duruşlarının işletme maliyetlerini artırması söz konusudur. İkinci olarak, düzeltilici bakım, ekipmanın ömrünü kısaltabilir ve sürekli olarak kullanılabilirlik oranını düşürebilir. Bu nedenle, modern endüstriyel tesislerde genellikle diğer bakım stratejileri (örneğin, önleyici bakım veya durum bazlı bakım) ile kullanılarak, düzeltilici bakımın etkileri en aza indirilmeye çalışılır.

Arıza bakımında, acil müdahale kadar önemli olan aşama müdahale sonrası analiz ve kalıcı aksiyonların planlanmasıdır. Arızaya müdahale sonrası, plansız duruş durumu ortadan kalksa bile arıza sonrası geçici önlem, kalıcı çözüm, tekrar önleyici önlem ve yaygınlaştırma gibi bir dizi aksiyon planının oluşturulması gerekmektedir.

1.2.4. Şartlı bakım (Durum bazlı bakım)

Durum bazlı bakım (Condition-Based Maintenance veya CBM), endüstriyel bakım stratejilerinden biridir ve makinelerin veya ekipmanın fiziksel durumunu sürekli olarak izleyerek, bakım işlemlerini bu duruma göre planlama prensibine dayanır. Bu strateji, makinelerde potansiyel sorunları önceden belirleme ve gereksiz bakım maliyetlerini düşürme amacını taşır. Durum Bazlı Bakım, sensörler, ölçüm cihazları ve diğer izleme yöntemleri aracılığıyla makinelerin gerçek zamanlı durumunu değerlendirir.

Durum bazlı bakımın temel özellikleri şunlardır:

Sensör ve izleme sistemleri:

Makinelerde bulunan sensörler, titreşim ölçerler, sıcaklık sensörleri gibi izleme sistemleri kullanılarak, makinelerin fiziksel durumu sürekli olarak takip edilir.

Veri analizi ve değerlendirme:

Elde edilen sensör verileri, veri analizi ve değerlendirme süreçlerine tabi tutulur. Bu, makinenin normal çalışma durumunu ve potansiyel arıza belirtilerini anlamak için kullanılır.

Önceden belirleme:

Durum Bazlı Bakım, makinede oluşabilecek sorunları önceden belirlemeyi amaçlar. Bu sayede, beklenmedik arızaların önüne geçilir ve planlı bakım daha etkili hale gelir.

Planlı bakım:

Durum Bazlı Bakım, belirli bir durumun tespit edildiği noktada bakım yapılmasını içerir. Bu, makinelerin gerçekten ihtiyaç duydukları anlarda bakıma alınmasını sağlar ve gereksiz duraksamaların önüne geçer.

İşletme sürekliliği:

CBM, işletmelerin sürekli olarak çalışabilmesini sağlar. Beklenmedik arızaların azaltılması ve planlı bakımın optimize edilmesi, iş sürekliliğini artırır.

Maliyet düşüşü:

Durum Bazlı Bakım, gereksiz bakım maliyetlerini düşürmeyi ve yalnızca gerekli olan bakım faaliyetlerine odaklanmayı amaçlar. Bu, işletmelerin genel maliyetlerini optimize etmeye yardımcı olur.

Durum bazlı bakım, modern endüstriyel tesislerde yaygın olarak kullanılan bir stratejidir. Makinelerin gerçek durumlarını sürekli olarak izleyerek, bakımın daha etkili ve verimli olmasını sağlar.

1.2.5. Toplam üretken bakım (TPM)

Toplam üretken bakım (TPM), endüstriyel bir bakım stratejisidir ve tesis içindeki tüm çalışanların katılımını sağlayarak ekipmanların tam potansiyelini ortaya çıkarmayı hedefler. TPM, işletmelerin verimliliklerini artırmayı, makinelerin arızalarını önlemeyi ve üretim

süreçlerini sürekli olarak iyileştirmeyi amaçlar. Şekil 1.3'te TPM yöntemlerinden 5S diyagramı verilmiştir.



Şekil 1.3: TPM metotlarından biri olan 5S uygulamasının diyagramı

5S aşağıdaki gibi açıklanabilir.

1. Sort: Ayıkla
2. Set in order: Düzenle
3. Shine: Temizle
4. Standardize: Standartlaştır
5. Sustain: Disiplin

TPM'nin temel prensipleri şunlardır:

Toplam katılım:

TPM, sadece bakım ekibini değil, aynı zamanda tesis içindeki tüm çalışanların katılımını önemser. İşçiler, ekipmanların bakımına ve performansına etkileyebilecek herhangi bir durumu rapor etmeye teşvik edilir.

Önleyici bakım:

TPM, makinelerin arızalarını önlemeyi amaçlar. Bu nedenle, önleyici bakım stratejileri, düzenli bakım ve düzeltici bakım yerine, makinelerin sürekli olarak en iyi durumda olmasını sağlamaya odaklanır.

Makinelerin toplam bakımı:

TPM, makine bakımını sadece bakım ekibi değil, tüm tesis içindeki çalışanlar tarafından gerçekleştirilen bir sorumluluk olarak görür.

Makine operatörleri, basit bakım görevlerini gerçekleştirmekten sorumludur ve bakım ekibi ile yakın bir iş birliği içindedir.

Eğitim ve bilgi paylaşımı:

Çalışanlara TPM konusunda eğitim verilir ve bilgi paylaşımı teşvik edilir.

İş birliği ve bilgi paylaşımı sayesinde, herkes sürekli iyileştirmeye katkıda bulunabilir.

Kaizen (Sürekli İyileştirme):

TPM, sürekli iyileştirmeye dayalı bir yönetim anlayışını benimser.

İşletmeler, sürekli olarak iş süreçlerini ve bakım stratejilerini iyileştirmeye odaklanarak daha verimli ve rekabetçi hale gelmeyi hedefler.

Düzen ve temizlik (5s):

TPM, düzen ve temizlik konusuna da önem verir ve 5S (Sıralama, Düzenleme, Temizlik, Standardizasyon, Disiplin) prensiplerini uygular.

Temiz ve düzenli bir çalışma ortamı, bakım süreçlerini ve genel üretkenliği olumlu yönde etkiler.

Toplam üretken bakım, bir tesisin genel performansını artırmayı ve makinelerin sürekli olarak en iyi durumda çalışmasını sağlamayı amaçlayan kapsamlı bir yaklaşımdır.

1.2.6. Durum bazlı bakım ve kestirimci bakım arasında karşılaştırma

Durum bazlı bakım (Condition-based maintenance - CBM) ve kestirimci bakım (Predictive maintenance - PdM), makinelerin bakımı için kullanılan iki farklı stratejidir. İki yaklaşımın temel farkları şunlardır:

Temel felsefe:

Durum bazlı bakım (CBM): Bu yaklaşım, makinelerin durumunu sürekli olarak izleyerek, belirli bir durumun tetikleyici olduğu durumlarda bakım yapmayı amaçlar. CBM, ölçümler ve sensör verileri üzerinden makinelerin anlık durumunu değerlendirir.

Kestirimci bakım (PdM): PdM ise makinelerin gelecekteki arızalarını tahmin etmeyi amaçlar. Büyük veri analitiği, makine öğrenimi ve diğer teknolojiler kullanılarak, elde edilen veriler üzerinden gelecekteki bakım ihtiyaçları önceden tahmin edilir.

Veri kullanımı:

Durum bazlı bakım (CBM): CBM, genellikle anlık verilere odaklanır. Makinelerden gelen sensör verileri ve ölçümler, makinelerin şu anda nasıl çalıştığını değerlendirmek için kullanılır.

Kestirimci bakım (PdM): PdM ise genellikle büyük veri setleri ve geçmiş performans verileri üzerinden çalışır. Makine öğrenimi algoritmaları, bu verileri analiz eder ve gelecekteki arıza olasılıklarını tahmin etmeye çalışır.

Zamanlama:

Durum bazlı bakım (CBM): CBM, makinelerin belirli bir duruma ulaştığı anda bakım yapmayı planlar. Bu durum, önceden belirlenmiş eşik değerlerin üzerindeki bir değişiklik olabilir.

Kestirimci bakım (PdM): PdM, gelecekteki bir arızanın ne zaman olabileceğini tahmin etmeye çalışır ve bu tahminlere dayanarak bakım planlar.

Bakım tipi:

Durum bazlı bakım (CBM): CBM, genellikle duruma özgü bakımı içerir. Yani, bir belirtilen durum veya değerlere ulaşıldığında, belirli bir bakım eylemi tetiklenir.

Kestirimci bakım (PdM): PdM ise genellikle önleyici bakım kategorisine girer. Gelecekteki arızaları önlemek ve planlamak için yapılır.

Her iki strateji de makinelerin daha etkili ve verimli bir şekilde bakımını sağlamayı hedefler, ancak kullanılan yaklaşım ve veri analizi yöntemleri arasında önemli farklar bulunmaktadır.



2. KALAN FAYDALI ÖMÜR VE EKİPMAN ETKİNLİĞİ

Tahmine dayalı bakım, makinelerin veya üretim ekipmanlarının belirli bir zaman aralığındaki sağlık durumunu tahmin etme ve öngörme sürecini ifade eder. Bu öngörüler, sensör, termal kamera, transmitter gibi ekipmanların yardımıyla toplanan verilerin analiziyle yapılır. Tahmine dayalı bakım, "Kalan Faydalı Ömür"ü (Remaining Useful Life- RUL- KFÖ) tahmin etmeyi amaçlar. Böylece makinelerin ve ekipmanların anlık ve gelecekteki durumu belirlenebilir ve olası arızalar önceden tahmin edilebilir. Oluşturulan tahminler sayesinde, bakım programı oluşturularak ihtiyaç duyulan bakım iş planına alınırken gereksiz bakımlar önlenir.

KFÖ tahmini, makinelerin gelecekteki performansını öngörmek ve arızadan önce kalan süreyi tahmin etmek için kullanılan bir süreçtir (Lei ve diğerleri, 2016).

KFÖ tahmininde genellikle üç model kullanılır:

- Hayatta Kalma Modeli: Arızanın meydana geldiği andaki veriler bilindiğinde,
- Bozulma Modeli: Arızanın ne zaman meydana geldiğini belirleyen bir eşik değeri bilindiğinde,
- Benzer Modeli: Makinenin sağlıklı olduğu bilinen bir zaman noktasından itibaren arıza anına kadar olan tüm veriler bilindiğinde uygulanır (Özkat, 2021).

Fabrikalarda ekipman etkinlik oranı, üretim tesislerinde kullanılan ekipmanların ne kadar süreyle ve ne kadar verimli bir şekilde çalıştığını ölçen bir performans göstergesidir. Bu gösterge, bir fabrikanın üretim verimliliğini ve ekipman kullanımını değerlendirmek için önemlidir. Ekipman etkinlik oranı, aşağıdaki faktörlere dayalı olarak hesaplanabilir:

Çalışma süresi (Working Time): Ekipmanın belirli bir süre boyunca ne kadar süreyle çalıştığı önemlidir. Çalışma süresi, bir ekipmanın beklenen çalışma saatleri veya günleri ile karşılaştırılabilir.

Verimlilik (Productivity): Ekipmanın ne kadar üretim yaptığı veya işlem tamamladığı göz önüne alınır. Üretilen ürün miktarı veya hizmet sağlama kapasitesi, ekipmanın verimliliğini değerlendirmek için kullanışlı bir ölçüdür.

Arıza süresi (Downtime): Ekipman arızaları ve onarımları nedeniyle kaybedilen süreler, ekipmanın etkinlik oranını olumsuz etkiler. Arıza süresinin minimize edilmesi, ekipmanın daha uzun süre çalışmasını sağlar.

Bakım süreleri (Maintenance Time): Planlı bakım süreleri, ekipmanın uzun vadeli sağlamlığını ve performansını artırabilir, ancak bu sürelerin etkin bir şekilde yönetilmesi gereklidir.

Ekipman etkinlik oranı, işletmelerin üretkenliği artırmak ve maliyetleri düşürmek için önemlidir. İyi bir ekipman etkinlik oranı, üretim süreçlerinin daha düşük maliyetle daha fazla ürün üretmesine olanak tanır. Bu nedenle fabrikalarda ekipman etkinlik oranının sürekli olarak izlenmesi ve iyileştirilmesi, işletmelerin rekabetçiliğini artırmalarına yardımcı olabilir.

2.1. Ekipman Etkinlik Oranı

Otomotiv fabrikasında ekipman etkinlik oranı, fabrikadaki üretim ekipmanlarının ne kadar süreyle ve ne kadar etkili bir şekilde kullanıldığını ölçen bir performans göstergesidir. Bu oran, üretim ekipmanlarının toplam süre içinde ne kadar süreyle üretim yaptığını ve bu süre içinde ne kadar verimli olduğunu değerlendirerek, tesisin genel verimliliği hakkında bilgi sağlar.

Ekipman etkinlik oranı genellikle şu formülle hesaplanır:

$$\text{Ekipman Etkinlik Oranı (\%)} = \frac{\text{Planlı Üretim Süresi} - \text{Planlı Duruş Süresi}}{\text{Planlı Duruş Süresi}} \times 100 \quad (2.1)$$

Bu formülde:


Planlı üretim süresi: Ekipmanın planlanan üretim süresi, yani makinenin ideal koşullarda çalışması gereken süredir.

Planlı duruş süresi: Ekipmanın planlanan duruş süresi, yani belirli bir bakım, ayar veya diğer duruş nedenleri için ayrılan süredir.

Ekipman etkinlik oranının yüksek olması, ekipmanın planlandığı gibi verimli bir şekilde çalıştığını ve üretim süreçlerine minimum kesintiyle katkı sağladığını gösterir. Bu durum ise tesisin daha yüksek verimliliğe ve üretkenliğe sahip olduğu anlamına gelir. Düşük bir Ekipman Etkinlik Oranı ise üretim ekipmanlarının beklenen performansı sağlamada sorunlar yaşadığını veya planlı duruş sürelerinin aşıldığını gösterebilir, bu da üretim verimliliğini olumsuz yönde etkilemektedir.

Otomotiv fabrikalarında bu tür performans göstergeleri, üretim süreçlerinin izlenmesi ve sürekli iyileştirme çabalarının yönlendirilmesi için önemlidir. Bu veriler, tesis yönetimine

ekipman etkinliđi konusunda bilgi sađlar ve operasyonel sũreçlerin daha verimli ve rekabetçi olması için çeşitli stratejilerin belirlenmesine yardımcı olmaktadır. Şekil 2.1 de ekipman etkinlik oranının toplam zaman içerisinde verimsiz sũrelerden ayrıştığı oranlar verilmiştir.



Şekil 2.1. Ekipman etkinlik oranı ve diđer kayıp sũreler

Etkinliđi ölçmenin yolu ise kayıpları analiz etmekten geçer. TPM uygulamasına göre ekipman etkinliđine etkiyen 8 büyük kayıp vardır. Bunlar:

- Kapatma Kaybı
- Arıza Kaybı
- Setup-Ayar Kaybı
- İkmal-Doldurma
- Başlama
- Hız
- Çokote (takılma-rolanti)
- Hurda



3. MAKİNE ÖĞRENMESİ METODU

Makine öğrenmesi, bilgisayar sistemlerinin deneyimlerinden öğrenerek, veri analizi yapabilme ve gelecekteki görevleri daha iyi gerçekleştirebilme yeteneğine sahip olma sürecini ifade eder. Temel amacı, bir algoritmanın belirli bir görevi, veri üzerinden öğrenme ve deneyim kazanma süreciyle gerçekleştirebilmesidir.

Makine öğrenmesinin temel özellikleri şunlardır:

Öğrenme Yeteneği: Makine öğrenmesi algoritmaları, belirli bir görevi daha iyi gerçekleştirmek için deneyim ve veri kullanarak kendilerini geliştirebilirler.

Deneyime Dayalı Çalışma: Algoritmalar, geçmiş verileri analiz ederek öğrenirler. Bu nedenle, geçmiş deneyimlere dayalı olarak gelecekteki tahminleri veya kararları daha iyi yapabilirler.

Özelleştirilebilirlik: Algoritmalar, belirli bir görev için tasarlandıkları kadar genel amaçlı da olabilirler. Yani, bir algoritma belirli bir probleme özgü hale getirilebilir.

Doğrusal Olmayan İlişkileri Tanıma: Makine öğrenmesi, doğrusal olmayan, karmaşık ilişkileri tanıma ve modelleme yeteneğine sahiptir. Bu, karmaşık veri setlerindeki desenleri keşfetme açısından önemlidir.

Otomatik Güncelleme: Bazı makine öğrenmesi modelleri, zamanla yeni verilerle güncellenerek performanslarını artırabilirler.

Makine öğrenmesi, genellikle denetimli ve denetimsiz öğrenme olmak üzere iki ana kategoriye ayrılır:


3.1. Denetimli Öğrenme (Supervised Learning)

Bu öğrenme tipinde, algoritma eğitim sürecinde giriş verileri ile birlikte doğru çıkış verileri (etiketler) ile beslenir. Algoritmanın amacı, giriş verileri ile etiketler arasındaki ilişkiyi anlamak ve bu ilişkiyi öğrenmek, böylece yeni, daha önce görülmemiş giriş verileri üzerinde tahminlerde bulunabilmektir. Şekil 3.1 de denetimli öğrenmenin akış şeması verilmiştir.

dinamiklere bağılı olan oluşan verilerin, her ekipmanda oluşturduğu etki-çıkı arasındaki ilişkinin öğretilmesi amaçlanmıştır.

3.2. Denetimsiz Öğrenme (Unsupervised Learning)

Bu öğrenme tipinde, algoritmaya eğitim verileri içinde etiket bilgisi verilmez. Yani, giriş verileri yalnızca özelliklerden oluşur, ancak bu verilere karşılık gelen bir çıkış etiketi veya hedef bilgisi bulunmaz. Algoritmanın amacı, bu veri setindeki desenleri, grupları veya yapıları ortaya çıkarmak ve bu desenlere dayalı olarak bilgi elde etmektir. Şekil 3.2 de denetimsiz öğrenme akış şeması verilmiştir.



Şekil 3.2. Denetimsiz öğrenme akış şeması

Denetimsiz öğrenme şu temel türlerde gerçekleşebilir:

Kümeleme (Clustering): Giriş verileri, benzer özelliklere sahip olan gruplara ayrılır. Örneğin, benzer türdeki belgeleri gruplandırmak, müşteri segmentasyonu gibi.

Boyut Azaltma (Dimensionality Reduction): Veri setindeki gereksiz özellikleri çıkararak, verinin temel yapısal özelliklerini daha anlaşılır ve kullanışlı hale getirme anlamını taşımaktadır. Örneğin, PCA (Principal Component Analysis) veya t-SNE (t-distributed stochastic neighbor embedding) gibi teknikler kullanılabilir.

Birliktelik Kuralları (Association Rules): Veri setindeki öğeler arasındaki ilişkileri belirleme. Örneğin, liftin kaldırdığı araç gövdelerini kategorize ederek hangisinin daha sık geçtiğini hangisinin daha seyrek geçtiğini belirleme.

Denetimsiz öğrenme algoritmaları, genellikle veri setindeki içsel yapıları keşfetmek, desenleri anlamak ve bu desenlere dayalı olarak yeni bilgiler üretmek amacıyla kullanılır. Bu tür öğrenme genellikle keşifsel analiz, veri madenciliği ve veri görselleştirmesi gibi uygulamalarda kullanılır.

Denetimsiz öğrenme, özellikle büyük veri setlerinde ve veri içerisindeki gizli desenleri ortaya çıkarmak istendiğinde güçlü bir araç olabilir. Ancak, bu tür bir öğrenme tipinde, algoritmanın

öğrenme süreci sırasında insan müdahalesi olmaksızın doğru sonuçlar elde etmek bazen zor olabilir. Bu nedenle, denetimsiz öğrenme genellikle daha fazla keşif ve analiz gerektiren bir süreçtir.

3.3. Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, bir makine öğrenme paradigmasıdır ve bir ajanın çevresindeki durumları gözlemleyerek, bu durumlara göre kararlar almasını ve bu kararların sonuçlarından öğrenmesini amaçlar. Temelde bir ajan, bir ortamda belirli bir hedefi gerçekleştirmeye çalışırken, bu süreçte aldığı aksiyonların sonuçlarına göre ödüller veya cezalar alarak öğrenir.

Pekiştirmeli öğrenme süreci aşağıdaki temel bileşenleri içermektedir

Ajan (Agent): Öğrenme sürecine katılan karar verici birimdir. Bir robottan bir bilgisayar programına kadar çeşitli sistemler olabilir.

Çevre (Environment): Ajanın etkileşimde bulunduğu ve üzerinde aksiyonlar gerçekleştirdiği dış dünyadır.

Durum (State): Belirli bir zamandaki çevre durumunu temsil eden bilgilerdir. Durum, ajanın gözlemlediği çevresel faktörleri içerir.

Aksiyon (Action): Ajanın çevreye etki etmek için gerçekleştirdiği işlemlerdir.


Ödül (Reward): Ajanın belirli bir durumda gerçekleştirdiği bir aksiyonun sonucunda alınan anlık geri bildirimdir. Ajan, hedefine ulaşma veya bir görevi yerine getirme amacıyla bu ödülleri maksimize etmeye çalışır.

Pekiştirmeli öğrenme, öğrenme sürecinin daha az denetim içermesiyle (etiketli veri veya belirli çıkışlar olmaksızın) diğer öğrenme türlerinden farklıdır. Ajan, çevresiyle etkileşimde bulunarak deneme-yanılma yöntemiyle en iyi stratejileri öğrenir.

Bu öğrenme tipi, özellikle oyun teorisi, robot kontrolü, finansal işlemler, trafik yönetimi ve yapay zekâ alanındaki birçok uygulamada kullanılır. Pekiştirmeli öğrenme algoritmaları arasında Q-learning, Deep Q Network (DQN), ve Actor-Critic gibi çeşitli yöntemler bulunmaktadır.

4. MATERYAL VE METOT

Bu çalışmada otomotiv sektöründe sıkça kullanılan konveyör sistemleri, drop lift ve makaslı lifti sistemleri, otomatik caraskal-vinç sistemleri gibi transfer ekipmanları, endüstriyel kontrol ve otomasyon teknolojisinin her alanında görülebilen, lojik kontrol ekipmanı (PLC), Asenkron motor ve Motor sürücüsü, Python uygulaması, sensör teknolojileri ve algılama sistemleri kullanılmıştır. İlk aşamada temel Excel uygulamasında veri toplama birleştirme ve kategorize adımları tamamlanarak, ideal durum şartları belirlenmiş ve algoritma oluşturulmasında yapay zekâ kütüphanesinden hazır algoritma şablonları kullanılmıştır. Çalışmanın ilk denemeleri için titreşim, motor sıcaklığı ve akım değerlerini takip edilerek gözlemlenen ekipman Şekil 3.3'te verilmiştir.



Şekil 3.3. Yatay transfer sağlayan hareketli konveyör sistemi

Veri toplama:

Bu çalışmanın başlangıcında, otomotiv üretim hattındaki makinelerin durumlarını izlemek ve kestirimci bakım modelini eğitmek için gerekli veriler toplanmıştır. Sensörler, titreşim ölçerler, sıcaklık sensörleri ve diğer izleme cihazları kullanılarak makine performansına dair geniş bir veri seti elde edilmiştir.

Veri temizleme ve düzenleme:

Toplanan veri seti, eksik veya anlamsız verilerden arındırılmıştır. Karmaşıklığı azaltmak ve modelin daha iyi öğrenmesini sağlamak için veriler düzenlenmiştir. Anlamlı özellikler belirlendi ve gereksiz değişkenler kaldırılmıştır.

Proses mühendisliği:

Makine öğrenmesi algoritmalarının daha etkili olabilmesi için proses mühendisliği yapılmıştır. Sürecin uçtan uca analitik veri değerlendirmesi yapılabilmesi için bakım, yazılım ve ölçüm süreçleri birleştirilerek bakım yönetim prosesi oluşturulmuştur. Sensör ve diğer algılayıcıların en doğru veriyi fiziksel olarak hangi noktadan alabileceği, haberleşme protokolünün belirlenmesi, algoritmalarda hangi verilerin kullanılacağı belirlenmiştir.

Model seçimi:

Bu aşamada, kestirimci bakım modelini eğitmek için uygun bir makine öğrenmesi algoritması seçilmiştir. Çeşitli algoritmalar, modelin doğruluğu, hassasiyeti ve hatırlama yeteneği gibi performans ölçütleri üzerinde karşılaştırılmıştır.

Model eğitimi:

Seçilen algoritma ile veri seti üzerinde bir eğitim süreci başlatılmıştır. Model, makine durumu ile arıza olasılığı arasındaki ilişkiyi öğrenmek için yeterli sayıda iterasyonla eğitilmiştir.

Model doğrulama:

Eğitim sürecinin ardından, modelin doğruluğunu değerlendirmek için ayrı bir doğrulama veri seti kullanılmıştır. Modelin gerçek dünya senaryolarında ne kadar iyi performans gösterdiği objektif bir şekilde değerlendirilmiştir.

Kestirimci bakım stratejisi oluşturma:

Eğitilen model, belirlenen bakım eşik değerlerini kullanarak otomotiv üretim hattındaki makinelerin gelecekteki arızalarını tahmin etmeye başlamıştır. Bu tahminlere dayanarak, kestirimci bakım stratejisi oluşturuldu ve uygulanması için bir plan geliştirilmiştir.

Gerçek zamanlı izleme ve güncelleme:

Modelin devreye alınmasının ardından, sürekli olarak yeni veri ile beslenerek güncellenmesi sağlanmıştır. Gerçek zamanlı izleme, modelin değişen koşullara uyum sağlamasını ve daha doğru kestirimler yapmasını sağlamıştır.

Bu metodoloji, makine öğrenmesi ile kestirimci bakım uygulamalarını geliştirmek ve endüstriyel tesislerde ekipman etkinliğini artırmak için kapsamlı bir yaklaşım sunmaktadır.

Bu çalışmada, geleneksel metotlarının daha verimli yapılabilmesi, zamana dayalı yapılan planlı bakım süreçlerinin plansız duruş ve arızalarda istenilen etkinliği göstermemesi sebebiyle, anlık durum değerlendirme ile bakım ihtiyacının otonom belirlenerek bakım programının ihtiyaca göre güncellenebilir olması amacıyla yapılmıştır.

Bakım programının oluşturulması için, veriler toplanmış, yapay zekâ yardımıyla en etkili algoritmalar oluşturulmuş ve sonuca doğrudan etki eden en verimli bakım programı için makine öğrenmesi yöntemleri uygulanmıştır.

Uygulamaların yapıldığı üretim sahası 10.000 adetten fazla birlikte ve haberleşme ağı ile bağlı çalışan makinelerin ve ekipmanların takip edildiği bir alan olması sebebiyle ekipmanlar envanter üzerinden ve daha önce elde edilen veriler incelenerek kategorize edilmesi sağlanmıştır. Anlık olarak üretim verileri MES (Manufacturing Execution System) adlı program üzerinden alınmıştır. MES, üretim anında anlık çıkan arızaların Lojik kontrol sağlayan devre elemanı (PLC) üzerinden veri olarak arızaları ve arızalı ekipmanları görüntüleyebileceğimiz bir sistem arayüzüdür. Çalışmada incelenen makineler ve ekipmanlar, arıza yaşanan duruş anında, programlanabilir ekipman kontrol elemanı olan Siemens marka S 7 400 serisi PLC üzerinde uyarı verir. PLC üzerinde oluşan arıza uyarısı MES sistemine ileterek veri tabanı oluşmaya başlar. Toplanan veriler çalışmanın amacı olan ekipman etkinlik oranını artırmaya yönelik olarak yapay zeka aracılığıyla oluşturulan algoritmalarda kullanılır. Çalışmanın üretim ve bakım sistemi üzerinde oluşturduğu etki, MES üzerinde görüntülenebilir olmalıdır.

3 farklı veri kaynağı kullanılarak tahminleme yapılmasına karar verilmiştir.

- Titreşim
- Sıcaklık
- Akım


Motor sürücüsü üzerinden, sürücü sıcaklığı, motor sıcaklığı, pano sıcaklığı ve akım bilgisi toplanır. Makinelerin hareket kaynağı olan motorun çalışma şartlarını, devir ve hız ayarını kontrol eden ve denetleyen ekipman sürücü olarak adlandırılır. Bu çalışmada konveyörler için Siemens G120 CU 240E-2PN-F model sürücü, SEW marka motorlar için MDX61B Profiline model sürücü kullanılmıştır.

Döner ekipmanların yataklamaları üzerine titreşim sensörü koyularak rulman üzerine etki eden titreşim frekansı ölçülmektedir. Bu çalışmada Banner QM42VT model titreşim sensörü seçilmiştir.

Titreşim sensörü aşağıdaki adımlar izlenerek veri toplama adımına başlanmıştır.

Sensör yerleştirme ve konfigürasyon:

Doğru konumlandırma: Titreşim sensörleri, makinelerin kritik noktalarına doğru bir şekilde yerleştirilmelidir. Bu noktalar genellikle rulmanlar, dişliler, pervaneler gibi makinelerin önemli bileşenleridir. Sensör, rulman merkeze dik, yüzeyi tam kavrayacak şekilde yerleştirilmiştir. Şekil 4.1 de titreşim sensörü uygulanmış bir asenkron motor fotoğrafı verilmiştir.



Şekil 4.1. Titreşim sensörü uygulaması

Sensor ayarı: Sensörlerin hassasiyeti ve örnekleme hızı gibi ayarları, izlenen makinenin özelliklerine göre doğru bir şekilde konfigüre edilmiştir.

Veri toplama:

Sürekli veri akışı: Titreşim sensörleri sürekli olarak titreşim verileri alınmış ve bu verileri bir merkezi veri toplama veya izleme sistemi üzerinden toplanmıştır.

Frekans analizi: Veriler, frekans analizi yöntemleriyle incelenmiştir. Özellikle belirli frekanstaki titreşimler, potansiyel arızaların belirtileri olabileceği için, sensör imalatçısı ile frekansların rulman tipine göre hangi aralıkta ne anlama geleceği know-how bilgisi alınarak sürece devam edilmiştir.

Normal durum benchmarking:

Makinelerin normal titreşim Profili: İlk aşamada, makinenin normal işleyiş durumu belirlenmiştir. Bakımları eksiksiz yapılmış ve kullanıma yeni alınan bir ekipmanın değerleri referans alınmıştır.

Anomalilerin belirlenmesi:


Titreşim değişiklikleri: Titreşim sensörleri, makinedeki herhangi bir titreşim değişikliğini algılar. Bu değişiklikler, genellikle bir arızanın belirtileri olarak kayıt altına alınmıştır.

Veri analizi: Toplanan veriler, makine öğrenimi algoritmaları veya basit istatistiksel analizler kullanılarak incelenmiştir.

Alarm ve kestirimler:

Anormal durumlar için alarm: Titreşim sensörleri, belirlenen eşik değerleri aştığında otomatik olarak bir alarm üretebilir.

Şekil 4.2'de titreşim sensörünün verilerinin oluşması ve transferini ifade eden akış şeması verilmiştir.



Şekil 4.2. Titreşim verisi oluşturma diyagramı

PLC, "Programmable Logic Controller" kelimelerinin kısaltmasıdır ve Türkçe 'de "Programlanabilir Mantık Kontrol Cihazı" olarak adlandırılır. PLC'ler, endüstriyel otomasyon sistemlerinde, fabrika otomasyonunda ve diğer kontrol uygulamalarında kullanılan bir tür

dijital bilgisayar tabanlı kontrol cihazıdır. Temel olarak, PLC' ler endüstriyel süreçleri, makineleri ve otomasyon sistemlerini kontrol etmek ve yönetmek için tasarlanmıştır.

PLC'lerin Temel Özellikleri:

Programlanabilirlik: PLC'ler, kullanıcıların özel kontrol algoritmalarını ve mantık şemalarını programlayabilmelerini sağlayan bir programlama dilini desteklemektedir.

Modülerlik: Genellikle modüler bir yapıya sahiptirler, bu da sistemin ihtiyaçlarına göre genişletilebilir ve özelleştirilebilir oldukları anlamına gelmektedir.

Giriş/Çıkış kontrolü: Giriş ve çıkış modülleri aracılığıyla dijital ve analog sinyalleri işleyebilirler. Bu, sensörleri ve aktüatörleri kontrol etmek için kullanılır.

Sanal çalışma: Bir PLC, önce programlandıktan sonra bağımsız olarak çalışabilir. Yani bir bilgisayar bağlantısı olmadan programını uygulayabilmektedir.

PLC'ler, genellikle bir endüstriyel otomasyon sistemindeki diğer cihazlarla (sensörler, aktüatörler, HMI – İnsan Makine Arayüzü gibi) iletişim kurabilir ve bir süreç veya makineyi kontrol etmek için tasarlanmış programları çalıştırabilmektedir.

PLC 'nin çalışma prensibi:

Giriş modülleri: Sensörler, anahtarlama cihazları ve diğer giriş cihazlarından gelen fiziksel sinyalleri (örneğin, bir düğmenin açık veya kapalı olma durumu) alır.

Merkezi işlem birimi (CPU): Giriş modüllerinden gelen bilgileri işler ve programın tanımladığı mantık ve kontrol algoritmalarını uygular.

Çıkış modülleri: Makine veya süreç üzerinde kontrolü sağlamak için hareketli parçaları kontrol etmek veya diğer çıkış cihazlarına sinyaller göndermek için kullanılır.

Program belleği: Kullanıcının programladığı mantık ve kontrol algoritmalarını depolar.

PLC'ler, kullanıcıların endüstriyel süreçleri programlayarak ve kontrol ederek otomasyon sistemlerini yönetmelerine olanak tanır. Bu sayede üretim süreçleri daha verimli, güvenilir ve esnek hale getirilebilir. Şekil 4.3'te işletmede kullanılan PLC fotoğrafı verilmiştir.



Şekil 4.3. PLC panosu ve Siemens S7-1500 PLC görseli

Lojik kontrol eleman ihtiyaç duyduğu verileri asenkron motorlara bağlı sürücülerden motor akım ve sıcaklık bilgisi elde ederken, titreşim sensöründen almıştır. PLC' de toplanan veriler, yapay zekâ yardımı ile oluşturulan algoritmaların denkleminde girdi olarak kullanılmak üzere veri tabanına iletilmektedir. Toplanan ürün, sıcaklık, titreşim ve motor akım verileri girdi olarak değerlendirilirken, MES üzerinde oluşan arıza ve duruş süreleri çıktı olarak kabul edilmiştir. Bu çıktılar bakım programının oluşturulmasında ve makine öğrenmesi uygulamasında yeniden girdi olarak kullanılacaktır. Algoritma oluşturmak için yapay zekâ kullanmanın bir diğer faydası, verileri kullanılmasıyla elde edilen çıktıların, ilk verilere besleme verisi oluşturması ve bu sayede tekrar ederek öğrenen ve gelişen bir ekosistem oluşturmasıdır.

Toplanan verilerle ortaya çıkan veri tabanı üzerindeki değişiklik düzenleme işlemlerine imkân sağlayan programlama dili olarak SQL (Structured Query Language- Yapılandırılmış Sorgu Dili) kullanılır. Verileri çıkarma, değiştirme ve depolama gibi çeşitli işlemleri gerçekleştirir. SQL, ilişkisel veri tabanları ile çalışmak için tasarlanmıştır. Birbirleriyle ilişkili olan bu veriler, farklı veri değerleri arasındaki çeşitli ilişkileri ifade eden satırlar ve sütunlar ile bilgileri tablo şeklinde depolar.

Verilerin ekosisteme dahil olması için kullanılacak algoritmalar, Python üzerinde oluşturulmuştur. Python, makine öğrenmesi uygulamaları geliştirmek için yaygın olarak kullanılan bir programlama dilidir. Makine öğrenmesi projeleri geliştirmek için Python kullanmak oldukça yaygındır çünkü Python, zengin bir makine öğrenimi kütüphane ekosistemine ve kullanıcı dostu bir sözdizimine sahiptir. Makine öğrenimi algoritması oluşturmak için aşağıdaki adımlar izlenmiştir.

Adım 1: Python ve gerekli kütüphanelerin kurulumu

Python ücretsiz olarak kullanılabilen bir programlama dilidir. Makine öğrenmesi projeleri için kullanılan popüler kütüphaneleri ise Şekil 4.4'te gösterildiği gibi başlanarak devam eden adımlar izlenerek oluşturulabilir. Şekil 4.5'te kütüphane kurulumu adımı model oluşumuna başlanma adımı verilmiştir.

```
bash

pip install scikit-learn pandas matplotlib
```

Şekil 4.4. Python'da kütüphane kurulumu adımı 1

```
model = Sequential()

# RNN katmanı eklenir
model.add(SimpleRNN(units=64, activation='relu', input_shape=(timesteps, input_dim)))

# Çıkış katmanı eklenir
model.add(Dense(units=output_dim, activation='sigmoid'))
```

Şekil 4.5. Modelin oluşturulması

Adım 2: Veri setinin incelemesi


Sensörlerden ve PLC üzerinde toplanan anlık verilerle birlikte, manuel olarak girilen arıza türleri, duruş süreleri ve üretim verileri set olarak kategorize edilip incelenmiştir. Kullanılan akım, sıcaklık ve titreşim verileri değişken verileri, arıza kök neden, arıza süresi, üretim süresi verileri ile eşleştirilmiştir.

Adım 3: Veri hazırlığı

Veri setini temizlemek için, veri üzerine bir time-out biti eklenmiş ve sadece normal koşullarda çalışma verileri alınmıştır. Çalışma esnasındaki anlık veri kayıpları ve anlık değişkenlikler aralık dışında bırakılarak set içinden çıkarılmıştır. Bu durum, örneğin titreşim sensörü takılı bir liftin üzerinde geometrisi anormal olan bir araç gövdesi geldiğinde liftin durumundan bağımsız olarak sadece o gövdeye özel anlık bir titreşim sebep olması ihtimaline karşı önlem olarak alınmıştır. Aynı şekilde haberleşme protokolündeki anlık kopukluk durumunda akım verisindeki kısa süreli değişiklik kapsam dışına alınmıştır.

Adım 4: Veri görselleştirme

Veriyi görselleştirerek, veri setindeki desenleri anlamak ve makine öğrenimi modeliniz için önemli özellikleri belirlemek, Şekil 4.6' da görüldüğü gibi daha spesifik sonuçlar elde edilmesini sağlamıştır.



Şekil 4.6. Akım veri setinin görselleştirilmesi

Adım 5: Model seçimi

Çalışmanın gereksinimlerine ve veri setinizin yapısına göre uygun bir makine öğrenimi algoritması seçilmelidir. Sınıflandırma ve regresyon çalışmalarında istatistiksel olarak daha yaygın kullanılan RNN Recurrent Neural Network (Yinelemeli Sinir Ağı), algoritması seçilmiştir.

Verilerin kategorizasyonu ve algoritma oluşturulması için, açık kaynak bir RNN kütüphanesinden önceden hazırlanmış bir algoritma şablonu alınmış ve bu şablona verilere özgü düzenlemeler yapılmıştır. RNN, zaman serileri üzerinde çalışabilen yapay sinir ağıdır. Bu özelliği, RNN' lerin geçmiş veri girdilerini hatırlayabilmesine ve bu bilgileri kullanarak gelecekteki girdileri tahmin edebilmesine olanak tanımaktadır. Kısacası, RNN' lerin işleyiş prensibi bir iç durum belleği üzerine kuruludur.

Verinin en yüksek analitik değerlendirilebilme kapasitesine sahip olması nedeniyle, ilk algoritmanın oluşturulmasında RNN sinir ağları kullanılarak Python programında kod yazılmıştır.

Buradan sonraki süreçte aşağıdaki adımlar gerçekleşir:

1. Verileri yükleme
2. Verileri eğitim ve test setlerine ayırma
3. RNN modelini oluşturma
4. Modeli eğitme
5. Modeli değerlendirme
6. Tahminleme

Elde edilen veriler, "vibration_data.csv" olarak isimlendirilen dosyadan alınır. Bu dosya, her bir titreşim ölçümünün zamanını ve değerini içeren bir sütun matrisini içerir. Veriler, eğitim

ve test setlerine 80/20 oranında ayrılır. Eğitim seti, modelin eğitildiği verileri içerirken, test seti, modelin performansının değerlendirildiği verileri içerir.

RNN modeli, 128 nöronlu bir Embedding katmanı, 128 nöronlu bir LSTM (Uzun Kısa Süreli Bellek) katmanı ve 1 nöronlu bir çıktı katmanından oluşur. LSTM, özellikle zaman serisi veya sıralı verilerle çalışırken kullanılan bir tür tekrarlayan sinir ağı (RNN) katmanıdır. Bu katman, sıralı verilerdeki uzun vadeli bağımlılıkları daha iyi ele alabilen bir yapı sunar ve geleneksel RNN' lerdeki sorunları çözmek amacıyla tasarlanmıştır. LSTM, geçmiş bilgileri unutma, mevcut bilgileri güncelleme ve gelecekteki bilgileri hatırlama yeteneğine sahiptir. Bu özellikleri sayesinde, LSTM uzun vadeli bağımlılıkları öğrenebilir ve saklayabilir.

Embedding katmanı, doğal dil işleme ve metin madenciliği uygulamalarında kullanılan bir sinir ağı katmanıdır. Bu katman, kelimeleri sayısal vektörlere dönüştürerek, kelime dağarcığını anlamlı bir uzayda gömme (embed) işlemini gerçekleştirir ve bu sayede benzer anlamdaki kelimeler arasında uzaklıkları korur. Embedding katmanı, her bir titreşim ölçümünü bir vektöre dönüştürür. Çıktı katmanı, arıza olasılığını tahmin eder.

Model, 100 epoch boyunca Adam optimizatörü kullanılarak eğitilir ve eğitim kaybı ile doğruluğu değerlendirilir.

```

import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import SimpleRNN, Dense

# Basit bir zaman serisi oluřturalım
timesteps = 100
time = np.arange(timesteps)
X = np.sin(0.1 * time) + 0.1 * np.random.randn(timesteps)

# Veriyi eğitim seti olarak ayıralım
X_train = X[:80]
y_train = X[1:81]

# Veriyi uygun formata dönüřtürelim
X_train = X_train.reshape((1, X_train.shape[0], 1))
y_train = y_train.reshape((1, y_train.shape[0], 1))

# RNN modelini oluřturalım
model = Sequential()
model.add(SimpleRNN(10, activation='relu', input_shape=(timesteps-1, 1)))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')

# Modeli eğitelim
model.fit(X_train, y_train, epochs=50, verbose=1)

# Tahmin yapalım
X_test = X[80:]
X_test = X_test.reshape((1, X_test.shape[0], 1))
y_pred = model.predict(X_test)

# Sonuçları görselleřtirelim
plt.plot(time, X, label='Gerçek Veri')
plt.plot(np.arange(81, timesteps), y_pred.flatten(), label='Tahmin')
plt.legend()
plt.show()


```

Şekil 4.7. Akım verilerini tahminleme algoritması

Bu kodlama ile motor akım verisi için temel oluřturulmuřtur. Ardından veriyi normalize eder ve ardından RNN modelini eğitilmiřtir. Modelin eğitilmiř olduėunu göstermek için eğitim seti ve test seti üzerinde tahminler yapılmıř ve sonuçları görselleřtirilmiřtir.

Çalıřma yapılan fabrikada, bakım yönetimi ve iř planları Maximo isimli uygulama üzerinden yapılmaktadır. Maximo, bir organizasyonun sahip olduėu varlıkları, bu varlıkların konumlarını, durumlarını ve bakım geçmiřlerini takip etmek için bir platform saėlar. Varlıklar arasında ekipman, makineler, binalar, araçlar gibi birçok farklı öėe bulunabilir. Ana amaç olarak, önleyici bakım, düzeltici bakım ve öngörücü bakım gibi çeřitli bakım stratejilerini destekler. Bu sayede organizasyonlar, ekipmanların optimum performansını saėlayarak iř

sürekliliğini artırmakta ve maliyetleri minimize etmektedir. Böylece bakım ekiplerinin iş emirlerini oluşturmaya, yönetmesine ve takip etmesine olanak tanır. Bu, bakım süreçlerini düzenli bir şekilde yönetmeyi ve izlemeyi sağlamaktadır. Şekil 4.8'de Maximo uygulamasının bir sayfasından alınmış ekran görüntüsü verilmiştir.




Şekil 4.8. Maximo uygulaması üzerinde bir ekipmanın bakım bilgi ekran görüntüsü

Maximo' da oluşturulan iş emirleri, bakım planını belirlenen PDA adlı ekipmanlara yönlendirilir. PDA, bir bakım iletişim aracı olarak işlev görür; bakım operatörlerinin yanında bulunarak ilgili personele atanan işi, iş adımlarını ve süresini görüntüler. İş tamamlandığında, sistemle geri bildirimde bulunarak işin kapatılmasını veya iş açık durumunu ileten bilgileri aktarır. PDA' lar, bakım yönetim sisteminde kullanılan Taşınabilir Veri Girişi (PDA) araçlarıdır. Bu taşınabilir cihazlar, saha personeli ve bakım ekiplerinin hareket halindeyken iş emirleri, envanter yönetimi, varlık takibi, bakım kayıtları gibi işlemleri gerçekleştirmelerine olanak tanır. Örnek bir PDA görüntüsü Şekil 4.9'da sunulmuştur.



Şekil 4.9. PDA görüntüsü

Genellikle bu cihazlar, bakım yönetim sistemi yazılımına entegre edilmiş mobil uygulamalar aracılığıyla işlev gösterir. Bu sayede bakım ihtiyaca göre anlık olarak planlanırken, plansız duruş yaşanması muhtemel arızaların önüne geçilmiş olunur. Şekil 4.10' da akış diyagramı verilmiştir.



Şekil 4.10. Veri ve komut akış diyagramı

Geçmişteki arıza sürelerinin çalışma sonrasında meydana gelen değişiklikleri değerlendirmek amacıyla, arızalar ortaya çıkmadan önce gerçekleştirilen müdahaleleri karşılaştırıldı. Bu çalışma, arıza sürelerinde yaklaşık %35'lik bir düşüşle çalışmanın etkinliğini doğrulanmıştır. Doğrulama sürecinde ilk aşama olarak, pareto analizi yapılmış ve ekipmanlar ile arızalar arasındaki ilişki belirlenmiş, aynı zamanda çalışma kapsamının sınırları çizilmiştir.

Pareto analizi, iş süreçlerinde veya problemlerde en önemli ve etkili faktörleri belirlemek için kullanılan bir yönetim ve kalite kontrol tekniğidir. Bu analiz, genellikle "80/20 kuralı" olarak bilinen prensibe dayanarak, problemlerin veya başarıların büyük bir kısmının belirli bir azınlık tarafından oluşturulduğunu ifade eder. Bu prensip, kaynakların en etkili şekilde yönetilmesine yardımcı olur.

MES sisteminden elde edilen arıza duruş, bakım ve üretim verileri odak grup oluşmasında kullanıldığı gibi projenin etkinliğini değerlendirmede de kullanılmıştır.

4.1. Veri Setleri

4.1.1. Titreşim verileri

Her canlı, vücudundaki olumsuz değişikliklere tepki verir. Örneğin, bir besin değerini kaybettiğinde küflenir ve yeşillenmeye başlar. İnsan vücudu da bir uzuv zarar gördüğünde kızarır, morarır veya ağrı hissi verir. Makineler de benzer şekilde, arıza meydana gelmeden önce belirli uyarılarla işaret verir. Bu uyarılar, sıcaklık artışı, yüksek titreşim, artan gürültü gibi belirtilerle kendini gösterebilir. Bu nedenle, makine ve ekipmanların düzenli olarak kontrol edilmesi, olası sorunlara karşı önlem alınması önemlidir. Özellikle dönme hareketi yapan ekipmanlarda titreşim, önemli bir işaret olabilir ve bu konuda dikkatli bir değerlendirme yapılmalıdır.

ISO (International Standards Organization), makinelerde titreşimin oluşturduğu frekansları yorumlamak için yaptığı çalışmalar sonucunda Şekil 4.11' de paylaşılan veriyi uluslararası standart olarak kabul etmiştir.

Velocity Severity		Velocity Range Limits and Machine Classes			
mm/s RMS	in/s Peak	Small Machines Class I	Medium Machines Class II	Large Machines	
				Rigid Supports Class III	Less Rigid Supports Class IV
0.28	0.02				
0.45	0.03	Good			
0.71	0.04		Good	Good	Good
1.12	0.06	Satisfactory			
1.80	0.10		Satisfactory		
2.80	0.16	Unsatisfactory (alert)	Unsatisfactory (alert)	Satisfactory	
4.50	0.25				Satisfactory
7.10	0.40		Unsatisfactory (alert)	Unsatisfactory (alert)	
11.20	0.62	Unacceptable (danger)	Unacceptable (danger)	Unacceptable (danger)	Unacceptable (alert)
18.00	1.00				
28.00	1.56				
45.00	2.51				

Şekil 4.11. ISO EN 10816-1 Titreşim standardı

ISO 10816 Titreşim standardı, makine ve ekipmanları güçlerine göre sınıflandırarak uygun titreşim aralıklarını belirlemiştir. Kategorilere göre, I grubu küçük makineleri, II grubu orta boy makineleri ve özel temel üzerine oturtulmuş makineleri, III grubu ise büyük makineleri içermektedir (Engür, 2016).

Çalışmada analiz yapılan makina, harcadığı güç bakımından 0,7-7,5 kW arasında değişmektedir. Konveyörler ve liftler beton zemine kimyasal ve çelik dübellerle sabitlenmiştir. Ancak caraskallar uzay çatı konstrüksiyonuna sahip askı sistemleri ile zemine çelik kolonlarla sabitlenmiş şekilde askıda çalışmaktadır. Çalışmanın yapıldığı transfer ekipmanlarının analizi, makinanın kullanım süresi, arıza sayısı gibi parametreleri dikkate

olarak I grubuna dahil edilmiştir. I grubu ekipmanlarda 0,2 mm/s ile 2,00 mm/s titreşim hızı kabul edilebilir sınır olarak gözlemlenirken, 2,00 mm/s ile 4,50 mm/s hız kritik değerler olduğu görülmüş ve 4,50 mm/sn titreşim hızına ulaşmış bir makinedeki arıza durumuna geçme hızındaki parabolik eğri, kritik durumda acil müdahale yapılması gerektiğini göstermektedir. Tablo 4.1 de veri setinin oluşması için yapılan ölçümlerin bir kısmı paylaşılmıştır. Liftlere “LFT” ile başlayan ekipman numarası verilmiş, konveyörlerde ise “KON” ile başlayan ekipman numaraları verilmiştir.

Titreşim hızı, titreşim sensörünün bulunduğu ekipmanın türünün ve devir sayısının yanı sıra, ekipmanın bağlı olduğu makine (konveyör vs.) zeminle bağlantı türüne, üzerinden geçen yükün miktarına bağlı olarak değişkenlik göstermektedir.

Tablo 4.1. Veri seti örnekleme

Ekipman Kodu	RPM d/d	Akım A	Motor Sıcaklığı C	Titreşim Hızı mm/s
LFT.6x.1	950	11,14	112,20	1,10
LFT.6x.2	950	11,14	91,80	1,38
LFT.6x.3	950	11,02	104,55	1,80
LFT.6x.4	950	11,08	99,96	1,73
LFT.6x.5	950	10,60	97,92	1,18
LFT.6x.6	950	10,40	91,80	1,70
LFT.6x.7	950	10,99	104,55	2,14
LFT.6x.8	950	11,40	99,96	1,60
LFT.6x.9	1100	11,17	97,92	1,37
LFT.6x.10	1100	11,17	91,80	1,38
LFT.6x.11	1100	11,05	104,55	1,70
LFT.6x.12	1100	11,11	112,20	2,08
LFT.6x.13	1100	10,63	105,57	1,13
LFT.6x.14	1100	10,43	112,20	1,47
LFT.6x.15	1100	11,02	99,96	2,11
LFT.6x.16	1100	11,43	112,20	2,46
LFT.6x.17	1100	11,90	99,96	1,51
LFT.6x.18	1100	2,20	115,26	2,93
KON.6x.1	1450	2,00	107,42	2,24
KON.6x.2	1450	2,04	97,02	1,68
KON.6x.3	1450	2,00	95,04	1,23
KON.6x.4	1450	1,90	89,10	1,45
KON.6x.5	1450	2,26	101,48	1,78
KON.6x.6	1450	2,06	108,90	2,18
KON.6x.7	1450	1,90	102,47	1,05
KON.6x.8	1450	2,42	108,90	1,29

Tablo 4.1.(Devam) Veri seti örnekleme

KON.6x.9	1450	2,20	97,02	2,09
KON.6x.10	1450	2,24	117,81	2,58
KON.6x.11	1450	2,20	97,02	1,07
KON.6x.12	1450	2,09	95,04	1,56
KON.6x.13	1450	2,48	117,81	2,24
KON.6x.14	1450	2,26	111,87	2,62
KON.6x.15	1450	2,09	97,02	1,08
KON.6x.16	1450	2,00	95,04	1,00
KON.6x.17	1450	2,10	89,10	1,82
KON.6x.18	1450	2,20	101,48	2,08

4.1.2. Akım verileri


IEC (Uluslararası Elektroteknik Komisyonu) standartları, asenkron motorların akım değerlerini belirleyen spesifik tek bir değeri içermez. Motor akımı, motorun tasarımı, gücü, gerilimi ve çalışma koşullarına bağlı olarak değişir.

Asenkron motorların akım değerleri genellikle motorun teknik belgelerinde belirtilir. Bu belgelerde, nominal akım (rated current), başlangıç akımı (starting current), çalışma akımı (full load current) gibi değerler bulunabilir. Bu değerler, motorun belirli çalışma koşullarında ne kadar akım çekeceğini gösterir.

Motorun tasarımına ve uygulama alanına bağlı olarak, IEC standartları farklı motor sınıfları ve performans sınıfları için çeşitli akım değerlerini tanımlar. Örneğin, IEC 60034-1 standardı, elektrik motorlarının genel teknik özellikleri hakkında bilgi sağlar ve nominal akım gibi parametreleri içerir. Akım verilerini algoritma hazırlamada kullanmak için, her bir motorun teknik bilgi dokümanından nominal akım değerleri ekipmana özel olarak algoritmaya dahil edilmiştir.

Şekil 4.12’de Sew marka lift motorunun etiketi ve etiket değeri üzerinden alınacak bilgilerinin açıklaması verilmiştir.

Elektrikli bir motorun etiketinde genellikle aşağıdaki bilgiler bulunur: Motor Tipi ve Modeli, Güç Kapasitesi (Watt veya HP), Gerilim ve Akım Bilgisi, Hız ve Devir Sayısı, Frekans, Koruma Sınıfı/IP Derecesi, İzolasyon Sınıfı, Üretici Bilgisi, Çalışma Yönü, Montaj Bilgileri. Bu bilgiler, motorun doğru şekilde bağlanması ve işletilmesi için önemlidir. Her motor modeli ve tipi için bu bilgiler değişebilir, bu nedenle motor etiketinin dikkatlice incelenmesi önemlidir.



Satır	Bilgiler
[1]	50 Hz için bilgiler: • Anma gücü, çalışma şekli • Nominal akım • Anma verimlilik • IE sınıfı
[2]	60 Hz için bilgiler: • Anma gücü, çalışma şekli • Nominal akım • Anma verimlilik • IE sınıfı

Şekil 4.12. Motor etiketi üzerindeki bilgiler

Şekil 4.13'te sıralı konveyör sistemleri bulunan hattın fotoğrafı verilmiştir. Konveyörlerin renovasyonu sonrası, kayış gerginlikleri, konstrüksiyon rijitliği ve rulman durumları referans olarak kaydedilmiştir.



Şekil 4.13. Sıralı kayış tahrikli konveyör sistemleri

4.1.3. Sıcaklık verileri

Asenkron elektrik motorlarında risk faktörlerinden bir tanesi de yüksek sıcaklıktır. Çeşitli iç ve dış anormal koşulların oluşması durumunda, motorda sıcaklık artışı meydana gelebilir. Yüksek sıcaklık durumunda motorlarda geri dönüşü ve onarımı olmayan hasarlar meydana gelebilirken, mekanik sistemler de hasar alarak uzun süreli üretim kayıpları oluşabilir. Şekil 4.14'te aşırı ısınma sonucu stator arızası yaşamış bir motor görüntüsü paylaşılmıştır. Motor statoru, elektrik motorlarının ana statik parçasıdır. Motorun statoru, genellikle sabit duran ve dönen bir rotor etrafında yer alan elektromıknatıslardan oluşur.



Şekil 4.14. Stator arızası yaşamış bir motor bobini

IEC (International Electrotechnical Commission-Uluslararası Elektroteknik Komisyon) tarafından, 60034-11 standartında, Elektrik Motorları Termal Koruma standartında elektrik motorları için termal koruma yöntemlerini belirlenmiştir. Elektrik motorlarının yüksek sıcaklık durumlarından korumak için termal koruma önlemleri alınmalıdır. IEC 60034-11 standardı, motorlardaki aşırı ısınma durumlarına karşı koruma sağlamak için kullanılan yöntemleri ve standartları belirlemiştir. Standart, elektrik motorları için güvenli ve etkili termal koruma sağlamak amacıyla tasarlanmıştır. Elektrik motorları, endüstriyel uygulamalarda geniş bir yelpazede kullanıldığından, bu tür standartlar motorların güvenli ve verimli bir şekilde çalışmasını sağlamak için önemlidir.

Şekil 4.15'de Siemens marka bir asenkron motorun ve Siemens G120 model sürücü için, EN 60034-11'e göre motor sıcaklığı ayarlama parametreleri verilmiştir. Motor sıcaklığı 4 farklı yöntemle algılanabilir. Sensörün olmaması (yaygın kullanım) durumunda akım değerleri üzerinden kullanılan hazır denklem ile motor sıcaklığı tahminlenir ve sürücüye iletilir.

Alternatif olarak, PTC (Positive Temperature Coefficient) termistörü ile ölçümlenir. Bir direncin sıcaklık arttıkça direncinin arttığı bir tür termistördür. PTC termistörleri, pozitif sıcaklık katsayısına sahip oldukları için, sıcaklık yükseldikçe elektrik direnci artar. Bu özellikleri, PTC termistörlerini sıcaklık kontrolü, akım sınırlama ve otomatik devre koruma gibi uygulamalarda kullanılmak üzere uygun kılar.

130 °C sıcaklığa kadar motor sıcaklığı normal kabul edilirken, 130-145 °C aralığı kritik eşik olarak kabul edilmektedir. 145 °C sıcaklığa ulaştığında ise motor arıza moduna geçmektedir. Sıcaklık artış hızının yüksek olması durumunda, motorun kendini korumaya alması hasarı önleyemeyebilir. Bu sebeple algoritma oluşturulurken sıcaklığın lineer artışı ile parabolik artışının tahminlemesi farklı bakım programı oluşturmaktadır.

Parametre	Açıklama
P0335	Motor soğumasını belirtin 0: Kendiliğinden soğuma - motor milindeki fanla (IC410* veya IC411*) - (fabrika ayarı) 1: Yabancı soğutma - motordan bağımsız olarak çalıştırılan fanlarla (IC416*) 2: Kendiliğinden soğuma ve iç soğutma* (geçiş fanı) 3: Yabancı soğutma ve iç soğutma* (geçiş fanı)
P0601	Motor sıcaklığı sensörü sensör tipi 0: Sensör yok (fabrika ayarı) 1: PTC termistörü (→ P0604) 2: KTY84 (→ P0604) 4: ThermoClick sensörü
	Bağlantı no.
	14 PTC+ KTY anot ThermoClick
	15 PTC- KTY katot ThermoClick
P0604	Motor sıcaklığı uyarı eşiği (fabrika ayarı 130 °C) Uyarı eşiği, ya modülâtörün kapandığı, ya da <i>Imaks</i> değerinin düşürüldüğü değerdir (P0610)
P0605	Motor sıcaklığı arıza eşiği (fabrika ayarı: 145 °C)
P0610	Motor yüksek sıcaklığı tepkisi Motor sıcaklığı uyarı eşiğine ulaştığında davranışı belirler. 0: Motorun tepkisi yok, sadece bir uyarı 1: <i>Imaks</i> (fabrika ayarı) uyarı ve azaltması daha düşük bir devir sayısına neden olur 2: Mesaj ve kapatma (F07011)
P0640	Akım sınırı (A'daki giriş)

Şekil 4.15. Bir sıcaklık sensörü aracılığıyla motor sıcaklığı tespit parametreleri

Motor sıcaklık verisi bir referansla karşılaştırıldığı için, sürücü üzerinden alınan verilerle çalışma devam edilmiştir. Farklı bir senaryoda motor bloğu termal kamera ile izlenerek sıcaklık kayıt altına alınabilir ve görüntü işleme teknolojisi kullanılarak çalışmaya devam edilebilir.

Konveyörlerde kullanılan Siemens G-120 model sürücü üzerinden PLC' ye düşen sıcaklık verisi Şekil 4.16'da verildiği şekilde oluşur. Üç haneli oluşan değerde sağdan ilk hane ondalık değeri ifade eder.

ANALOG_OUTPUT ▶ PLC_1 [CPU 1214C DG/DC/DC] ▶ Watch and force tables ▶ Watch table

	Name	Address	Display format	Monitor value	Modify value
1	*TERMOCUPLE*	%IW100	DEC	276	
2	*ANALOG_OUTP...	%QW80	DEC	7004	
3	*NOMRX-SCALEX*	%MD120	Floating-point nu...	0.2533333	
4	*START-ANAHTARI*	%I0.0	Bool	TRUE	
5	*SÜRÜCÜ-START-S...	%Q0.0	Bool	TRUE	
6					

Şekil 4.16. Sürücü üzerinden alınan sıcaklık verisi

PLC kullanarak motor sıcaklık kontrolü programı yazmak için genel bir rehber aşağıda verilmiştir. Ancak, özel gereksinimlerde ve kullanılan PLC modeline bağlı olarak, detaylar değişmektedir. Aşağıdaki adımlar, genel bir programlamaya rehberlik etmek üzere tasarlanmıştır ve belirli bir uygulamaya göre uyarlanmalıdır.

PLC Programlama yazılımının açılması:

Siemens PLC'ler genellikle TIA Portal (Totally Integrated Automation) adlı bir programlama ortamı kullanır. TIA Portal açılır ve proje oluşturulur.

Donanım konfigürasyonunun yapılması:

PLC'nin kullanılacağı donanım bileşenlerini (Giriş/Çıkış modülleri, sensörler, vb.) konfigüre edilir ve sisteme bağlanır.

Motor sıcaklık sensörlerinin bağlanması:

Motorun sıcaklığını ölçecek sensörleri donanıma bağlanır. Bu sensörler termoelektrik, termistör veya başka bir sıcaklık sensörü türü olabilmektedir.

Giriş ve çıkışların ayarlanması:

Motor sıcaklık sensörlerini okumak ve motoru kontrol etmek için gerekli olan giriş ve çıkışları (I/O) tanımlanır.

Kontrol Programının Oluşturulması:

TIA Portalda motorun sıcaklık kontrolü için bir kontrol programı oluşturulmalıdır. Bu program, sıcaklık sensörlerini okuma, PID kontrolü uygulama ve motoru güvenli bir sıcaklık aralığında tutma işlevlerini içermelidir.

Alarm durumlarının eklenmesi:

Motorun aşırı ısınması durumunda veya başka bir hata durumunda alarm durumları eklenmelidir. Bu durumlarla ilgili uygun aksiyonlar belirtilmelidir.

Programı yüklenmesi ve test edilmesi:

Oluşturulan programı PLC' ye yüklenir ve sistemi test edilir. Sıcaklık değerlerini izlenir, PID kontrolünün düzgün çalıştığından emin olunmasının ardından alarm durumlarının doğru bir şekilde işlediği kontrol edilir.

Bu adımlar genel bir rehberdir ve spesifik gereksinimlere bağlı olarak değişiklik gösterebilir. Ayrıca, Siemens PLC' lerin belirli modelleri ve TIA Portalın belirli sürümleri farklı özelliklere sahip olabilir. Bu nedenle, kullanılan PLC modeline ve yazılım sürümüne özel dokümantasyon ve rehberlere başvurmak önemlidir.



5. ARAŞTIRMA BULGULARI

Kestirimci bakım ve makine öğrenmesi, endüstriyel sistemlerin etkin bir şekilde yönetilmesinde önemli rol oynayan iki kilit kavramdır. Literatürde yapılan önceki çalışmalar genellikle kestirimci bakım uygulamalarını ya da makine öğrenmesi metotlarını ayrı ayrı ele almıştır. Ancak, bu karşılaştırma yazısında odaklanılacak olan konu, bu iki alandaki gelişmelerin birleştirilerek daha etkili bir sistem oluşturulmasıdır.

Literatürde incelenen birçok çalışma, kestirimci bakım uygulamalarının genellikle makine öğrenmesi metotları kullanılmadan yüksek başarılar elde ettiğini vurgulamıştır. Ancak, bu başarıların bazıları, makine öğrenmesi ile tahminleme yeteneklerinin entegre edildiği çalışmalarla karşılaştırıldığında geride kalmıştır. Bu durum, geleneksel yöntemlerin belirli senaryolarda etkili olduğunu, ancak makine öğrenmesinin potansiyelini tam olarak kullanmadığını göstermektedir.

Bu çalışmanın öne çıkan katkıları arasında, makine öğrenmesinin sadece tahminleme başarısını değil, aynı zamanda bakım planlama başarısını da artırması bulunmaktadır. Canlı güncellenebilir ve denetlenebilir bir bakım yönetim sistemi, endüstriyel sistemlerde esneklik ve verimliliği artırarak operasyonel mükemmelliğe önemli bir katkı sağlayacaktır.

Kestirimci bakım ve makine öğrenmesi alanındaki bu yenilikçi yaklaşım, önceki çalışmaların ötesine geçerek daha etkili, dinamik ve adaptif bir sistem oluşturmayı amaçlamaktadır. Bu çerçevede, geleneksel ve modern tekniklerin entegrasyonu, endüstriyel bakım yönetimi alanında önemli bir ilerleme sağlayabilir.

Bu çalışmanın temel amacı, makine öğrenmesi araçlarını kestirimci bakım araçları ile birleştirerek hem tahminleme başarısını yükseltmek hem de bakım yönetim sistemini canlı olarak güncellenebilir ve denetlenebilir hale getirmektir. Geleneksel kestirimci bakım uygulamalarının başarısını artırmak adına makine öğrenmesi potansiyelini tam olarak kullanarak, sistemdeki değişikliklere anında tepki verebilen bir yapı oluşturulması hedeflenmektedir.

Yapılan analiz sonuçları, makine öğrenmesi tabanlı kestirimci bakımın başarıyla uygulandığını ve bu yöntemin üretim süreçlerinde önemli iyileştirmelere yol açtığını göstermiştir. Arıza sürelerinde %35 oranında gözlemlenen azalma, sistemlerin daha güvenilir ve verimli bir şekilde çalıştığını ortaya koymaktadır.

Makine öğrenmesi algoritmalarının, üretim tesislerindeki ekipmanların durumunu sürekli olarak izleyerek arızaları önceden tahmin etme kapasitesi, planlı bakım süreçlerini optimize etme ve beklenmeyen duruş sürelerini azaltma konularında önemli bir avantaj sağlamıştır. Bu bağlamda, yapılan çalışmanın sonuçları, kestirimci bakım uygulamalarının geleneksel yöntemlere kıyasla üretim verimliliğinde belirgin bir artışa katkıda bulunabileceğini vurgulamaktadır.

Bu olumlu gelişmelerin ötesinde, makine öğrenmesi ile desteklenen kestirimci bakım stratejilerinin işletme maliyetlerinde düşüş sağlamak ve uzun vadeli sürdürülebilirlik hedeflerine ulaşmak adına önemli bir adım olduğunu belirtmek önemlidir. Gelecekteki çalışmalar, farklı endüstriyel bağlamlarda bu yöntemlerin uygulanabilirliğini daha fazla değerlendirebilir ve spesifik işletme ihtiyaçlarına yönelik özelleştirilmiş çözümler geliştirebilir.

Sonuç olarak, bu araştırma, makine öğrenmesi temelli kestirimci bakım stratejilerinin, üretim süreçlerinde güvenilirliği artırma ve bakım maliyetlerini düşürme potansiyeline işaret etmektedir. Bu bulgular, endüstriyel tesislerin rekabet avantajı elde etmeleri ve sürdürülebilir üretim pratiklerine geçiş yapmaları açısından önemli bir yönlendirici olabilir.

Çalışmada, bir otomotiv tesisinde beklenen ve gerçekleşen arıza durum bilgileri Tablo 5.1’de verilmiştir. Çalışma sonrası başarı oranı bu verilerle kıyaslanarak hesaplanmıştır. Arıza sürelerini hesaplamada 12 aylık süre baz alınmıştır. Arızaların sebep olduğu duruş süreleri sisteme otomatik olarak düşmekte ve kök neden manuel olarak girilmektedir. Arızalanan ekipmanlar ve arıza sebepleri ayrı incelenmiş, çalışma sonunda tahminlemeyle duruş sürelerinde ve arıza kök nedenlerinin verilerindeki azalma karşılaştırılmıştır.

Tablo 5.1. Ekipmanların arıza süreleri ve oranları

	Ekipman Grubu	Süre	Oran
1	Robotik Sistemler	9360	25%
2	Fikstürler	5096	13%
3	Konveyörler	7280	19%
4	Lift ve asansörler	5980	16%
5	Caraskal ve Raylı Sistemler	6240	16%
6	Diğerleri	3900	10%
	TOPLAM	37856	100%

Üretimi etkileyen duruş sürelerindeki arızaları incelendiğinde ilgili süre içerisindeki tüm arıza türleri Tablo 5.2’ de verilmiştir.

Tablo 5.2. Arıza türleri

	Arıza Türü	Süre	Oran
1	Haberleşme Arızası	8650	23%
2	Motor Arızası	6400	17%
3	Malzeme ömrü, Zorlanma	6000	16%
4	Sürücü Arızası	4150	11%
5	Pnömatik Arızalar	3980	11%
6	Diğerleri	3302	9%
7	Safety	3060	8%
8	Fikstür Arızaları	2314	6%
	TOPLAM	37856	100%

Çalışma odağı belirlerken, duruş sürelerinin kök nedenleri incelenerek ekipman ve arıza bazlı iki sınıfa ayrıldığında Tablo 6.3 elde edilmiştir. Bir tarafta en sık yaşanan arızalar yer alırken diğer tarafta en sık arıza yaşanan ekipmanlar listelenmiştir. Arızaların %51 i üç ana transfer makine grubunda yaşanırken, tüm arıza türleri içerisinde titreşim, sıcaklık ve akım ile öngörülebilecek üç arızanın oranı %44 seviyesindedir. Tablo 5.3’ te odak arıza ve ekipmanlar verilmiştir.

Tablo 5.3. Çalışma odağına alınan arıza ve ekipmanlar

ÇALIŞMA ODAĞI			
51%	Konveyörler	Motor Arızası	44%
	Lift ve Asansörler	Malzeme ömrü ve Zorlanma	
	Caraskallar	Sürücü Arızası	

Konveyör, genellikle endüstriyel tesislerde kullanılan bir taşıma sistemidir. Bu sistem, malzemeleri belirli bir yönde hareket ettiren, genellikle sabit bir yol üzerinde bulunan bir taşıma bandını içerir. Konveyörler, geniş bir endüstriyel uygulama yelpazesinde kullanılmaktadır, örneğin üretim hatlarında, depolama tesislerinde, madencilik sektöründe ve malzeme taşıma işlemlerinde sıkça görülür.

Bir konveyör sistemi genellikle bir motor, tahrik birimi, taşıma bandı ve destek yapılarından oluşur. Motor, taşıma bandını veya üzerinde hareket sağlanan mili/rolleri hareket ettirir ve

malzemelerin belirli bir mesafeye taşınmasını sağlar. Konveyörler, büyük miktarlarda malzeme taşımak, iş süreçlerini otomatikleştirmek ve üretim verimliliğini artırmak için kullanılır.

Farklı endüstriyel ihtiyaçlara uygun olarak tasarlanan çeşitli konveyör tipleri bulunmaktadır. Bu tipler arasında bantlı konveyörler, zincirli konveyörler, rulo konveyörler ve vidalı konveyörler gibi çeşitler yer almaktadır. Her bir konveyör tipi, belirli bir uygulama veya endüstri gereksinimine göre tercih edilir.


Lift, genellikle yüklerin dikey olarak taşınmasını sağlayan bir ulaşım aracıdır. Yüksek binalarda, alışveriş merkezlerinde, hastanelerde ve birçok farklı endüstriyel ve ticari ortamda yaygın olarak kullanılan bir asansör sistemidir. Temel olarak, bir kabin veya platform, bir dikey şaft boyunca hareket eder ve bu sayede kişiler veya yükler, bir kat veya seviyeden diğerine taşınabilir.

Makaslı lift, özellikle inşaat ve endüstriyel alanlarda sıklıkla tercih edilen bir türdür. Makaslı liftin ana özelliği, bir makas mekanizması aracılığıyla yukarı ve aşağı hareket edebilen bir platforma sahip olmasıdır. Bu mekanizma genellikle bir X şeklindeki çelik makasları içerir ve bu makaslar, platformu yükseltmek veya alçaltmak için birbirine bağlanmıştır. Makaslı liftler genellikle taşıma kapasitelerine ve ihtiyaca göre değişiklik gösterebilir. İnşaat sektöründe, yapı işleri sırasında personeli ve malzemeleri yüksek noktalara erişim sağlamak için yaygın olarak kullanılır.

Makaslı liftler genellikle diğer asansör türlerine göre daha güvenilir ve sağlamdır, aynı zamanda taşıma kapasiteleri ve manevra kabiliyeti açısından çeşitli ihtiyaçlara uygun olarak tasarlanabilirler.

Otomotiv endüstrisinde liftlerin üzerinde genellikle bir konveyör bulunmaktadır. Bu sayede yük dikey yönde hareket edebilirken önünde veya arkasındaki istasyona transfer olabilmektedir.


3KY.K-LFT501 numaralı makaslı liftin, vidalı mil yatağı üzerindeki titreşim sensöründen gelen uyarı sonucunda, hafta sonu planlı bakım programına alınmıştır. Yapılan incelemede, liftin iç yatak rulman bilyalarında yağsızlık nedeniyle aşınma tespit edilmiştir. Rulman değişimi ve diğer yatakların yağlanması işlemlerinin ardından, Şekil 5.1'deki iki paralel grafikten sağ tarafta görüleceği üzere titreşim optimum değerine geri dönmüştür.



Şekil 5.1. Titreşim analizi yapılan bir ekipmanın titreşim grafiği


Titreşim analizi, bir makinenin farklı iş şartları altında oluşturduğu titreşimlerin farklılıklarını gözlemlenmiştir. Özellikle, askıda çalışan bir konveyör üzerinde hareket eden araç gövdesinin ağırlığı, redüktör ve şaftın dinamik özelliklerini etkileyerek çeşitli titreşim modlarına neden olabilmektedir. Mekanizmalar arasında güç iletimi sağlayan kayış sistemleri, kayış gerginliği, ekipmanın zemine sabitleme durumu ve statik fizibilitesi gibi faktörlere bağlı olarak farklı titreşim frekanslarında uyarıcı etkiler yaratabilir. Bununla birlikte, endüstride yağsızlık kaynaklı arızaların titreşimle tahminlenmesi üzerine yapılan çalışmalarda, aşırı yağlamanın yarattığı anormal titreşim etkileri gözlemlenmiş ve bu anormal değerler dikkate alınmıştır. Bu gözlemler, titreşim analizinin makine sağlığı izleme süreçlerinde önemli bir araç olduğunu vurgulanmaktadır.

Bu çalışma, motor akım verilerinin belirgin bir grafik oluşturduğu ve çeşitli problemlere farklı eğrilerle tepki verdiği gözlemlenmiştir. Şekil 5.2’ de sunulan grafik incelendiğinde, bir drop liftin motor akımının yük, kalkış ve bekleme esnasında düzenli bir seyir izlediği ancak belirli bir noktada düzensizlik gösterdiği belirlenmiştir. Ekipman kontrol edildiğinde, yük kaybının tambur kılavuzundaki bir kopukluktan kaynaklanan bir anlık sıkışma tespit edilmiştir. Bu anlık sıkışma, farklı arıza tahminleme yöntemleri üzerinde zorluk yaratmaktadır. Bu noktada, akım grafiği arızanın meydana geldiği noktayı açıkça işaret etmiştir.



Şekil 5.2. Drop lift motor akım grafiği


Kestirimci bakım uygulamasında, motor sıcaklığının artışının incelenmesi, dikkate değer bir kestirimci gösterge olarak ortaya çıkmaktadır. Bu çalışmada elde edilen bulgulara göre, motor sıcaklığı belirli bir noktadan sonra parabolik bir artış göstermekte ve 130 °C' yi aşarak 145 °C' ye ulaşma süresi, motor akımı nominal değer in %10 üzerinde olduğunda yaklaşık 12 saat olarak belirlenmiştir. Özellikle, sıcaklık değeri ile sıcaklık artış hızının analizi, motor arızalarını tahminleme açısından önemli bir veri kaynağı olarak ortaya çıkmaktadır. Bu bilgiler, motor performansının kritik değişikliklerini belirleme ve önleyici bakım stratejilerini optimize etme konusunda değerli bir araç sağlamaktadır. Normal koşullarda çalışan bir motorun sıcaklık eğrisi Şekil 5.3'te verilmiştir.



Şekil 5.3. Motor bobini zamana bağlı sıcaklığı


Makine öğrenmesi ile yapılan bakım programının arıza sürelerine etkisi Şekil 5.4'te verilmiştir. Temmuz 2023 tarihine kadar veri toplanmış, programlama ve yazılım süreçleri

tamamlanmıştır. Aylık raporlanan arıza süreleri çalışmanın uygulanması ile Ağustos ve Eylül aylarındaki etkisi ölçülerek sonuçlar gözlemlenmiştir.



Şekil 5.4. Arıza sürelerinin zamana bağlı değişimi

Mekanik bakım iş planı ve bakım malzeme hareketleri izlendiğinde, aynı personel sayısı ile daha fazla sayıda iş kaleminin kapatıldığı ve personellerin sahada geçen çalışma saatlerinin izlenebilirliğinin arttığı tespit edilmiştir. Bu izlenebilirlik 8 saatlik bir mesainin kaç saatini planlı süreli iş yapıldığını görmemizi sağlamaktadır. Şekil 5.5'te bakım için harcanan efor görülmektedir. Bakım operatörlerinin etkinliği, bakım çalışması tarifli ve tanımlı olmadığı durumlarda nispeten düşük çıkarak kayıtsız zaman oluşmaktadır. Ancak bakım ihtiyacının önceden belirlenmesi ve bakım programının tüm çalışma süresi içine yerleştirildiğinde iş verimi ve iş kapatma oranında artış gözlemlenmiştir.



Şekil 5.5. Bakım programının devreye alınması sonrası bakım eforu

Motor sıcaklığı, titreşim ve akım verilerinin kestirimci bakımda kullanılması, arızaların 1 saat ile 1 hafta arasındaki sürelerde önceden tahmin edilmesini sağlamıştır. Bu verilerin yapay zekaya bağlı olarak oluşturulan algoritmalarla entegre edilmesi, bakım programının anlık olarak güncellenmesine olanak tanımıştır. Bu sayede, bakım süreçleri daha etkin ve verimli hale gelmiştir. Yapay zekâ destekli algoritmalar, motorun durumunu sürekli olarak izler ve olası arıza durumlarını önceden belirleyerek önleyici müdahale imkânı sağlamıştır. Bu yenilikçi yaklaşım, işletmenin üretkenliğini artırırken aynı zamanda bakım maliyetlerini minimize etmelerine olanak tanımıştır. Sonuç olarak, motor bakımında kullanılan bu entegre yaklaşım, endüstriyel tesislerin süreçlerini daha güvenilir ve etkili bir şekilde yönetmelerine yardımcı olmuştur.

6. SONUÇLAR VE ÖNERİLER

Geleneksel bakım yaklaşımları, üretim endüstrilerinde yaygın olarak kullanılan bakım yöntemlerini içerir. Buna rağmen, arıza oluşmasının ardından kök neden ve aksiyon karar süresinin uzun olması, yedek parça tedarikinde yaşanan sorunlar ve birbirini tetikleyen arıza olasılıkları gibi faktörler, bakım maliyetlerini artırmaktadır. Ek olarak, periyodik bakım aralıkları uzun tutulduğunda, beklenmedik arızaların artma olasılığı bulunurken, kısa tutulduğunda ise ihtiyaç fazlası bakımların ve üretim verimliliğinin azalması ihtimali bulunmaktadır. Ekipman etkinlik oranını artırmak için bakım programları düzenli bir şekilde uygulanmalıdır; ancak bakım ihtiyacı çalışma koşulları ve ekipmanın özellikleri gibi birçok etkenle ilişkilidir. Bu nedenle sınırlı kaynakların ihtiyaç duyulan alanda değerlendirilmesi gerektirir. Kestirimci bakım, endüstriyel ekipmanların performansını optimize etmek ve beklenmedik arızaların önüne geçmek amacıyla geliştirilen bir bakım stratejisidir. Bu strateji, makine verilerini sürekli olarak izleyerek değişen koşullara anında tepki verir ve bakımın en uygun zamanını belirler. Bu, işletmelerin arızaları önceden tahmin etmelerini sağlarken ihtiyaç olmadığı halde bakım iş gücü harcamalarının ve malzemelere finansal kaynak ayırmanın önüne geçer.

Kestirimci bakım, genellikle endüstriyel makinelerin sensörlerinden gelen verileri kullanarak çalışır. Bu sensörler, titreşim, sıcaklık, basınç ve diğer önemli parametreleri ölçerek makinelerin sağlığını değerlendirir. Elde edilen bu veriler, gelişmiş analitik ve makine öğrenimi algoritmaları kullanılarak işlenir. Bu sayede, makinelerin performansı ve potansiyel arıza durumları hakkında detaylı bilgiler elde edilir.

Bu çalışmada, odak noktası otomotiv fabrikasındaki bakım yönetimi üzerinde olup, makine öğrenmesi tekniklerinin kullanımıyla bu yönetim pratiğinin iyileştirilmesi amaçlanmıştır. Makine öğrenimi algoritmalarının entegrasyonu, fabrikadaki ekipmanların bakımının daha etkin ve verimli bir şekilde yönetilmesini hedeflemektedir. Bu çerçevede, özellikle ekipman etkinlik oranının artırılması ve üretim verimliliğinin optimize edilmesi öncelikli hedefler arasında yer almaktadır. Bu çalışma, otomotiv endüstrisindeki bakım stratejilerini yeniden şekillendirmeyi ve daha rekabetçi, sürdürülebilir bir üretim ortamı oluşturmayı amaçlamaktadır. Yapay sinir ağının verilerin sınıflandırılması ve kendini besleme döngüsü oluşturabilme yeteneği sayesinde denetimli makine öğrenmesi metotları arasında en verimli yöntem olacağı tespit edilmiştir.

Entegrasyon süreci üzerindeki odaklanma, bakım planlama sistemine daha etkin bir şekilde entegre edilebilmek adına önemli bir adım olacaktır. Sistemler arasındaki veri akışının düzenlenmesi ve sürekli bir güncelleme mekanizması oluşturulması, bakım ekiplerinin daha hızlı ve doğru kararlar almasını sağlayabilir.

Farklı endüstrilerdeki özel ihtiyaçlar ve koşullar göz önüne alınarak, bu makine öğrenmesi modelinin evrensel bir uygulama alanı bulabilmesi farklı endüstrilerin ihtiyaçlarına ve veri kaynaklarına göre uyarlanması gerekebilir. Bu çalışmanın sınırlarını ihtiyaç duyulan yüksek arıza oranına sahip ekipmanlar belirlemiştir.

Bu çalışmada, bir otomotiv fabrikasındaki ekipman etkinliği Pareto analizi ile incelenerek belirli ekipman grupları ve hedef arızalar belirlenmiştir. Çeşitli veri kaynakları kullanılarak toplanan veriler kategorize edilmiş ve algoritma için uygun hale getirilmiştir. Yapay zekâ ve makine öğrenmesi araçları, algoritmaların oluşturulması, sebep-sonuç ilişkisinin kurulması ve bakım yönetim sistemine tahminlerin iletilmesi aşamalarında kullanılmıştır. Kullanılan Recurrent Neural Network (RNN) makine öğrenme yöntemleri sayesinde, kestirimci bakım tahminleri %81,7 başarı oranıyla gerçekleştirilmiştir.

Bununla birlikte, kullanıcı deneyimini geliştirmek ve çalışanların bu teknolojiyi daha etkili bir şekilde kullanmalarını sağlamak adına eğitim ve kullanıcı dostu araçlar konusunda da yatırımlar yapılmalıdır. Bu, çalışmanın kurumsal düzeyde daha yaygın bir kabul görmesine yardımcı olabilir.

Ayrıca bu çalışmada farklı ekipman gruplarında en sık karşılaşılan arızaların tahminlenmesine odaklanılmıştır. İlerleyen aşamalarda veri setleri zenginleştirilerek haberleşme ve otomasyon kaynaklı arızaların tahminlenmesi ve önlenmesi amaçlanmaktadır.

Sonuç olarak, makine öğrenmesi ile kestirimci bakım yöntemlerinin başarıyla uygulandığı bu çalışma, sürekli bir iyileştirme sürecine tabi tutularak daha geniş bir etki alanına yayılabilir. Bu, gelecekteki endüstriyel bakım uygulamalarında daha akıllı, verimli ve öngörülebilir bir yaklaşımın benimsenmesine katkıda bulunabilir.

Bu çalışmada, genel üretim verilerinin yanı sıra özellikle titreşim, akım ve motor sıcaklığı verileri kullanılarak kestirimci bakım alanında önemli adımlar atılmıştır. Elde edilen sonuçlar, bu temel verilerin kullanılmasının ekipman durumunun doğru bir şekilde değerlendirilmesine ve potansiyel arızaların önceden tespit edilmesine katkı sağladığını göstermektedir. Gelecekteki çalışmalarda, ultrasonik ses, termal kamera ve yağ analizi gibi ilave veri kaynaklarının entegrasyonu, tahminleme yeteneğinin daha da artırılması ve bakım

stratejilerinin daha etkili bir şekilde optimize edilmesi hedeflenmektedir. Bu çoklu veri kaynaklarının birleştirilmesi, ekipmanların daha güvenilir ve verimli bir şekilde çalışmasını destekleyerek endüstriyel süreçlerin iyileştirilmesine yönelik önemli bir adım olacaktır.





KAYNAKLAR

- Acar G., *Otomotiv Sektöründe Kullanılan Kestirimci Bakım Yöntemleri ve Uygulamaları*, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, 2014 (372696)
- Akgül M., N.K. Akın, E. K. Ergin, (2020) *Makine Öğrenmesi ile Kestirimci Bakım Sistemlerinin Performans Değerlendirmesi*", Makine ve Tesisler Dergisi, 61, 20-28.
- Akgül M., N. K. Akın, E. K. Ergin, (2020), *Makine Öğrenmesi Tabanlı Kestirimci Bakım Sistemleri için Bir Uygulama*", Mühendis ve Makine Dergisi, 59, 26-33.
- 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 machinelearning solutions and key aspects*. Sensors Journal, 20, 109
- Arslan A., İ. A. Çelik, İ. A. E. Özdemir, (2021) *Makine Öğrenmesi Tabanlı Kestirimci Bakım Sistemleri: Bir İnceleme*", Makine ve Tesisler Dergisi, 62, 30-38.
- Arslan A., İ. A. Çelik, İ. A. E. Özdemir, (2021) *Makine Öğrenmesi Yöntemlerinin Kestirimci Bakım Uygulamalarına Etkisi*", Mühendis ve Makine Dergisi, 60, 21-28.
- Calayır G.& Kabak M. (2021) *Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama* Journal of Turkish Operations Management, 5, 662-675
- Cardoso D.& Ferreira L. (2021) *Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools*, Applied Sciences 11,1-18
- 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
- Cavalieri, S., & Cutuli, G. (2010). *Performance evaluation of OPC UA. In 2010 IEEE 15th conference on emerging technologies & factory automation ETFA 2010*, 1,40-70
- Ceyhan H.& Kasapbasi M., (2021), *Üretim Sistemlerinde Makine Öğrenmesi ile Kestirimci Bakım Uygulaması ve Modellemesi*, Avrupa Bilim ve Teknoloji Dergisi, 33, 167-175
- Florien E.& Sgarbossa F.& Zennero I, *Machine learning-based predictive maintenance: A cost-oriented model for implementation* International Journal of Production Economics 236,54-63
- Zhang H., M. Wu, and L. Wang, (2022) *An Artificial Intelligence-Based Approach for Product Data Management*, IEEE Access, 10, 24342-24352
- Lee, S. K. Kim, and J. H. Kim, (2023) *The Use of Artificial Intelligence in Product Data Management: A Case Study*, IEEE İşlemleri Mühendislik Yönetimi, 70, 345-354.
- 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

Öztanır O., *Makine Öğrenmesi Kullanılarak Kestirimci Bakım*, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, (2018)(10231701)

Öztürk A., A. Çalık, M. E. Özmen, *Makine Öğrenmesi ile Kestirimci Bakım*, Mühendis ve Makine Dergisi, (2022), Cilt 61, Sayı 513, ss. 26-33.

Sarmiento J.& Monroj J& Moreno F.& Galindo C. & Bonelo J.& Jimenez J., (2020) *A predictive model for the maintenance of industrial machinery in the context of industry 4.0*, Journal of Manufacturing Technology Management, 32, 255-275

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, 150, ss. 17-30



ÖZGEÇMİŞ

İlk ve Ortaöğretimi Bolvadin’de tamamladı. 2015 yılında Yıldız Teknik Üniversitesi Makine Mühendisliği Bölümünden mezun oldu. 2016-2019 yılları arasında demir çelik endüstrisinde Borçelik firmasında Yardımcı Tesisler Mühendisi, gıda endüstrisinde Cargill firmasında Yardımcı Tesisleri Süpervizörü olarak çalıştı. 2020 yılı itibariyle Ford Otosan’da Teknoloji Bakım ve Proje Kıdemli Mühendisi olarak çalışmaktadır.

TEZDEN TÜRETİLEN YAYIN VE ESERLER

Sarısoy F., Bingöl M., Kestirimci Bakım Uygulamalarının Makine Öğrenmesi Yöntemleri ile Bakım Yönetim Sistemine Uygulanması, *4. Uluslararası Akdeniz Bilimsel Araştırmalar ve İnovasyon Kongresi*