



**MAKİNE İMALAT SEKTÖRÜNDE
KULLANILAN TAKIM UÇLARI İÇİN
YAPAY ZEKÂ İLE KESTİRİMCİ
BAKIM UYGULAMALARI**

Mehmet ŞAHİN

Makine Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**Danışman: Dr. Öğr. Üyesi Aytaç MORALAR
2022**

T.C.
TEKİRDAĞ NAMIK KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**MAKİNE İMALAT SEKTÖRÜNDE KULLANILAN TAKIM UÇLARI İÇİN YAPAY
ZEKÂ İLE KESTİRİMCİ BAKIM UYGULAMALARI**

MEHMET ŞAHİN

ORCID: 0000-0002-1344-4255

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ
Danışman: Dr. Öğr. Üyesi Aytaç MORALAR

HAZİRAN-2022
Her hakkı saklıdır.

ÖZET

MAKİNE İMALAT SEKTÖRÜNDE KULLANILAN TAKIM UÇLARI İÇİN YAPAY ZEKÂ İLE KESTİRİMCİ BAKIM UYGULAMALARI

Mehmet ŞAHİN

Makine Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Aytaç MORALAR

Bu çalışmada verileri alınan makineler için anomali tespiti ile kestirimci bakım yaklaşımı gerçekleştirilmiştir. Çalışmanın konusuyla ilgili literatür taraması yapılmıştır ve önceki çalışmalara ait görüşler açıklanmıştır. Makinelerin devam eden ömründe gerçekleşen olası arızaları önlemek veya önceden gerçekleşebilecek hatalardan haberdar olabilmek için, çalışmak istenen makinenin verileri toplanıp, belirli türlerde anomali tespiti yapıp anomali durumlar tespit edilerek bu sayede gelecekte gerçekleşebilecek olası arızalardan kaçınılmaya çalışılmıştır.

Anahtar Kelimeler: Kestirimci bakım, Makine öğrenimi, Endüstri 4.0, Anomali tespiti, Makine imalatı

ABSTRACT

PREDICTIVE MAINTENANCE APPLICATIONS WITH ARTIFICIAL INTELLIGENCE FOR CUTTING TOOLS USED IN MACHINE MANUFACTURING INDUSTRY

Mehmet ŞAHİN

Department of Machine Engineering

MSc. Thesis

Supervisor: Assist. Prof. Dr. Aytaç MORALAR

In this study, predictive maintenance approach with anomaly detection was carried out for the machines whose data were taken. A literature review on the subject of the study was conducted and the opinions of previous studies were explained. In order to prevent possible malfunctions in the ongoing life of the machines or to be aware of the errors that may occur in advance, the data of the machine desired to work is collected, certain types of anomaly are detected, anomaly situations are detected, and thus possible malfunctions that may occur in the future are tried to be avoided.

Keywords: Predictive maintenance, Machine learning, Industry 4.0, Anomaly detection, Machine manufacturing

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ÇİZELGELER DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
SİMGELER DİZİNİ	vii
KISALTMALAR DİZİNİ	viii
TEŞEKKÜR	ix
1. GİRİŞ	1
1.1. Kestirimci Bakım ve Anomali	1
1.2. Literatür Özeti.....	1
1.3. Çalışmanın Amacı ve Kapsamı	5
2. BAKIM VE KESTİRİMCİ BAKIM	6
2.1. Kestirimci Bakım Teknikleri	8
2.2. Endüstri 4.0.....	8
2.3. Makinelere Bilgi Toplama	11
2.4. Makine Öğrenimi	12
2.5. İmalat Firmalarında Enerji Verimliliği	13
2.5.1. İmalat Firmalarının Karşılaştığı Problemler.....	14
3. PROBLEM TANIMI	16
3.1. Mevcut Bakım	17
3.2. Planlanan Bakım	17
4. ANOMALİ TESPİTİ ÜZERİNE KAVRAMLAR	18
4.1. Gözetimli ve Gözetimsiz Öğrenme (Supervised and Unsupervised Learning).....	18
4.2. Anomali Türleri	18
5. MATERYAL METOD	20
5.1. Materyal.....	20
5.2. Metot	20
5.2.1. Veri Seti Hakkında.....	20
5.3. Verinin Hazırlanması	21
5.3.1. Zaman Serisinin hazırlanması	22
5.3.2. Hedef Verinin Hazırlanması.....	23
5.3.3. Eksik Hedef Veri ve verinin tamamlanması.....	24

5.3.4. Hedef verinin tekrar organize edilmesi	25
5.4. Zaman serisi gösterimleri	25
5.5. Kutu grafikleri	28
5.6. Algılayıcılar	29
5.6.1. Eşik değeri (Threshold).....	29
5.6.2. Dörtte Birlik (Quartile)	30
5.6.3. Interquartile	31
5.6.4. GESD (Generalized Extreme Studentized Deviate)	32
5.6.5. Kalıcı Seri ile aykırı durum aralığı bulma.....	33
5.6.6. LevelShift ile kalıcı seri aralığı bulma	34
5.6.7. Oynaklık seviyesi (Volatility Level) ile kalıcı seri bulma	34
5.6.8. Sezonsal (Seasonal) yöntem.....	35
5.6.9. Autoregression bazlı yöntem.....	35
5.6.10. Tüm özelliklerin analizi	36
6. SONUÇLAR.....	41
KAYNAKLAR.....	42
ÖZGEÇMİŞ.....	44

ÇİZELGELER DİZİNİ

Çizelge 5.1 Veri setinde özellikler ve açıklaması.....	20
Çizelge 5.2 Veri seti hakkında istatistiksel bilgiler	21
Çizelge 5.3 Bir zaman verisi	22
Çizelge 5.4 Frekansa göre zamanları belirleme.....	22
Çizelge 5.5 Hedef verinin hesaplanması ve tekrar düzenlenmesi	23
Çizelge 5.6 Hedef verinin eksikliklerin tekrar düzenlenmesi	24



ŞEKİLLER DİZİNİ

Şekil 5.1 ROT_VEL, LOAD1, TEMP1, R172, X_POS, Y_POS, Z_POS ve XYZ_POS için 3 saatlik grafikler	26
Şekil 5.2 ROT_VEL, LOAD1, TEMP1, R172, X_POS, Y_POS, Z_POS ve XYZ_POS için 15 dakikalık grafikler	27
Şekil 5.3 Tüm verilerden elde edilen kutu grafikleri	28
Şekil 5.4 LOAD1 ve 160 eğik değeri için anomali durumları	29
Şekil 5.5 TEMP1 ve 30 eğik değeri için grafik	30
Şekil 5.6 Dörtte birlik değerleri gösterilen normal dağılım olasılık yoğunluğu (Kaynak: https://en.wikipedia.org/wiki/Quantile)	30
Şekil 5.7 X_POS için dörtte birlik yönteminin %99 ve %1 aralık dışındaki durumlarda aykırı değerleri.....	31
Şekil 5.8 X_POS için dörtte birlik yönteminin %99,9 ve %0,1 aralık dışındaki durumlarda aykırı değerler.....	31
Şekil 5.9 Kutu grafiğinde de kullanılan interquartile aralık yöntemi (Kaynak: https://en.wikipedia.org/wiki/Interquartile_range)	32
Şekil 5.10 Interquartile yöntemi	32
Şekil 5.11 GESD testinden elde edilen grafik (üst sınır = 0,3)	33
Şekil 5.12 Kalıcı Seri Yöntemi.....	33
Şekil 5.13 LevelShift yöntemi ile inceleme	34
Şekil 5.14 Oynaklık seviyesi grafiği.....	34
Şekil 5.15 Sezonsal yöntem ile anomali tespiti	35
Şekil 5.16 Autoregression yönteminin 1 günlük veri için çıktısı	35
Şekil 5.17 Tüm özellikler ve tüm veri için interquartile yöntemi sonuçları	37
Şekil 5.18 Tüm özellikler için autoregression yöntemi	39

SİMGELER DİZİNİ

μm Mikrometre

mm Milimetre

ms Milisaniye



KISALTMALAR DİZİNİ

PCB	Baskılı devre kartı
TCP	Takım merkez noktası
PALLET_ID	Bir veya iki numaralı palet
TOOL_NUMBER	Takılan takımın verisi
TOOL_GROUP	Takımların gruplandırılmış tanımlaması
ROT_VEL	Döner eksenin dönme hızı
LOAD1	Döner eksenin maruz kaldığı yük miktarı
TEMP1	Döner ekseninde oluşan sıcaklık değeri
R172	Takım ömrünün saniye cinsinden değeri
X_POS	Bir program kodu bloğundaki X pozisyonunun değeri
Y_POS	Bir program kodu bloğundaki Y pozisyonunun değeri
Z_POS	Bir program kodu bloğundaki Z pozisyonunun değeri
XYZ_POS	X, Y, Z değerlerinin birleşimden elde edilmiş değer
IOT	Nesnelerin interneti
CPS	Siber fiziksel sistemler
AI	Yapay zekâ
MÖ	Makine öğrenimi
ISO	Uluslararası Standardizasyon Örgütü
M2M	Sistem makineden makineye

TEŐEKKÜR

GerçekleőtirmiŐ olduėum alıŐmada, teoride ve deneylerde her zaman yardımlarıyla bana destek olan ve destekleriyle beni alıŐmamda yönlendiren saygı deėer danıŐmanım Dr. Öğr. Üyesi Ayta MORALAR ve deėerli hocam Do. Dr. Erdiñ UZUN'a sonsuz Őukranlarımı sunar ve teŐekkür ederim.

Mehmet ŐAHİN

Makine Mühendisi



1. GİRİŞ

1.1. Kestirimci Bakım ve Anomali

Kestirimci bakım, hedeflenen ekipmandan aktif olarak çalıştığı zamana ait verileri alınması ve bu alınan verilerin analiz edilerek öngörülemeyen bakım ihtiyaçlarının önüne geçilmesi, ekipmanın aktif olduğunda gerçekleşebilecek arızaların tespit edilmesini sağlayan bir yöntemdir. Bu yöntemin temeli, farklı teknikler ve aletler kullanılarak, elde olan ekipmanlardan alınan verilere dayanmaktadır. Kestirimci bakımın öncelikli amaçları, öngörülemeyen arızaların sayısını büyük ölçüde azaltmak, azalan arızalar ile birlikte ekipmanların çalışma süresini arttırmak, uzun süreli çalışan ekipmanların bakım maliyetlerini azaltmak ve ekipmanların doğru analiz edilerek gereksiz bakım yapılmamasını sağlamaktır.

Ele alınan çalışmada, kestirimci bakım kavramının dışında belli türlerde anomali tespiti yapılarak da olası arızalar saptanmaya çalışılmıştır. Anomali tespiti, bir zaman serisi içinden önemli ölçüde farklı olan verilerin, olayların veya kalıplarından tespitine denir. Genel olarak konuşursak, sisteminizin normal akışında herhangi bir davranış değişikliği fark ederseniz, bu davranışın sebeplerini öğrenebilir, gizli sorunları ortaya çıkarabileceğiniz gibi tamamen ortadan kaldıracabilirsiniz. Bu tespit işlemini manuel yapmak ve tüm veriyi 7/24 izlemek için birkaç personelle yapılamayacak kadar zor bir süreçtir. Bu davranış tespitleri önceden otomatik ve hızlı şekilde yapmak önem kazanmıştır.

1.2. Literatür Özeti

Ele alınan bu çalışmada, gerçek hayattaki bir üretim hattına kestirimci bakım yaklaşımı incelenmiştir. Bu bahsedilen konuyla alakalı çeşitli metodolojilere ait farklı görüşler yer verilmiştir. Makine öğrenimi algoritmaları sayesinde öngörülen arızalar saptanmaya çalışılmıştır ve bu sayede üretimi daha etkin kılarak istenmeyen bölünmeleri durdurmak istenmiştir. Ele alınan konuyla alakalı birçok deney yapılmış ve olumlu sonuçlar alınmıştır [1].

Yapılan bu çalışmada öncelikli olarak var olan bakım metotları üzerine değinilmiştir. Çalışmanın devamında ekipmanların basınç, sıcaklık ve titreşim gibi özelliklerinin izlenebilmesini sağlayan sensörlerden bahsedilmiştir. Ancak bu sensörlerin büyük şirketler için daha uygun, küçük ölçekli firmalar için maliyetli bir seçenek olduğu söylenmiştir ve bu tarz sensörlerden gelen verilere ihtiyaç duymadan üretim hattına ait elde edilen kayıp verilerden yola çıkarak tahmine dayalı bir bakım yöntemi önerilmesine değinilmiştir. Bunun için 24 saat

kesintisiz PVC profili üretimi yapan bir işletmeye ait üretim hattındaki kg, ekipmanların çalışmalarındaki hızlarının farkları ve en son uygulanan bakım üstünden geçen vardiya sayısı gibi veriler kullanılmıştır. Bu verilerin kullanılması için belirli modeller oluşturulmuştur ve en doğru yöntemin sinir ağları yöntemi olduğu görülmüştür [2].

Yapılan bu çalışmada çeşitli deney ve veri toplama metotlarından bahsedilmiştir [3].

Yapılan bu çalışmada imalat sektöründe geçmişten günümüze kadar devam eden önemli genel problemlerden bahsedilmiştir [4].

Yapılan bu çalışmada imalat sektöründeki kesici uç takımlarının hasar analizlerine ve değerlendirmelerine değinilmiştir. Bu kesici uçların hasar analizlerini yaptıktan sonra ise yapılabilecek önlemler belirtilmiştir. Verilen altı adet kesici uç takım kodundan ilkinde burun aşınması, ikincide çentik aşınması, üçüncüsünde mekanik çatlak, dördüncüsünde serbest yüzey aşınması, beşincide yorulma aşınması, altıncıda uç kırılması belirlenmiştir ve bunların analizleri doğrultusunda nasıl önlemler alınabileceği de belirtilmiştir [5].

Yapılan bu çalışmada matkap ucunun aşınmasının gözlenmesi üzerine yapılan yöntemler tanıtılmış ve imalat sektöründeki kesici takımlarının aşınmaları gözlemlenmiştir. Bu aşınmaların gözlemlenmesi için farklı metotlar izlenmiştir. Bu aşınmaları incelemek için direkt ve indirekt teknikler ile incelenmiştir [6].

Yapılan bu çalışmada kesici takım uçlarına ve makinelerin kondisyonlarına değinilmiş, açıklanmış ve incelenmiştir. Takım uçlarının makinenin performansında önemli bir yeri olduğundan bahsederek bu takım uçlarının yerleştirilmesinde önemli arızaların çıktığından bahsedilmiştir. Bu ortaya çıkan arızaların en önemli üç tanesinin geometrik, termal ve fazla güçten kaynaklanan arızalar olduğundan bahsedilmiştir. Bu çalışma genel olarak bahsedilen arızaların geometrik bölümüne odaklanmış ve çeşitli kaynaklarla bu takım uçlarının yaşadığı arızaları analiz edip incelemiştir [7].

Yapılan bu çalışmada tornalama işlemlerini açıklanmış ve tornalama işlemlerinde ortaya çıkabilecek arızalara değinilmiştir. Bu değinilen arızaların hangi stratejiler izlenerek ve hangi modeller uygulanarak çözülebileceği anlatılmıştır [8].

Yapılan bu çalışmada öncelikle imalat kavramı ve imalat türleri hakkında detaylıca bahsedilmiştir. Çalışmanın devamında genel olarak bakım planlama ve bakım planlamada

kullanılan teknikler hakkında bilgi verilmiştir. Daha sonra elde olan probleme karşı bir bakım tasarlanmış ve bu arızanın çözümü için ekipmana uygulanmıştır [9].

Yapılan bu çalışmada Endüstri 4.0 ve dijital uygulamaların akıllı cihazlarda nasıl uygulanacağını açıklar. Aynı zamanda endüstriyel otomasyon kontrol sistemleri ve IoT uygulamalarına örnekler verilmiştir [10].

Yapılan bu çalışmada dördüncü sanayi devrimi olan Endüstri 4.0 kavramını vurgulanmıştır. Sanayi devriminin tarihsel akışını birleştirerek, Endüstri 4.0 kavramı ele alınmış ve Endüstri 4.0'ın başarısının önemli kaynakları olan Nesnelerin İnterneti, siber-fiziksel sistemler, büyük veri, veri analizi ve akıllı fabrikalar kısaca tanımlanmıştır. Sözde dördüncü sanayi devrimi. Ardından Endüstri 4.0'ın üretim dünyasında ve günlük hayatta uygulanmasına değinildi. Ayrıca Endüstri 4.0 literatürünün mevcut durumunu anlamak için literatür taraması yapılmıştır. Araştırma sonuçları, iş dünyasında ve ilgili literatürde Endüstri 4.0 kavramına olan ilginin arttığını göstermektedir [11].

Yapılan bu çalışmada, kesici takımın durumunu izlemek ve işleme sırasında kırılma torkunu tahmin etmek için literatürde geliştirilen model incelenmiştir. Takım durumu izleme için kullanılan doğrudan ve dolaylı ölçüm yöntemlerinin özellikleri incelenmekte ve takım durumu izleme için kullanılan sensörler ve yöntemler karşılaştırılmaktadır. Çevrimiçi takım izleme sistemi üç unsurdan oluşur. Bunlar; tanımlar, matematiksel işlemler ve karar analizidir. Kullanılan sensörler ve yöntemler uluslararası standartlar olmasına rağmen sektör ihtiyaçlarına tam olarak cevap verebilecek bir durum izleme modeli henüz oluşturulamamıştır. Talaşlı imalat operasyonlarında takımların durumunu izlemek için endüstride kullanılabilecek bir sistem yapmak, üretim maliyetlerine, ürün kalitesine, ürün miktarlarına, tezgâh stabilitesine, takım seçimine ve kesme parametresi analizlerine önemli katkı sağlayacaktır [12].

Yapılan bu araştırmada öncelikle yalın üretim sistemlerinin tarihçesinden ve temel unsurlarından bahsedilmiştir. Yalın üretim sisteminde genel üretim bakımının görünümünü ve kapsamını inceledi. Genel üretim ve bakım işlerinin verimliliğini ölçmek için bir maliyet analizi modeli geliştirilmiş ve ortaya çıkan model farklı firmalara uygulanmıştır. Modelleme yaparken, genel üretim ve bakım harcamalarının yanı sıra altı ana kaybın (arızalar ve plansız üretim duruşları, kurulum ve ayar kayıpları, rölanti ve küçük duruş süreleri, düşük hızda çalışma, başlatma kayıpları, kalite hataları) iyileştirilmesini de göz önünde bulundurduk. Oluşturulan model farklı firmalarda farklı makinelere uygulanmış ve sonuçlar kapsamlı üretim ve bakım

çalışmalarının altı büyük kayıptan kaynaklanan maliyetlerin düşürülmesinde etkin rol oynadığını göstermektedir. Ancak araştırma sonuçları gösteriyor ki, altı büyük kayıp belli bir seviyeye ulaştığı için maliyetleri düşürdükten sonra toplam üretken bakım yatırımı aynı verimliliği göstermemektedir [13].

Bu çalışmada kestirimci bakım, endüstri ortamında üretilen büyük veriler aracılığıyla bakım yönetiminin potansiyelini ve eğilimlerini dinamik olarak yönetir. Kestirimci bakım; ekipman ve bileşenlerinin arızalanmadan önce ömrünü tahmin etmek, verileri analitik yöntemlerle analiz etmek, arıza olasılığını değerlendirmek ve önleyici tedbirler almaktır. Bu nedenle, ekipmanın planlanmamış arıza sürelerine maruz kalacağı ortamlarda, önleyici bakım stratejileri, bakımı planlamak ve optimize etmek için gerçek zamanlı verileri ve tahmine dayalı makine öğrenimi algoritmalarını kullanır [14].

Bu çalışmada, test uygulamasını etkileyen faktörler ve başarısızlığın ana nedenleri incelenmekte ve durum izleme teknolojisi üzerinde durulmaktadır. Bu amaçla laboratuvar ortamında oluşturulan test düzenekleri ve testler incelenmiş, yapılacak araştırmanın testleri için özgün test düzenekleri ve test planları oluşturulmuştur. Planlanan testin başarısız olmasının ana nedeni radyal ve aksenal titreşim verileri ve güç tüketimi verileri toplanıp analiz edilerek iki farklı durum izleme teknolojisi karşılaştırılmakta ve sonuçlar verilmektedir. Test araştırmasında öncelikle sektördeki mevcut sistem örnek alınarak bir test cihazı kurulmuş, beş farklı durumda mekanik gevşeklik, eksen kaçıklığı, balanssızlık ve yağsız olmak üzere dört kusur beş farklı seviyede üç farklı devir sayısında uygulamaya tabi tutulmuştur [15].

Ele alınan bu çalışmada, takım referans konumlarını düzeltmek için termal hataları modellemek ve tahmin etmek için veri odaklı bir yaklaşım önermektedir. Makinenin termal durumundan bağımsız olarak, takım konumunun otomatik olarak ayarlanması, istenen kalite ve hassasiyette parçalar üretebilir ve üretkenliğini önemli ölçüde artırır. Bu amaçla Tornos SwissNano4 makinesinde sıcaklık sensörleri ve takım konumu ölçümü için yüksek hassasiyetli ölçüm cihazları kullanılmaktadır. Bu iki ölçümle ilgili verileri toplamak için bir dizi deney yapılmıştır. Dört ana makine öğrenimi algoritması, toplanan veri alt kümesi üzerinde eğitilir ve kalan veri alt kümesi üzerinde test edilir [16].

Ele alınan bu çalışmada, Endüstri 4.0'da makine öğrenimi ve çıkarımı kullanarak kestirimci bakım için çerçevelere odaklanılmıştır. Özellikle de tahmine dayalı bakım bağlamında makine öğrenimi tekniklerini ve ontolojilerini uygulamanın zorlukları ele

alınmıştır. Uygulama ve kullanım durumları açısından alanın zorluklarını göstermek için kestirimci bakım alanına odaklanılmıştır. Son olarak, tahmine dayalı bakımın Endüstri 4.0 ile ilgili yakın bir konu olduğunu, ancak makine öğrenimi ve çıkarım uygulamalarında daha iyi araştırılması gereken bazı zorluklar olduğunu not edilmiştir [17].

Ele alınan bu çalışmada, maksimum enerji ve malzeme verimliliği elde etmek için iki yönü tamamen dikkate alan yeni bir iş sistemi tasarım yöntemi önerilmiştir. İlk olarak, iş mili sisteminin enerji eğrisi, enerji akışı analizi temelinde açıkça modellenmiştir. Ardından, kesme parametresi sınırlamaları, işleme gereksinimleri ve anahtarlama güç kayıpları ile ilgili çoklu kısıtlamalara tabi olarak, maksimum enerji verimliliği ve minimum hacmi hedefleyen, iş mili motoru ve dişli sisteminin parametre optimizasyonu için çok amaçlı bir optimizasyon modeli kurulmuştur. Son olarak, geliştirilen optimizasyon modelini çözmek için geliştirilmiş çok amaçlı tabanlı bir öğretim optimizasyon algoritması (MO-ITLBO) önerilmiştir. Önerilen torna mili sistemi tasarım yönteminin performansı, farklı çalışma koşulları üzerinden gösterilmiştir. Deneysel sonuçlar, enerji tasarrufu sağlayan ve malzeme tasarrufu sağlayan takım tezgahlarının tasarımının gerçekleştirilebileceğini göstermektedir [18].

Ele alınan bu çalışmada, özellikle ilgili terimler ve kavramlar arasında kavramsal ayrımlar sağlanmış, makine öğrenimi ve derin öğrenme yoluyla otomatik analitik modelleme süreci açıklanmış ve bu tür akıllı sistemleri elektronik pazarlarda ve bağlantılı işletmelerde uygularken ortaya çıkan sorunlar tartışılmıştır [19].

1.3. Çalışmanın Amacı ve Kapsamı

Tezgahların aşırı ve sürekli olarak kullanımlarında takım uçlarının zamanla deforme olduğu, ekonomik ve zamana bağlı dezavantajlar oluşturduğu bilinmektedir. Bu sürekli olarak oluşan deformeleri firma için bir tehdit oluşturmasından kurtarmak için, bu çalışmanın amacı belli bir sürede tezgahlardan veri toplayarak, ne kadar çalışma süresinde bakıma girdiğini hesapladıktan sonra kestirimci bakımın yardımıyla takım uçlarını deforme olmadan ve firmalara herhangi bir zarar sağlamadan tezgâhı bakıma sokmaktır.

2. BAKIM VE KESTİRİMCİ BAKIM

Kestirimci bakımdan bahsetmeden önce bakımın ne olduğu ve bakımın ne için gerekli olduğunu açıklamak gereklidir. Basit olarak özetlemek gerekirse bakım, elde bulunan ekipmanlardaki arızaların giderilerek, öngörülen ekipman ömrü devamında herhangi bir arıza vermeden çalışmasına devam etmesi şeklinde açıklanabilir. Makinelerdeki beklenmedik arızalar sebebiyle, bu firmaların sahip olduğu ekipmanlar, firmalara her geçen gün yüksek maliyetlere ve zaman kayıplarına sebebiyet vermektedir. Bu sebeple bakım, üretimin sürekliliğinin sağlanması açısından önemli bir yere sahip olduğundan çeşitli bakım teknolojileri geliştirilmiştir. Bu çalışmada ele aldığımız bakım stratejilerinden kestirimci bakım ise, ekipmanlara uygulanabilecek en doğru yöntemlerdendir.

Bakım yöntemleri temel olarak düzeltici bakım ve önleyici bakım olmak üzere iki gruba ayrılmaktadır. Düzeltici bakımda bakım işlemi arıza meydana geldikten sonra yapılırken, önleyici bakımda arıza meydana gelmeden önce yapılmaktadır. Önleyici bakımın da kendi alt türleri bulunmaktadır. Bunlar şarta dayalı bakım ve zaman bazlı bakım olarak özetlenebilir. Son yıllarda üretim yapan işletmelerde gelişen sensör sistemleriyle birlikte üretim ekipmanlarına yönelik veri toplanması ve ekipman durumunun izlenmesi kolaylaşmış, kestirimci bakım yöntemleri diğer bakım yöntemlerine göre daha çok ön plana çıkmıştır. Kestirimci bakım teknikleri izlenen üretim sürecinin mevcut durumundan hareketle bakımın ne zaman yapılması gerektiğini tahmin etmeye dayalıdır. Bu yaklaşım rutin veya zamana dayalı diğer önleyici bakım tekniklerine göre bakım maliyetinde avantaj sağlamaktadır. Yalnızca belirli durumlar oluştuğunda bakım işlemi yapılacağından parçanın bozulma durumunun tahminine göre yapılan şarta dayalı bakım olarak da kabul edilebilir [2].

Endüstriyel Nesnelerin İnterneti (IoT) veya Endüstri 4.0 olarak da bilinen sanayi devriminin dördüncü dalgasına girerken, ekipman kullanımına, işletme maliyetlerine ve çalışan verimliliğine daha fazla önem veriyoruz. Odaklanmış. Endüstriyel Nesnelerin İnterneti, düşük maliyetli sensörleri operasyonlara etkin bir şekilde entegre eder. ile ilgili. Makine verilerini toplamak ve anlamlı çıkarımlar yapmak için gelişmiş analitik Yapıyı kullanın. Endüstriyel IoT, üreticilerin üretkenliğini %30 artırıyor vermesi bekleniyor. Makine arızalarının bakımını tahmin etmek için gelişmiş analitiği kullanın Strateji, kestirimci bakım uygulaması olarak adlandırılır. Tahmine dayalı bakım, son zamanlarda Endüstriyel Nesnelerin İnterneti'nin en sık atıfta bulunulan uygulaması olarak vurgulanmıştır. Tahmine dayalı bakım, sorunları ekipmanın arızalanmasına neden olmadan önce çözerek üreticilerin bakım maliyetlerini düşürmesini,

ekipman ömrünü uzatmasını, arıza süresini azaltmasını ve üretim kalitesini ve verimini artırmasını sağlar. Ancak bu faydaları gerçekleştirmek için gelişmiş bir dijital altyapı ve IoT platformlarının devreye alınması gerekiyor. Ayrıca, makine verilerini analiz etmek için makine öğrenmesi ve tahmine dayalı modelleme gibi istatistiksel tekniklerin kullanılması bir zorunluluk haline gelmiştir [14].

Teknik alandaki ilerlemeler nedeniyle nükleer enerji, havacılık ve diğer güvenli ve güvenilir endüstrilerdeki olası arızalar büyük kayıplara neden olacağından olası arızalar önceden tespit edilebilir.

Mekanik ekipmanların işleyişi izlenerek satın alma işlemine başlandı. Bakım teknolojisindeki ilerlemeler, kestirimci bakım adı verilen yeni bir sistemi ortaya çıkardı. Fabrikalarda kestirimci bakım uygulamalarının tanıtılmasından önce, operatörler sıcaklık değişimlerini, artan gürültüyü ve arıza belirtilerini algılamak için duyularını kullanmaya çalışıyordu. Bu sistem ile bazı testler yapılabilmektedir. Ancak bu iş tamamen operatörün yeteneklerine bağlıdır. Operatör makineyi çok iyi tanımiyorsa kestirimci bakımın başarı oranı doğrudan düşecektir [13].

Makine çalışmalarını engellemeden, işleyişlerini yakından izleme olanağı doğuran kestirimci bakım sistemi, gereksiz duruşları ortadan kaldıracak gibi gereksiz parça değiştirmeleri de önlemektedir. Arıza oluşturacak nokta önceden algılandığından, geleceğe yönelik bir bakım programı oluşturulmasını sağladığı gibi doğabilecek ani duruşlara neden olan arızaları da ortadan kaldırmaktadır [13].

Kestirimci bakım, hedeflenen ekipmandan aktif olarak çalıştığı zamana ait verileri alınması ve bu alınan verilerin analiz edilerek öngörülemeyen bakım ihtiyaçlarının önüne geçilmesi, ekipmanın aktif olduğunda gerçekleşebilecek arızaların tespit edilmesini sağlayan bir yöntemdir. Bu yöntemin temeli, farklı teknikler ve aletler kullanılarak, elde olan ekipmanlardan alınan verilere dayanmaktadır. Nesnelerin interneti teknolojilerinden faydalanılarak, ekipmana ait verilerin toplanmasında ve analiz edilmesinde kolaylık sağlanır.

Kestirimci bakımın öncelikli amaçları;

- Öngörülemeyen arızaların sayısını büyük ölçüde azaltmak
- Azalan arızalar ile birlikte ekipmanların çalışma süresini arttırmak
- Uzun süreli çalışan ekipmanların bakım maliyetlerini azaltmak
- Ekipmanların doğru analiz edilerek gereksiz bakım yapılmamasını sağlamak

2.1. Kestirimci Bakım Teknikleri

Titreşim izleme, günümüzde kestirimci bakımdaki en temel durum izleme teknolojisidir. Ayrıca, titreşim görüntüleme teknolojisini desteklemek için görsel inceleme, termal görüntüleme, triboloji, titreşim görüntüleme, elektrik testi, ultrasonik test ve diğer tahribatsız test teknolojileri kullanılmaktadır. Görsel inceleme, endüstride kullanılan ilk kestirimci bakım tekniğidir. Sanayi devrimi ile birlikte bakım personeli, periyodik arızaları tahmin etmek için makine ve ekipmanların kilit noktalarında görsel incelemeler yaptı. Bu teknik, kestirimci bakım uygulamalarında halen başarıyla kullanılmaktadır. Termal görüntüleme, yalnızca elektrik sistemlerinin izlenmesine yardımcı olmakla kalmayıp aynı zamanda makinelerin, yapıların ve sistemlerin izlenmesine de yardımcı olan bir kestirimci bakım teknolojisidir. Cihazın yaydığı kızılötesi enerjinin sıcaklık değişimlerine göre ayırt edilmesini sağlar. Eğitimli personel de bu verilere dayanarak arızaların oluşumunu tahmin edebilir.

Triboloji terimi, mekanik yatakların yağlanmış rotor destek yapısını kapsayan genel bir terimdir. Tribolojinin kestirimci bakıma dahil edilmesiyle ilgili olarak, motor yağı analizi ve aşınma partikül analizi olmak üzere iki ana teknik uygulanmaktadır. Çoğu şirket elektromekanik sistemlere dayalı olmasından dolayı titreşim analizini en temel arıza tespit yöntemlerinden biri haline getirmektedir. Titreşim analizi doğru kullanıldığında en güçlü algılama yöntemi olarak rolünü yerine getirecektir. Dalga biçimini ve spektrumu gösterme imkanı, en küçük değişiklikleri bile algılayabilir. Titreşim teknolojisine ek olarak, özellikle motorlardaki kusurları tespit etmek için güç tüketimi verilerinin de analiz edilmesi gerekiyor. Ultrasonik test, belirli bir frekansta gürültünün ölçülmesini ve analizini içeren titreşim görüntülemeye benzer. Titreşim analizinden farkı, daha yüksek bir frekansta ölçüm yapması ve genel olarak genel gürültü ölçümü ve kaçak tespiti için kullanılmasıdır. Çalışmalar, rulman arızalarını tespit etmede titreşim analizinden daha etkili olduğunu göstermiştir.

2.2. Endüstri 4.0

Endüstri 1.0, 18. yüzyılın sonlarında buhar makinesinden güç ve hareket üretilmesiyle başlayan endüstri devrimidir. Endüstri 2.0, 20. yüzyılın başlarında Henry Ford'un montaj bantları kullanarak ilk seri üretimi gerçekleştirilmesi ile başlamıştır. Endüstri 3.0, 1970'lerden itibaren endüstriyel otomasyon sistemlerinin doğması ve üretim süreçlerinde kullanılmaya başlaması ile olmuştur. Böylece ürünlerin daha hızlı, kaliteli ve düşük maliyet ile seri

üretimlerin yapılması gerçekleşmiştir. Akıllı fabrika, insan, makine ve ortam içinde bulunan nesnelerin yazılım ve donanımlar aracılığıyla, birbirleriyle etkileşim içinde işbirlikçi olarak çalışabildiği ve nesnelerin kendi kendine kararlar alabildiği sistemler bütünüdür. Hızla gelişen dünyada öğrenme hızını geliştirip değişime adapte olma yeteneğini artırmayan işletmeler rekabetçi olamayacaklardır [1].

Endüstri 4.0, endüstriyel otomasyona özgün yaklaşıma bazı değişiklikler getiriyor. Nesnelerin İnterneti (IoT) ve Siber Fiziksel Sistemler (CPS) teknolojileri, bilişsel otomasyon kavramını tanıtarak ve böylece akıllı üretim uygulayarak akıllı ürün ve hizmetler ortaya çıkararak bu bağlamda rol oynamaktadır. Bu yeni yaklaşım, şirketleri daha dinamik bir ortama davet ediyor. Bu şirketlerin çoğu, büyük bir varlığın her zaman üretkenliğe yardımcı olmadığı bu yeni duruma hazır değil. Bu büyük veri seti, geleneksel üretimi teknolojinin her yerde olduğu sensör donanımlı akıllı fabrikalara dönüştüren Endüstri 4.0 ilkesinden kaynaklanmaktadır. Bu kavramın uygulanması, daha verimli karar vermeyi kolaylaştıran ve arızalardan daha hızlı kurtarmaya olanak tanıyan bir karar destek sistemi tasarlamak için veri analitiğinin kullanılmasını içerir [17].

Bir üretim ortamına kestirimci bakım uygulamak bazı faydalar sağlar ve bazı zorlukların üstesinden gelmeyi içerir. Makine öğrenimi kullanımı, makine öğrenimi algoritmalarını eğitmek için büyük miktarda veriye dayalı olarak makinelerin faydalı ömrünü tahmin etmek gibi arızaları tahmin etme ve tahmin etme gibi ek görevleri mümkün kılar. Hataları teşhis etmek için kullanılır [17].

Endüstri 4.0'ın kullandığı teknolojiler:

- Siber Fiziksel Sistemler (Cyber Physical Systems)
- Yatay ve Dikey Entegrasyon (Vertical & Horizontal Integration)
- Akıllı Robotlar (Autonomous Robots - Co-robots, Collaborative robots)
- Nesnelerin İnterneti (IoT, Internet of Things)
- Büyük Veri ve Analizi (Big Data & Analytics)
- Bulut Bilişim (Cloud Computing)
- Arttırılmış Gerçeklik ve Sanal Gerçeklik (Augmented Reality & Virtual Reality)
- Eklemeli Üretim (Additive Manufacturing)
- Siber Güvenlik (Cyber Security)
- Yapay Zekâ (Artificial intelligence)

Yukarıda maddeler halinde verilmiş olan Endüstri 4.0 teknolojilerinden bu tezin çalışma konusu ile ilgili olanlar aşağıda anlatılmıştır [1].

- **Nesnelerin İnterneti:** "Nesnelerin İnterneti" olarak adlandırılan Nesnelerin İnterneti, ağ üzerinden bağlanan fiziksel cihazlar arasındaki iletişimi ve bu nesnelerin uzaktan kontrolünü içerir. Sistem makineden makineye (M2M) iletişimi destekler ve hızla gelişmeye devam eder

İnternet ilk kullanıldığında insanların birbirlerinden uzakta olsalar bile birbirleriyle iletişim kurmalarına yardımcı oluyordu. Ayrıca, küreselleşmenin temel bir bileşeni olarak internet, mevcut pazar yapılarında ve iş stratejilerinde değişikliklere yol açmıştır. Açıktır ki, hedef boyuta aktarılan bu tür bir iletişim, şüphesiz pazar yapısını ve şirketin üretim ve satış stratejisini etkileyecektir. Günümüzde birçok büyük teknoloji ve yazılım şirketi Nesnelerin İnterneti ile ilgili ürünler üretmektedir. Türkiye'de Siemens ve Koç Sistem gibi şirketler ile dünyanın her yerinde IBM ve Oracle gibi uluslararası yabancı şirketler Nesnelerin İnterneti alanına büyük yatırımlar yaptılar. Örneğin Koç sistemi; baz istasyonlarının, elektrik sayaçlarının, üretim ekipmanlarının ve daha birçok ekipmanın uzaktan yönetimi ile Nesnelerin İnterneti Platformu 360 için kendi mimarilerine isim verdiler. Platform 360 vizyonu sadece üretim sürecini değil aynı zamanda lojistik ve pazarlama süreçlerini de kapsamaktadır [11].

- **Büyük Veri:** Günümüzde internet üzerinden büyük miktarda veri toplanabilmektedir. Ancak genel bir bakış açısıyla bilgi kirliliğinin artması nedeniyle insanlar bu bilgiyi kullanmanın ve ondan doğru bilgiyi seçmenin çok zor olduğunu düşünüyor. Aslında bilgi kirliliği bir gerçektir ve son zamanlarda ciddi bir büyüme yaşanmaktadır. Ancak bu bilgiler mutlaka doğru bilgilerin elde edilemeyeceği anlamına gelmez. Günümüzde bu bilgilerin ayrıştırılması konusunda birçok çalışma yapılmaktadır. Örneğin Koç Sistem, Endüstri 4.0 araçlarından biri olan büyük veri üzerine araştırma yaptı. Bu sistemin ana özelliği, mevcut karmaşık büyük verileri basitleştiren IQ Plus sistemi olarak adlandırılmaktadır.

Günümüzde veriler makineler ve ekipmanlar tarafından üretilmekte ve bulut altyapı sistemlerinde saklanmaktadır. Gerekliğinde işletme yöneticileri veya günlük hayatta tüketiciler bu verilere erişebilir. Mevcut ağlardaki veri ölçeğinin önümüzdeki birkaç yıl içinde çok daha büyük olacağına inanılıyor. Bu nedenle, endüstri perspektifinden büyük veri, Endüstri 4.0'da önemli bir rol oynayacaktır. Alman hükümetinin tahminine göre Endüstri 4.0'ın yakıtı büyük veri olacak.

Genel bir bakış açısıyla bilgi üretimi ve bilgi depolama, siber-fiziksel sistemlerde sürekli olarak akıllı makineler aracılığıyla gerçekleştirilecektir. Bir süre sonra bu bilgilerin

analiz edilmesi, ölçülmesi ve yapılandırılması gerekir. Bu noktada büyük veri analizi, diğer adı veri madenciliği öne çıkmaktadır. Büyük verinin analizi ve kullanımı ile verimliliği artırmak, hata oranlarını azaltmak ve esnekliği artırmak temel amaçtır [11].

- **Siber-fiziksel sistemler:** Siber-fiziksel sistemler, makineleri kontrol etmek için ek akıllı ve esnek yazılımların kullanılması anlamına gelen Endüstri 4.0'ın önemli bir parçasıdır. Siber-fiziksel sistemlerde, yerleşik üretim faktörlerindeki gömülü yazılımlar ve sensörler sayesinde önceden programlanan sistem iletişimi sağlayarak herhangi bir müdahaleye gerek kalmadan çalışabilmektedir. Bu nedenle genel bir çerçevede, sistemin başlangıcında programlama yapılarak, sistemin tüm süreci herhangi bir müdahale veya ekstra çaba gerektirmeden otomatik olarak gerçekleştirilebilir. Bu süreçte otomasyon önemli bir rol oynamaktadır. Öğrenen robotlar da dâhil olmak üzere birçok makine üretim sürecine dâhil edilmektedir. Bugün hepimizin bildiği gibi özellikle otomotiv endüstrisinde robotları ve araçları öğrenmek bazı üretim süreçlerini de içeriyor [11].

Endüstri 4.0'ın genel amacı sistemlerin hızlı ve etkin bir şekilde üretimlerini gerçekleştirmesidir. Olası gerçekleşebilecek arızaların hızlıca tespit edilip engellenecektir. Bu avantajların yanı sıra, bu işler gerçekleşirken maliyetler de en düşüğe tutulacak ve işçilerin yoğunlukta olduğu geniş fabrikalar yerine robotların yoğunlukta olduğu, her zaman müdahalede bulunma gerekliliği olmadan her zamanki işleri daha hızlı ve etkin bir şekilde yapmaktır.

2.3. Makinelere Bilgi Toplama

Kestirimci bakımı doğru bir şekilde gerçekleştirebilmek için makinelere bilgi toplama önemli bir aşamadır. Bağlantılı operasyonların güzelliği, üreticilerin birden fazla kaynaktan veri toplayıp kullanabilmesidir. Veriler bağlama duyarlı olduğu sürece, yöneticilerin atölye durumu ve performansı hakkında daha derin bir anlayış kazanmalarına yardımcı olabilir ve hatta boşlukları doldurmaya ve mevcut verilere bağlam eklemeye yardımcı olabilir.

Tıpkı deneyler gibi, bilimsel veri toplama yöntemleri de bilim ve teknolojiye gelişmeler nedeniyle büyük ölçüde çeşitlenmiştir. Verilerin manuel olarak toplandığı günler geride kaldı. Teknolojinin gelişmesiyle birlikte tüm süreç bilgisayar ortamına geçebilmekte ve veriler programlama sistemi üzerinde otomatik olarak toplanabilmekte ve güncellenebilmektedir. Esas olarak bilgisayar destekli imalatta kullanılır. Benzer şekilde, verileri güncellemek için işlemleri kontrol etmeye gerek yoktur. Bu tür sistemler belirli zaman

aralıklarında güncellenecek şekilde programlanabilir. Bununla birlikte, daha iyi ve daha doğru sonuçlar elde etmek için diğer basit veri toplama yöntemleri de gelişmiş veri toplama yöntemleriyle birleştirilebilir. Örneğin gözlem, tüm deneyler için geçerli olan en basit veri toplama yöntemidir [3].

Gelişmiş modern veri toplama yöntemleri birçok yönü içerebilir. Deney tipi veya deneyde kullanılan reaktanlar, kullanılacak yöntemin tipini belirler. Ayrıca beklenen sonuçlar, kullanılacak yöntem ve ekipmanların belirlenmesinde kullanılabilir. Gelişmiş veri toplama yöntemleri gerektiren termal yönetim deneyleri gibi bazı karmaşık deneyler vardır. Termal analizde toplanması gereken veriler, zamanla sıcaklıktaki değişiklikleri içerir. Bu nedenle, toplanacak verilerin karmaşıklığı nedeniyle algılama veya gözlem gibi basit yöntemler uygulanamayabilir. Veri toplamak için termal göstergeler ve termal cihazlar (ısı emiciler ve PCB düzlem kalınlığı gibi) gibi daha gelişmiş yöntemler kullanılabilir. Sıcaklık değişikliklerini izlemek için bir termometre ve ısı göstergesi kullanılabilir. Okumalar daha sonra deneyin sonunda analiz için kontrol/izleme programına yüklenebilir.

Bu nedenle, bu tür deneylerde veri toplama, çoklu toplama ve kaydetme yöntemlerini içerebilir. Toplanacak ve kaydedilecek veriler basınç ve kuvvet değişikliklerini içerir.

Şok ve titreşim deneyleri, dakikadaki devir sayısı gibi bilgilerin toplanmasını içerebilir. Şok ve titreşim testleri genellikle motorun veya araba gövdesinin hareketli parçaları üzerinde yapılır. Şiddetli titreşimler sadece motorun genel çalışmasına müdahale etmeyecek, aynı zamanda titreşim işlemi sırasında ileri geri hareket nedeniyle eklemlerin gevşemesine neden olacağı için dezavantajlı da olabilecektir. İyi bir motor titreşimi en aza indirmelidir. Bu özellik motorun birçok parçasının doğru şekilde sıkıldığını gösterir. Öte yandan, bazı parçalar titreşim gerektirir. Bu nedenle, çalışan motor testlerini veya gerçek motor titreşimlerini izlemek çok önemlidir. İzleme, test etme ve veri toplamayı içerebilir [3].

2.4. Makine Öğrenimi

Bir bilgisayarda bilgiyi kodlamak yerine, makine öğrenimi (MÖ), örneklerden ve gözlemlerden anlamlı ilişkileri ve kalıpları otomatik olarak öğrenmeye çalışır. Makine öğrenimindeki ilerlemeler, insan benzeri bilişsel yeteneklere sahip akıllı sistemlerin son zamanlardaki yükselişinin iş ve kişisel yaşamlarımıza nüfuz etmesini, elektronik pazarlarda birbirine bağlı etkileşimleri akla gelebilecek her şekilde şekillendirmesini ve kuruluşların üretkenliği, katılımı ve çalışanları elde tutma kararlarını iyileştirmesini sağladı. Bireysel

kullanıcı tercihlerine uyum sağlayan eğitilebilir yardım sistemleri ve geleneksel finansal ticaret piyasalarını bozan ticaret araçları geliştirmesini sağlamıştır [19].

Genellikle yapay zekâ (AI) olarak adlandırılan bu tür sistemlerin gelişmiş problem çözme yetenekleri, tahminler, kurallar, yanıtlar, öneriler veya benzer sonuçlar üreten analitik modellere dayanır. Analitik modeller oluşturmaya yönelik ilk girişimler, bilinen ilişkileri, prosedürleri ve karar mantığını, elle hazırlanmış kurallar aracılığıyla akıllı sistemlere (örneğin, tıbbi teşhis için uzman sistemler) açıkça programlamaya dayanıyordu. Yeni programlama çerçevelerinin mevcudiyeti, verilerin mevcudiyeti ve gerekli bilgi işlem gücüne yaygın erişim ile yönlendirilen analitik modeller, artık yaygın olarak MÖ olarak adlandırılan yöntemler kullanılarak giderek daha fazla oluşturulmaktadır. MÖ, insanları, bilgilerini makineler tarafından erişilebilir bir biçimde yorumlama ve resmileştirme yükünden kurtarır ve akıllı sistemlerin daha verimli bir şekilde geliştirilmesini sağlar [19].

2.5. İmalat Firmalarında Enerji Verimliliği

İmalat, toplam küresel enerji tüketiminin yaklaşık %37'sini oluşturan yoğun bir endüstridir. Küresel enerji krizi ve çevresel etki nedeniyle imalatta enerji tüketiminin azaltılması acilen ele alınması gereken önemli bir konudur. İmalat endüstrisindeki çeşitli enerji tüketicileri arasında, büyük miktarda enerji tüketen ancak enerji verimliliği düşük olan takım tezgâhları ana enerji tüketicileridir. Tipik bir öğütme işleminin enerji verimliliği sadece %14,8'dir. Bu nedenle, sürdürülebilir üretim ve daha temiz üretim elde etmenin anahtarı olan takım tezgahlarının enerji verimliliğini artırmak önemli ve zorunludur [18].

Genel olarak konuşursak, takım tezgahlarının enerji verimliliğini artırmanın iki yolu vardır. Bir yandan, enerji ve malzeme tasarrufu sağlayan takım tezgâhları tasarlamakla ilgilidir. Bir diğeri, enerji tasarrufu için işlemeyi optimize etmektir. Bu iki yaklaşım arasında, enerji verimli takım tezgahlarının tasarımı, tasarım aşamasında takım tezgahlarının sürdürülebilirliğini geliştirmenin umut verici bir yolu olarak kabul edilir. Bu amaçla Uluslararası Standardizasyon Örgütü (ISO) tarafından 2017 yılında yayınlanan ISO 14955-1 standardı, enerji verimli takım tezgâhları için tasarım yöntemleri için bir çerçeve sunmaktadır. Takım tezgahının iş mili sistemi, besleme sistemi ve yardımcı sisteminin enerji tasarrufu için optimize edilmesi gereken ana parçalar olduğuna dikkat çekildi. Ancak standart, bu bileşenler için ayrıntılı bir enerji verimli tasarım yaklaşımından yoksundur. Bir takım tezgahının iş sistemi genellikle en büyük enerji ve malzeme tüketicisidir. Toplam takım tezgâhı enerjisinin

%15'inden fazlasını tüketir. Ayrıca mil sistemi, üretim sürecinde çok fazla malzeme tüketir. Uygulayıcıların takım tezgahlarının enerji ve malzeme tasarrufu potansiyeline sürdürülebilirlik perspektifinden bakmaları önemlidir [18].

Son on yılda, birçok araştırmacı iş sistemlerinin enerji tüketimi analiziyle uğraştı, çünkü iş sistemlerinin enerji tüketim özelliklerini anlamak enerji tasarrufunda ilk adımdır. Bu çalışmaya dayanarak, bazı araştırmacılar enerji verimliliğini artırmak için iş mili motoru optimizasyonu üzerinde çalışmaya başladılar. Verimli bir iş mili sistemi tasarımı için bir iş mili motoru seçmek için kullanılacak bir motorun optimum çalışma frekansını ve çalışma torkunu elde etmek için bir yöntem geliştirdi, CNC takım tezgâhı (bilgisayar sayısal kontrolü) iş mili sistemlerinin enerji tasarrufu potansiyelini araştırdı. Bu çalışmanın sonuçları, hızlanma limitleri ve motor gücü limitleri gibi iş mili motor parametrelerinin optimize edilmesiyle enerji tüketiminde %10'luk bir azalmanın sağlanabileceğini göstermektedir [18].

2.5.1. İmalat Firmalarının Karşılaştığı Problemler

Teorik tanımı bir kenara bırakırsak, üretim biriminin kurulmasının kâr etmek ve para kazanmak olduğu söylenebilir. Bu tanıma göre imalatta kârlılığı etkileyen her faktör bir imalat problemi olarak değerlendirilebilir. Bu faktörlerin en önemlileri veya imalat sorunları şu şekilde sıralanabilir:

- Normal imalat dönemindeki problemler
- Tesisin kuruluş ve deneme çalışması dönemindeki problemler
- Tesisin bakım ve onarımı ile ilgili problemler [4]

İmalat teknolojisi son yıllarda tam otomatik aşamaya girmiş olsa da bilgisayar destekli ekipmanların kullanılması nedeniyle, talaşlı imalat ve delme işlemlerinde hala çözülmemiş iki problem vardır: takım aşınması ve kırılması. Malzemelerle ve iş parçasının yüzeyinin mekanik hareket nedeniyle malzeme kaybetmesi durumu, takım aşınmasının dinamikleri karmaşıklığı nedeniyle tam olarak anlaşılmadığından, bu problemler imalat teknolojisinde çözülmeyi bekleyen temel problemler haline gelmiştir. Ayrıca insansız fabrikalarda hasarlı veya hasarlı aletlerin değiştirilmesinden kaynaklanan duruş kaybı da dikkate alınması gereken önemli bir durumdur. Sanayileşmiş bir ülkede aşınma ve yıpranmanın ekonomik maliyetinin ülkenin gayri safi milli hasılasının %7'sine eşit olduğu tahmin edilmektedir [6].

Talaşlı imalat işlemi sırasında takım çok yüksek bir sıcaklıkta tutulur ve takımın gerilme ve deformasyon meydana gelir. Bu deformasyonlar ve aşınmalar talaş kaldırma

işlemine olumsuz etkileyebilir. Takımda meydana gelen bu deformasyonlar; iş parçasının yüzey kalitesini bozarak iş parçasının kalitesini düşürür, takım tezgâhı milinin ve yatağın titreşimini artırır ve talaş kaldırma için gereken enerjiyi yükselterek enerji tüketimini ve üretim maliyetlerini artırır. Tüm bu olumsuz faktörler, takım ömrünün kısalmasına ve takım maliyetlerinin artmasına neden olacaktır. Takım ömrünü etkileyen faktörlerin anlaşılması, bu etkilerin en aza indirilmesi ve kontrol edilmesi en uygun takım ömrü ve takım değiştirme zamanının belirlenmesi için çok önemlidir [5].

Kesici takımın talaşlı imalat işlemi sırasında ısıl yorulması ve mekanik yorulması, kırılması, aşınması ve plastik deformasyonu takımı kullanılmaz hale getirecektir. Takım ömrü, işlenmiş parçaların kalitesini ve maliyetini doğrudan etkileyen önemli bir faktördür. Bu nedenlerle takım ömrünü etkileyen faktörlerin anlaşılması, gerekli önlemlerin alınması, takım ömrünün belirlenmesi ve uygun takım değiştirme süresinin belirlenmesi gerekmektedir [5].

İşleme operasyonlarında takımların durumunu izlemek için birçok yöntem geliştirilmiştir. Bunlardan çok azı başarıyla kullanılmıştır. Kullanılan sensörler ve yöntemler uluslararası standartlarda olmasına rağmen şu anda sektörün ihtiyaçlarını tam olarak karşılayan bir takım durum izleme modeli bulunmamaktadır.

Koşullar ve analiz, değerlendirme ve karar verme için uygun veri işleme yöntemlerini kullanın. Takım durum izleme ve erken uyarı sistemi için geliştirilen modelde tek sensör kullanılıyorsa, işleme sürecinin karmaşıklığından dolayı sensörde elde edilecek verilerin analizi yapılırken ölçüm ve tespit hataları olabilir. Birden fazla sensör sistemin güvenilirliğini artıracaktır. Kurulan modelin sanayide etkin bir şekilde uygulanabilmesi için araştırmada öncelikle atölye ortamına uygulanabilecek yöntemler seçilmeli, kullanılan yöntemlerin ekonomik olması gerekmektedir [12].

Takım durumunun izlenmesinde kullanılan dolaylı ve doğrudan yöntemler endüstride etkin bir şekilde kullanılabilir. Teknoloji kullanımı çalışmalarında aşağıdaki faktörlerin dikkate alınması geliştirilecek modelin etkinliğini artıracaktır.

- Kullanılan sensörlerin yüksek kapasitesi
- Yapay sinir ağının geliştirilmesi
- Veri aktarımı ve analizi için donanım ve yazılım geliştirme
- Dijital denetleyici kontrol ünitesini ve takım durumu izleme modelini iyileştirin
- Çoklu sensör modelini kullanmanın ek yöntemi [12]

3. PROBLEM TANIMI

İşleme hatası, işlenmiş parçanın gerçek boyutu ile gerekli boyut arasındaki fark olarak tanımlanabilir. İşlenen bir parçanın maksimum hata miktarı, parçanın hassasiyet (tolerans) değerini de temsil eder. Bütün bunlar kullanılan sistemin (işleme ve ölçüm) doğruluğuna bağlıdır. Ulaşılabilir nihai doğruluk, işleme sisteminin nominal doğruluğundan daha düşük olmalıdır. Örneğin, bir işleme sisteminin (makine) konumlandırma doğruluğu 5µm ise, sistem tarafından işlenen iş parçasının doğruluğu <5µm olmalıdır.

Yüksek üretkenlik ile birleşen enerji verimliliği, takım tezgâhı endüstrisinde önemli bir rekabet avantajı haline geliyor. Genel olarak torna tezgâhları ve özel olarak İsviçre tipi torna tezgâhları için 8 saate kadar süren bir ısınma aşaması, makinenin enerji verimliliğini artırmak için önemli bir potansiyeli temsil eder. Isınma aşaması, takım konumunun doğruluğunu ve dolayısıyla işleme sürecinin doğruluğunu artırmak için makineyi termal olarak stabilize etmek üzere tasarlanmıştır. Makinenin çeşitli parçalarının (mil, çalışma alanı, eksenler vb.) artan sıcaklığı bazı parçaların deforme olmasına neden olabilir.

Takım Merkez Noktasının (TCP) referans konumunu doğrudan etkiler. Bu fenomene termal kayma veya termal hata denir [1]. Termal sapmanın etkilerini azaltmak için, takım tezgâhı kullanıcıları, termal stabilize elde etmek için makineyi işleme malzemesiyle veya malzeme olmadan saatlerce çalıştırır. Gerçek zamanlı olarak telafi etmek için takım referans konumunu düzelterek termal hatayı tahmin etmek, ısınma süresini bastırır veya en azından büyük ölçüde azaltır [16].

Tornalama işlemlerinde iş parçası boyutu hatalarının sınıflandırılması farklı şekillerde yapılmaktadır. Hatanın doğasına göre, işleme hataları kaynaklarına göre dinamik ve yarı statik olmak üzere altı temel kategoriye ayrılabilir:

- Kesme Kuvvetlerinden kaynaklanan hatalar,
- Takım-tezgâh sisteminin geometrik ve kinematik hataları,
- Isıl hatalar,
- Takım ve tezgâh elemanlarının aşınmasından kaynaklanan hatalar
- Cihaz-ekipman hataları
- Diğer hatalar (parça bağlama, malzeme kusuru, titreşim vs.)

Isıl deformasyonlar ve takım aşınması kaynaklı hatalar en fazla 10 mm civarında seyrederken, deformasyondan kaynaklanan hatalar 100 mm seviyelerine kadar yükselir. Bu sebeple hatada işleme sisteminin kesme kuvvetleri altındaki deformasyonu hâkimdir [8].

3.1. Mevcut Bakım

Firmaların karşılaştığı önemli konulardan ve sorunlardan biri de üretimde kullanılan araçların (makine, tezgâh, ekipman vb.) arızalanması durumunda ne yapılması gerektiğidir. Şirketler genellikle bu sorunu daha fazla makine satın alarak ve üretimin kesintiye uğramamasını sağlamak için bazı yedek parçaları bulundurarak çözerler. Bu ekonomik olarak uygulanabilir bir çözüm değildir. Bazen bazı firmalar arızalanan veya bir süre hizmet dışı kalacak makineleri almak yerine makine satın alarak üretime devam etmektedirler. Ancak makine bakımı sırasında toplam makine sayısı bariz bir şekilde artacağından bunun ekonomik olarak uygulanabilir bir çözüm olmadığı görülmektedir.

İşletme yönetiminin temeli; kıt kaynakların en makul ve ekonomik kullanımı olduğu için bu durumda başka çözümler aramakta bir sakınca yoktur. Bu özellikle sürekli üretim sistemlerinde önemlidir. Çok makineli bir üretim hattında, bir veya daha fazla makine arızalanırsa, yedek parça yoksa üretim durabilir. Kesikli imalatta ise arıza veya bakım nedeniyle devre dışı kalan bir makine yerine aynı tip başka bir makinenin geçici olarak kaydırılması da sorunu çözebilir. İmalatın durması, işletme için parasal bir kayıptır. Makine parkının artırılması ise maddi kaynak gerektirir. Öyleyse bu kaybı, üretimi olumsuz etkilemeyecek bir şekilde azaltmak düşünülmelidir.

İmalatın durması ekonomik açıdan bir kayıp olduğuna ve makinelerin arızalanmaları da bir noktadan sonra kaçınılmaz olduğuna göre; ya arızaları en kısa zamanda onarmak, ya da arızalanmaları mümkün olan en düşük seviyeye indirmek hedeflenmelidir. Bunun için de, belirli dönemlerde imalatı durdurup makineleri bakıma almak en akılcı yoldur. Buna rağmen, belli bir yaştan sonra makinelerin bakım masrafları işletmeye büyük bir yük olur. Bu nedenle, makineleri ekonomik oldukları sürece elde tutmak gerekir. Bu süre geçildikten sonra makineleri yenilemek, elde tutmaktan daha akılcı bir tutumdur [9].

3.2. Planlanan Bakım

Bu çalışmada planlanan bakım ise güncel çalıştığı zamana ait verileri alınan ekipmanın bakımını herhangi bir şekilde üretimi aksatmadan ve zamanı etkin kullanarak yapmaktır. Alınan verilere anomali tespiti yapılarak öngörülen ve öngörülemeyen arızalar tespit edilerek ekipmanı durdurmaya gerek kalmadan veya ekipmanı yenilemeye gerek kalmadan bakımı yapılabilecektir; yani kestirimci bakım ile eldeki ekipmanın bakımı yapılacaktır. Bu sayede olası maliyetlerden ve üretimdeki etkin olmadığı zamandan büyük miktarda azaltmış olacağız.

4. ANOMALİ TESPİTİ ÜZERİNE KAVRAMLAR

Anomali tespiti, bir zaman serisi içinden önemli ölçüde farklı olan verilerin, olayların veya kalıplarından tespitine denir. Genel olarak konuşursak, sisteminizin normal akışında herhangi bir davranış değişikliği fark ederseniz, bu davranışın sebeplerini öğrenebilir, gizli sorunları ortaya çıkarabileceğiniz gibi tamamen ortadan kaldırebilirsiniz. Bu tespit işlemi manuel yapmak ve tüm veriyi 7/24 izlemek için birkaç personelle yapılamayacak kadar zor bir süreçtir. Bu davranış tespitleri önceden otomatik ve hızlı şekilde yapmak önem kazanmıştır.

Anormallik tespiti durağan bir veri üzerine yapılabileceği gibi akan ve zaman verisi içeren olabilir. Bu tez, fabrika ortamından toplanan verilerle ilgilendiği için zaman verisi içeren veriler ile ilgilenecektir.

Anormalliğin doğası gereği farklı durumlarda karşımıza çıkabilir. Sadece bir modelle tüm anormallikleri algılamak imkânsızdır. Algılama algoritmalarını (algılayıcılar - dedector), özellik mühendisliği yöntemlerini (dönüştürücüler - transformers) ve topluluk (ensemble) yöntemlerini (toplayıcılar - aggregators) uygun şekilde seçmek ve birleştirmek, etkili bir anormallik tespiti modeli oluşturmanın anahtarıdır. Bu tezde, özellikle algılayıcılar ayrıntılı bir şekilde incelenecektir [20].

4.1. Gözetimli ve Gözetimsiz Öğrenme (Supervised and Unsupervised Learning)

Bir makine öğrenmesi işlemi gözetimli veya gözetimsiz olmak üzere iki farklı öğrenme modeli ile yapılabilir. Bir uzmanın öncelikle problemini inceleyerek öğrenme modelini hangi şekilde çözeceğine karar vermelidir. Gözetimli öğrenmede önceden hazırlanmış ve işaretlenmiş bir veri setine ihtiyaç vardır. Gözetimsiz öğrenmede ise mevcut ham veri üzerinden çalışabilir. Her iki yönteminde probleme göre avantajları vardır, ancak tezimizdeki veride olduğu gibi Endüstri 4.0 yeni paylaşan fabrikalar için öncelikle gözetimsiz metotların tercih edilmesi iyi olacaktır [21].

4.2. Anomali Türleri

Anomali, zaman serilerinde birçok farklı olay türünü içeren çok geniş bir kavramdır. Örneğin, bir değer artışı, bir oynaklık kayması, sezonluk düzenin ihlali gibi veri belirli bağlama bağlı olarak anormal veya normal olabilir. Bir sistem kurulurken farklı modeller dikkate alınmalı ve veri için en uygun yöntemler seçilmelidir.

Kullanılabilecek yöntemler:

- Aykırı değer (Outliner)
- Seviye kaydırma (Level shift)
- Desen değişimi (Pattern change)
- Sezonluk düzen (Seasonality)

Aykırı Değer: Aykırı değer, bir zaman serisinde bir özelliğe ait veriler arasında önemli ölçüde farklı olan bir veri noktasıdır. Aykırı değer tespiti için iki farklı yöntem kullanılır.

- Kullanıcı tanımlı eşik değerleri
- Geçmiş verilerden elde edilmiş istatistiksel değerler

Seviye yükselme ve kayması: Bir zaman serisinde değerler belli bir artış ve uyum içerebilir. Bu durumda ani artış veya azalma, değişiklik geçici ise ani yükselme, kalıcı ise seviye kayması olarak adlandırılır. Bir ani bir aykırı değere benzer görünse de aykırı değer zamandan bağımsız iken bu durum zaman bağlıdır.

Desen değişimi: Bir önceki yöntem, değer dışındaki desenlerin değişimini tespit etmek için geliştirilebilir. Örneğin, desenlerdeki kaymalar ilgi çekiciyse, zaman pencerelerinde izlenecek istatistik ortalama yerine standart sapma olabilir.

Sezonluk düzen: Bir zaman serisi sezonluk faktörlerden etkilendiğinde (örneğin günün saati, haftanın günü, yılın ayı) sezonluk bir deseni olabilir. Bir kullanıcının sezonluk desenleri ayırt etme konusunda dikkatli olması gerekir. Sezonluk bir dizi, sezon doğası gereği her zaman sabit, genellikle yorumlanabilir ve bilinen bir döneme sahiptir [22].

5. MATERYAL METOD

5.1. Materyal

Bu bölümde HEMA'dan alınan veri seti, 02.03.2021 – 24.03.2021 tarihleri arasında bir torna sisteminden (ZAK HCN 6000 Yatay işleme merkezi) toplanan 1.902.604 satırdan oluşan veri topluluğu alınmıştır. Bir önceki bölümde kısaca anlatılan konular burada sayısal veriler üzerinden anlatılacak ve karşılaştırmalar yapılacaktır. Deneylede, Python programlama dili kullanılacaktır. Aykırı durum tespiti için Python'daki Anomaly Detection Toolkit (ADTK) (<https://adtk.readthedocs.io/>) kütüphanesi kullanılmıştır. Bu kütüphanede kullanılan modüller ve kullanılan parametreler deneylede verilecektir. Çizim içinde matplotlib kütüphanesi (<https://matplotlib.org/>) tercih edilmiştir.

Belirli sayıda veri seti alınarak bunlara anomali tespiti yapılması için belli yöntemler kullanılmıştır. Bunlar aykırı değer, seviye yükselme ve kayması, desen değişimi ve sezonluk düzendir.

5.2. Metot

5.2.1. Veri Seti Hakkında

Veri seti, 02/03/2021 – 24/03/2021 tarihleri arasında bir torna sisteminden (ZAK HCN 6000 Yatay işleme merkezi) toplanan 1.902.604 satırdan oluşan verileri içerir. Bu veri içinde zaman bilgisi yanı sıra 10 özellik dikkate alınmıştır. Bu özellikler ve açıklaması Çizelge 5.1'de verilmiştir.

Çizelge 5.1 Veri setinde özellikler ve açıklaması

#	Özellik ismi	Açıklama
1	ZAMAN	Makineden gelen zaman bilgisidir.
2	PALLET_ID	Farklı paletlerde farklı ürünler üretilmektedir. Bu tanımlayıcı değer 1 veya 2 verisini alır. 1 numaralı ve 2 numaralı palet anlamına gelir.
3	TOOL_NUMBER	Operatör tarafından takılan takımın verisini içerir. (1-40 arasında farklı takımlar olabilir.)
4	TOOL_GROUP	Takımların gruplandırılmış bir tanımlamasını içerir.

Çizelge 5.1. Veri setinde özellikler ve açıklaması (devamı)

#	Özellik ismi	Açıklama
5	ROT_VEL	Döner eksenin dönme hızını tutar.
6	LOAD1	Döner eksenin maruz kaldığı yük miktarını tutar.
7	TEMP1	Santigrat cinsinden döner ekseninde oluşan sıcaklık değeridir.
8	R172	Operatör tarafından takımın ömrünü saniye cinsinden gösteren değerdir.
9	X_POS	Bir kontrol programı içindeki bir program kodu bloğunun konumuna bir referans gösterir. X, Y ve Z pozisyonlarının değerlerini tutar.
10	Y_POS	
11	Z_POS	
12	XYZ_POS	X, Y, Z değerlerinin birleşimden elde edilmiş değerdir. (Bakınız Bölüm 4.2.)

Çizelge 5.1.'de sayısal ve çalışmamız açısından araştırması yapılacak özelliklerin istatistiksel incelemesi Çizelge 5.2.'de verilmiştir.

Çizelge 5.2 Veri seti hakkında istatistiksel bilgiler

#	AÇIKLAMA	Ortalama	Standart Sapma	Minimum	Maksimum
5	ROT_VEL	1943,53	1835,93	0	7350,06
6	LOAD1	7,82	24,24	4	172
7	TEMP1	26,62	1,19	0	29
8	R172	3191,76	4391,47	0	17351
9	X_POS	41,06	210,55	-801	651,800
10	Y_POS	112,09	167,69	-798	744
11	Z_POS	195,98	292,48	-732,73	851,28
12	XYZ_POS	372,91	267,56	0	1182,42

Bu istatistiksel verilerden sonra zaman serisi şeklinde veriyi hazırlamak önemlidir.

5.3. Verinin Hazırlanması

Verinin hazırlanmasını zaman serisinin hazırlanması ve hedef verilerin hazırlanması olmak üzere iki alt başlıkta inceleyeceğiz.

5.3.1. Zaman Serisinin hazırlanması

Bir zaman verisin sıralı ve belli bir frekansta olması önemlidir. Makine üzerinden gelen veri üzerinde bir zaman verisi olur. Bu zaman verisi Çizelge 5.3.'te olduğu gibi süreler arasında tam bir frekans olmayabilir.

Çizelge 5.3 Bir zaman verisi

2021-10-05 18:18:57.128000+00:00
2021-10-05 18:18:57.340000+00:00
2021-10-05 18:18:57.542000+00:00
2021-10-05 18:18:57.744000+00:00
2021-10-05 18:18:57.946000+00:00
2021-10-05 18:18:58.158000+00:00
2021-10-05 18:18:58.371000+00:00
2021-10-05 18:18:58.573000+00:00
2021-10-05 18:18:58.786000+00:00
2021-10-05 18:18:58.978000+00:00

Çizelge 5.3.'e dikkat edilirse milisaniye tarafında tam bir frekans yoktur. Bilgisayarlar arka planda birçok işlem ile ilgilendiği için tam bir frekans tutturmak zordur. Ancak, bir model oluşturmak için verinin belli bir frekansta olması gerekir. Bu frekansı belirleme işlemi veriyi inceleyen kullanıcıya kalır. Kullanıcının zaman serisi yanında oluşan veriyi yorumlaması ve değişimleri yakalaması gerekir. Veri incelendikten sonra dakika, saniye ve milisaniye içeren bir frekans değeri seçilir. Çizelge 5.4. üç farklı frekans için sonuçları verir.

Çizelge 5.4 Frekansa göre zamanları belirleme

Saniye	500 Milisaniye	250 Milisaniye
2021-10-05 18:18:57+00:00	2021-10-05 18:18:57+00:00	2021-10-05 18:18:57+00:00

Çizelge 5.4 Frekansa göre zamanları belirleme (devamı)

Saniye	500 Milisaniye	250 Milisaniye
2021-10-05 18:18:58+00:00	2021-10-05 18:18:57.500000+00:00	2021-10-05 18:18:57.250000+00:00
	2021-10-05 18:18:58+00:00	2021-10-05 18:18:57.500000+00:00
	2021-10-05 18:18:58.500000+00:00	2021-10-05 18:18:57.750000+00:00
		2021-10-05 18:18:58+00:00
		2021-10-05 18:18:58.250000+00:00
		2021-10-05 18:18:58.500000+00:00
		2021-10-05 18:18:58.750000+00:00

5.3.2. Hedef Verinin Hazırlanması

Hedef veri üzerinde analiz yapılacak ve incelenecek veridir. Zamana bağlı olarak çevredeki cihazlardan veri gelir. Çizelge 5.5., gelen verinin saniye bölümü ve hedef veriyi içerir.

Çizelge 5.5 Hedef verinin hesaplanması ve tekrar düzenlenmesi

Saniye	500Milisaniye		500 Milisaniye		
	En Büyük		Ortalama		
57.128	55.379.455	57.000	55.379.455	57.000	55.379.455
57.340	55.379.455	57.500	55.379.455	57.500	18.651.625
57.542	55.379.455	58.000	18.651.625	58.000	96.211.625
57.744	18.651.625	58.500	590.700	58.500	590.700

Çizelge 5.5 Hedef verinin hesaplanması ve tekrar düzenlenmesi (devamı)

Saniye	500Milisaniye	500 Milisaniye
	En Büyük	Ortalama
57.946	18.651.625	
58.158	18.651.625	
58.371	590.700	
58.573	590.700	
58.786	590.700	
58.978	590.700	

Hedef değışkende zamana göre en büyük, en küçük, ortalama değer seçilebilir. Burada en uygun yöntem incelemeler sonucu belirlenir.

5.3.3. Eksik Hedef Veri ve verinin tamamlanması

Özellikle donanımsal sebeplerden ötürü hedef veride eksiklik olabilir. Bu durumda hedef verinin incelenmesi ve uygun bir yöntemle tamamlanması gerekir. Çizelge 5.6., eksik veri ve iki farklı tamamlama yöntemini göstermektedir.

Çizelge 5.6 Hedef verinin eksikliklerin tekrar düzenlenmesi

Saniye	500Milisaniye		500 Milisaniye		
	Bir önceki veri		Doğrusal Hesaplama		
57.000	55.379.455	57.000	55.379.455	57.000	55.379.455
57.500	18.651.625	57.500	18.651.625	57.500	18.651.625
58.000	96.211.625	58.000	96.211.625	58.000	96.211.625
58.500	590.700	58.500	590.700	58.500	590.700
59.000	?	59.000	590.700	59.000	96.211.625
59.500	18.651.625	59.500	18.651.625	59.500	18.651.625
60.000	?	60.000	18.651.625	60.000	96.211.625
60.500	590.700	60.500	590.700	60.500	590.700
61.000	?	61.000	590.700	61.000	590.700
62.500	590.700	62.500	590.700	62.500	590.700

- Bir önceki veya bir sonraki veri: Eksik veriden bir önceki son veya ilk veri tamamlama için kullanılabilir. Çizelge 5.3.3.'da eksik veriden bir önceki veri eksik veriyi tamamlamada kullanılmıştır.
- Ortalama kullanılması: Eksik verilerden önceki veya sonraki bir veya daha fazla verinin ortalaması kullanılabilir.
- Doğrusal enterpolasyon: Eksik veri veya verilerden öncesi ve sonrası bulunur ve lineer bir doğru şeklinde ara değerler hesaplanır. Özellikle zaman serilerinde sıklıkla kullanılan bir yöntemdir. Çizelge 5.3.3.'da basit bir doğrusal hesaplama yapılmıştır.
- Önceki verilere bağlı doğrusal enterpolasyon: Bir makine üzerinde çalışma sırasında benzer durumlar ortaya çıkar. Bu benzer durumları istatistiksel bilgiler elde edilip doğrusal enterpolasyon oluşturmasında kullanılabilir.
- Farklı enterpolasyon yöntemlerinin kullanılması: Linear yöntem yerine kübik, polinom ve kübik polinomsal gibi yöntemler kullanılabilir.
- Büyük veya küçük anlamsız veri ile doldurma: Bu sayede sorun grafiklerde daha rahat görülebilir.

Bu işlemi yaparken uzun süre vermediği durumlarda yapılmaması gerektiği görülmüştür. Orada cihazın 1 veya 2 dakika kapalı olması dahi anormallik tespitinde sorun yaratabilir. Ayrıca, seçilecek yöntemin iyi araştırılması gerektiği ve probleme göre en uygun yöntemin kullanılması gerektiği görülmüştür.

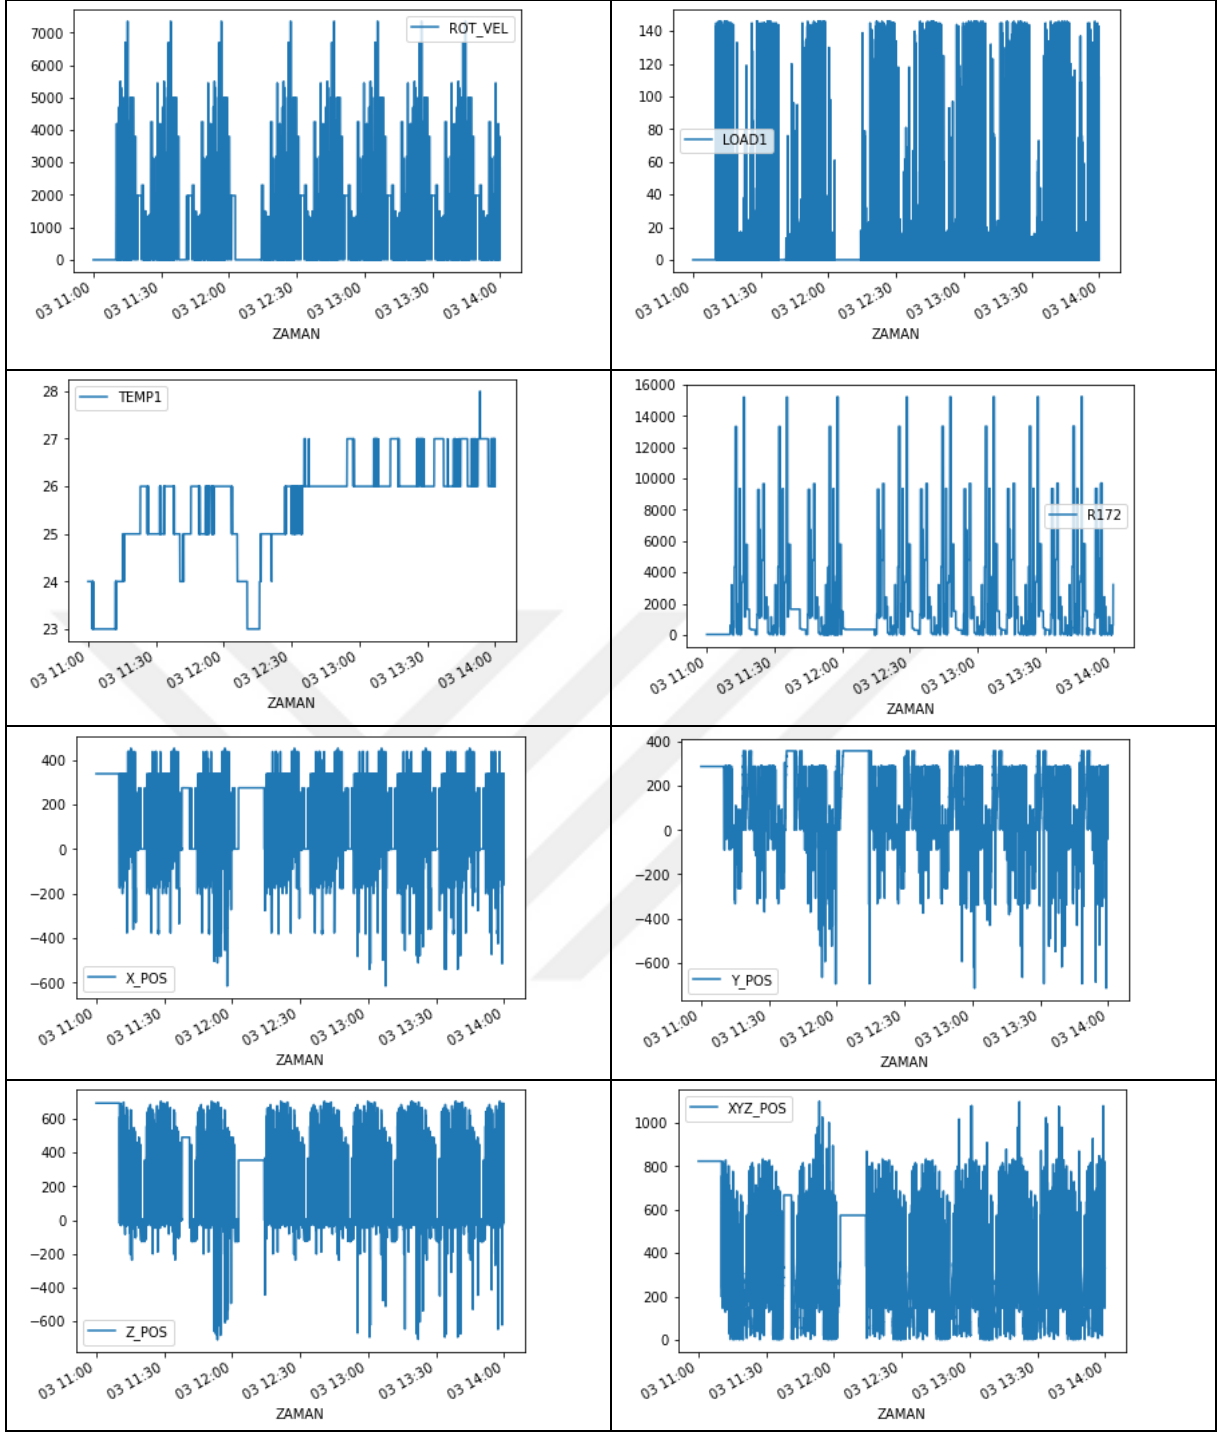
5.3.4. Hedef verinin tekrar organize edilmesi

Hedef verinin birden fazla olması durumunda her hedef veri ayrı ayrı incelenebileceği gibi birden fazla veri üzerine de bir model kurulabilir. Ayrıca, birden fazla veri uygun formülasyonlar tespit edilip tek veriye indirgenebilir. Bu noktada yine verinin çok iyi incelenmesi önemlidir. Bu veride, X_POS, Y_POS, Z_POS verileri aşağıdaki denklem ile birleştirilmiştir.

$$XYZ_POS = \sqrt{X_POS^2 + Y_POS^2 + Z_POS^2} \quad (5.1)$$

5.4. Zaman serisi gösterimleri

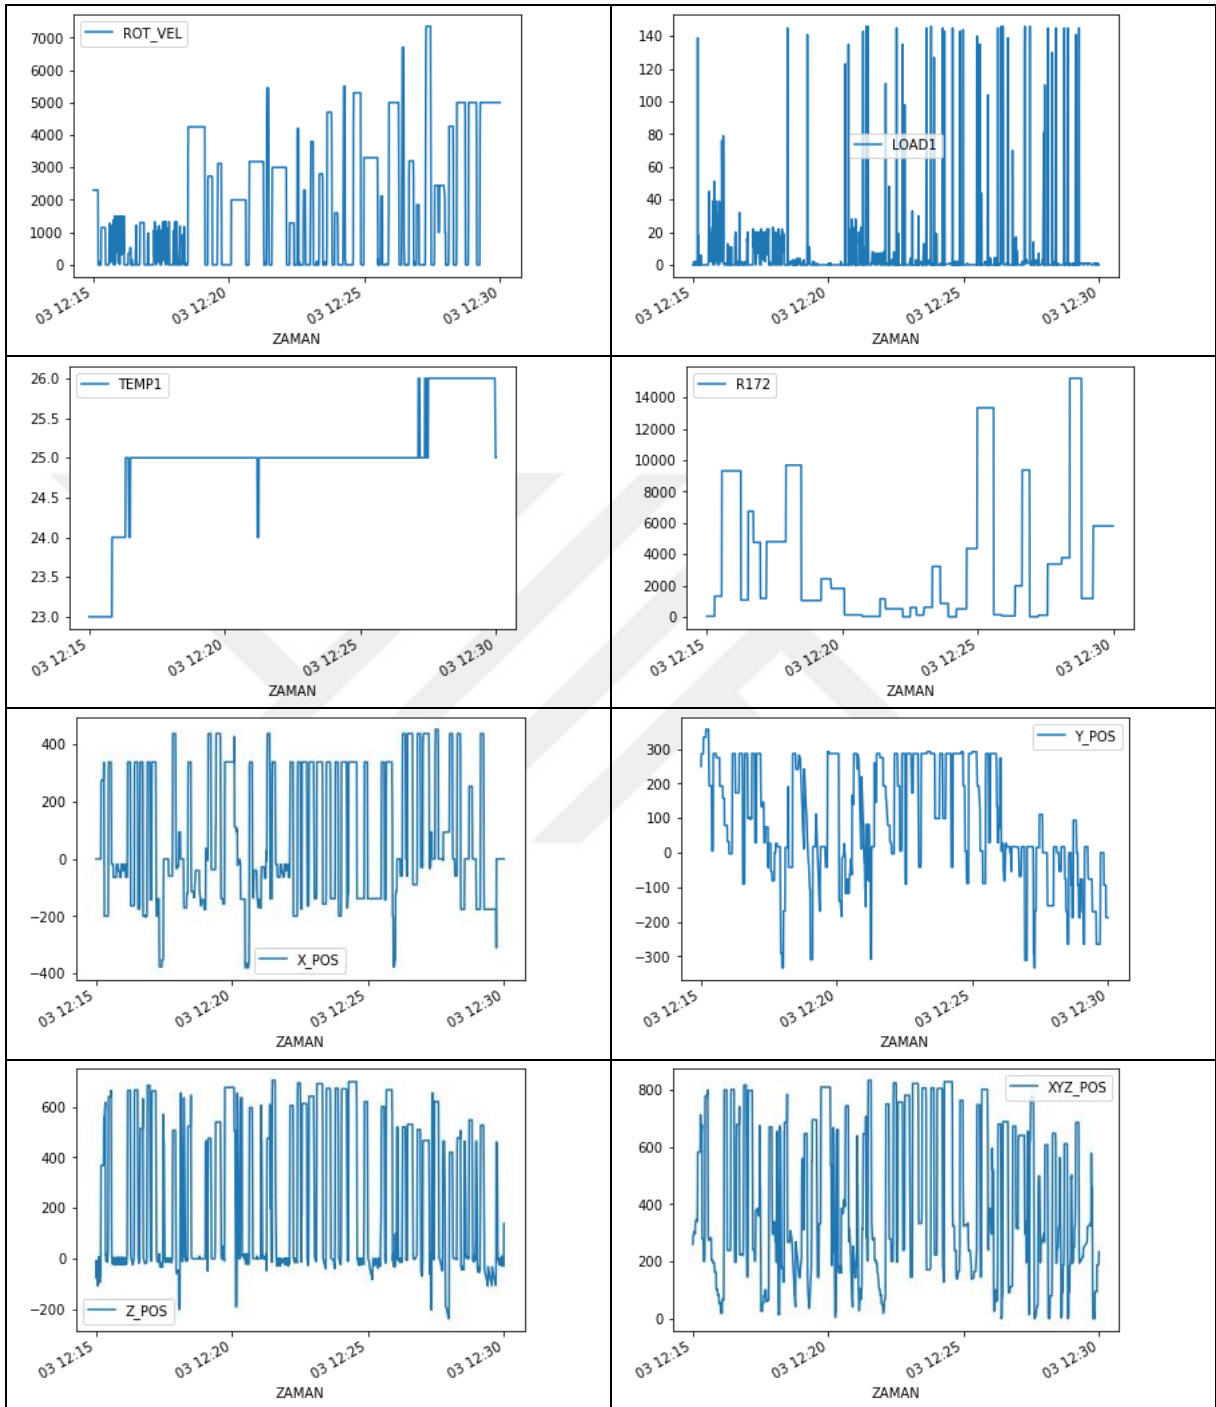
Bu bölümde ROT_VEL, LOAD1, TEMP1, R172, X_POS, Y_POS, Z_POS ve XYZ_POS için zaman ve verileri içeren bir grafik üzerinden veriler incelenecektir. Burada tüm veriyi incelemek yerine parçasal inceleme veriyi daha iyi anlamak için tercih edilmiştir. Bunun için 03.03.2021 tarihindeki saat 11:00 ve 14:00 arasındaki veri gösterimini Şekil 5.1.'de verilmiştir.



Şekil 5.1 ROT_VEL, LOAD1, TEMP1, R172, X_POS, Y_POS, Z_POS ve XYZ_POS için 3 saatlik grafikler

Şekil 5.1. incelendiğinde grafiklerde benzer desenler oluştuğu görülmektedir. Saat 12 gibi sistemin 15 dakika durduğu görülmektedir. ROT_VEL ve LOAD1 verileri düzenli iken TEMP1 yani sıcaklık verisi saat 12:30'dan sonra arttığı görülmektedir. Hatta saat 14'e doğru 28 dereceye kadar çıktığı görülmektedir. Üç veriden oluşturulmuş XYZ_POS'unda verileri yorumlayabilmek için kullanılabileceği görülmektedir. İki farklı PALLET_ID burada daha açık

gözükmektedir. Şekil 5.1.'de üç saatlik verileri daha iyi yorumlamak için süre kısaltılabilir. Şekil 5.2., 15 dakikalık grafikleri gösterir.

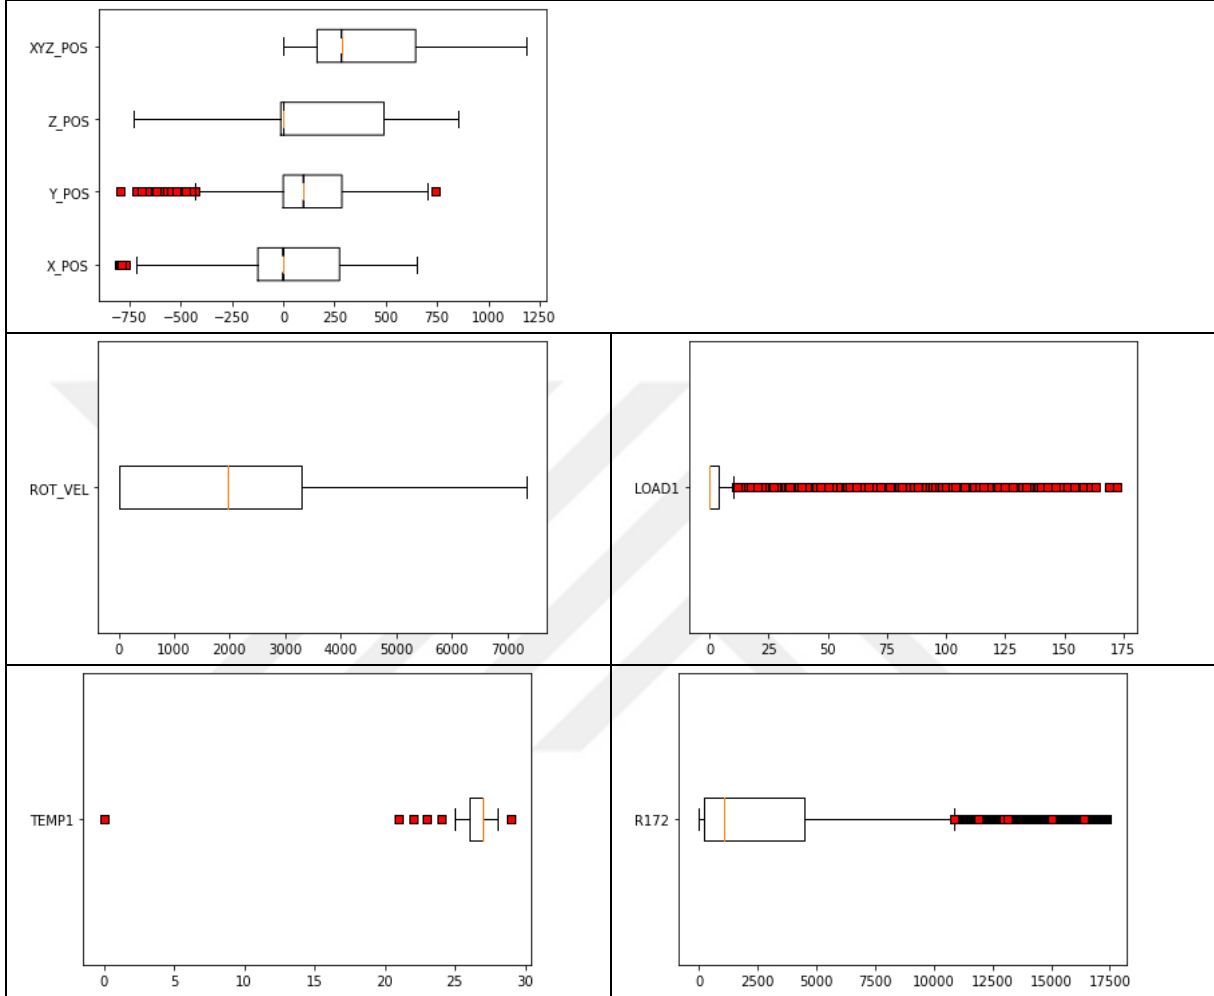


Şekil 5.2 ROT_VEL, LOAD1, TEMP1, R172, X_POS, Y_POS, Z_POS ve XYZ_POS için 15 dakikalık grafikler

15 dakikalık grafiklerde LOAD1 değerinin çok değişken olduğu ve sıfıra yaklaştığı görülmektedir. X_POS, Y_POS ve Z_POS değerlerinde de farklılıklar vardır. Tüm verileri analiz etmek için kutu grafikleri kullanılabilir.

5.5. Kutu grafikleri

Kutu grafikleri (boxplot) oluşan veriyi miktarlarını yorumlamak için kullanılabilir. Şekil 5.3. elimizdeki tüm verilerden oluşmuştur.



Şekil 5.3 Tüm verilerden elde edilen kutu grafikleri

Kutu grafikleri oluşturulurken dörtte birlik (Quantiles) değeri yüzde 50'lik kısım (Q2) ortalama değeri verir. Şekil 5.3.'te kutu grafikleridir. Yüzde 25'lik kısmın ortalaması (Q1) için en düşük verilerin ortalaması alınır. Başka bir deyişle en küçük değerden başlayıp verileri %25'i alınıp bir kutunun alt sınırı belirlenir. En düşük değerden başlayıp verilerin %75 için bir kutunun üst sınır belirlenir. Bunlarından arasındaki değer kutu olarak çizilmiştir. Kutuların yanlarındaki çizgiler için aşağıdaki denklemler kullanılır.

$$\text{Fark} = Q3 - Q1 \quad (5.2)$$

$$\text{Alt sınır} = Q1 - 1,5 \times \text{Fark} \quad (5.3)$$

$$\text{Üst sınır} = Q3 + 1,5 \times \text{Fark} \quad (5.4)$$


Bunların sınırların dışındaki değerler aykırı değer (outliner) olarak kabul edilmiştir. Şekil 5.3.'te Y_POS ve X_POS değerlerinin aykırı olup olmadığının ayrıca bir uzman ile incelenmesi gerekir. LOAD1'de çok fazla aykırı durum vardır. Yapılan görüşmede 160 üzeri durumların aykırı olarak kabul edildiği söylenmiştir. Yukarıdaki denklemler ile bu duruma ulaşamadığı görülmektedir. TEMP1 değerinin sıfır derece olduğu durumlar tespit edilmiştir. Bunun sebebi makineden sıcaklık verisinin gelmemesi veya hatalı gelmesi olabilir. Bu durumda sıcaklık sensörünün incelenmesi gerekir. Veriler inceledikten sonra aykırı tespiti için gözetimli ve gözetimsiz metotlar kullanılabilir.

5.6. Algılayıcılar

Aykırı durumu belirlemek için çok farklı yöntemler kullanılabilir. Bu bölüm, aykırı durumu tespit etmek için kullanılabilecek yöntemler ve bu yöntemlerin incelenmesine ayrılmıştır.


5.6.1. Eşik değeri (Threshold)

Bu yöntem tamamen uzman tecrübesine bağlıdır. Uzmanın belirlediği en yüksek ve en düşük değerlerin dışındaki değerler aykırı değer olarak alınır. Veri setimizde, bu durum için TEMP1 ve LOAD1 özellikleri kullanılabilir. Verinin alındığı HEMA firmasında yapılan görüşmede LOAD1 için 160 üzeri durumlardan sistemin uyarı vermesi önerilmiştir. Diğer taraftan TEMP1 değerinin 20 ile 30 derece arasında olabileceği aktarılmıştır. Tüm veri yerine sonuçların daha iyi görülmesi için günlük veri kullanılmıştır. Şekil 5.4, 15.03.2021 tarihinde LOAD1 verisini ve 160'ı geçen durumları gösterir.



Şekil 5.4 LOAD1 ve 160 eşik değeri için anomali durumları

Şekil 5.4.'te 3 anomali durumu karşımıza çıkar. TEMP1 için 30 dereceyi aşan durum veri setinde yoktur. Aynı tarihler için Şekil 5.5.'te görüldüğü bir anomali durumu yoktur.




Şekil 5.5 TEMP1 ve 30 eşik değeri için grafik

Bu yöntemin en kötü tarafı aykırı durum tespiti için uzmana ihtiyaç duyması verinin uzun süre analiz edilmesini gerektirmesidir. Ancak, sistem kaynaklarını en az kullanan ve en sade yöntem olduğu da unutulmamalıdır. Python tarafında “ThresholdAD” ve high / low parametreleri kullanılmıştır.


5.6.2. Dörtte Birlik (Quartile)

Burada veri yüzdesel olarak ayrılır. İstatistik ve olasılıkta, dörtte birlik bir olasılık dağılımının aralığını eşit olasılıklarla sürekli aralıklara bölen veya bir örnekteki gözlemleri aynı şekilde bölen kesme noktalarıdır. Python tarafında QuantileAD ve high/low parametrelerinde değişiklikler yapıp üretilen grafikler incelenecektir.




Şekil 5.6 Dörtte birlik değerleri gösterilen normal dağılım olasılık yoğunluğu (Kaynak: <https://en.wikipedia.org/wiki/Quantile>)

Şekil 5.6.'da, $(-\infty, Q1)$, $(Q1, Q2)$, $(Q2, Q3)$ ve $(Q3, +\infty)$ olmak üzere dört aralık vardır. Buradaki yüzde değeri kullanıcı tarafından belirlenebilir. Örneğin %99'dan yüksek ve %1'den düşük olan değerler aykırı değer olarak kabul edilebilir. Örneğin X_POS için 15/03/2021 tarihindeki aykırı durum grafiği Şekil 5.7.'deki gibidir.



Şekil 5.7 X_POS için dörtte birlik yönteminin %99 ve %1 aralık dışındaki durumlarda aykırı değerleri

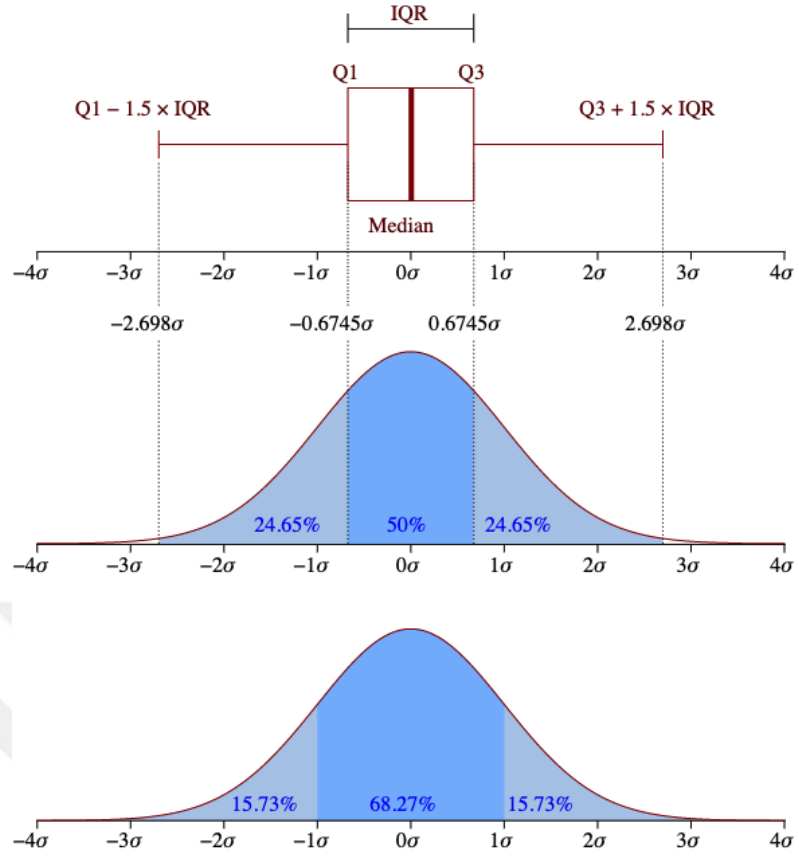
Şekil 5.7.'de görüldüğü gibi %99 ve %1 gibi küçük değerler dahi çok fazla aykırı durum üretmiştir. Bu yöntem kullanılırken çok dikkatli seçim yapılması ve verinin çok iyi irdelenmesi gerekir. Örneğin değerleri %99,9 ve 0,1% yapılırsa bu durumda aşağıdaki grafik oluşur.



Şekil 5.8 X_POS için dörtte birlik yönteminin %99,9 ve %0,1 aralık dışındaki durumlarda aykırı değerler


5.6.3. Interquartile (Çeyrekler Açıklığı)

Bir önceki yöntem yerine literatürde önerilen yöntem interquartile'dir. Burada Q1 ve Q3 arasındaki değer %50 veya %68,27 alınabilir. Ardından Şekil 5.9.'daki denklemler ile aralık genişletilir. Bu aralık dışında kalan değerler aykırı durum olarak değerlendirilir.



Şekil 5.9 Kutu grafiğinde de kullanılan interquartile aralık yöntemi (Kaynak: https://en.wikipedia.org/wiki/Interquartile_range)

Bu yöntem, eğitim verilerinin yalnızca küçük bir kısmının veya hatta hiçbirinin anormal olmadığı durumlarda genellikle bir önceki yöntem tercih edilir. Bu yöntem sayesinde X_POS için aşağıdaki grafik elde edilmiştir.




Şekil 5.10 Interquartile yöntemi

Bu yöntemde alt değerlerin aykırı veri olarak tespit edildiği görülmüştür. Python tarafında InterQuartileRangeAD modülü ve c parametresi olarak 1,5 değeri kullanılmıştır.

5.6.4. GESD (Generalized Extreme Studentized Deviate)

GESD, yaklaşık olarak normal bir dağılımı kullanan tek değişkenli bir veri setinde bir veya daha fazla aykırı değeri tespit etmek için kullanılan basit bir istatistiksel yaklaşımdır. İstatistiksel yaklaşımlar, düzenli verilerin bazı istatistiksel modelleri takip ettiğini ve modeli takip etmeyen verilerin aykırı değerler olduğunu varsayar. GESD, Grubbs testinin ve Tietjen-Moore testinin, şüpheli aykırı değerlerin tam olarak belirtilmesi gerektiğine dayanır. GESD testi, yalnızca şüpheli sayıda aykırı değer için bir üst sınırın belirtilmesini gerektirir. Bu üst sınır 0,3 olarak belirlendiğinde X_POS için üretilen şekil aşağıdaki gibidir.




Şekil 5.11 GESD testinden elde edilen grafik (üst sınır = 0,3)

Şekil 5.11’de göre bu yöntem ile üst sınır 0,3 için aykırı durum görülmemiştir. Python tarafında GeneralizedESDTestAD ve alpha değeri 0,3 olarak ayarlanmıştır.

5.6.5. Kalıcı Seri ile aykırı durum aralığı bulma

Bundan önceki yöntemler tek değere odaklanır. Ancak, bu yöntemler uzun süreleri ve ardışık bir sorun olabilir. Kalıcı seri (persistent series), değişkenin belirli bir tarihteki değerinin önceki değerle yakından ilişkili olduğu seridir. Bu yöntem seri aradığı için hesaplama zamanı diğer yöntemlere göre daha uzundur. Python tarafında PersistAD modülü ve parametre olarak c değeri 3,0 ve side değeri negative olarak ayarlanmıştır.




Şekil 5.12 Kalıcı Seri Yöntemi

Kalıcı seri analizi her veri için uygun değildir. Kullandığımız veri seti içinde çok uygun olmadığı görülmüştür.

5.6.6. LevelShift ile kalıcı seri aralığı bulma

LevelShift yan yana iki kayan zaman penceresinde medyan değerler arasındaki farkı izleyerek değer seviyesinin kaymasını algılar. Ani yükselmelere karşı hassas değildir ve gürültülü aykırı değerler sık sık meydana geliyorsa iyi bir seçim olabilir. Bu yöntem için Python tarafında LevelShiftAD kullanılmıştır. Bu modülde $c=6,0$, $side='both'$, $window=50$ parametreleri seçilmiştir.




Şekil 5.13 LevelShift yöntemi ile inceleme

Bu yöntemin verimiz için uygun olmadığı sonucuna varılmıştır. Çeşitli parametre değişikliklerine rağmen iyileşme sağlanamamıştır.

5.6.7. Oynaklık seviyesi (Volatility Level) ile kalıcı seri bulma

Python'da VolatilityShiftAD modülü kullanılmıştır. Bu modül, yan yana iki kayan zaman penceresinde standart sapmalar arasındaki farkı izleyerek oynaklık seviyesinin kaymasını tespit eder. Parametre olarak $c=6$ ve $window=30$ tercih edilmiştir.




Şekil 5.14 Oynaklık seviyesi grafiği

Hem Őekil 5.13. hem de Őekil 5.14. kaydırma yöntemlerinin verimiz için uygun olmadığı görülmektedir.

5.6.8. Sezonsal (Seasonal) yöntem

Python tarafında SeasonalAD modülü kullanılmıştır. Bu modül, sezonsal düzenin anormal ihlallerini tespit ediyor. Bu modül için $c=3,0$ ve $side="both"$ değerleri kullanılmıştır. X_POS için elde edilen grafik aşağıdaki gibidir.




Őekil 5.15 Sezonsal yöntem ile anomali tespiti

Bu yöntemin daha az sayıda aykırı değer döndürmüŐtür. Bu metot daha büyük verilerde denenebilir.

5.6.9. Autoregression bazlı yöntem

Bu yöntem, zaman serilerinde otoregresif davranıştaki anormal değışiklikleri tespit eder. Python'da AutoregressionAD modülü kullanılmıştır. Bu modülde $n_steps=7$, $step_size=12$, $c=3,0$ parametreleri kullanılmıştır. 1 günlük veride elde edilen sonuçlar Őekil 5.16.'daki gibidir.

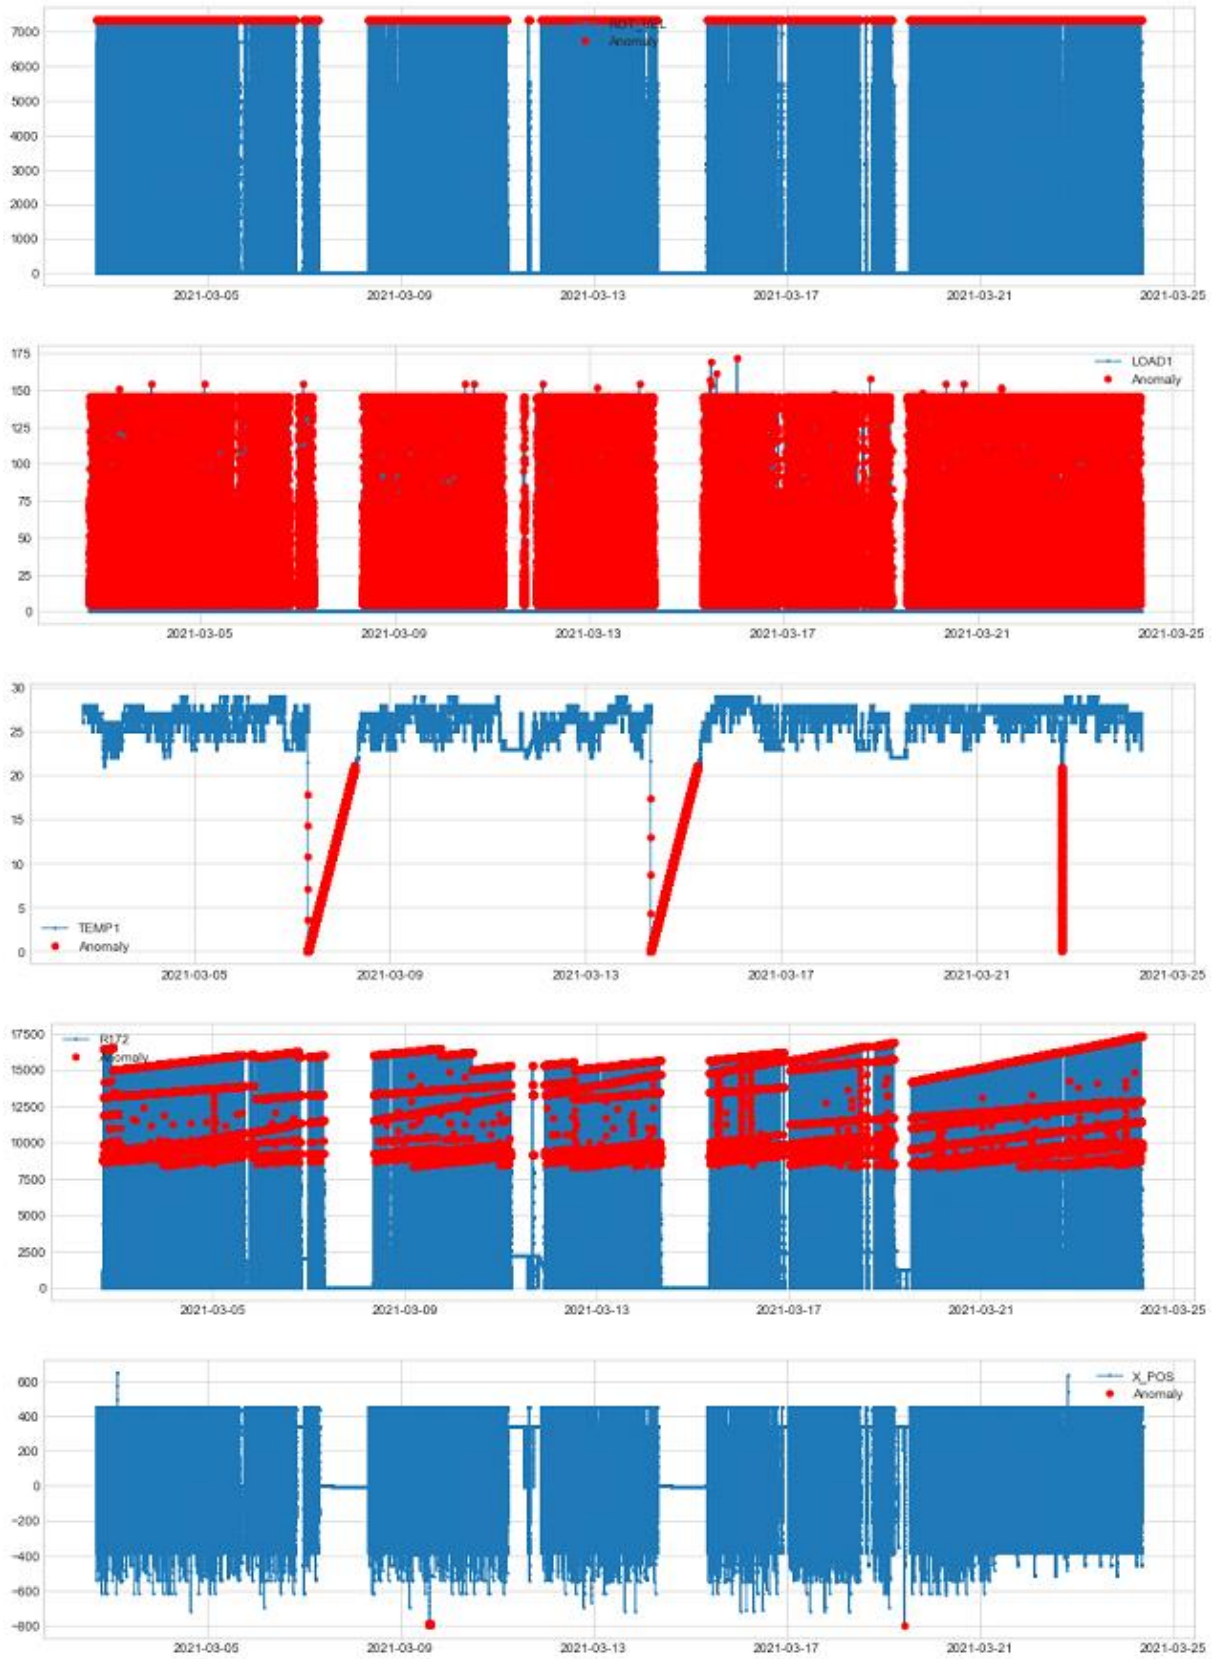


Őekil 5.16 Autoregression yönteminin 1 günlük veri için çıktısı

Sezonsal ynteme gre daha fazla aykırı deęer bulmaktadır. Parametreler ile denemeler yapıp aykırı deęer sayısı azaltılabilir veya arttırılabilir. Bu yntemin en byk avantajı sezonsal ynteme gre ok daha hızlı olmasıdır.

5.6.10. Tm zelliklerin analizi

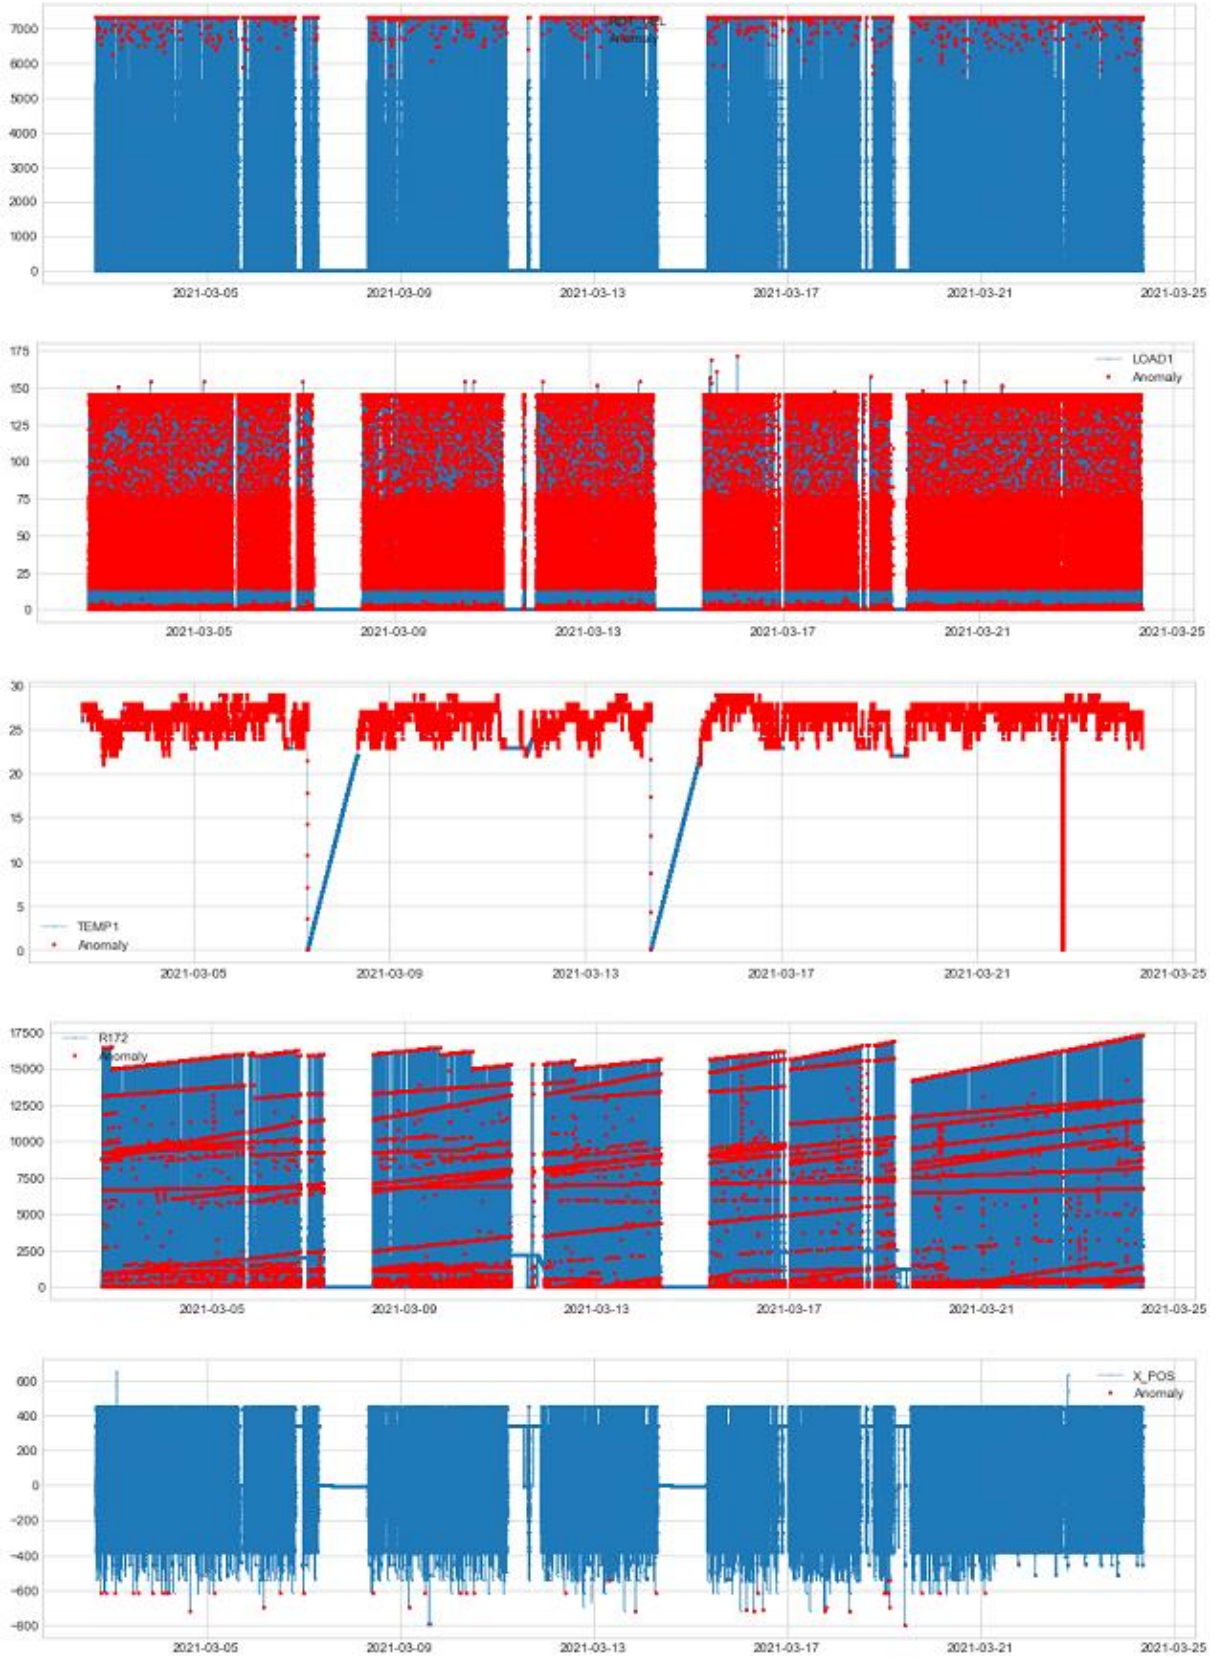
nceki blmlerde farklı yntemlerin denemeleri yapıldı. Eşik deęeri belirleme yntemi iin saha tecrbesi gerekir. Zamanla zellikleri daha iyi tanıdıęımızda eşik deęerini maksimum ve minimum deęerlerini belirleyip bu yntemi tercih edebiliriz. Bu yntemin en byk avantajları sistem kaynaklarını az kullanması ve ok kolay uygulanabilir olmasıdır. LOAD1 ve TEMP1 saha dnşleri alındıęı iin bu yntem kullanılabilir. Interquartile yntemi drtte birlik yntemler arasında tercih edilebilecek bir yntemdir. Eşik deęeri yntemi dıřındaki tm yntemler bir eęitim verisine ihtiya duyar. Bu veriden elde ettięi istatistiksel bilgilere gre aykırı deęerler bulunmaya alıřılır. Elimizdeki tm deęerleri interquartile yntemi ile test ettięimizde ařaęıdaki sonular elde edilmiřtir.



Şekil 5.17 Tüm özellikler ve tüm veri için interquartile yöntemi sonuçları

Şekil 5.17.'ye göre makinenin dönme hızını veren ROT_VEL 7300 civarına çıktığında aykırı bir durum olduğu görülmüştür. Yapılan görüşmede, gün içinde bazı durumlarda bu hıza çıktığı ve uyarı durumu oluşturulabileceği ön görülmüştür. Dönen eksenin maruz kaldığı yük miktarını tutan LOAD1 için interquartile yöntemi hiç uygun değildir. Yük çok değişken olduğu için birçok değer aykırı olarak işaretlenmiştir. Yapılan görüşmede 140'ın üzerine çıktığında uyarı 170 üzerine daha önemli uyarı verilebileceği söylenmiştir. Bunun için eşik değeri yöntemi yeterlidir. Sıcaklığı tutan TEMP1 değerine veri gelmediğinde 0 değeri alınmıştır. Bu durumlar aykırı durum olarak seçilmiştir. Bunun yerine en alt değer 20 derece alınabilir. 30 derecenin üzerine çıkılmadığı görülmüştür. Bu durum içinde eşik değeri yöntemi yeterlidir. R172 takımın ömrünü saniye cinsinden verir. Ancak, operatörün takım uçlarına bakarak takımın durumuna göre bazen bu değeri arttırdığı ifade edilmiştir. Örneğin 5000 saniye verilen bir takım 2000'e geldiğinde operatör bakar ve tekrar değeri 5000'e getirebilir. Bu özellik üzerine araştırma yapmak çok sağlıklı değildir. X_POS, Y_POS ve Z_POS değerleri arasında Y_POS özelliğinde aykırı durumlar fazla bulunmuştur. Sonradan üretilen XYZ_POS özelliğinde aykırı durum gözükmemektedir. Y_POS değeri -600 civarında sistem uyarı verebilir.

Seviye kaydırma ve desen değiştirmeye dayalı yöntemler verisetimiz için uygun olmadığını karar verilmiştir. Bu yöntemler yerine sezonsal ve autoregression yöntemleri tercih edilebilir. Sezonsal yöntem uygun olsa da veri üzerinden aykırı değerleri bulurken sistem kaynaklarını çok kullanmaktadır. Autoregression yöntemi benzer sonuçlar verirken daha kısa sürede çalıştığı ve sistem kaynaklarını daha az kullandığı için tercih edilebilir. Şekil 5.18., tüm özellikler ve tüm veriler için autoregression yönteminden elde edilen grafikleri verir.



Şekil 5.18 Tüm özellikler için autoregression yöntemi

Şekil 5.18., autoregression yöntemi interquartile yöntemine göre çok daha fazla aykırı değer üretir. LOAD1, TEMP1 ve R172 özelliklerine her iki yöntemde uygun değildir. Bunun için eşik değeri yöntemi en uygun değerlendirme yöntemidir. X_POS, Y_POS, Z_POS özellikliğinden elde edilen verilen sistemde uyarı için kullanılabilir. Ancak, her üç özelliğin bileşkesi olan XYZ_POS özelliği autoregression yönteminde çok daha az aykırı değer ürettiği görülmektedir. Bu yöntemde uyarı üretmek için kullanılabilir.



6. SONUÇLAR

Ele alınan bu çalışmada, kestirimci bakımın ana fikri, şirketlerde uygulandığında nasıl avantaj sağladığı ve genel olarak firmaların karşılaştığı torna sistemlerinde, takım uçlarında oluşan sıkıntılar ele alınmıştır. Belirlenen bir torna sisteminin durdurulmadan, bulunduğu şirkete herhangi bir zaman ve ekonomik zarar vermeden bakıma girmesini sağlamak için kestirimci bakımdan faydalanılmıştır. 02./03/2021 – 24/03/2021 tarihleri arasında bir torna sisteminden (ZAK HCN 6000 Yatay işleme merkezi) toplanan 1.902.604 satırdan oluşan veri topluluğu alınarak aykırı durumu tespit etmek için kullanılacak yöntemler denenmiştir. Bu veri setlerine yöntemler uygulandıktan sonra seviye kaydırma ve desen değiştirmeye dayalı yöntemlerin veri setimiz için uygun olmadığı tespit edilmiştir. Bu yöntemler yerine sezonsal ve autoregression yöntemler tercih edilebilir. Mevsimsel yaklaşım uygun olsa da verilerdeki aykırı değerlerin bulunması söz konusu olduğunda çok sayıda sistem kaynağı kullanılabilir. Autoregression yöntem, benzer sonuçlar vermesi, daha kısa sürede çalışması ve daha az sistem kaynağı kullanması nedeniyle tercih edilmesi daha uygun görülmüştür. Özet olarak yapılan bu çalışmada kullanım sırasında makinenin olası arızalarını önlemek veya olası hatalardan önceden haberdar olmak için çalışılacak makinenin verileri toplanır ve toplanan verilere anomali tespiti uygulanarak gerçekleştirilecek arızalar ortaya çıkarılmaya çalışılmıştır. Bu sayede gelecekte olabilecek olası arızaların önüne geçilmeye uğraşmıştır.

KAYNAKLAR

- [1] K. Jamieson, *The Analysis of Adaptive Data Collection Methods for Machine Learning*, Madison: Ann Arbor, MI : ProQuest LLC, 2015.
- [2] C. Aydın, *Üretim Yapan Bir İşletme için Veri Odaklı Kestirimci Bakım Modellerinin Karşılaştırılması*, Ankara: Hacettepe Üniversitesi, 2021.
- [3] UKEssays, «Data Collection Method In Mechanical Engineering,» 2018.
- [4] A. Bir, «İmalatta karşılaşılan problemler,» *Uludağ University Journal of The Faculty of Engineering*, cilt 1, no. 1, pp. 205-210, 1984.
- [5] N. B. Üllen, «Tornalama işlemlerinde çeşitli kesici takım uçlarının hasar mekanizmaları,» *2nd International Eurasian Conference on Science, Engineering and Technology (EurasianSciEnTech 2020)*, Gaziantep, 2020.
- [6] H. M. Ertunç ve İ. Sevim, «Kesici Takımların Aşınmasını Gözlemleme Üzerine Yapılan Çalışmalar,» *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 7, no. 1, pp. 55-62, 2001.
- [7] R. Ramesh, M. Mannan ve A. Poo, «Error compensation in machine tools — a review: Part I: geometric, cutting-force induced and fixture-dependent errors,» *International Journal of Machine Tools & Manufacture*, cilt 40, no. 9, pp. 1235-1256, 2000.
- [8] E. S. Topal ve C. Coğun, «BSD Tornalamada İşleme Hataları ve Düzeltme Stratejileri Üzerine Bir Derleme Çalışması,» *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, cilt 22, no. 1, pp. 142-151, 2006.
- [9] Ç. Teke, *İmalat Sektöründe Uygun Bakım Ve Stratejisinin Belirlenmesi İçin Bir Yöntem Tasarımı Ve Uygulaması*, Sakarya : Sakarya Üniversitesi, 2018.
- [10] A. Kayar Ve F. Öztürk, «Machine Data Collection and Analysis in Industry 4.0 Applications,» %1 içinde *2nd International Conference on Life and Engineering Sciences*, İstanbul, 2019.
- [11] N. S. Pamuk Ve M. Soysal, «Yeni Sanayi Devrimi Endüstri 4.0 Üzerine Bir İnceleme,» *Verimlilik Dergisi*, no. 1, pp. 41-66, 2018.
- [12] Y. Işık, «Talaşlı İmalatta On-Line Takım Durumu İzleme Yöntemleri,» *Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, cilt 9, no. 1, pp. 81-91, 2004.
- [13] B. Köksal, *İşletmelerde toplam üretken bakım uygulamalarıyla verimliliğin artırılması ve sektörel bir uygulama*, İstanbul: Yıldız Teknik Üniversitesi, 2009.
- [14] M. Ü. Gürsoy, U. C. Çolak, M. H. Gökçe, C. Akkulak ve S. Ötleş, «Endüstri İçin Kestirimci Bakım,» *International Journal Of 3d Printing Technologies And Digital Industry*, cilt 3, no. 1, pp. 56-66, 2019.

- [15] S. S. Erol, *Dinamik sistemlerin kestirimci bakımına etki eden faktörlerin durum bazlı incelenmesi*, Denizli: Pamukkale Üniversitesi, 2015.
- [16] N. Ouerhani, B. Loehr, A. Rizzotti-Kaddouri, D. S. D. Pinho, A. Limat ve P. Schinderholz, «Data-Driven Thermal Deviation Prediction in Turning Machine-Tool - A Comparative Analysis of Machine Learning Algorithms,» *Procedia Computer Science*, cilt 200, pp. 185-193, 2022.
- [17] J. Dalzochio, R. Kunst, E. Pignaton, A. Binotto, S. Sanyal, J. Favilla ve J. Barbosa, «Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges,» *Computers in Industry*, cilt 123, pp. 1-15, 2020.
- [18] Q. Yi, C. Li, Q. Ji, D. Zhua, Y. Jin ve L. Li, «Design optimization of lathe spindle system for optimum energy efficiency,» *Journal of Cleaner Production*, cilt 250, no. 3, pp. 1-16, 2020.
- [19] C. Janiesch, P. Zschech ve K. Heinrich, «Machine learning and deep learning,» *Electron Markets*, pp. 685-695, 2021.
- [20] R. Chalapathy ve S. Chawla, «Deep Learning for Anomaly Detection: A Survey,» 2019.
- [21] C. Lee, «Predicting land prices and measuring uncertainty by combining supervised and unsupervised learning,» *International Journal of Strategic Property Management*, cilt 25, no. 2, pp. 1-10, 2021.
- [22] O. Abdelrahman ve P. Keikhosrokiani, «Assembly Line Anomaly Detection and Root Cause Analysis Using Machine Learning,» *IEEE Access*, cilt 8, 2020.