



**KESTİRİMCİ BAKIM ZAMANLARININ MAKİNA
ÖĞRENMESİ YÖNTEMLERİYLE
TAHMİNLENMESİ: DEMİR ÇELİK SEKTÖRÜNDE
BİR UYGULAMA**

Tuğba KÖPRÜ

**2022
YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ**

**Tez Danışmanı
Doç. Dr. Fuat ŞİMŞİR**

**KESTİRİMCİ BAKIM ZAMANLARININ MAKİNA ÖĞRENMESİ
YÖNTEMLERİYLE TAHMİNLENMESİ: DEMİR ÇELİK SEKTÖRÜNDE
BİR UYGULAMA**

Tuğba KÖPRÜ

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Endüstri Mühendisliği Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Doç. Dr. Fuat ŞİMŞİR**

**KARABÜK
Haziran 2022**

Tuğba KÖPRÜ tarafından hazırlanan “KESTİRİMCİ BAKIM ZAMANLARININ MAKİNA ÖĞRENMESİ YÖNTEMLERİYLE TAHMİNLENMESİ: DEMİR ÇELİK SEKTÖRÜNDE BİR UYGULAMA” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Fuat ŞİMŞİR

.....

Tez Danışmanı, Endüstri Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 30/06/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Dr. Öğr. Üyesi Halil İbrahim DEMİR (SAÜ)

.....

Üye : Doç. Dr. Fuat ŞİMŞİR (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Selçuk ÖZCAN (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Tuğba KÖPRÜ

ÖZET

Yüksek Lisans Tezi

KESTİRİMCİ BAKIM ZAMANLARININ MAKİNA ÖĞRENMESİ YÖNTEMLERİYLE TAHMİNLENMESİ: DEMİR ÇELİK SEKTÖRÜNDE BİR UYGULAMA

Tuğba KÖPRÜ

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı:

Doç. Dr. Fuat ŞİMŞİR

Haziran 2022, 80 sayfa

Bu çalışmada bir demir çelik tesisinin sıcak hadde tezgahlarından alınmış olan titreşim, akım ve motor devir hızı verileri kullanılarak arıza tahminlemesi yapılmıştır. Her makine, arıza öncesi belirli sinyaller vermektedir. Bu sinyaller gözlemlenerek arıza meydana gelmeden arızanın tahminlenmesi ve önlenmesi, arıza kaynaklı meydana gelebilecek olan zaman, üretim, malzeme, para gibi kayıpların önüne geçecektir. Belirlenmiş olan problemin çözümünde yapay zekanın alt dallarından biri olan makine öğrenmesi algoritmaları kullanılmıştır. Makine öğrenmesi algoritmalarının denetimli öğrenme yöntemlerinden olan destek vektör makinaları ve karar ağaçları algoritmaları kullanılarak tahminleme sağlanmıştır.

Yapılan tahmin alıřmaları sonucunda hangi yntemin daha doęru sonular verdięi tespit edilmiřtir. alıřma kapsamından modellerin girdi parametresi olarak drt ayrı titreřim verisi, akım verisi ve RPM verisi kullanılmıřtır. Modelin iki adet ıktısı bulunmaktadır. Bunlar arıza var, arıza yok deęerleridir. Model, arıza eřięine ulařıldıęı noktalarda iřletmeyi bakım yapılması konusunda uyarmaktadır. R Studio programında, R yazılım dili kullanılarak geliřtirilen modelde iki ayrı makine ęrenmesi algoritması ile sonu alınmıřtır. alıřmanın sonucunda karar aęaları algoritmasının destek vektr makinaları algoritmasına oranla doęruluęu daha yksek sonular verdięi tespit edilmiřtir.

Anahtar Szckler : Makina ęrenmesi, Kestirimci Bakım

Bilim Kodu : 90619

ABSTRACT

M. Sc. Thesis

FORECASTING PREDICTIVE MAINTENANCE TIMES WITH MACHINE LEARNING METHODS: AN APPLICATION IN THE IRON AND STEEL INDUSTRY

Tuğba KÖPRÜ

**Karabük University
Institute of Graduate Programs
Department of Industrial Engineering**

Thesis Advisor:

Assoc. Prof. Dr. Fuat ŞİMŞİR

June 2022, 80 pages

In this study, failure estimation was made by using vibration, current and engine speed data obtained from the hot rolling stands of an iron and steel plant. Each machine gives certain signals before failure. By observing these signals, estimating and preventing the malfunction before it occurs, will prevent the losses such as time, production, material, money that may occur due to the malfunction. Machine learning algorithms, one of the sub-branches of artificial intelligence, were used to solve the identified problem. Prediction is provided by using support vector machines and decision tree algorithms, which are among the supervised learning methods of machine learning algorithms.

As a result of the estimation studies, it was determined which method gave more accurate results. Four different vibration data, current data and RPM data were used as input parameters of the models within the scope of the study. The model has two outputs. These are fault, no fault values. The model warns the business to perform maintenance at the points where the failure threshold is reached. In the R Studio program, the results were obtained with two different machine learning algorithms in the model developed using the R software language. As a result of the study, it has been determined that the decision trees algorithm gives higher accuracy than the support vector machine algorithm.

Key Word : Maintenance Management, Predictive Maintenance, Breakdown Estimation, Machine Learning

Science Code : 90619

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Do. Dr. Fuat ŐİMŐİR'e sonsuz teőekkürlerimi sunarım.

Tez alıőmamda ve hayatımın her anında yanımda olan ve bir an olsun desteęini esirgemeyen en yakın arkadaőım, dostum, deęerli eőim sayın Ertan Yavuz KÖPRÜ'ye teőekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xiii
KISALTMALAR	xiv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	7
BAKIM YAKLAŞIMLARI.....	7
2.1. DÜZELTİCİ BAKIM.....	9
2.2. ÖNLEYİCİ BAKIM.....	11
2.3. KESTİRİMCİ BAKIM.....	11
2.4. DEMİR ÇELİK SEKTÖRÜ VE BAKIM YAKLAŞIMLARI.....	12
2.4.2. Demir Çelik Üretimi	12
2.4.2.1. Sıcak Haddeleme İşlemi	13
2.4.2.2. Demir Çelik Üretiminde Bakımın Önemi	15
2.5. LİTERATÜR TARAMASI.....	17
BÖLÜM 3	27
MAKİNA ÖĞRENMESİ.....	27
3.1. MAKİNA ÖĞRENMESİ YÖNTEMLERİNİN AŞAMALARI	29
3.1.1. Veri Normalizasyonu.....	31

3.2 MAKİNA ÖĞRENMESİ ALGORİTMALARI.....	32
3.2.1. Denetimli Öğrenme	33
3.2.1.1. Sınıflandırma Teknikleri.....	33
3.2.1.2 Regresyon Teknikleri.....	36
3.2.2. Denetimsiz Öğrenme	36
3.2.2.1. Kümeleme	36
3.2.3. Pekiştirmeli Öğrenme	37
BÖLÜM 4	38
UYGULAMA	38
4.1. ISO TİTREŞİM DEĞERLERİ TABLOSU	40
4.2. ÇALIŞMANIN KAPSAMI VE VERİ SETİ.....	42
4.3. VERİLERİN KORELASYONU	46
4.4. UYGULAMA ARAÇLARI	48
4.4.1 Tahmin Analizi	49
4.5 DESTEK VEKTÖR MAKİNALARI TAHMİN UYGULAMASI.....	50
4.5.1. Grid Arama	52
4.5.2. Kernel Metodu.....	54
4.5.3. Destek Vektör Makinaları Test Datası ve Tahmin Sonuçları Karşılaştırması.....	54
4.5.4 Destek Vektör Makinası Uygulama Sonuçları	57
4.6 KARAR AĞAÇLARI TAHMİN UYGULAMASI	57
4.6.1. Grid Arama	59
4.6.2. Karar Ağaçları Test Datası ve Tahmin Sonuçları Karşılaştırması	62
4.6.3 Karar Ağaçları Uygulama Sonuçları	62
4.7 DENEYSEL SONUÇLAR.....	64
BÖLÜM 5	71
TARTIŞMALAR VE ÖNERİLER	71
KAYNAKLAR	74
ÖZGEÇMİŞ	80

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Bakım türleri	7
Şekil 2.2. Slab ve kütük	13
Şekil 2.3. Sıcak haddeleme üretim akışı	14
Şekil 2.4. Haddeleme prosesi rulman yerleşimi.....	14
Şekil 3.1. Yapay zeka ve makina öğrenmesi ilişkisi.....	27
Şekil 3.2. Literatürün makina öğrenmesi konusunda sınıflandırılması	29
Şekil 3.3. Makine öğrenmesi akış şeması	31
Şekil 3.4. Makina öğrenmesi algoritmaları gösterim tablosu	32
Şekil 3.5. Denetimli öğrenme tasviri	33
Şekil 3.6. Denetimsiz öğrenme tasviri	33
Şekil 4.1. Akış diyagramı.....	38
Şekil 4.2. Sıcak hadde tezgahı gösterimi	39
Şekil 4.3. Uygulamanın yapıldığı işletme üretim sahasından bir görüntü	40
Şekil 4.4. ISO 10816-1 Titreşim standardı	41
Şekil 4.5. Çalışmanın aşamaları	49
Şekil 4.6. Verilerin destek vektör makinaları ile sınıflandırılması	50
Şekil 4.7. Modelin özellikleri.....	52
Şekil 4.8. Tüm parametrelerin kombinasyonu	54
Şekil 4.9. Karar ağaçları yayılım sistematiği	58
Şekil 4.10. R studio girdi parametreleri	59
Şekil 4.11. Ağaç diyagramı.....	62
Şekil 4.12. Akım RPM değerleri grafiği	65
Şekil 4.13. Sensörlerin titreşim değerleri grafiği	65
Şekil 4.14. Grid arama sonucu	66
Şekil 4.15. Test verisi RPM- Akım grafiği	67
Şekil 4.16. Eğitim verisi RPM-Akım grafiği	68

	<u>Sayfa</u>
Şekil 4.17. Eğitim verisi F1 ve F2 titreşimleri grafiği	68
Şekil 4.18. Test verisi F1 ve F2 titreşimleri grafiği	69
Şekil 4.19. Karar ağaçları grid arama	69

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. Çalışmada kullanılan verilerin bir bölümü.....	44
Çizelge 4.2. Verilerin ortalama ve standart sapma değerleri.....	46
Çizelge 4.3. Korelasyon analizi tablosu	47
Çizelge 4.4. Hata Hesaplama denemeleri örnek tablosu	53
Çizelge 4.5. Test verilerinin bir kısmı	55
Çizelge 4.6. Destek Vektör Makinaları Tahmin Sonuçları	56
Çizelge 4.7. Destek Vektör Makinaları Model Sonuçları	57
Çizelge 4.8. Grid arama yapılan parametremelerin taraması	60
Çizelge 4.9. Karar ağaçları tahmin sonuçları	63
Çizelge 4.10. Karar ağaçları model sonuçları.....	64
Çizelge 4.11. Destek Vektör Makinaları algoritması test verisi ve tahmin değerlerinin karşılaştırılması	67
Çizelge 4.12. Karar ağaçları test verisi ve tahmin değerlerinin karşılaştırılması	70

KISALTMALAR

CM	: Corrective Maintenance (Düzeltilici Bakım)
PM	: Preventive Maintenance (Önleyici Bakım)
TPM	: Total Productive Maintenance (Toplam Verimli Bakım)
PdM	: Predictive Maintenance (Kesitirmci Bakım)
RUL	: Remaining Useful Life (Kalan Faydalı Ömür)
ML	: Machine Learning (Makina Öğrenmesi)
FM	: Finishing Mill (Bitirme Frezesi)
RIPG	: Restarted Iterated Pareto Greedy (Yeniden Başlatılan Yinelenen Açgözlü Pareto Algoritması)
FMEA	: Failure Mode Effect Analysis (Arıza Modu ve Etki Analizi)
PSO	: Particle Swarm Optimization (Parçacık Sürüsü Optimizasyonu)
RRE	: Reusable Rocket Engine (Yeniden Kullanılabilir Roket Motoru)
POMDP	: Partially observable Markov decision process (Kısmen gözlemlenebilir Markov karar süreci)
RAMI4.0	: Reference Architectural Model Industrie 4.0 (Referans Mimarisi Modeli Endüstri 4.0)
BPMN	: Business Process Model and Notation (Yenilikçi Bir İş Süreci Modeli ve Gösterimi)
DSR	: Design Science Research (Tasarım Bilimi Araştırması)
DIAs	: People's Digital Integration Assistants (İnsanların dijital entegrasyon Asistanları)

BÖLÜM 1

GİRİŞ

Gelişen teknoloji insan yaşamında birçok alanda yenileşme meydana getirmiştir. Gelişen yaşam alanlarıyla beraber çeşitlenen mal ve hizmetler hayatın vazgeçilmez bir parçası olmuş, ihtiyaç, ihtiyacı doğurmuş bunun sonucunda günden güne artan talep, bugünkü endüstriyi meydana getirmiştir. Endüstrileşmenin tarihi 1700'li yıllara dayanmaktadır. Birinci sanayi devrimi ile başlayan kaynak kullanımı günümüze kadar artarak devam etmiş, artmaya da devam edecektir. Endüstrileşmenin bu derece artması dünya üzerindeki kaynakların kısıtlanmasına neden olmuştur. Hammadde kaynaklarının azalması maliyetlerin artmasına neden olmuş ve kıt kaynakları optimal kullanımı bütün işletmeler için kritik bir nokta haline almıştır.

Makina ekipmanlarını etkili şekilde kullanmak, faydalı ömürlerinden efektif şekilde yararlanmak günümüzün önemli uğraşları arasında yerini almıştır. Malzemeyi, kalıp ekipmanını efektif şekilde uzun süre; tüm fonksiyonlarıyla aktif olarak kullanılmak, bakım planlarını doğru şekilde yapmakla mümkündür. Kullanım sürecinde olan makina ekipman parçaları ve aksamalarında meydana gelen deformasyonun doğru noktada tespit edilmesi ve müdahale edilmesi, daha büyük maliyetli arızalar meydana gelmeden tamiratının yapılmasını ve bunun sonucunda ekipmanların faydalı ömürlerinin uzamasını sağlar. Makina ekipmandan optimum süreyle verim alabilmek ancak bakımların doğru periyotlarla yapılması ve arızaların doğru noktada tespit edilmesiyle olanaklı kılınabilir.

Günümüzde bakım yaklaşımının önemi her geçen gün artmaktadır. İşletmeler bu konu üzerinde spesifik çalışmalar gerçekleştirmektedirler. Bakım sistemlerinin gelişmesi mühendislikten üretime, robotikten elektrige, donanımdan yazılıma kadar günümüzün kritik konuları arasında yerini çoktan almıştır (Vrkonyi-Koczy et al., 2012). Arıza

meydana geldiğinde bakım yapılması; işletmelere arıza kaynaklı makina ekipman zararı, üretim duruşuna sebep olduğu için bakım sürecinde yaşanılacak üretim kaybı, üretim hattında malzeme varken arıza meydana geldiğinde hattaki malzemenin kaybı gibi zararlar getirmektedir. Bu sebeple bakım mantığı günümüzde arıza meydana gelmeden önce tahminlenmesi ve üretim hattında duruşa sebebiyet verilmeden elimine edilmesi gereken bir durum halini almıştır.

Bakım yaklaşımları iki ana kategoride toplanmaktadır. Bunlar önleyici bakım ve düzeltici bakım olarak karşımıza çıkmaktadır (Jimenez et al., 2020). Düzeltici bakım klasik bakım yaklaşımıdır. Arıza meydana geldiğinde üretim hattına müdahale edilmesi, gerekli bakım ve tamiratın yapılması anlamına gelmektedir. Düzeltici bakım yaklaşımında öncelikle arıza meydana gelir, arızadan kaynaklı deforme olan makina ekipman maliyetine katlanması gerekir. Ayrıca arıza meydana geldiğinde üretim hattında duruşa sebebiyet verebilir. Bu duruş süresinde üretilmesi gereken ama üretilmeyen mamulün kaybına da katlanmak gerekir. Bütün bu kayıplar göz önüne alındığında, düzeltici bakım maliyet açısından işletmelere büyük yük getirmektedir.

Önleyici bakım yaklaşımında isminden de anlaşılacağı gibi arıza meydana gelmeden önce yapılan bakım faaliyetlerini kapsamaktadır. Önleyici bakım yedek parça yönetimini de kapsayan bir konudur. Tasarruf sağlamak için, yedek parça ve önleyici bakım stratejileri mümkün olduğunca beraber tasarlanmalıdır (Lolli et al., 2022). Arızanın meydana gelmesini önlemek için üretim hatlarına müdahale edilmesi, üretimin durdurulmaması, ya da duruş zamanlarında hatlarda yapılan geliştirmelerle hattın sürekli olarak aktif kalması sağlanmaya çalışılır. Buna göre arıza, bakım ekipmanlarının da hazırda bekletilmesi gerekmektedir.

Düzeltici bakım (CM) ve önleyici bakım (PM), güvenilirlik ve bakım sistematüğinde sıklıkla bahsedilen konulardır. Kısaca tanımlayacak olursak arıza durumundaki sistemi onarmak için yapılan bakıma düzeltici bakım, sistemin performansını iyileştirmek için planlı aralıklarla yapılan bakıma önleyici bakım denir (Hashemi et al., 2022). Önleyici bakım, kendi içinde planlı bakım ve tahmine dayalı bakım olmak üzere iki gruba ayrılır. Planlı bakım belirli periyotlarda üretim hatlarında yapılan bakımı ifade eder. İşletmeler genelde yıl başında bir bakım periyodu hazırlarlar. Bu periyotta makina

ekipmanlara bakım yapılır. Yalın üretim felsefesi olan toplam verimli bakım (TPM) da bu kapsamda değerlendirilebilir. TPM, işletme yönetiminde, sahada çalışan en son işçiye kadar personellerin tamamını kapsayan bir süreçtir. Amacı tüm yaşam döngüsü boyunca makina ekipmanların etkinliğinin üst düzeye çıkarılmasıdır (Tortorella et al., 2021).

Önleyici bakım yaklaşımları içerisinde değerlendirilen diğer bir konu ise kestirimci bakımdır. Kestirimci bakım işletmeler için kritik bir nokta haline gelmiştir. Büyük işletmelerin neredeyse tamamı efektif olarak çalışan kestirimci bakım planları uygulamakta ve ekipmanlarını aktif olarak kullanmaktadır. Kestirimci bakım iki temel noktada işletmelere yardımcı olmaktadır. Bunlardan birincisi arıza meydana gelmeden, sorun ortaya çıkmadan önce uyarı vermesi ve arıza oluşmadan tahminleyebilmesi ikincisi ise ekipmanların faydalı ömürlerinin uzaması için optimal bakım zamanını belirlemesidir (Hasegawa et al., 2020).

Kestirimci bakım (Predictive Maintenance -PdM) son zamanlarda üzerinde çok sayıda çalışma yapılan konulardan biri olmuştur. Hem kalan faydalı ömrün (Remaining Useful Life-RUL) tahminlenmesi hem de arıza meydana gelmeden önce uyarı veren sistemler sayesinde arızalar minimize edilmeye çalışılmaktadır. Geleceğe yönelik yapılan bu tahminleme işleminde makina öğrenmesi (ML) algoritmaları sıklıkla kullanılır olmuştur. Fakat bu kapsamda yapılan çoğu model endüstriyel işletmelere göre tasarlanmamış, sadece teoride kalmıştır (Zhai et al., 2021). Bu tarz modellerin kullanılmasına işletmelerin büyük ölçüde ihtiyacı vardır. Makina öğrenmesine dayalı kestirimci bakım modelleri işletmelerde makina ekipman, işçilik, üretim duruşu gibi maliyetlerden kurtarabilecek bir çıkış noktasıdır.

Makina öğrenmesi yöntemleri, eldeki veriler kullanılarak meydana gelebilecek durumları tahmin etmeyi hedefler. Bu kapsamda makina öğrenmesi kendi içinde denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üçe ayrılır. Denetimli öğrenme, denetimsiz öğrenmeye göre daha doğru sonuçlar verir ve kullanımı daha kolaydır. Literatür incelendiğinde denetimsiz öğrenme türlerinin sayısının, denetimli öğrenme türlerine oranla oldukça az olduğu karşımıza çıkmaktadır.

Denetimsiz öğrenmede elde bulunan tek şey veridir. Bu veriler işlendiğinde ortaya çıkacak sonuçla ilgili önceden tahminleme yapmak herhangi bir bilgiye sahip olmak çok zordur. Müdahale gerektirmeyen bir öğrenme sürecidir. Denetimsiz öğrenme türlerine kümeleme algoritması örnek verilebilir. Denetimli öğrenme ise sınıflandırma ve regresyon teknikleri olmak üzere iki ana başlığa ayrılır. Sınıflandırma teknikleri başlıca; destek vektör makinaları, karar ağaçları, naive bayes, en yakın komşu, diskriminant analizi olarak sınıflandırılmaktadır. Destek vektör makinaları veri sınıflandırma alanında başarısını kanıtlamış bir tekniktir. Diğer makina öğrenmesi algoritmalarından farklı olarak büyük boyutlu verileri tek seferde işleyebilmektedir.

Karar ağaçları sınıflandırma işleminde hızlı olması ile bilinen bir algoritmadır. Kolay görselleştirme, basit tanımlama gibi özellikleri dolayısıyla çokça tercih edilen bir tür olarak karşımıza çıkmaktadır. Veri işleme prosesinde algılanması ve kullanılması kolay bir tür olarak karşımıza çıkmaktadır. Yüksek doğruluk noktasında adını duyurmuş olan naive bayes yöntemi, binary formatında çıktılar üretmektedir. Diskriminant analizi ise farklı parametreleri aynı zamanlı olarak işleyebilme özelliğine sahiptir. Araştırmacılar tarafından sıklıkla tercih edilmektedir.

Bu kapsamda bu çalışmada arıza meydana gelmeden önce tahminleme yapabilen ve arıza meydana geleceğini bir uyarı yardımıyla işletme personeline bildiren bir model kurulmuştur. Model, demir çelik sektöründe, slab, kütük, bobin, nervürlü inşaat çeliği, doğalgaz borusu, kangal gibi üretim portföyü geniş olan bir işletmede uygulanmıştır. Çalışma, işletmenin sıcak haddeleme tesisinin “Bitirme Haddesi-Finishing Mill” (F1) pasosunda yerleştirilmiş olan titreşim ve motor devir sayısını ölçen sensörlerden alınan verileri ile yapılmıştır. Çalışmada makina öğrenmesi algoritmalarından; destek vektör makinaları ve karar ağaçları tercih edilmiş ve R programla dili kullanılmıştır.

Bu çalışma kapsamında, makinalardan gelen titreşim değerlerinin dalgalanmasına göre arıza, meydana gelmeden önce fark edilebilecek ve arızadan önce önlem alınabilecektir. 7/24 Sürekli üretim yapan bir tesis olması dolayısıyla, arıza kaynaklı duruşların önüne geçmek ve üretimin devamlılığını sağlamak açısından işletmeye büyük katkı sağlayacağı ön görülmektedir. Buna ek olarak işletmenin ürettiği mamul yaklaşık 1000 derece sıcaklığa sahiptir. Üretim hattında meydana gelebilecek duruş ya

da arıza, mamulün sıcaklığında değişikliklere sebebiyet verebilir ve sıcaklık farkı kalite kusurlarına neden olabilir. Üreticinin pazarda tutunabilmesi ve rakiplerine oranla üstünlük sağlayabilmesi kaliteli ürün üretmesi ve pazara kaliteli ürün sunması ile mümkündür (Şimşir et al., 2018). Bu çalışma ile mamullerin kalitesine de katkı sağlayacaktır

Ayrıca üretim hattında meydana gelen anlık arıza, o anda üretimde bulunan malzemenin hurdaya çıkmasına neden olmaktadır. Hattın durması malzemenin formunun bozulmasına neden olmaktadır ve üretime devam edilemez duruma getirmektedir. Bu da mevcutta haddelenen slabın üretim zayiatı olarak kaydedilmesine sebebiyet vermektedir. Hattın anlık duruşu makineler arasındaki senkronizasyonu da bozmakta ve arıza giderildikten sonra istenilen hızda üretim yapılabilmesin önüne geçmektedir. Hattın dengeye gelmesi zaman almakta ve bu süre kayıp zaman olarak işletmenin hanesine yazılmaktadır. Arıza meydana gelmeden müdahale edilmesini öngören bu çalışma bütün bu kayıpların önüne geçmeyi planlamaktadır.

Çalışmada üretim hattından alınmış olan örnek veriler programda işlenmiştir. Alınmış olan tahmin çıktıları değerlendirilmiştir. Program canlı sisteme entegre edilmemiştir. Ama elde edilen sonuçlar canlı sisteme entegre edilirse büyük katkı sağlayacağını göstermektedir. Programın canlı sisteme entegrasyonu için anlık titreşim verilerini toplayan yazılımın, bir servis yardımıyla verileri modele aktarması ve anlık çıktı vermesi gerekmektedir. Sisteme entegrasyonu fabrikanın entegrasyon birimleri sağlayabilirler.

Tezin bundan sonraki bölümünde bakım yaklaşımları detayları olarak incelenmiş, Literatürde ve pratikte kullanılan bakım yaklaşımlarından bahsedilmiştir. İşletmelerde yapılan her türlü bakım türünün önemi vurgulanmıştır. Literatür taraması kısmında ise bakım süreçlerinde kullanılan yapay zeka yöntemlerine ilişkin literatürde bulunan kaynaklar taranmış, kısa özetler halinde sunulmuştur. Üçüncü bölümde ise problemin çözümünde kullanılan makina öğrenmesi ve algoritmaları detaylı bir şekilde anlatılmıştır. Dördüncü bölümde ise verilerin alındığı işletmeye ilişkin bilgiler verilmiş, ardından verilerin alındığı hattın teknik özellikleri açıklanmıştır. Hattan alınmış verilerden örnekler verilmiştir. Tezde kullanılan; Destek vektör makinaları ve

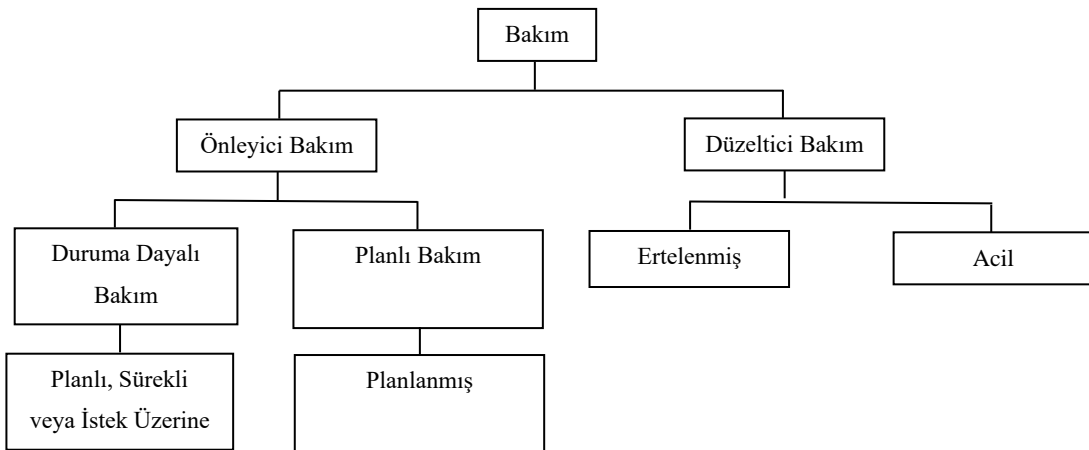
karar ağaçları algoritmalarının uygulama adımları açıklanmıştır. Grafikler yardımıyla model çıktıları yorumlanmıştır. Sonuçlar bölümünde ise iki ayrı algoritmanın sonuçlarının karşılaştırılması yapılmıştır. Modellerin doğruluk değerleri gösterilmiştir.

BÖLÜM 2

BAKIM YAKLAŞIMLARI

Endüstriyel işletmelerin kritik konularının başında bakım gelir. Bakım belirli aralıklarla makina ve ekipmanların sistemlerinin, donanımlarının, çalışma durumlarının kontrol edilmesi ve deforme olan noktalarında yenileme, tamirat yapılmasıdır. Bakım faaliyetleri; çalışan makina ve ekipmanların ömürlerini uzatır, performansının belirli aralıkta kalmasını sağlar ve meydana gelebilecek büyük çaplı arızaların önlenmesini sağlar. Bu kapsamda bakım üretilen ürünün kalitesinden, karlılığına, malzeme ömründen, duruş sürelerinin azaltılmasına kadar işletme için kritik olan bir çok nokta da önem arz etmektedir (Susto et al., 2015).

Bakımın temel amacı makina ve ekipmanlarda meydana gelebilecek arıza sayısını azaltmak ve üretim esnasında duruşlara neden olabilecek arızaları önlemektir. Bu kapsamda bakım Şekil 2.1’de gösterildiği gibi, temelde iki ana kategoriye ayrılır. Bunlar önleyici bakım ve düzeltici bakım olarak karşımıza çıkar. Önleyici bakım herhangi bir durum meydana gelmeden önce makina ve ekipmanlara müdahale edilmesi demektir. Önleyici bakım kendi içinde iki kategoriye ayrılır. Bunlar planlı bakım ve duruma dayalı bakım olarak adlandırılır (Jimenez et al., 2020).



Şekil 2.1. Bakım türleri.

Planlı bakım herhangi bir arıza meydana gelme durumu beklenmeksizin, belirli periyotlarla yapılan bakımı ifade eder. Genelde işletmeler yıl başlarında, yıllık bakım planı hazırlarlar. Hazırlanan plan kapsamında yıl içinde bakım faaliyetleri sürdürülür, bu bakım planı arıza, duruş vs. ile ilişkisi olmaksızın devam eder. Yalın üretim yaklaşımlarından olan toplam verimli bakımın da (TPM) konusu içerisine giren planlı bakım, işletmelere büyük yarar sağlar. Üretimin kesintisiz olarak devam etmesini sağlayan bir faaliyettir. Önleyici bakım yaklaşımının sağladığı faydanın farkına varan işletme sayısı günden güne artmakta, işletmeler bu konuya yatırım yapmaya devam etmektedirler.

Son zamanlarda seri üretim hatlarındaki bakım yaklaşımları, üretim planlama ve montaj hattı dengesi ile beraber ele alınır olmuştur. Buradaki hedef bakım yapılırken montaj hattına ve üretim planına olumsuz etki yapmadan bakım işlemini tamamlamaktır. Aslında bakımın temel amacı üretim ve montaj hattı planının efektif şekilde uygulanmasının sağlanmasıdır. Yani herhangi bir arıza duruşla karşılaşmadan üretimin sürekli olarak devam etmesinin sağlanmasıdır. Bu durum işletmenin ürettiği üründe, çalışan personelinden, iş güvenliğine ve dahi müşteri memnuniyetine kadar uzanan etkili bir süreçtir.

Bakım stratejisinin destek olduğu bir diğer konuda mamul kalitesidir. Üretim için kullanılan makina ve ekipmanlarda meydana gelebilecek arızalar, ürünlerin kalitesini de olumsuz yönde etkileyebilir (Rokhforoz & Fink, 2022). Aslında üretim kalitesi ve üretim kesintilerinin önlenmesi temelde işletmenin bakım stratejisine bağlıdır. Bakım planlamasının temel amacı ise müşteri taleplerini yerine getirirken, üretim sisteminin kullanılabilirliğini üst düzeye çıkarmaktır. Kısaca tanımlanacak olursa önleyici bakım ekipmanları her daim sağlıklı tutmak için kurulmuş bir stratejidir.

Bakım yaklaşımlarına başka bir açıdan bakılacak olursa, imalat bileşenlerinin performans düşüşüne bağlı olarak ürün kalitesinde düşüşler meydana gelebilir (Han et al., 2021). Eğer işletme bu kalite düşüşünün farkına varamazsa ve satışlara aynen devam ederse müşteri tarafına yansıyan bir memnuniyetsizlik meydana gelebilir. Ürün kalitesinin düşüşü ile birlikte müşteri kaybı, prestij kaybı yaşanabilir. Bu gibi ihtimallere fırsat verilmemesi için işletmenin bakım stratejisini efektif bir şekilde

oluşturup uygulaması gerekmektedir. Görüldüğü üzere üretim ekipmanlarının bakımı, montaj hattı, üretim çizelgesi, ürün kalitesi, üretim hedefi, müşteri memnuniyeti vs. birçok konuyu etkileyen kompleks bir yapıdır. Burada tahmine dayalı bakım olan kestirimci bakımın önemi gün yüzüne çıkmaktadır.

Tahmine dayalı bakım (PdM), bir işletmedeki hem öngörülemeyen bakım hem de öngörülebilir arızaların yönetimi için kullanılabilecek etkili bir stratejidir (Aremu et al., 2020). Yapılan araştırmalar tahmine dayalı bakımın (PdM) üretim, operasyonel maliyet, güvenlik yönetimi maliyetleri başta olmak üzere birçok maliyeti iyileştirdiğini göstermektedir. Ayrıca ekipmanların durumunu aktif olarak takip edebilme imkanı sunduğu için gereksiz ve fayda sağlamayan bakım maliyetlerini elimine ettiğini kanıtlamaktadır (Aremu et al., 2020). Bu nedenle bakım stratejisi kurulması için işletmelerin harcamış olduğu bütçenin geri dönüşü çok kısa sürede sağlanabilmektedir.

Kestirimci bakım, ekipman arızalarının ve üretim, onarım, sistem vs. kayıpların önlenmesi için etkili bir yöntemdir. Geleneksel bakım yöntemleri ekipmanların yaşam döngüsünden verileri kullanamadığı için doğru zamanda müdahale edilmesine imkan sağlayamaz. Arıza zamanında giderilmezse üretimin durmasına ve hatta ciddi kayıplara neden olabilir. Bu nedenle arızaları önceden tahminlemek ve sistemin güvenliğini arttırmak için kestirimci bakım yaklaşımlarını kullanmak gereklidir (Luo et al., 2020). Günümüzde kestirimci bakım her sektörde kullanılan yeni bir trend haline almıştır. Bu sayede her sektörde güvenlik ve kalite yükselişe geçmektedir.

2.1. DÜZELTİCİ BAKIM

En basit haliyle, herhangi bir ekipmanda meydana gelen arızanın ardından, sorunlu bölgeye yapılan bakım işlemidir. Arıza giderme, tamirat olarak da isimlendirilebilir. Bu bakım türü aslında bazı kaynaklarda bakım olarak kabul edilmemektedir. Devam eden üretime efektif bir yaklaşımla sorun giderici bir bakış açısına sahip değildir. Arıza olduktan sonra müdahale etmek anlamına gelmektedir. Başka bir deyişle üretim hattında herhangi bir aksaklık görünmüyorsa hattın çalışması aynen devam edecek, çalışan hatta dokunulmayacaktır (Jimenez et al., 2020). Bu yaklaşım günümüz

endüstrisinde kabul görmeyen, maliyet açısından kaybı büyük, sistemleşmeden uzak bir durum olarak kabul edilmektedir.

Düzeltilici bakım (CM) arıza meydana gelmeden önce herhangi bir faaliyet gerektirmez. Arıza meydana geldiği an işletmenin kullanılabilir kaynaklarıyla beraber arızanın olduğu noktaya müdahale etmesini öngörür. Bu kapsamda düzeltilici bakımda arıza kaynaklı ekipmandan kayıp söz konusu olur. Herhangi bir ekipmana arıza meydana gelmeden önce müdahale edilmiş olsa küçük bir tamiratla giderilebilecek sorun, arızadan sonra çok büyük maliyelere sebebiyet verebilir. Ayrıca arıza meydana gelmesi o anda üretim hattında çalışan personele de zarar gelmesini neden olabilir. Bu açıdan bakıldığında iş sağlığı açısından da arıza meydana gelmesi risk teşkil etmektedir. İşletmelerin hedefi arızayı gidermek değil, arıza meydana gelmesini önlemek olmalıdır.

Buna ek olarak arızalar büyük ölçüde üretim kaybına neden olabilir. Hatta üretim devam ettiği bir anda, ansızın meydana gelen bir arıza, hatta o anda üretilmekte olan malzemeyi büyük ölçüde deforme edip, maliyet yaratabilir. Ayrıca arıza meydana geldiği anda çok büyük olasılıkla üretim duracaktır. Üretim duruşu arıza giderilip sistem devreye alınana kadar devam edecektir. Bu durumda işletme elindeki kaynakları ölçüsünde üretim sistemine müdahale edebilir. Eksik bir ekipman olması ya da teknik personel eksikliği olması durumunda, üretim duruşu uzayacaktır (Gan et al., 2022). İşletmenin katlanacağı maliyet de giderek artacaktır.

Bakım sistemini planlama ve yürütme, karmaşık bir yapıya sahip olması nedeniyle oldukça zor problem türlerindedir. Bakım işinde sistemi oluşturan bütün birimler birbirine bağımlı olarak hareket eder. Önleyici bakım faaliyetleri planlanabilir ve plana göre hareket edilebilirken, düzeltilici bakım faaliyetleri sistemin çalışmasını doğrudan etkilediği için zamana karşı duyarlılığı yüksek faaliyetleridir (Özgür-Ünlüakın et al., 2021). Maliyetlerin bu kadar yüksek olduğu günümüz koşullarında işletmelerin bakım stratejilerini sadece düzeltilici faaliyetler üzerine kurmaları efektif bir yaklaşım değildir. Önleyici bakım stratejilerini de etkin ve etkili olarak kullanan işletmeler her zaman bir adım önde olacaklardır.

2.2. ÖNLEYİCİ BAKIM

Bakım yaklaşımlar temelde iki ana başlık altında toplanmıştır. Bunlar düzeltici bakım ve önleyici bakım olarak tanımlanabilir. Düzeltici bakım arıza meydana geldikten sonra yapılan işlemleri kapsamaktadır. Önleyici bakım ise arıza meydana gelmeden önce yapılan ve arıza oluşmasını önlemeyi hedefleyen bakım türüdür. Makina ve ekipmanların izlenmesi ve kontrol edilmesi için önleyici bakım kritik bir öneme sahiptir. Önleyici bakım da kendi içinde iki başlığa ayrılmıştır. Bunlar planlı bakım ve kestirimci bakım olarak adlandırılır (Wong et al., 2022).

Günümüzde bakım yaklaşımlarının öneminin farkına varılmış ve işletmeler büyük ölçüde bu alanda çalışmalara başlamıştır. Otomotivden, robotiğe farklı sektörlerdeki işletmelerde bakım alanında çalışmalar hız kazanmış durumdadır. Bu konuya ilişkin Wang & Miao'nun 2021 de yaptıkları çalışmalarında, önleyici bakıma yönelik geliştirilmiş matematiksel modellerin yetersiz kaldığı üzerinde durmuşlardır. Çalışma kapsamında semiMarkov modeli altında optimal bir önleyici bakım optimizasyon modeli formüle edilmiştir. Minimum bakım maliyetini hedefleyen çalışmada rüzgar türbini sistemindeki yaylı amortisörle uygulama gerçekleştirilmiştir.

2.3. KESTİRİMCİ BAKIM

Günümüz toplumun artan tüketim ihtiyaçlarına cevap verebilmek gitgide zorlaşmaktadır. Artan talebi dengeleyebilmek ve toplumun ihtiyaçlarına cevap verebilmek için taleple aynı ölçüde üretimin de artması gerekmektedir. Üretimin artması demek sanayileşmenin artması, bununla birlikte endüstride kullanılan sistemsel gelişmelerinde hız kazanması demektir. Hızlı üretim, tesislerde duruşların minimize edilmesiyle sağlanabilir. Duruşların minimize edilebilmesi için arıza meydana gelmeden müdahale edilmeli, arıza kaynaklı bir duruş yaşanmasının önüne geçilmelidir. Burada bahsi geçen yöntem kestirimci bakım adı altında incelenen ve arızadan önce müdahale edilerek, hattın arıza vermesinin önüne geçilerek, duruş kaynaklı yaşanabilecek kayıpları engelleyen bakım sistemidir.

Son yıllarda bakım alanında büyük deęişimler ve dönüşümler yaşanmıştır. Bunların en başında kestirimci bakım yaklaşımlarında yaşanan gelişmeler gelmektedir. Literatüre bakıldığında arıza meydana gelmeden önce tahminlemeyi sağlayan birçok model geliştirildiğine rastlanmaktadır. Leohold et al., 2021 de yaptığı çalışmasında, literatürde bakıma yönelik kurulmuş olan modeller üç ana başlık altında toplanmıştır. Bu modeller veriye dayalı modeller, deneyime dayalı modeller ve fizik temelli modeller olarak karşımıza çıkmaktadır. Veriye dayalı modeller girdilerin ve çıktılarının istatistiksel yöntemlerde işlendiği modeller ya da makina öğrenmesi gibi algoritmaların kullanıldığı, geçmiş verilerin işlendiği ve tahminleme yapılan modellerdir. Deneyime dayalı modeller kişisel tecrübelerden yola çıkılarak yapılan bakımları içermektedir. Fiziksel temelli modeller ise bir makinanın ya da ekipmanın durumunun fiziksel davranışını tanımlayan matematiksel modellerdir.

2.4. DEMİR ÇELİK SEKTÖRÜ VE BAKIM YAKLAŞIMLARI

Demir çelik sektörü kalkınmanın öncüsü olarak nitelendirilen ve sanayileşmenin temel yapı taşı olarak kabul edilen stratejik bir üretim sektörüdür (Yaşar, 2013). Ülkemizde demir çelik yatırımları 1930'lü yıllara dayanmaktadır. Ülkenin kurucuları demir çelik sanayisinin öneminin farkına varmışlar ve konu üzerinde çalışmalar yapmışlardır. Ülkemizde 1937 yılında ilk demir çelik tesisinin temelleri Karabük ilinde atılmıştır. Bu hamlenin ardından demir çelik sanayisinin gelişimi artarak devam etmiştir. 1965 yılında ülkenin ikinci demir çelik fabrikası Ereğli civarında kurulmuştur. 1975 yılında ise üçüncü demir çelik tesisi İskenderun bölgesinde kurulmuştur (Öztürk, 2012.).

2.4.1. Demir Çelik Üretimi

Demir çelik sektörünün ham maddesi demir cevheridir. Cevherin yer altından çıkarılmasının ardından, yoğunlaştırma, dökme, dövme, haddeleme, çekme yöntemleri ile imalat gerçekleştirilir (Ersöz et al., 2016). Sıvı ham demirin, üretimi yüksek fırın işletmesinde gerçekleşmektedir. Karmaşık bir yapıya sahip olan bu işlemin süresi oldukça uzundur. Yüksek fırının imalat kapasitesine bağlı olmakla birlikte, bir dökümün tamamlanması ortalama 6-8 saat sürmektedir (Köprü & Özcan, 2020). Teknolojinin ilerlemesi ve demir çelik üretiminde farklı yöntemlerin bulunmasıyla

beraber, yüksek fırın gazının kullanıldığı demir çelik üretimi, yerini elektrikli ark ocağına bırakmıştır. Ark ocakları ile beraber, demir çelik üretimi için kullanılan demir cevheri de yerini hurdadan üretime vermiştir (GökceciK & DulkadiRoğlu, 2021).



Şekil 2.2. Slab ve kütük.

Günümüzde elektrikli ark ocaklarından alınan sıvı ham demir, sürekli döküm tesislerinde kütük ya da slab olarak dökülmektedir. Kütük boyutları slaba göre daha küçüktür. Kütük genellikle kangal haddehanelerinde işlenir. Kütük haddehanelerinde çoğunlukla kangal, nervürlü inşaat çeliği, filmaşın gibi uzun ürünler üretilir. Slab ise boyut olarak daha büyük olan malzemedir. Slabtan yassı sıcak ürünler olan bobin ve levha üretilir. Bobin ve levha, uzun ürünlere oranla daha katma değerli mamullerdir. Yapılan araştırmalar, ülkemizde katma değerli malzemelerin üretiminde kullanılan yassı mamuller grubunun üretiminin rekabet gücünün düşük olduğunu göstermektedir. Çalışma sonuçları ülkemizin yassı mamul üretimi için gerekli olan teknoloji ve alt yapının yeterli olduğu yönündendir. Son yıllarda yassı mamul üretimim kapasitesi artmakta ve araştırma geliştirme çalışmalarıyla bu konular desteklenmektedir (Çeştepe, 2018).

2.4.1.1. Sıcak Haddeleme İşlemi

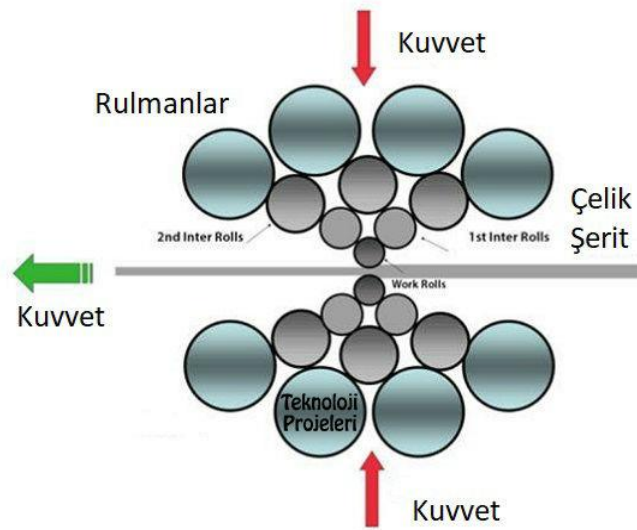
Döküm tesislerinden alınan kütük ve slab hadde proseslerinde kangal, bobin, levha gibi malzemelere dönüşür. Bobin ve levha bunlardan en kıymetli olanlarıdır. Slabın bobin ve levhaya dönüşmesi haddeleme prosesi sonucunda olur. Haddeleme çeşitlerinde olan sıcak haddeleme, sürekli dökümden alınan sıcak slabın soğumadan hadde fırınına alınması şeklinde devam eden üretim sürecidir. Tav fırınlarında yaklaşık 1200-1400 derece sıcaklığa getirilen slabın kalınlığı, dönen merdaneler yardımıyla

0,4-0,6 mm kalınlığa kadar düşürülür. Hadde işleminin hatasız gerçekleşebilmesi için malzeme üzerinde ısınma soğumadan dolayı oluşan kalıntılar basınçlı su ile giderilir. Hedef kalınlığa ulaşıldıktan sonra malzeme bobin haline getirilir.



Şekil 2.3. Sıcak haddehane üretim akışı.

Şerit haddeleme bölgesinde, hadde tezgahları ile bitirme grubu merdaneler bulunmaktadır. Merdaneler aracılığıyla haddelenen malzemeler, üzerlerindeki basıncı yatak bölgelerine iletirler. Şekil 2.3'de gösterildiği gibi hadde merdaneleri üç bölümden oluşmaktadır. Birinci bölüm haddelenen malzemeyle doğrudan temas etmektedir. Gövde olarak adlandırılır. İkincisi yataklarda çalışan kısımlardır. Muylular olarak da adlandırılırlar. Üçüncü ise mile bağlanan kısımdır (Karagöz, 2009). Hadde merdanesi malzemesinde genelde dökme demir ve çelik kullanılır. Dökme demirin kullanıldığı merdane üretim şeklinde kokil kalıp kullanılırken, çelik merdane üretimleri dövme yolu ile yapılır.



Şekil 2.4. Haddeleme prosesi rulman yerleşimi.

2.4.2. Demir Çelik Üretiminde Bakımın Önemi

Demir çelik sektörü, tüm endüstriyel işletmelerin hammaddesini üretmesi nedeniyle en önemli sanayi dallarından biri olarak kabul görmektedir. Başta inşaat olmak üzere demir yolu, uçak, roket, otomotiv, gemi, beyaz eşya gibi mamullerin üretiminde demir çelik sektörünün katkısı vardır. Demir çelik sektörü katma değeri ve doğru üretim stratejileri izlendiğinde karlılığı en yüksek olan sektörlerden biridir. Ülkemizde karlılığı en yüksek işletmeler sıralandığında demir çelik tesislerinin üst sıralarda yer aldığını görürüz. İhracat noktasında da büyük paya sahip olan demir çelik sektörü ülkemiz sanayisinin lokomotifi konumundadır.

Maddi manevi kazancın bu derece büyük olduğu bir sektörde üretim hacminin ve kalitesinin artırılmasının ne derece önemli olduğu açıktır. Üretim hacmi ve kalitesinin artırılabilmesinin temel şartı, üretimde kullanılan ekipmandan maksimum faydanın sağlanmasıdır. Makina ve ekipmanlar üretime başladıkları anda maksimum performansı sergilerler. Zamanla performanslarında düşüşler görülmeye başlar. Donanımlarında eskime, deformasyon, arızalanma sebebiyle ilk günkü performansla üretim gerçekleştiremez olurlar. Ekipmanlarda görülen performans düşüşü üretilen ürünün kalitesini de olumsuz etkileyebilmektedir.

Aşağı ivmeli olan performans grafiğinin sabit kalması ya da tolere edilebilecek düzeyde olması efektif bir bakım stratejisi izlenmesiyle mümkün olabilir. Demir çelik sektörü 24 saat aralıksız üretim gerçekleştiren bir sektördür. İşletmeler 24 saat, üç vardiya olacak şekilde üretimlerini kesintisiz şekilde gerçekleştirir. Bu derece yoğun performansın sergilendiği üretim hatlarında bakı kritik konulardan biri olarak karşımıza çıkmaktadır. Günümüzde küçük ölçekli işletmeler düzeltici bakım olarak adlandırılan arıza meydana geldikten sonra müdahale edilmesini ön gören bakım yaklaşımını yaygın olarak kullanmaktadırlar. Fakat bu yöntem hem üretilen mamulün kalitesi hem de arızadan kaynaklı üretim duruşu ve üretilmekte olan mamulün kaybına katlanmak zorundadır.

Orta ve büyük ölçekli işletmeler bakım yaklaşımlarını geliştirmiş ve arıza olmadan önce müdahale edilebilecek sistemler aramaktadırlar. Önleyici bakım olarak

adlandırılan bu bakım yaklaşımı işletmelere çok yönlü kazanç sağlamaktadır. Bunlardan birincisi arıza meydana gelmesinin önlenerek olmasından dolayı, arıza kaynaklı duruş yaşanmasının önüne geçmiş olmaktadır. Herhangi bir ekipmanda yaşanacak arıza, boyutuna bağlı olarak, belirli bir süre hatta duruşa sebebiyet verecektir. Bu süre arızanın durumuna bağlı olarak değişiklik gösterebilmektedir. Hasarın büyük olduğu durumlar, günlerce üretim hattının durmasına sebep olabilir. Burada sadece üretim kaybı yaşanmaz. Üretim planı aksamasına bağlı olarak müşterilerden alınan siparişlerde de aksama meydana gelir. Bu durum müşterinin gözünde işletmenin güvenilirliğini zedeleyebilir. Hatta müşteri kaybına bile sebebiyet verebilir.

Diğer bir kayıp, arızadan kaynaklı, ekipmandan yaşanacak, geri dönüşü olmayan ya da çok büyük düzeylerde olabilecek tamirat maliyetidir. Önceden müdahale edilse cüzi maliyetlerle çözülebilecek problemler, arıza yaşandıktan sonra işletmeleri büyük maliyetlere katlanmak zorunda bırakabilir. Arıza yaşanması herhangi bir ekipmanı inaktif duruma getirmenin yanında, bir daha kullanılmayacak duruma da getirebilir. Bu durum işletmeyi makina ekipman yatırımı yapmak zorunda bırakabilir. Günümüzde ekipmanların büyük çoğunluğunu ihraç eden bir konumda olmamız dolayısıyla, yeni ekipman yatırımı maliyeti birçok işletmeye çok ağır gelebilmektedir. Ayrıca hazır sermayenin kullanılmasını gerektirecek bu durum işletmeleri büyük çıkmazlara sokabilmektedir.

Konuya diğer bir açıdan bakacak olursak, gerekli bakımları yapılmamış olan ekipmanın performansı zamanla düşecektir. Performansına paralel olarak üretim kalitesinde de düşüşler meydana gelmeye başlayacaktır. Üretilen mamulde meydana gelen kalite düşüşü işletmenin bütün birimlerine ekstra iş yükü getirecektir. Kalite biriminden geri dönen mamuller katlanılacak olan başlıca kayıplar olacaktır. Kalite düşüşünü önlemek için mekanik, elektrik bakım ekibi fazla mesai harcayacak belki de hattı durdurmak zorunda kalacak ve kayıp zamana sebebiyet verebilecektir. Bu konunun diğer bir açısı da müşteri tarafına etki edecektir. Kalite düşüşü müşteriler tarafından fark edilecek ve müşteri memnuniyeti olumsuz etkilenecektir. Bu durum müşteri şikayetlerinin artmasına, müşteriden geri dönen malzemenin fazlalaşmasına

ve sonucunda da müşteri kaybetmeye kadar gidebilecek kritik bir süreçtir. İşletmenin isminin piyasada kötü anılmasına da sebebiyet verebilecektir.

İşin diğer bir boyutu ise iş sağlığı güvenliği kısmıdır. Bakımı düzenli yapılmayan ekipman her an bir arızaya sebep olabilir. Bu durum makina da çalışan personeli de olumsuz etkileyebilir. Yaşanacak herhangi bir arızada etrafa verilecek olan zarar iş sağlığı güvenliğinin de konusu olarak kabul edilmelidir. Günümüzde özellikle demir çelik üretiminde kullanılan makineler çok büyük akımlarla ve güçlerle çalışmaktadır. Bu sebepten ötürü herhangi bir arıza durumunda etrafa verilecek olumsuz etkinin boyutu da derece büyük olabilmektedir. Bu konu iş sağlığı güvenliği ekiplerince de takip edilmesi gereken kritik bir meseledir.

Görüldüğü üzere ekipmanın bakımının sebep olabileceği kayıplar çok yönlüdür. Bu kayıpların önüne geçilebilmesi için işletmelerin yapması gereken şey kendilerine bir bakım stratejisi belirlemek olmalıdır. Bu sayede hem yaşanacak kayıplardan dolayı katlanılacak maliyet ortadan kalkmış olacaktır hem de işletme personelleri ve yöneticileri kendilerini daha güvende hissedeceklerdir. Bu sayede her an bir arıza yaşanacak mı tereddüdü içerisinde olmaktan da kurtulmuş olacaklardır. Yapılacak bakım yatırımları ile gelecekte yaşanabilecek birçok maliyet önlenmiş olur.

2.5. LİTERATÜR TARAMASI

Zhang et al., 2021 yılında yaptığı çalışmasında montaj atölyesi iş akış çizelgelemesinde hem önleyici bakım (PM) hem de düzeltici bakım (CM) maliyetlerinin ortak optimizasyonunu ele almıştır. Üretim çizelgeleme ve bakım planlamasının ortak optimizasyonu, üretim sürekliliğinin ve güvenliğinin üzerindeki etkisinin büyüklüğünü vurgulamıştır. Deneysel sonuçlara göre, önerilen RIPG (Tekrarlı Açgözlü Algoritma- Restarted Iterated Pareto Greedy) modeli, bakım maliyetleri ve üretim süresi birlikte düşünüldüğünde en yüksek performansa sahiptir.

Yepez et al., 2019 yılında yaptığı çalışmasında, bakım endüstrisinin diğer sistemlere kıyasla otomasyonlaşma yolunda geri planda olduğu vurgulamıştır. Buna ek olarak düzeltici bakım prosedürünün büyük ölçüde insan bilgisine ve kararına dayalı hareket

ettiği söylenmiştir. Hasarlı bileşenin yerinin tespit edilmesinde, onarılmasında ve arıza süresinin azaltılmasında insan bilgi ve becerisinden ziyade otomasyonlaşmanın gerektiği açıklanmıştır. Çalışmada bakım süreçlerinde insan kararlarına destek niteliği taşıyacağı öngörülen bakım prosedürü oluşturmak için ürünün Arıza Modu ve Etki Analizi (FMEA) grafiği kullanılmıştır. FMEA raporundaki bilgileri kullanılarak, operatörlerin en kritik bileşenlere yönlendirilebileceği açıklanmıştır.

Yu et al., 2019 yılında yaptığı çalışmasında, üretim hattında genel bakım ve enerji maliyetlerinin minimuma indirilmesi için düzeltici bakım yaklaşımının nasıl uygulanması gerektiğini konu edinmiştir. Modern üretim sistemlerinde makinaların ve ekipmanların birbirine bağımlı çalıştığı, herhangi birinde meydana gelecek arızanın üretim hattının tamamını etkileme riski olduğu üzerinde durulmuştur. Bu noktada düzeltici bakımın önem kazandığını savunmuştur. Arıza durumunda maliyetlerin minimize edilmesi için bir model önerilmiş ve model simülasyon ortamında test edilmiştir.

Saltmarsh & Mavris, 2013 yılında yaptıkları çalışmalarında, kompleks yapıdaki makina ekipmanların bakımlarının sistemsel olarak değil, bileşen bazında yapılması gerektiğini savunmuşlardır. Bu gibi büyük yapıdaki sistemlerde meydana gelen arızaların, pareto analizinde olduğu gibi küçük parçalardaki arızalardan kaynaklı olabileceğini öngörmüştür. Ve arızalı parçanın tespit edilmesi için bir algoritma önermiştir. Çalışmanın ilk bölümünde düzeltici bakım modellemesi tanıtılmış, ikinci bölümde düzeltici bakım için kümeleme çalışması yapılmış, üçüncü bölümde, sistemin nasıl simüle edileceği açıklanmış, dördüncü bölümde ise kümeleme yaklaşımı açıklanmış ve son bölümde de sonuçlar tartışılmıştır.

Planlanmış bakım faaliyetlerinin, düzeltici bakım faaliyetlerini tamamen kaldırmaya yetmediğini vurgulayan bir çalışmada, herhangi bir düzeltici bakım faaliyetinin, bakım maliyetlerinin büyük çoğunluğunu oluşturma ihtimalinin varlığı üzerinde durulmuştur. Çalışmada düzeltici bakıma ayrılan maliyetin tahmin edilmesi üzerinde durulmuştur (Erkoyuncu et al., 2017). Kenne et al., 2003 yılında yaptığı çalışmasında, havacılık ekipmanlarının düzeltici bakım maliyetleri üzerinde durmuştur. Yapılmış olan bu

çalışmada, sistemin onarım oranları kontrol edilerek optimal bir düzeltici bakım politikası hazırlanmıştır.

İşletmelerin bakım politikalarını sadece düzeltici bakım yaklaşımına göre düzenlemeleri her zaman kayba neden olacaktır. Düzeltici bakım faaliyeti arıza meydana geldiğinde müdahale etmeyi öngörür. Fakat işletmeler arıza meydana gelmeden önce fark etmeli ve arızanın meydana gelmesini önlemesi gerekmektedir. Bu şekilde arıza kaynaklı yaşanacak olan zarar elimine edilmiş olur. Bu noktada önleyici bakım faaliyetlerinin önemine dikkat çekilmektedir. Arıza olmadan önce uyarı veren sistemlerin varlığı bakım yaklaşımında işletmelere büyük faydalar sunmaktadır. Fakat önleyici bakım faaliyetlerinin de maliyeti mevcuttur. Fang & Zhaodong, 2015 yılında yaptıkları çalışmalarında, makina parçalarının arıza oranının, ekipmanın yaşam döngüsündeki bakım ve destek maliyetleri üzerindeki etkisini analiz etmişlerdir. Varılan sonuç şöyledir; arıza oranını azaltmak, ekipman yaşam döngüsü maliyetini etkili bir şekilde azaltmaktadır.

Otonom araçlarda planlı bakıma ilişki yapılmış bir çalışma, bakım planlarının kolaylaştırılması üzerinde durulmuştur. Çalışmada, bir kamyon şirketinin minimum ekonomik riski ile bakım kararını tanımlayan bir bakım modeli oluşturulmuştur. Ekonomik riskler değerlendirilirken bakım maliyetleri dikkate alınmıştır. Çalışmanın sonucunda önerilerin modeli riski hatırı sayılır bir ölçüde azalttığı sonucuna varılmıştır (Tao et al., 2022). Önleyici bakımın (PM), bütçeden tasarruf etmede, kullanılan malzemeyi iyi durumda tutmada ve makina ekipmanın ömrünü uzatmada etkili bir strateji olduğunu savunan bir çalışmada asfalt kaplama konusu üzerinde çalışılmıştır. Çalışmada kaplama performans parametresini tahmin etmek amacıyla parçacık sürüsü optimizasyonu (PSO) algoritması kullanılmıştır (Li et al., 2022).

Gelişen teknoloji yaşamı dünyamızın ötesine taşımakta hızlı adımlarla ilerlemektedir. Uzay taşımacılığı, uzaya seyahatin sıklıkla konuşulduğu günümüzde, uzay taşımacılığı için kullanılacağı ön görülen yeniden kullanılabilir roket motoru (RRE), önleyici bakımına ilişkin bir çalışma yapılmıştır. Çalışma yeniden kullanılabilir roket motoru (RRE) için önleyici bakım şeması önermektedir. Önerilen şemada önleyici bakım maliyetinin azaltılması hedeflenmiştir (Jin et al., 2022). Uzay çağını yaşadığımız,

hedeflerin ve yönlerin uzaya çevrildiği günümüzde, uzay taşımacılığına ilişkin çalışmalar yol gösterici nitelik taşımaktadır.

Bakım yaklaşımları ekipmanlarla kalmayıp üretimin birçok alanına etki eden geniş bir konudur. Üretim hatlarında meydana gelen herhangi bir arıza bakım durumu fabrikayı uçtan uca etkiler. Yang et al., 2021 yılında yaptığı çalışmada, bakım stratejisi ile üretim planı arasındaki ilişkiye değinmiştir. Önleyici bakım maliyetleri, iş çizelgeleme maliyetleri, işleme maliyetlerini göz önünde bulundurarak bir üretim politikası tasarlamayı hedeflemiştir. Problemi Markov karar süreci çerçevesinde ele almıştır. Önerilen algoritma performansı simüle edilmiştir, sonuçlar önerilen yaklaşımın efektif olduğunu doğrulamıştır.

İşletmelerin tamamı performansı yüksek, kapasitesi geniş makinalarla çalışmayı tercih eder. Yüksek performanslı makinelerden zamanla ilk gün ki verim alınamamaya başlar. Makinenin kullanımını sonucu yıpranması nedeniyle ardışık çalışma süreleri kısalmaya, buna paralel olarak bakım süreleri artacaktır. Önleyici bakım faaliyetlerinin aktif olarak gerçekleştirilmesi makinaların arıza verme sıklığını düşürecektir. Ayrıca arıza vermesi önlenen makinada, bakım maliyeti de daha az olacaktır. Bununla birlikte makina yıpranması da azalacak, makina kapasitesi daha uzun süre korunabilecektir. Bu konuyu dikkate alan bir çalışma üretim çizelgesi ve bakım stratejisini birlikte ele alan bir optimizasyon modeli kurmuştur. İşleme hızının her makinenin çalışma süresini ve çizelgeleme düzenini etkilediğini vurgulanmıştır (An et al., 2022).

İşletmelerde verimli ve sorunsuz üretimin gerçekleştirilmesinde önleyici bakımın rolü büyüktür. Önleyici bakımların gerçekleştirilmesi arıza meydana gelmesini ve ağır hasarlı kayıplar meydana gelmesini engeller. Dışarıdan bakıldığında gereksiz gibi görülebilen önleyici bakımlar, üretim sistemlerinin kilit noktalarıdır. (Su et al., 2022 yılında yaptığı çalışmada, kompleks yapıdaki bir işletmenin önleyici bakım planlaması için model bir model önermiştir. Ayrıca çalışmada önleyici bakımın önemi üzerinde durulmuştur. Çalışmada seri üretim hatlarında önleyici bakım karar verme sürecinde Merkezi olmayan kısmen gözlemlenebilir Markov karar süreci (Dec-POMDP) kullanılmıştır.

Düzenli üretim ve önleyici bakım senaryoları dikkate alınarak montaj hattı dengelemesi (ALBP_RP/PM) konusunu, montaj hattı dengeleme, montaj üretimi ve makina ekipman bakımını birlikte ele almaktadır. Herhangi bir istasyonda bakım yapılacaksa, montaj hattının sürekliliğinin sağlandığı ve üretim planının etkilenmesinin en aza indirildiği bir plan uygulanır. Bu konuyu ele alan bir çalışma optimal plan oluşturmak için komşu arama ve matris azaltma yöntemlerini kullanmıştır (Tang et al., 2022). Üretim hattının kompleks yapısı ve birbiriyle olan ilişkisi dikkate alındığı zaman, düzenli üretim ve önleyici bakım senaryoları dikkate alınarak montaj hattı dengelemesi (ALBP_RP/PM), yaklaşımının önemli sonuçlar doğuracağı açıktır.

Günümüzde teknolojinin gelişmesiyle verinin önemi anlaşılmış ve veriye dayalı yöntemler önem kazanmıştır. Kestirimci bakım alanında da veriye dayalı yöntemlerle tahminleme yapmanın avantajları ortaya çıkmıştır. Bu sebeple kestirimci bakım konusunda makina öğrenmesi yöntemlerinin kullanılması giderek yaygınlaşmıştır. Yüksek otomasyonlu üretim hatlarında makine bileşenlerinin kesintilerinden kaynaklanan makinelerin plansız duruş sürelerini en aza indirmek önemlidir. Allah Bukhsh et al., 2019 yılında yaptıkları çalışmalarını iki ana bölüme ayırmışlardır. Çalışmanın birinci bölümde hataların sınıflandırması yapılmış, ikinci aşamada ise makina öğrenmesi yöntemleri kullanılarak faydalı ömrün tahminlemesi yapılmıştır. Varılan sonuçta kullanılan veri setlerinin genişliğinin sonuca ulaşma da önemli olduğu vurgusu yapılmıştır.

Endüstri 4.0'ın gelişmesi ile üretimde odak nokta olması günümüzün önemli bir gerçeğidir. Endüstri 4.0 duruşları minimize etmeyi ve üretimi, verimliliği, karı maksimize etmeyi hedeflemektedir. Bu kapsamda kestirimci bakım da önem kazanmaktadır. Bousdekis et al., 2019, p. 4 yaptığı çalışmasında, endüstri 4.0 kapsamında Kestirimci bakım özelindeki çalışmaların derlemiştir. Çalışmada kestirimci bakımla beraber sensörlerin kullanımının ve öneminin arttığı vurgulanmıştır. Maliyetlerin azaltılması günümüzün önemli noktaları arasında kabul edilmektedir. Makina arızalarının ve duruşların azaltılması da maliyet azaltmak kadar önemli bir konudur. Kestirimci bakım konusu burada da kilit nokta olarak karşımıza çıkmaktadır. En doğru sensör algoritma seçimine ilişkin yapılmış bir çalışma da

kestirimci bakımın doğru şekilde yapılabilmesi için verinin sağlıklı şekilde alınması gerektiği konusu üzerinde durulmuş ve doğru veri için doğru sensör kombinasyonları açıklanmıştır (Kammerer et al., 2021).

Theissler et al., 2021 yılında otomotiv sektöründeki maliyet fazlalığı, hammadde miktarının giderek azalmasına bağlı pahalılık ve kaynaklarının giderek azalması sebebiyle otomotivde kestirimci bakımın önemi üzerinde durmuştur. Çalışma kapsamında öncelikle arızalar sınıflandırılmıştır. Ardından derin öğrenme yöntemleriyle kestirimci bakım zamanları tahminlenmiştir. Nguyen & Medjaher, 2019 yılında yaptıkları çalışmalarında, bakım politikalarının klasik bakım ve ideal tahmini bakım olarak ikiye ayırmışlardır. Çalışmada kestirimci bakım zamanlarının tahminlenmesi için bir model önerilmiştir. Sensör ölçümlerine dayalı yeni bir dinamik kestirimci bakım öneren çalışmada gerçek bir sistemde testler yapılmış ve olumlu sonuçlar alınmıştır.

Kestirimci bakım sadece büyük ölçekli işletmeler değil, orta ve küçük ölçekli işletmeler için de önem arz etmektedir. Karlılığı maksimize etmek, üretim duruşlarının minimize etmek için işletmelerin kestirimci bakım çalışmalarını yapmaları gerekmektedir. Welte et al., 2020 yılında, orta ve küçük ölçekli işletmelerdeki kestirimci bakım çalışmalarını ele almıştır. Yapılmış olan çalışmada küçük ve orta ölçekli işletmelerin kestirimci bakım çalışmaları yapan şirketlerinden danışmanlık almaları ve belirledikleri pilot bölgelerde uygulamaya başlamaları gerektiği sonucuna varılmıştır.

Bir enjeksiyon kalıplama makinesinin kritik bileşeni için yapılmış olan bakım tahminleme çalışmasında veri odaklı bir model geliştirilmiştir. Çalışmada kullanılan verilerin kalitesi üzerinde durulmuştur. Verilerde yapılabilecek bir yanlışlığın tahminlemede büyük hatalar meydana getirebileceği vurgulanmıştır (Rivera et al., 2019). Otomotiv sektöründe yapılmış olan diğer bir çalışmada maliyetlerin azaltılması için kestirimci bakım üzerinde durulmuş ve çalışan bir hatta yapay sinir ağıları kullanılarak kestirimci bakım tahminleme çalışması yapılmıştır. Beş ayrı grupta, 24 ayrı makina ile çalışılmış olan proje de sensörlerden daha detaylı veri alınması ile

makina parçaları arasında korelasyon kurulabileceği, gerçek arıza merkezine daha yakın tahminleme yapılabileceği söylenmiştir (Einabadi et al., 2019).

Daniyan et al., 2020 yılında, Yapay zeka yöntemleri ile tahminleme yaptığı çalışmada, kalan faydalı ömrü ölçmeye yönelik araştırma yapmıştır. Matlab 2018 kapsamında gerçekleştirilmiş olan proje de ekipmanın kullanılabilirliğini, güvenliğini ve performansını artıracaktır bir model öne sürülmüştür. Görüldüğü gibi makina öğrenmesi yaklaşımları ile kestirimci bakım çalışmaları günümüz endüstrisinin odağında olan noktalardandır. Son dönemde endüstri 4.0 la beraber kestirimci bakım konusundaki son gelişmelerin özetlendiği bir çalışmada arıza teşhisinde veriye dayalı çok etmenli sistemlerin umut vaad ettiği açıklanmıştır (Drakaki et al., 2021).

Schwendemann et al., 2021 yılında yaptığı çalışmada, taşlama makinalarındaki rulmanların kestirimci bakımı üzerinde durmuştur. Yapılan analiz iki kısımda toplanmıştır. Birinci kısımda rulman arızalarının sınıflandırılması, rulmanların kalan faydalı ömrünün hesaplanması ele alınmıştır. İkinci kısımda olası bir arızanın, arıza meydana gelmeden önce tespit edilmesinin sağlayacağı kazancın önemi vurgulanmıştır. Bakım süreçlerinde tahminlemede yeterli düzeyde veri tutulmaması, veri analiz yöntemlerinin uygulanabilirliği konusunda tecrübenin çok az olması nedeniyle gerçek dünyadaki uygulamalarının çok nadir olduğunu vurgulanmıştır. Bu çalışmada veri setlerindeki sapmaların ve hataların tespit edilmesi için bir model öne sürülmüştür. Ardından endüstriyel radikal fanlar üzerine çalışan bir tesiste model denenmiş ve sonuçları yorumlanmıştır. Bu çalışmanın ilk bölümünde, veri setlerindeki kaymaların tespiti ve tahmini için makine öğrenimi algoritmaları ile eğitilmiş regresyon modeli kullanılmıştır (Zenisek et al., 2019).

Bakım uygulamaları, sektördeki rekabet üzerinde doğrudan ve derin bir etkiye sahiptir. Veri üretenin makina ve ekipmanların sürekli izlenmesini gerektirir. Metalurji endüstrisinden alınmış olan verileri inceleyen bir çalışmada kestirimci bakım tahminleme çalışması yapılmıştır (Fernandes et al., 2019). Dalzochio et al., 2020 yılındaki çalışmada, endüstri 4.0 ile birlikte kestirimci bakım alanının önemi üzerinde durulmuştur. Konuya ilişkin çalışmaların son yıllarda yoğunlaştığını fakat bu konunun açıklığı kavuşması için üzerinde çok daha fazla çalışılması gerektiğini

vurgulamaktadır. Maliyetler, arıza nedenli duruşlarda yaşanan kayıpları da göz önüne alındığında konunun ehemmiyeti bir kez daha gün yüzüne çıkmaktadır. Gohel et al., 2020 yılında yaptığı çalışmasında, kestirimci bakım konusunu nükleer bir tesiste ele almıştır. Nükleer alt yapı sistemlerinin ulusal güvenlik, hükümet, işletmeler, toplum ve vatandaşların yaşamları için önemini vurgulayan çalışmada, kestirimci bakım tahminlemesinde destek vektör makinesi ve lojistik regresyon algoritmaları kullanılmıştır. İşletme ve bakım maliyetlerini azaltmak amacıyla geliştirilmiş başka bir model, yeni bir kestirimci bakım yaklaşımı önermektedir. Bu model Referans Mimarisi Modeli Endüstri 4.0 (RAMI4.0)' dayalı olarak geliştirilmiştir. Çalışmada yenilikçi bir İş Süreci Modeli ve Gösterimi (BPMN) oluşturmak için gerçek zamanlı üretim izleme, iş süreçleri ve Tasarım Bilimi Araştırmasına (DSR) dayalı entegrasyondan bahsedilmiştir. Model; uydu TV, kablolu TV, canlı ses ve video yayın hizmetleri gibi görsel-işitsel hizmetlerin bakım maliyetini azaltmakta kullanılmıştır (Sahba et al., 2021).

Amram et al., 2021 yılında yaptığı çalışmada, bir veri merkezindeki sabit disk arızaların önceden tahminlenmesi hedeflemiştir. Tahminlemede kullanılan verilerin anlaşılabilirliğinin geliştirilmesi üzerinde durmuştur. Çalışmada, yorumlanabilir makina öğrenmesi algoritmaları olarak adlandırılmış olan Optimal Sınıflandırma Ağacı ve Optimal Hayatta Kalma Ağacı modellerini kullanılmıştır. Çalışmada hem sabit disklerin uzun vadeli sağlığını değerlendirilmiş hem de kısa vadeli arızaları tahminlenmesi yapılmıştır. İnsanların dijital entegrasyon asistanları (DIAs) ile kestirimci bakım süreçlerine hibrit olarak dahil olması üzerine bir çalışılma yapılmıştır. Yapılmış olan çalışmada işletmelerin kestirimci bakımda, DIA'ları akıllı hoparlörler, tabletler, akıllı telefonlar, masaüstü bilgisayarlar ve karma gerçeklik uygulamaları gibi farklı donanımlarda kullanabileceği öne sürülmüştür (Wellsandt et al., 2021).

Destek vektör makinaları yaklaşımlarının kullanıldığı diğer bir alanda bakım alanıdır. Bakım süreçlerinin güvenliğini arttırmak için yapılan bu çalışmada Naive Bayes sınıflandırıcıları, destek vektör makineleri ve ağaç tabanlı modeller dahil olmak üzere farklı modeller kullanılmıştır. Planlı bakımlar sırasında meydana gelen beklenmedik durumlara karşı önlem alınması gerektiğini savunan çalışma, bu durumların sonucunu

hızlı ve güvenilir bir şekilde tahmin etmek için makine öğrenimi modellerinden yararlanmıştır (Toubeau et al., 2022).

Arena et al., 2022 yılında, kestirimci bakım uygulamalarında, karar verme sürecinde karar ağaçlarının kullanıldığı bir çalışma yapılmıştır. Çalışma kapsamında her seviye için, en uygun bakım stratejisi uygulamasının sağlanmasına yönelik, ağaçların yaprak düğümlerinde tasarruflar ve potansiyel maliyetler değerlendirilmiştir. Geliştirilmiş model gerçek bir üretim tesisinde uygulanmış ve sonuçları gözlemlenmiştir. Çalışmada makina öğrenmesi temelli kestirimci bakımın karlılık sağladığı sonucuna ulaşılmıştır.

Sinyallerin hızla değiştiği nükleer santrallerde denetimsiz yöntemler kullanılarak sinyal doğrulama çalışması yapılmıştır. Çalışmada kullanılan algoritma üç tür sinyal arızasını algılamak için optimize edilmiştir. Bunlar; yüksekte takılma, düşüğe takılma ve olduğu gibi takılmadır. Çalışmanın sonuçları sinyallerin durumunu doğru bir şekilde algılayabildiğini göstermiştir (Choi et al., 2022).

Barua & Zou, 2021 yılında yaptıkları çalışmalarında, hava alanlarındaki bakım ve rehabilitasyon (M&R) çalışmalarının planlanmasında, makina öğrenmesi temelli bir yaklaşımın önermişlerdir. Çalışmada denetimli öğrenme algoritmalarından yararlanılmıştır. Chicago O'Hare Uluslararası Havaalanında gerçekleştirilen çalışmada Pekiştirmeli Öğrenme (RL) yöntemlerinden olan Q öğrenme algoritması kullanılmıştır. Çalışmanın sonucunda maliyeti büyük ölçüde azaltacak bir sonuca ulaşılmıştır.

Literatür incelendiğinde örnek veriler kullanılarak tahminleme yapılması çalışmalarında yapay zeka yöntemlerinden olan makina öğrenmesine sıklıkla yer verildiği görülmüştür (Güven et al., 2021). Kestirimci bakımda, tahminleme yapılması gereken kritik konuların başında gelmektedir. Literatüre bakıldığında söylenebilir ki; kestirimci bakım çalışmalarında çoğunlukla makina öğrenmesi algoritmaları tercih edilmektedir. Makina öğrenmesi algoritmaları arasında destek vektör makinalarının verdiği sonuçların doğruluk değerinin yüksek olması tercih edilebilirliğini arttırmaktadır. Buna ek olarak işlenen verilerin cinsine göre karar ağaçları ve rasgele

ormanlar algoritmaları da kestirimci bakım konusunda tercih edilen algoritmalar arasında yerini almaktadır.

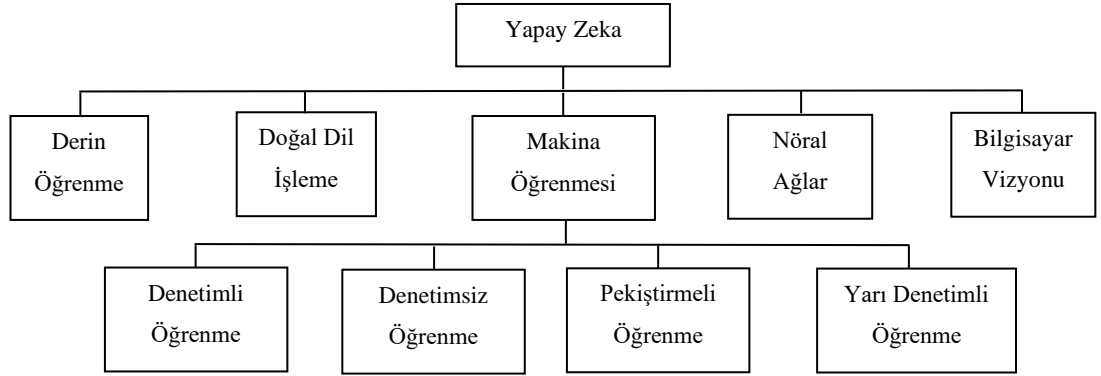
Kestirimci bakıma ilişkin literatür tarandığında, konunun öneminin ve kazancının çok fazla olduğu ama bu konudaki akademik çalışma sayısının çok sınırlı olduğu tespit edilmiştir. Bu konuya eğilimin endüstriyel anlamda sağlayacağı kazancın büyük olacağı ön görülmektedir. Buna ek olarak günümüzün kritik konularından olan yapay zeka ve yapay zeka yöntemlerinin kestirimci bakım problemlerini çözmede kullanılması problem sonuçlarının doğruluğu açısından önemlidir. Literatürde yapay zeka yöntemlerinin kullanıldığı çalışmalar mevcut olmasına karşın, kestirimci bakım problemlerinin yapay zeka yöntemleri ile çözüldüğü kaynak sayısı sınırlıdır. Yapay zeka yöntemlerinden olan makina öğrenmesinin de bu konuda önemi ortadır.

Literatür incelendiğinde demir çelik sektöründe kestirimci bakım çalışmasının çok sınırlı sayıda olduğu görülmüştür. Metal sektöründe bazı alanlarda tahminleme çalışması yapılmış olsa bile, demir çelik endüstrisinde, sıcak haddehane de kestirimci bakıma ilişkin çalışma sayısı literatürde yetersiz olduğu görülmüştür. Literatürde bulunan kestirimci bakım çalışmaları incelendiğinde, çoğunlukla titreşim ve sıcaklık verisinin kullanıldığı tespit edilmiştir. Bu çalışmada titreşim verisine ek olarak motor Revolutions Per Minute- RPM değeri ve akıma da yer verilmiştir. Yapılmış olan bu çalışmanın, demir çelik sektöründe, sıcak haddehane de kestirimci bakım çalışmasına yönelik kaynak oluşturması itibari ile literatüre sağlayacağı düşünülmektedir.

BÖLÜM 3

MAKİNA ÖĞRENMESİ

Gelişen teknoloji ile beraber makina öğrenmesi günümüzün çok ilgi çeken konularından biri haline almıştır (Fradkov, 2020). Bakımdan, üretime, satıştan, robotiğe kadar birçok alanda toplanan veriler makina öğrenmesi algoritmaları ile anlamlandırılıp yarar sağlanmaya çalışılmaktadır. Şekil 3.1’de gösterildiği gibi makina öğrenmesi yapay zekanın bir alt dalı olarak kabul edilmektedir (Ramachandran et al., 2022). Yapay zeka çalışmalarının paralelinde ortaya çıkmış bir alandır. Makina öğrenmesi, yapay zeka yaklaşımlarında olduğu gibi insanı örnek alır. Verileri ve algoritmaları insan öğrenme şeklini taklit etmek için kullanır.



Şekil 3.1. Yapay zeka ve makina öğrenmesi ilişkisi.

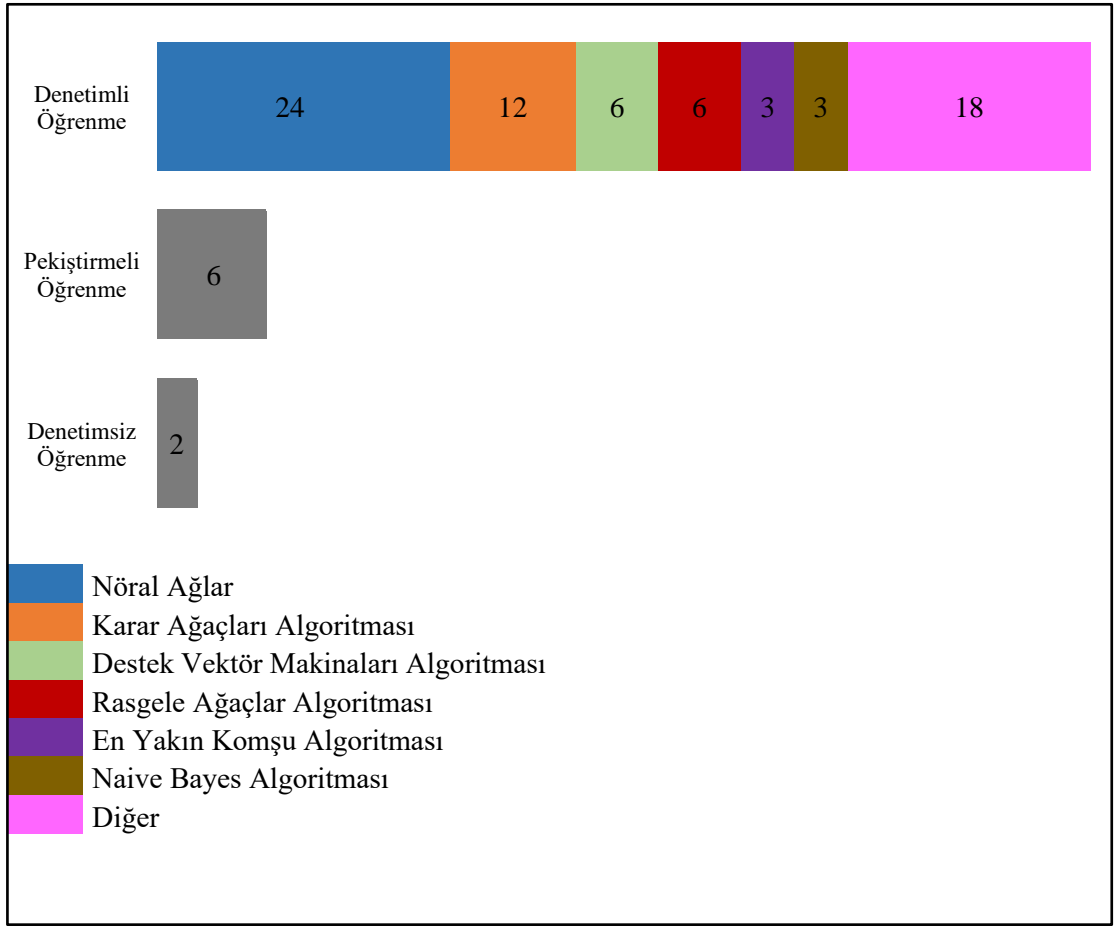
İnsan ve hayvanlarda olduğu gibi bilgisayarların deneyimlere dayalı öğrenmesine makina öğrenmesi denir. Makina öğrenmesi veriler arasındaki ilişkiyi ortaya çıkarmaya ve bu ilişkiden geleceğe yönelik tahminlerde bulunmaya çalışır. Günümüzde verinin öneminin artmasına bağlı olarak makina öğrenmesinin de önemi artmıştır. Makina öğrenmesinin çözüm geliştirdiği problem konuları; finans, görüntü

işleme, enerji üretimi, otomotiv, hayvancılık, tıp gibi çeşitli alanlarda olabilir. Görüldüğü gibi makina öğrenmesi yöntemlerinin kullanım alanı çok geniştir.

Yapay zeka ve makina öğrenmesi yöntemlerinin kullanımının yaygınlaşması insan iş gücüne duyulan ihtiyacı önemli ölçüde azaltmıştır (Patel & Shah, 2021). Artık işletmelerde birçok işi yazılımlar aracılığıyla yönetilen akıllı robotlar gerçekleştirmektedir. İnsandan kaynaklı verimsizlik ve yanlış üretimin büyük ölçüde önüne geçilmiştir. Uzun çalışma saatlerinin ardından insanda meydana gelen performans kaybına bağlı oluşacak hatalar önlenmiştir. Tehlikeli işlerde insanlar yerine yapay zekanın çalışması güvenlik riskini büyük ölçüde ortadan kaldırmaktadır. Karar verme süreçlerinde büyük veri setlerini işleyen makina öğrenmesi yöntemleri daha doğru kararları, duygulardan uzak, daha realistik ve daha kısa sürede verebilmektedir.

Bunun yanında yapay zeka ve makina öğrenmesi yöntemlerinin gelişmesinin getirdiği bazı dezavantajlarda bulunmaktadır. Koşulsuz bunun başında işsizlik gelmektedir. İnsan gücüne dayalı işlerin büyük çoğunluğunu robotların yapmaya başlaması, insan gücüne duyulan ihtiyacın azalması işsiz kalan insan sayısının artmasına sebebiyet verecektir. Bunun haricinde yapay zekalı makinaların kullanımı, satın alınması, bakımı maliyet açısından çok yüksektir. Ciddi arızalarda kayıp kodları bulmak ve sistemi eski haline getirmek büyük maliyetlere sebebiyet verecektir.

Makina öğrenmesi geçmiş verileri işleyerek, gelecekte meydana gelebilecek verileri tahminleyen modeller oluşturmak için çok çeşitli algoritmalar içerir (Arumugam et al., 2022) . Makina öğrenmesi model geliştirilme sürecinde büyük ölçekli veri kümelerini kullanır (Paullada et al., 2021). Makina öğrenmesi temelde üç ana konuya ayrılmaktadır. Bunlar denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmesidir. Şekil 3.2’da literatürdeki makina öğrenmesi çalışmaları kullandıkları yöntemlere göre sınıflandırılmıştır. Yapılan sınıflandırmada çalışmaların çoğunun denetimli öğrenme üzerinde olduğunu göstermektedir (Fahle et al., 2020).



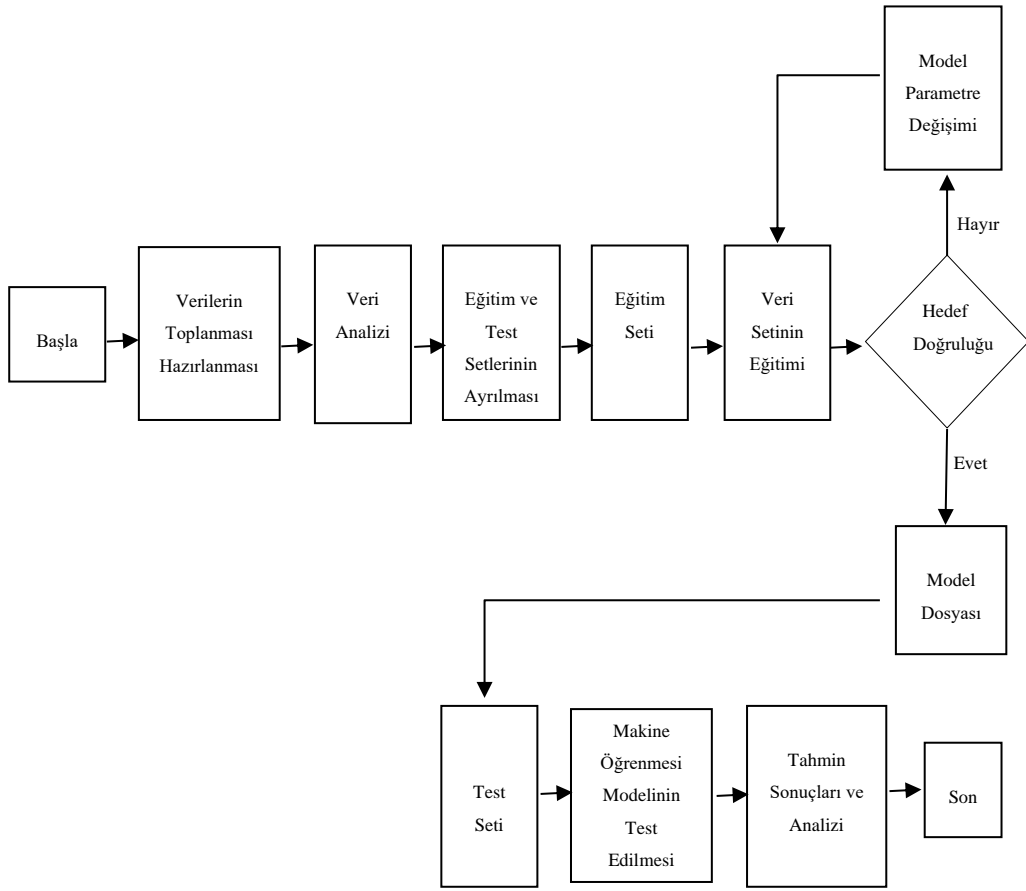
Şekil 3.2. Literatürün makina öğrenmesi konusunda sınıflandırılması.

3.1. MAKİNA ÖĞRENMESİ YÖNTEMLERİNİN AŞAMALARI

Her geçen gün sahip olduğumuz veri sayısı artmaktadır ve artmaya devam edecektir. Veri sayısının bu denli artması verilerin işlenebilirliğini daha da zorlaştırmaktadır. Tam da bu noktada veri işleyen algoritmaları olan ihtiyaç gün yüzüne çıkmaktadır. Verilerden çıkarılan anlamlı bilgilerin sağladığı faydanın farkına varılmasıyla beraber makina öğrenmesi gibi veri işleyen yöntemlere olan talep de artmaya başlamıştır. Sahip olunan büyük verinin makina öğrenmesi algoritmalarında kullanılmasında Şekil 3.3'de gösterildiği gibi belirli aşamalardan geçilir.

- 1. Aşama** Verilerin toplanması: Alınan veriler excel formatında ya da metin dosyası formatında olabilir. Burada amaç öğrenmenin gerçekleşebilmesi için geçmiş verilerin toplanmasıdır. Makina öğrenmesinde veri çeşitli, yoğun ve hacimli olmalıdır.

2. **Aşama:** Verilerin Hazırlanması: Makina öğrenmesinde kullanılacak verinin kalitesinin yüksek olması gerekmektedir. Verilerin tutarlılığı ölçülmeli ve varsa eksikler giderilmelidir. Toparlanan veriler işlenebilir hale geldikten sonra verilerin %80'i öğrenme modeli için kullanılırken %20'si değerlendirme adımı için kullanılmalıdır.
3. **Aşama:** Model Seçimi: En uygun algoritma ve veri gösterim şeklinin seçildiği aşamadır. Bazı modeller görsel verileri işlemekte daha iyidir, bazı modeller sayısal verileri bazıları ise metin verilerini. Veri setine en uygun modelin seçimi gerçekleştirilmelidir.
4. **Aşama:** Modelin Eğitimi: Verilerin seçilen model ile eğitiminin yapıldığı kısımdır. Makina öğrenmesinin kalbi denilebilir.
5. **Aşama:** Modelin Değerlendirilmesi: Bir modelin seçilip eğitildikten sonra ne tepki verdiğinin kontrol edildiği aşamadır. Bu aşamada ikinci adımda bahsedilen %20'lik veri seti kullanılır. Bu aşamada çıkarılacak sonuca göre ya bir sonraki aşamaya geçilir ya da bir önceki adıma geri dönülür.
6. **Aşama:** Parametrelerin Ayarlanması: Modelin parametrelerinde ufak değişiklikler yapılarak sonuçlarda farklılaşmalar sağlanır. Model yeniden eğitilir ve daha detaylı hassas tahminlemeler yapılması hedeflenir. Doğru tahminleme için önemli adımların başında gelir.
7. **Aşama:** Tahmin: Bu aşamada model kendi kendine tahminde bulunabilmektedir (Ashok Mahant & Pellakuri, 2021).



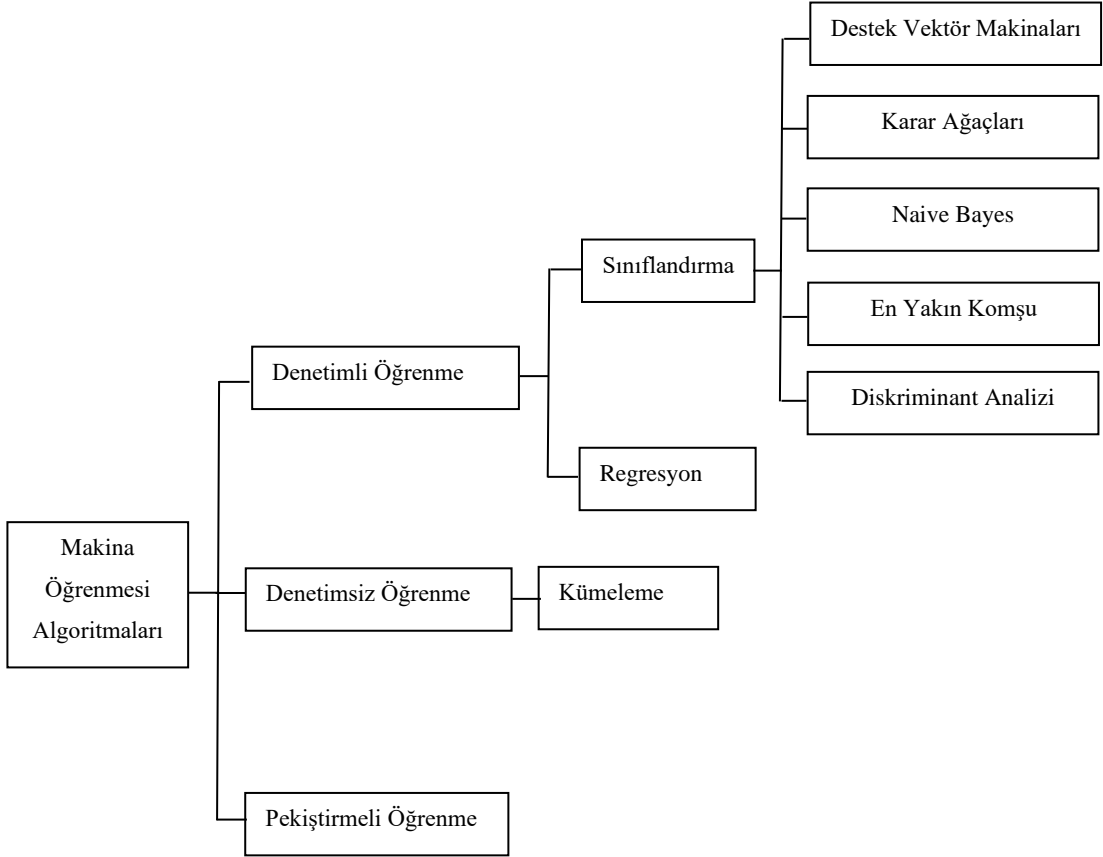
Şekil 3.3. Makine öğrenmesi akış şeması.

3.1.1. Veri Normalizasyonu

Makine öğrenimi algoritmalarında önemli işlemlerin başında veri yelpazesinin standart hale getirilmesi gelir. Normalizasyon olarak adlandırılan bu işlemde veriler Min-maks ölçekleme olarak da bilinen; $[0, 1]$ veya $[-1, 1]$ aralığında sabitlenir. Veriler normalleştirilmesi için verilerin minimum değeri ile orijinal değeri arasındaki fark hesaplanır. Ardından bu fark maksimum veri ile minimum arasındaki farka bölünür. Bu şekilde veri normalizasyonu gerçekleştirilir (Koranga et al., 2022).

3.2. MAKİNA ÖĞRENMESİ ALGORİTMALARI


Makina öğrenmesi bazı araştırmacılara göre denetimli ve denetimsiz öğrenme olarak ikiye ayrılırken, bazı araştırmacılarca makina öğrenmesi algoritmaları üç ana başlık altında toplanmıştır. Bunlar; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak sıralanabilir (Ashok Mahant & Pellakuri, 2021). Bazı araştırmacılar ise makina öğrenmesi algoritmalarını dört ana başlık altında toplamışlardır. Bunlar denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenmedir (Arena et al., 2022) . Bu çalışmada, makina öğrenmesi algoritmaları Şekil 3.4’de gösterildiği gibi üç ana başlık altında incelenmiştir.




Şekil 3.4. Makina öğrenmesi algoritmaları gösterim tablosu.

Denetimli öğrenme bir kişi tarafından manuel olarak eklenen verilerden öğrenme gerçekleştirir. Buna karşılık denetimsiz öğrenme verileri algoritmik olarak analiz eder, insan yardımı olmadan öğrenme işlemini gerçekleştirir. Şekil 3.5’de denetimli bir

yaklaşım örneği gösterilmiştir. Burada veri noktaları iki ayrı renktedir. Modelin (kesik çizgi) takılmasına izin verilir. Şekil 3.6'da denetimsiz bir yaklaşım örneği gösterilmiştir. Buradaki algoritma verilerdeki kalıpları (kümeler; kesikli çizgi) tespit etmeye çalışır (Yakimovich et al., 2021).



Şekil 3.5. Denetimli öğrenme tasviri.



Şekil 3.6. Denetimsiz öğrenme tasviri.

3.2.1. Denetimli Öğrenme

Makina öğrenmesinin kapsamlı bir dalıdır. Yüksek boyutlu girdi verilerini kullanarak öğrenme işlevini gerçekleştirir. Arıza teşhisi, nesne algılama, metin işleme gibi birçok alanda kullanılmış ve başarı elde edilmiştir (Zhou et al., 2021). Denetimli öğrenme genellikle denetimsiz öğrenmeye göre daha doğru ve basittir (Choi et al., 2022). Denetimli öğrenme tekniğinde, tahminleme yapılması için sınıflandırma ve regresyon teknikleri kullanılır.

3.2.1.1. Sınıflandırma Teknikleri

Sınıflandırma tekniği girdi parametrelerini sınıflara ayırır. Doğru mu yanlış mı, ekipman bozuk mu değil mi gibi yanıtlar öngörür. İşlenecek veriler sınıflandırılabilirse bu yöntem tercih edilmelidir. Sınıflandırma tekniği için çoğunlukla tercih edilen algoritmalar olarak; destek vektör makinesi (SVM), karar ağaçları, Naive Bayes, diskriminant analizi, lojistik regresyon, k-en yakın komşu ve sinir ağları sıralanabilir.

Destek Vektör Makinaları (SVM)

Günümüzde verilerin sınıflandırılmasında kullanılan birçok algoritma bulunmaktadır. Destek Vektör Makineleri (Support Vector Machine) çoğunlukla sınıflandırma problemlerinde kullanılır. Düzlemdeki noktaları doğru şekilde ayırmak için bir doğru çizer. Bu doğru iki sınıf verilerine de maksimum uzaklıkta olmalıdır. Karmaşık fakat küçük ve orta ölçekteki veri setlerinde daha başarılıdır. Destek vektör makinaları algoritması (SVM) son yıllarda sınıflandırma da güçlü algoritmalarından biri olduğunu kanıtlamıştır (Kumar & Gupta, 2021). Denetimli öğrenme yöntemlerinden biri olan destek vektör makinaları iyi bir sınıflandırıcı olarak kabul edilir ve birçok alanda kullanılmıştır. Konuşmacıların tanımlanması, izinsiz giriş tespiti, yüzlerin tespiti, yüz ifadelerin tanınması, beyin yaşı tahmini bunlardan bazılarıdır (Ganaie & Tanveer, 2021).

Klasik makina öğrenmesi algoritmalarının uygulanmasında belirli güçlükler bulunmaktadır. Bunların başında girdi, veri kümesinin büyük olmasına bağlı olarak, tek seferde tüm verilerin işlenmesinin mümkün olmaması gelmektedir. Bu denli büyük bir veri ile karşılaşıldığında verilerin uygun bir şekilde sınıflandırılması önemli noktalardan bir olarak karşımıza çıkar (Tukan et al., 2021). Bu noktada veri sınıflandırmasında kendini kanıtlamış bir yaklaşım olan destek vektör makinaları algoritması önem kazanır.

Karar Ağaçları

Karar ağacı veri madenciliği algoritmalarından biridir. Basit tanımlama, hızlı sınıflandırma, kolay görselleştirme gibi fonksiyonları vardır. Büyük ölçüdeki verilerde kullanılabilir. Karar ağacının veri işleme sürecinde uygulanması ve anlaşılması kolaydır (Ren et al., 2022). Karar ağaçları, sınıflandırma ve tahmin amacıyla kullanılacak veri kümeleri ile ilgili, anlaşılabilir kurallar üretir. Bu teknik hastalıkların tahminlenmesi ve kazaların tahminlenmesi gibi alanlarda sıklıkla kullanılır(Ren et al., 2022) . Karar ağacı algoritması, ağaca benzeyen görsel yapısı, grafik yapısından oluşması ve bunlara bağlı olarak kolay anlaşılması nedeniyle sıklıkla tercih edilen yöntemlerden olmuştur (Shanthi et al., 2022).

Naive Bayes

Makine öğrenimi yüksek doğruluk elde etmek için kullanılacak efektif yöntemlerden biridir. Veri sınıflandırmasında ise Naive Bayes yüksek bir doğruluğa sahiptir (Yudhana et al., 2021). Temelde istatistiksel olarak Bayes teoremine dayanan naif bayes sınıflandırma algoritmasının babası Matematikçi Thomas Bayes'dir. Temel işlevi sınıflandırma/ kategorilendirme yapmaktır. Siteme sunulan verileri inceler ve kategorileme yapar. Sisteme öğretecek veri binary ya da text formatında olabilir. Sonuçlarda binary formatında alınabilir.

Diskriminant Analizi

Diskriminant analizi, farklı parametreleri eş zamanlı olarak inceleyen ve parametrelerin gruplandırılmasını yapan istatistiksel bir metottur. Gelişmiş ve araştırmacılar tarafından sıklıkla tercih edilen bir metottur (Mohammadi-Moghaddam & Firoozzare, 2021).

En Yakın Komşu

Belirlenen hedef noktana en yakın mesafedeki noktayı bulmak, en yakın komşu arama modeli olarak adlandırılır. Veri madenciliği, makina öğrenmesi, robotik gibi birçok

alanda yaygın olarak kullanılır (Chatterjee et al., 2021). En basit makina öğrenmesi algoritması olarak kabul edilen en yakın komşu algoritması, diğer denetimli öğrenme algoritmalarının aksine eğitim aşamasına sahip değildir. Tembel bir öğrenme şekli olarak adlandırılan yöntemde eğitim ve test neredeyse aynı şeydir. Bu nedenle geniş veri kümelerinin işlenmesi için uygun bir yöntem olmadığı kabul edilir.

3.2.1.2. Regresyon Teknikleri

Belirli girdi parametrelerinden yola çıkarak bir sonucu tahminlemeye çalışan algoritmalarıdır. En sık kullanılan regresyon algoritmaları regülasyon, doğrusal model, doğrusal olmayan model, karar ağaçları, kademeli regresyon ve sinir ağları olarak sıralanabilir.

3.2.2. Denetimsiz Öğrenme

Bu yöntemde modelin kendi başına çalışmasına izin vermek gerekir. Denetimsiz öğrenme, denetlenmesine gerek olmayan bir makina öğrenmesi modelidir. Denetimsiz öğrenmede sisteme öğretilmez, sistem kendi kendine öğrenme işlemini gerçekleştirir. Temelde denetimsiz öğrenme, verilerimizden nasıl çıktılar elde edileceğine dair hiçbir fikir yürütülemediği ya da çok sınırdı şekilde fikir sahibi olduğu durumlarda kullanılır. Denetimsiz öğrenmede sadece veri vardır, başka bir bilgi mevcut değildir.

3.2.2.1. Kümeleme

Kümeleme denetimsiz öğrenme yöntemleri için önemli bir kavramdır. Kümeleme yöntemi veriler arasındaki doğal grupları bulur. Makina öğrenmesi yöntemleri arasında rağbet gören yaklaşımlardan biri de kümeleme yaklaşımıdır. Verilerin doğal kümeler oluşturduğunu savunan yöntem, grup sınırlarının düşük yoğunluklu bölgelerde olduğunu kabul eder (Bröker et al., 2022). Veri madenciliği yöntemlerinden biri olan kümeleme veri tabanlarındaki verileri gruplamak, ilişkili verileri aynı küme altında buluşturmak görevini üstlenmiştir.

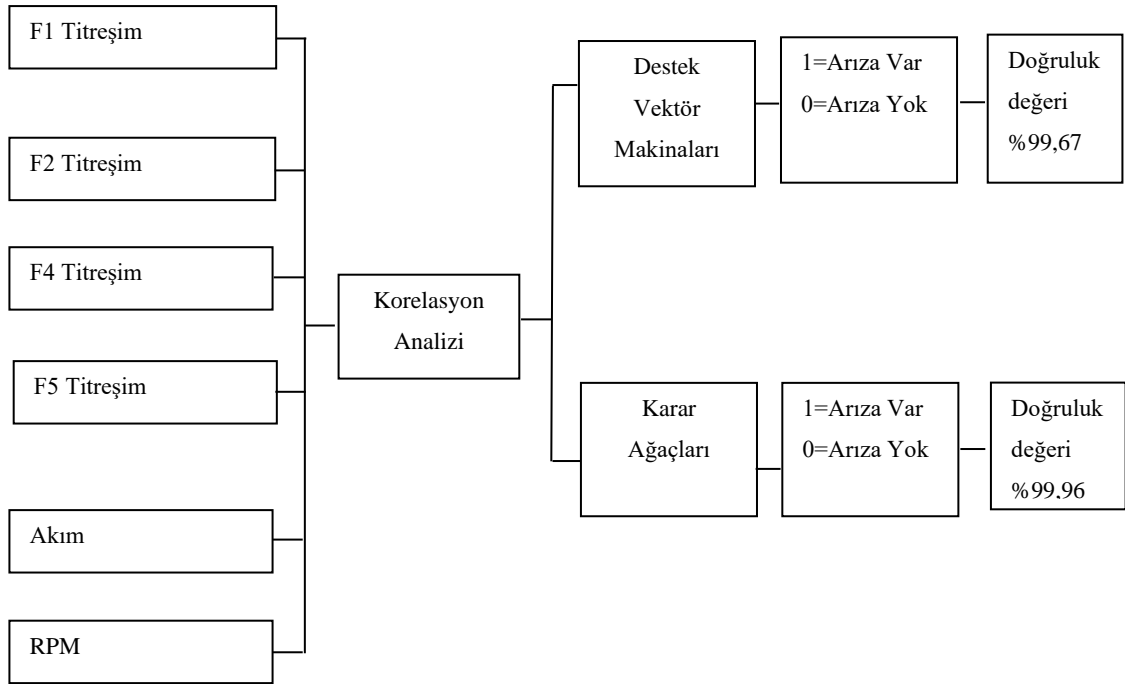
3.2.3. Pekiřtirmeli Öğrenme

Pekiřtirmeli öğrenme, denetimli ve denetimsiz öğrenme yöntemlerine göre karşımıza daha az çıkmaktadır. Diğer yöntemlere oranla daha az bilinmesinin nedeni kullanım alanının dar olmasıdır. Pekiřtirmeli öğrenme deneyimlerinden yola çıkılarak deneme yanılma yoluyla en iyi sonuca ulaşmayı hedefleyen makina öğrenmesi tekniğidir. Bu yöntemde ajan adı verilen, öğrenen bir makina mevcuttur. Bu makina karşılařtığı durumlara tepki verir bu karşılık ödül olarak adlandırılan sinyal alır.

BÖLÜM 4

UYGULAMA

İşletmelerde çok çeşitli bakım yaklaşımları uygulanmaktadır. Bakım, üretimde kullanılan makine ekipmanların performansında meydana gelen azalmaları ya da duruşları gidermek için yapılan faaliyetlerdir. Bakım yaklaşımı düzeltici bakım ve önleyici bakım olarak iki başlık altında incelenmektedir. Düzeltici bakım arıza meydana geldikten sonra müdahale etmeyi öngörürken, önleyici bakım arıza meydana gelmeden yapılan bakım işlemlerini kapsamaktadır.




Şekil 4.1. Akış diyagramı.

Günümüzde kaynak sıkıntısının artmasına bağlı olarak önleyici bakım yaklaşımları büyük ilgi görmeye başlamıştır. Önleyici bakım faaliyetlerinden olan kestirimci bakım

yaklaşımı, arıza meydana gelmeden önce, arızanın meydana gelmesi öngörülen noktalarda bakım yapılmasıdır ve günümüzde çokça rağbet gören bir konu haline almıştır. Kestirimci bakım, tahminlemeye dayanan bir yöntemdir. Tahminleme konusunda ise yapay zeka yöntemleri sıklıkla kullanılır hale gelmiştir. Yapay zeka yöntemlerinin bir alt dalı olan makine öğrenmesi kestirimci bakım konusunda efektif sonuçlar doğuran bir teknik olarak karşımıza çıkmaktadır. Makina öğrenmesi teknikleri birçok alanda sıklıkla kullanılan ve fayda sağlanan bir konudur.

Makine öğrenmesi; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana başlık altında incelenmektedir. Makina öğrenmesinin tahmine dayalı bakım uygulamalarıyla ilgili olarak; hata teşhisi, prognoz ve Kalan Faydalı Ömür (RUL) tahmini için sıklıkla kullanılmaktadır.



Şekil 4.2. Sıcak hadde tezgahı gösterimi.

Bu çalışma, demir çelik sektöründe faaliyet gösteren bir firmanın sıcak hadde tezgahlarında yapılmıştır. Finishing mil olarak adlandırılan ve haddeye giren slabın ilk olarak pasolar arasına girdiği bölümdür. Finishing mil de 7 adet merdane bulunur. Bunlar F1, F2, F3, F4, F5, F6, F7 olarak adlandırılır. Bu çalışma F1 pasosuna yerleştirilmiş olan sensörlerden alınan veriler ile, gelecekte meydana gelecek olan arızaları tahmin etmeyi amaçlamaktadır.

Uygulama yapılan firma demir çelik sektöründe faaliyet gösteren ve %100 yerli sermayeden oluşmuş olan holding boyutundaki bir firmadır. 1952 yılında Hatay iline

bağlı İskenderun ilçesinde faaliyet göstermeye başlamıştır. Çok küçük bir işletme olarak üretim hayatına başlayan işletme, günümüzde üç kıtada üretim yapan, yirmiye aşkın dev tesise sahip, yaklaşık 10.000 kişiyi istihdam eden Türkiye'nin en büyük sanayi kuruluşları arasında en ön sıralarda yerini almaktadır.

Yassı çelik üretiminde söz sahibi olan firma, ark ocağı tekniğini kullanmaktadır. Çalışma için firmanın Osmaniye tesislerinde bulunan sıcak haddehanesinde inceleme yapılmış ve hadde tezgahından veriler alınmıştır. 2009 yılında kurulmuş olan Osmaniye Tesisleri profil sac, filmaşın üretimi gerçekleştirmektedir.



Şekil 4.3. Uygulamanın yapıldığı işletme üretim sahasından bir görüntü.

4.1. ISO TİTREŞİM DEĞERLERİ TABLOSU

Doğadaki her canlı bedeni olumsuz değişiklik meydana geldiğinde tepki verir. Örneğin herhangi bir besin, besin değerini kaybettiğinde küflenir ve üzerinde yeşillenmeler meydana gelir. Ya da herhangi bir insan uzvu zarar gördüğünde kızarır, morarır ya da sahibine ağrı hissi verir. Aynı bunun gibi makinalarda arıza meydana gelmeden önce belirli uyarılarla, olacakları önceden haber verir. Makine ve ekipmanlarda meydana gelen uyarılar sıcaklık artması, titreşim miktarının yükselmesi, etrafa yaydığı gürültünün artması vb. şekillerde karşımıza çıkmaktadır. Bu nedenle çalışma yapılan

makine ekipmanı iyi dinlenmeli ve önlem alınmalıdır. Motorlar, pompalar gibi ekipmanlarda titreşim önemli bir yol gösterici olabilir.

	Makine		Küçük Makinalar Grup K	Orta Makinalar Grup M	Büyük Makinalar Grup G	Büyük Makinalar Grup G2
	In/s	mm/s				
Titreşim Hızı Vms	0.01	0.28	Çok İyi	Çok İyi	Çok İyi	Çok İyi
	0.02	0.45				
	0.03	0.71				
	0.04	1.12	iyi	iyi	iyi	iyi
	0.07	1.8				
	0.11	2.8	Dikkat	Dikkat	iyi	iyi
	0.18	4.5				
	0.28	7.1	Kabul Edilemez	Kabul Edilemez	Dikkat	Dikkat
	0.44	11.2				
	0.7	18				
	0.71	28	Kabul Edilemez	Kabul Edilemez	Kabul Edilemez	Kabul Edilemez
	1.1	45				

Şekil 4.4. ISO 10816-1 Titreşim standardı.

Tabloda gösterildiği gibi ISO 10816 Titreşim standardı, makine ve ekipmanları gücüne göre sınıflandırmış ve uygun titreşim aralıkları belirlemiştir (Dal & Morgül, 2006). K grubu makinalar, küçük makinalar olarak adlandırılırlar. Güçleri 15 kW'ın altında olan makinalardır. Bunlar küçük CNC tezgahlar, montaj makinaları vb. örnek olarak gösterilebilir. M grubu olan makinalar orta boy makinaları ve özel temel üzerine oturtulmuş makinaları kapsar. Orta boy makinaların gücü 15 kW ila 75 kW arasında değişen makinalardır. Özel temel üzerine oturtulmuş olan makinaların gücü ise 300 kW'ın üzerindedir. G grubu makinalar büyük makinalar olarak adlandırılan makinalardır (Engür,2016).

Çalışmada kullanılan verilerin alındığı makinanın harcadığı güç incelendiğinde yaklaşık olarak 275- 300 kw olduğu görülmektedir. Sıcak hadde tezgahları üretim sahasına kurulurken özel bir temele oturtulmalıdır. Yerin yüzeyi, aşınmaya karşı dayanımı göz önüne alınmalıdır. Yüksek tonaj ve güç altında çalışan makinaların kurulum aşamaları daha zahmetlidir. Bu da çalışmanın yapıldığı hadde tezgahını gruplandırmada bize yol göstermektedir. Makinayı gruplandırmada makinanın ne

kadar süredir kullanıldığı, şimdiye kadar verdiği arıza sayısı gibi parametrelerde dikkate alınmalıdır.

Makine gruplandırmaları incelendiğinde, çalışmanın yapıldığı makinanın M ya da G grubuna dahil olabileceği öngörülmektedir. Çalışmanın yapıldığı hadde tezgahı M Grubu makinalar arasında kabul edilmiştir. Bunun sebeplerinden biri G grubu makinalar kısıtlamasına göre analiz yapıldığında sonuçların anlamlı çıkmamasıdır. G grubu kriterleri kullanıldığında verilerden sadece titreşim değeri sonucu etkiler niteliktedir. Bu da doğru bir tahminleme yapılmasının önüne geçmektedir. Bu sebeple makine M grubu kabul edilmiş ve analizler ona göre yapılmıştır. Ayrıca makine on yılı aşkın süredir 7/24 esasına göre çalışmaktadır. Bu da titreşim değerlerin daha dikkatli dinlenmesinin önemli olduğu anlamına gelmektedir.

4.2. ÇALIŞMANIN KAPSAMI VE VERİ SETİ

Çalışma kapsamında F1 hadde pasosuna bağlı 4 adet titreşim sensöründen veriler alınmıştır. Üretim hattının dakika devir sayısı (RPM-Revolutions per Minute) ve akım değerleri de tahminleme de kullanılmıştır. Her bir sensörden yaklaşık 8100 adet veri kayıt altına alınmıştır. 4 adet titreşim sensörü, akım ve RPM değerleri de eklenince çalışmada yaklaşık olarak 50000 adet veri kullanılarak tahminleme gerçekleştirilmiştir. Veriler ISO titreşim tablosuna göre gruplandırılmıştır. Bu aşamada işletmeden de görüşler alınmış ve ölçüm yapılan anda arıza bildirimini oluşup oluşmayacağı kararlaştırılmıştır. Örnek veri seti tablosu aşağıda mevcuttur.

ISO 10816 Titreşim Standardına göre veriler analiz edilmiştir. Öncelikle ISO titreşim standardına göre makine gruplandırması yapılmıştır. Makinanın çalışma gücü, alınan veriler ve işletmenin yönlendirmesi ile çalışma yapılan makinanın M grubunda değerlendirilmesine karar verilmiştir. M grubu makinalar için belirlenen titreşim aralıkları şu şekildedir. 0 mm/s ile 1.12 mm/s titreşim aralığı kabul edilebilir aralıktır. 1.12 mm/s ile 2.8 mm/s titreşim aralığı izin verilebilir aralık olarak kabul edilmiştir. 2.8 mm/s titreşim üzerinde sorun başlamaktadır. Arıza meydana gelmeye yatkın süreci göstermektedir. ISO titreşim standardı 2.8 mm/s ile 7.1 mm/s titreşim aralığını tolere edilebilir olarak isimlendirmiştir fakat arıza meydana gelme noktasına çok yakındır.

7.1 mm/s üzerindeki titreşimler kabul edilemez olarak sınıflandırılmıştır. Bunun anlamı ya arıza meydana gelmiş ya da gelmek üzere demektir. Herhangi bir sensörden ölçülmüş olan titreşim değeri 2,8 mm/s'nin üzerinde ise arıza var, yani 1 olarak belirlenmiştir. Bunun nedeni mekanik aksamlarda meydana gelebilecek herhangi bir değişikliğin çok kısa süre içerisinde bütün aksama yayılmasıdır. Bu sebeple tespit edilebilecek tek bir anormal ölçüm hattın bakıma ihtiyaç duyabileceğini öngörmek için yeterlidir.

Veri alınan makine M grubuna dahil edilmiştir. İşletme ile de görüşülmüş ve 2012 yılında kurulmuş olan hadde tesisi, kullandığı teknoloji alt yapısı, makine ve ekipmanın durumu göze alınarak değerlendirilmiştir. Bu değerlendirmenin ardından 2,8 mm/s titreşim ve üzerinin makine yapısı için zararlı olacağı kararına varılmıştır. 2,8 mm/s titreşiminde bildirim almanın önemli ölçüde işletmeye yarar sağlayacağı kararlaştırılmıştır. Makinadan alınmış olan titreşim verileri 2,8 mm/s titreşim ve üzerinde uyarı verilmesi gerekecek şekilde gruplandırılmıştır. 2,8 mm/s titreşim ve üzerinde arıza var, 2,8 mm/s titreşim altında arıza yok şeklinde modelleme yapılmıştır. Verilerin sonuç ibaresinde arıza var durumu 1, arıza yok durumu ise 0 olarak ele alınmıştır.

Çizelge 4.1. Çalışmada kullanılan verilerin bir bölümü.

Akım	F1 Titreşim	F2 Titreşim	F4 Titreşim	F5 Titreşim	RPM
346.80	4.0057	2.5718	2.5704	1.7260	363.2500
348.25	4.0895	2.5226	2.6544	1.8795	365.2250
348.90	4.4025	2.6962	2.8078	1.8428	365.2250
348.60	4.4654	2.7355	2.7125	1.8075	367.1000
348.25	4.3929	2.6069	2.6653	1.9855	367.2250
348.00	4.5761	2.7812	2.7617	2.0824	368.3250
348.88	4.6448	2.8928	2.9608	2.2150	370.0000
348.13	4.4879	2.7993	2.7309	2.1705	369.9000
347.95	4.7512	2.9489	3.0462	2.2107	369.8500
347.18	4.6689	2.9149	3.0111	2.1410	369.9000
347.50	4.7107	2.9225	2.8447	2.0508	371.0250
346.65	4.6810	3.0440	2.9047	2.2338	370.6000
347.28	4.8032	2.9015	2.9404	2.2743	371.5500
348.00	4.8340	2.9132	2.8563	2.0873	370.5000
348.00	4.8192	2.7271	2.8056	2.2220	371.2500
348.10	4.8192	2.8181	3.1337	2.1571	370.5000
347.55	4.7844	3.0519	2.9803	2.1924	370.0000
347.75	4.5875	2.8724	2.7995	2.1175	367.8750
346.35	4.6604	2.9013	2.8505	2.1289	368.7500
346.80	4.8553	2.8252	2.8885	2.1342	368.5250
346.70	4.5703	2.6722	2.7252	1.9696	369.0000
346.70	4.8805	2.8452	3.0425	2.0486	368.2750
345.23	4.8098	2.8973	2.9858	2.2181	368.7250
346.05	4.7215	2.8315	2.8212	1.9833	368.2750
346.38	4.5595	2.8977	2.9868	2.2441	368.3750
346.00	4.6050	2.8810	2.9346	2.3510	367.4000
346.18	4.4604	2.8044	2.7026	2.1935	366.7750
346.63	4.4079	2.8002	2.8480	2.1944	367.2000
347.00	4.4029	2.7244	2.7738	2.1729	367.1000
346.75	4.3177	2.7186	2.7579	2.0870	367.3750
347.00	4.4582	2.7002	2.8610	2.1175	367.0750
347.33	4.2835	2.6121	2.6906	2.0253	368.0000
347.48	4.2101	2.6830	2.8438	2.1792	367.5250
347.18	4.3392	2.7011	2.9008	2.2287	368.8500
348.38	4.3538	2.6649	2.7850	1.9322	368.2250
348.80	4.3651	2.7071	2.7385	2.1743	368.3750
349.08	4.3945	2.8414	2.5805	2.1965	367.5500
349.00	4.5929	2.9360	2.8530	2.0370	368.1250

Çizelge 4.1. (devam ediyor).

Akım	F1 Titreşim	F2 Titreşim	F4 Titreşim	F5 Titreşim	RPM
305.00	4.6993	2.7584	2.6338	2.1499	367.6000
305.00	4.7135	2.9000	2.7290	2.1535	368.0000
305.00	4.6890	2.9076	2.7519	2.0795	368.8500
305.00	4.6427	2.8915	2.7351	2.0542	368.4250
305.00	4.6996	3.0400	2.8762	2.1510	368.8000
305.00	4.4591	2.9557	2.8143	2.1407	369.6000
305.00	4.5949	3.0782	2.6950	2.4324	369.8250
305.00	4.7758	3.0035	2.6830	2.2235	370.3000
305.00	4.5289	2.9414	2.8344	2.0533	370.7250
305.00	4.2815	2.7771	2.7375	2.0436	370.8500
305.00	4.5703	2.8932	2.6993	1.9510	370.4250
305.00	4.7284	3.1724	2.7937	2.1184	370.3500
305.00	4.6720	2.9545	2.7668	1.9407	370.0000
305.00	4.5334	2.9051	2.7901	2.0685	370.2000
305.00	4.6616	3.0521	2.9049	2.2436	370.1250
305.00	4.7414	3.0216	2.8492	2.1942	370.1250
303.30	4.8304	3.1335	2.8782	2.1275	369.5250
299.48	4.8412	3.0756	3.1740	2.2204	369.5000
296.75	4.5405	2.9919	2.8819	2.1466	369.4250
297.50	4.4314	2.8550	2.7078	2.1116	368.1750
297.28	4.4112	2.9664	2.9536	2.1289	368.4000
297.48	4.5504	3.0324	2.7051	2.1018	368.2500
297.20	4.4336	2.9011	2.6530	2.0443	368.0000
297.50	4.2907	2.8521	2.6300	2.0155	368.5250
297.35	4.4938	2.9905	2.6892	1.9987	368.3500
297.43	4.4148	3.0147	2.6872	2.1616	368.8750
297.23	4.6275	2.9792	2.8830	2.1342	368.7250
297.43	4.6367	3.0955	2.8666	2.0982	368.5000
297.83	4.5602	3.0002	2.6693	1.9797	368.3000
297.13	4.3967	2.9711	2.6667	2.0470	368.1500
303.85	4.6105	3.0129	2.8074	2.2559	369.0000
307.73	4.6222	3.0252	2.7472	2.1278	368.7500
301.38	4.6381	2.9610	2.5980	2.1560	369.0000
300.60	4.7070	2.9270	2.8816	2.2683	369.0000
299.73	4.7403	2.8903	2.8154	2.1540	369.6000
299.20	4.8758	3.1742	2.6700	2.1588	369.7000
301.65	4.9714	3.2162	2.8429	2.3653	369.7000
295.48	4.7522	3.0420	2.9174	2.0965	369.4750
294.15	4.5674	3.0932	2.7570	2.1418	369.8000

4.3. VERİLERİN KORELASYONU

Korelasyon analizi verilerin birbirini etkileme düzeyini ölçer. Çalışma yapılan makinadan alınmış olan 1 adet akım, 1 adet RPM ve 4 adet titreşim sensörüne ait verilerin birbiri ile korelasyonu SPSS programında ölçümlenmiştir. Verilerin matematiksel bağlantısı regresyon analizi ile ölçülürken, ilişki yönü ve ilişkinin düzeyi korelasyon analizi ile ölçülür. Korelasyon katsayısı ise bağımlı değişkenler ile bağımsız değişkenlerin arasındaki ilişkinin büyüklüğünü gösteren bir ifadedir. Korelasyon katsayısının 0'a yaklaşması, değişkenler arasındaki ilişkinin zayıflığını gösterir.

Korelasyon analizi, değişkenlerin birbiri ile beraber hareket edip etmediği, eğer beraber hareket ediyorlarsa ne düzeyde beraber hareket ettiklerini ölçen istatistiksel bir tekniktir. Korelasyon analizi yapılırken, verilerin normal dağıldığı varsayılmıştır bu nedenle pearson analizi yapılmıştır. Two tailed analiz yapılmıştır. Bunun anlamı dağılımın her iki tarafına bakarak korelasyon analizini yapmaktır. Verilerin birbiri ile ilişkisi ölçümlenmiştir.

Çizelge 4.2. Verilerin ortalama ve standart sapma değerleri.

Parametreler	Ortalama	Standart Sapma	Veri Sayısı
Akım	339.48	47.16	8116
F2Titreşim	1.93	1.03	8116
F4Titreşim	2.02	0.782	8116
RPM	323.9	56.681	8116
F5Titreşim	1.36	0.684	8116
F1Titreşim	3.06	1.591	8116

Tabloda görüldüğü üzere akım değerinin ortalaması 339.48, standart sapması 47.160 ve giriş yapan veri sayısı 8116'dır. F1 pasosundan alınan titreşim değerlerinin ortalaması 3.06, standart sapması 1.591 ve veri sayısı 8116'dır. F2 pasosundan alınan titreşim değerlerinin ortalaması 1.93, standart sapması 1.030 ve veri sayısı 8116'dır. F4 pasosundan alınan titreşim değerlerinin ortalaması 2.02, standart sapması 0,782 ve veri sayısı 8116'dır. F5 pasosundan alınan titreşim değerlerinin ortalaması 1,36,

standart sapması 0,684 ve veri sayısı 8116'dır. RPM değerinin ortalaması 323,9, standart sapması 56.681 ve veri sayısı 8116'dır.

Korelasyon tablosu incelendiğinde, çıkan sonuçların üzerinde iki yıldız bulunması ilişkinin anlamlı olduğunu ifade etmektedir. Korelasyon değerleri incelendiğinde akım ile F2 titreşimi arasında 0,276, akım ile F4 titreşimi arasında 0,237, akım ile RPM arasında 0,222, akım ile F5 titreşimi 0,261, akım ile F1 titreşimi 0,259 olduğu görülmüştür. F2 titreşiminin; akım ile 0,276, F4 titreşimi ile 0,975, RPM değeri ile 0,699, F5 titreşimi ile 0,991, F1 titreşimi ile 0,988 olduğu görülmektedir.

Korelasyon tablosu incelendiğinde ulaşılan sonuç şudur ki, akım, RPM, F1 titreşimi, F2 titreşimi, F4 titreşimi ve F5 titreşimi arasında anlamlı ve pozitif ilişki bulunmaktadır. Bu demek oluyor ki bir değişken artarken diğer değişken de artıyor. Akım arttıkça titreşim değerleri artmaktadır. RPM değeri arttıkça akım artmaktadır. Ya da tam tersi olacak şekilde sistem hareket etmektedir. Yani akım değeri azaldıkça titreşim değerleri ve RPM değeri buna bağlı olarak azalmaktadır. Veriler arasında pozitif ve olumlu bir ilişki vardır.

Çizelge 4.3. Korelasyon analizi tablosu.

Parametreler		Akım	F2Titreşim	F4Titreşim	RPM	F5Titreşim	F1Titreşim
Akım	Pearson Korelasyon	1	,276**	,237**	,222**	,261**	,259**
	Veri Sayısı	8116	8116	8116	8116	8116	8116
F2Titreşim	Pearson Korelasyon	,276**	1	,975**	,699**	,991**	,988**
	Veri Sayısı	8116	8116	8116	8116	8116	8116
F4Vibration	Pearson Korelasyon	,237**	,975**	1	,708**	,970**	,981**
	Veri Sayısı	8116	8116	8116	8116	8116	8116
RPM	Pearson Korelasyon	,222**	,699**	,708**	1	,696**	,663**
	Veri Sayısı	8116	8116	8116	8116	8116	8116
F5Titreşim	Pearson Korelasyon	,261**	,991**	,970**	,696**	1	,983**
	Veri Sayısı	8116	8116	8116	8116	8116	8116
F1Titreşim	Pearson Korelasyon	,259**	,988**	,981**	,663**	,983**	1
	Veri Sayısı	8116	8116	8116	8116	8116	8116

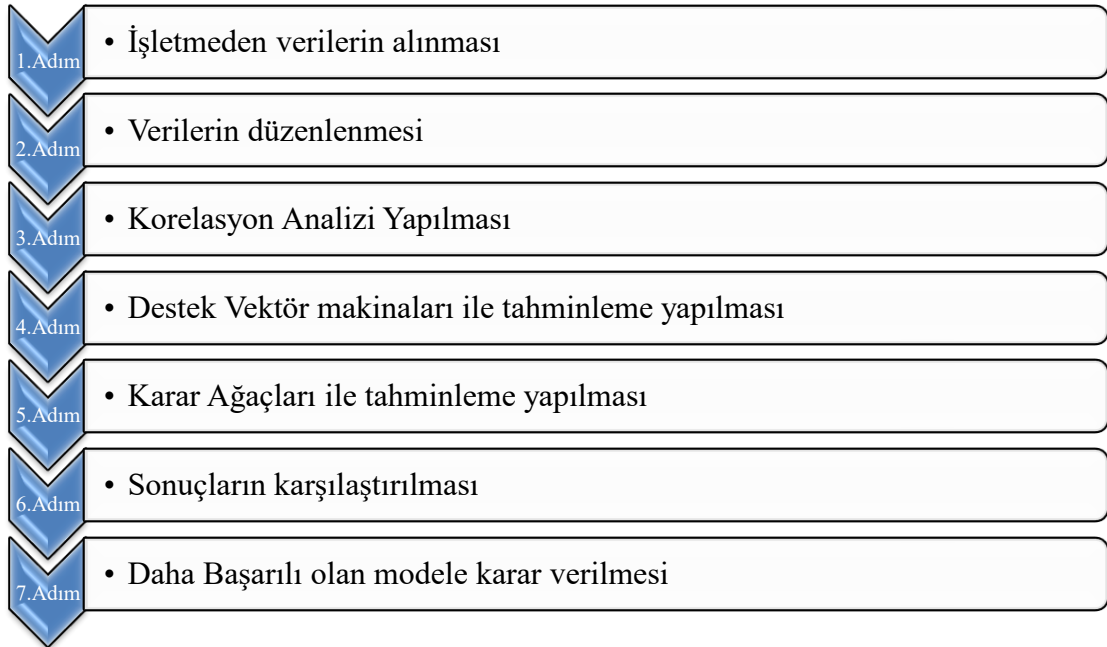
4.4. UYGULAMA ARAÇLARI

Problemin çözümünde R Studio programı tercih edilmiştir. İstatistiksel hesaplamalar ve analizler için sıklıkla tercih edilen bir analiz programıdır. Ayrıca yazılım ortamı olan R Studio Yeni Zelanda’da bir üniversitede geliştirilmiştir. S programlama diline benzemektedir. S programlama dilinin geliştirilmiş hali olarak da adlandırılmaktadır. Çoğunlukla istatistiki yazılım geliştirme ve programlama alanlarında kullanılmaktadır. R Studio, R dili için geliştirilmiş entegre bir geliştirme ortamıdır. R Studionun ticari sürümleri de mevcuttur fakat bu çalışmada ücretsiz olan versiyonu kullanılmıştır. Veri bilimi için modüler platformlara sahip olması, destek vektör makinaları, yapay sinir ağları, karar ağaçları, rasgele ormanlar gibi algoritmaların kütüphanelerinin bünyesinde bulundurulması, yaygın olarak kullanılması gibi nedenlerden ötürü çalışmanın yapıldığı Platform R Studio olarak seçilmiştir. Çalışmada R studionun 2022.02.1 versiyonu kullanılmıştır.

Yapılmış olan çalışmada R studionun belirli başlı kütüphaneleri kullanılmıştır. Bunlar e1071, caret, tidyverse kütüphaneleridir. E1071 kütüphanesi regresyon ve sınıflandırma modellerini bünyesinde bulunduran kütüphanedir. İçerisinde oldukça kıymetli istatistik modellerini barındırmaktadır. Bu çalışmanın ana bileşenlerinden olan destek vektör makinaları (Support Vector Machine) ve karar ağaçlarını (Gradient Boosting Machine) modelleri bu kütüphane içinde bulunmaktadır. Caret kütüphanesi de, regresyon ve sınıflandırma modellerinin öğretilmesinde kullanılan kilit bir kütüphanedir. Modelin öğrenme süreçleri için önem arz etmektedir. Model kapsamında standart pakette bulunan “plot” özelliği ile grafikler çizilmiştir. Buna ek olarak tidyverse koleksiyon paketine bağlı olan ggplot2 kütüphanesi de modele eklenerek daha kompleks ve görselliği yüksek grafikler kullanılmıştır. Modelde tanımlanmış olan kütüphanelerin R studiodaki gösterimleri şu şekildedir; `library(gbm)`, `library(ggplot2)`, `library(caret)`, `library(e1071)`.

4.4.1. Tahmin Analizi

Veriler işletmeden alındıktan sonra analizde ham haliyle kullanılamazlar. Verilerde ön bir temizlik ve düzenleme çalışması yapılması gerekmektedir. Bunun için alınmış veriler gözden geçirilmiş, eksik olan veri satırları silinmiş ve bu şekilde hatalı veriler ayıklanmıştır. Sonrasında verilerin birbirini etkileme oranları ve aralarındaki ilişkinin ölçümlenebilmesi için SPSS istatistik programında korelasyon analizi yapılmıştır. Ardından veriler destek vektör makinaları ve karar ağaçları algoritmaları ile işlenmiş ve tahminleme yapılmıştır. Yapılan işlemler adım adım aşağıdaki şekilde açıklanmıştır.




Şekil 4.5. Çalışmanın aşamaları.

Modellerin karşılaştırılmasını da doğruluk değerleri göz önüne alınmıştır. Modelin çalıştırılmasının ardından çıkan hatalı sonuçlar, modelin doğruluğa ne derece yakın olduğunu göstermektedir. Diğerlerine oranla doğruluk değeri yüksek olan model, sonuca en yakın değerleri tahminlemiş model olarak kabul edilir.

4.5. DESTEK VEKTÖR MAKİNALARI TAHMİN UYGULAMASI

Destek vektör makinaları genellikle sınıflandırma problemlerinde kullanılan bir makina öğrenmesi algoritmasıdır. Bir yüzeydeki iki ayrı cinse ait noktaları birbirinden ayırmak için kullanılır. İki ayrı sınıfa ait olan bu noktaların birbirinden olabildiğince uzak olmasını amaçlar. Sınıflandırma problemlerinde orta ve küçük ölçekli veri setlerinde yaygın olarak kullanılması, yorumlamaya açık oluşu nedeniyle bu çalışmada destek vektör makinaları algoritmaları tercih edilmiştir (García-Gonzalo et al., 2016).



Şekil 4.6. Verilerin destek vektör makinaları ile sınıflandırılması.

Verilerin destek vektör makinaları algoritmaları ile işlenmesinde R Studio programından yararlanılmıştır. Ve R programlama dili kullanılmıştır. Modelde kullanılan verilerin %70'i eğitim verisi olarak belirlenmiştir. Bu verilerde en iyi modelin seçimi için cross validation yapılarak performans testleri gerçekleştirilmiştir. Verilerin %30'u ise performansı ölçmek için test verisi olarak kullanılmıştır. Verileri normalize etmeye gerek yoktur. Modelin içindeki “preprocessing” yapısı verileri merkezileştirmekte ve maksimum, minimum normalizasyonu yapmaktadır.

Model kapsamında kullanılacak olan veriler, ISO 10816 Titreşim değerleri tablosunda belirtildiği gibi, M grubu makinalar için olan kısıtlar kapsamında işlenmiştir. M grubu

makinalarda titreşim değerinin 2,8 mm/s titreşime ulaşması arıza başlangıç eşiği olarak kabul edilmiştir. Modelde de arıza başlangıç eşiği 2,8 mm/s olarak ele alınmıştır. Modelde bu eşik belirlenmektedir. Modelde istenildiği zaman bu eşik değerinde değişiklik yapılabilir. Modelin sonucunda çıkacak olan veri değerleri 0, 1 olarak sınıflandırılmaktadır. Bu sebeple kurulan modelde sonuç kısmı için faktör dönüşümü yapılmıştır. Sonucun 0,1 değerlerini sahip olması nedeniyle destek vektör makinaları modeline girdilerin faktör olarak verilmesi gerekmektedir.

Modelde set seed olarak geçen kısım rasgele alınan değerlerin hep aynı yerde, aynı değer olarak alınabilmesini sağlar. Bu kod satırı, defalarca çalıştırılsa bile kodun aynı sonuçların alınmasını sağlar. Model sonucunda standartlaşmaya sebep olur. Normalde canlı sistemlerde bu kod satırı kullanılmaz bunun sebebi canlı sistemlerde anlık veri akışı sağlanmasıdır. Modellere birbirinden farklı veri girişleri olmaktadır. Bu çalışma üretim hattından alınmış olan örnek veri seti üzerinde gerçekleştirildiği için bu kod satırına ihtiyacımız vardır. Veri seti %70 ve %30 olmak üzere iki ayrı parçaya ayrılmıştır. Literatür incelendiğinde genellikle bu şekilde ayırım yapıldığı görülmüştür (Güven & Şimşir, 2020). Verilerin %70'i eğitim verisi, geri kalan %30 u ise test verisi olarak ayrılmıştır. Kodlamada %70'lik kısmın train, -indisli kısmın yani geriye kalan %30'luk kısmın test verisi olarak ayrıldığını görüyoruz.

Kodlamada cross validation olarak adlandırılan süreç işlemektedir. Burada %70 olarak ayrılmış olan eğitim verileri 10 eşit parçaya bölünmektedir. Bu 10 parçadan 9 adedi eğitim verisi, 1 adedi ise test verisi olarak ayrılmıştır. Bu durum her bir iterasyonda değişmektedir. Örneğin birinci iterasyonda 1 küme test kümesi iken, ikinci iterasyonda ikinci küme test kümesi olarak seçilmektedir. Cross validation bu şekilde çalışmaktadır.

4.5.1. Grid Arama

```
Support Vector Machines with Radial Basis Function kernel
5680 samples
 6 predictor
 2 classes: '0', '1'
```

Şekil 4.7. Modelin özellikleri.

Destek vektör makinaları algoritmalarında iki adet parametre bulunmaktadır. Bu parametreler hyper parameter olarak adlandırılır. Bu parametrelerden birincisi sigma ikincisi ise C'dir. C ceza puanı değerini ifade etmektedir. Kurulan model burada bahsi geçen sigma ve C ceza puanı değerinin optimal değerini bulmaya çalışmaktadır (Güven & Şimşir, 2020). Bu sebeple taguchi gibi bir modele ihtiyaç duyulmamaktadır. Şekilde gösterildiği gibi kurulan modelin detayına baktığımızda; modelin 6 tahmin edici, 2 sınıf ve 5680 örneğe sahip olduğu görülmektedir.

Kurulan modelde sigma değeri 0,1'den başlatılmıştır ve 2 ye kadar gitmektedir. Her bir iterasyonda 0,1 adet artmaktadır. C, ceza puanında ise 1'den başlatılmıştır ve 30'a kadar girmektedir. Her iterasyonda 2 şer olarak artmaktadır. Yani şu şekilde çalışmaktadır; sigma 0,1 için C ceza puanı değerini 1 almaktadır ve modeli çalıştırmaktadır. İterasyon sonucunda hata belirlemektedir. İkinci iterasyonda sigma hala 0,1 iken C ceza puanı değeri 2 arttırılır ve 3 olarak kabul edilir, model çalıştırılır ve hatası yakalanır. Bu şekilde C ceza puanı değeri 30 olana kadar devam edilir. C ceza puanı değeri 30'a ulaştıktan sonra, sigma değeri 0,1 arttırılır ve 0,2 olur. C ceza puanı değeri 1'den başlayarak her iterasyonda 2 arttırılır 30'a kadar devam edilir ve hatalar belirlenir. Bu şekilde aradaki tüm noktalarda hata değerleri belirlenir ve optimum nokta bulunmaya çalışılır.

Çizelge 4.4. Hata hesaplama denemeleri örnek tablosu.


Sigma	C	Doğruluk	Kappa
0.1	1	0.99683	0.99273
0.1	3	0.99701	0.99313
0.1	5	0.99701	0.99313
0.1	7	0.99701	0.99313
0.1	9	0.99701	0.99313
0.1	11	0.99736	0.99394
0.1	13	0.99736	0.99394
0.1	15	0.99736	0.99394
0.1	17	0.99736	0.99394
0.1	19	0.99736	0.99394
0.1	21	0.99754	0.99435
0.1	23	0.99754	0.99435
0.1	25	0.99754	0.99435
0.1	27	0.99754	0.99435
0.1	29	0.99754	0.99435
0.2	1	0.99701	0.99313
0.2	3	0.99701	0.99313
0.2	5	0.99718	0.99354
0.2	7	0.99736	0.99394
0.2	9	0.99754	0.99435
0.2	11	0.99754	0.99435
0.2	13	0.99754	0.99435
0.2	15	0.99754	0.99435
0.2	17	0.99754	0.99435
0.2	19	0.99754	0.99435
0.2	21	0.99754	0.99435
0.2	23	0.99736	0.99394
0.2	25	0.99736	0.99394
0.2	27	0.99736	0.99394
0.2	29	0.99736	0.99394
0.3	1	0.99701	0.99313
0.3	3	0.99701	0.99313
0.3	5	0.99736	0.99394
0.3	7	0.99754	0.99435
0.3	9	0.99736	0.99394

4.5.2. Kernel Metodu

Sınıflandırma yöntemlerinden bazıları doğrusaldır. Lojistik regresyon buna örnek olarak gösterilebilir. Bazı sınıflandırma teknikleri ise doğrusal değildir. Makine öğrenmesinin bir algoritması olan destek vektör makinaları ise doğrusal bir çizgi çizerek verileri sınıflara ayırmayı hedefler. Kernel metodu, doğrusal olarak ayrılamayan verilerin, doğrusal şekilde sınıflandırması sağlanır ve başarılı sonuçlar elde edilmeye çalışılır.

Çalışma kapsamında kullanılan method svmRadial dir. SVM destek vektör makinalarını ifade etmektedir. Radial ise kernel metodunu temsil etmektedir. Veriler düzgün dağılmadığında, normal olmadığında bu method sıklıkla tercih edilmektedir. Kodlamada geçen pre processing kısmı ise verinin normalizasyonunu yapmaktadır. Ekstra bir veri normalizasyonuna gerek kalmamaktadır.

4.5.3. Destek Vektör Makinaları Test Datası ve Tahmin Sonuçları Karşılaştırması



Şekil 4.8. Tüm parametrelerin kombinasyonu.

Cross validation, sigma diyagramına göre destek vektör makinalarında en iyi sonucu veren sigma değerinin 2 olduğu, en iyi sonucu veren C ceza puanı değerinin de 25 olduğu görülmüştür.

Tabloda test veri sonuçları bulunmaktadır. Tahmin sonuçları ile test data sonuçları karşılaştırıldığında, test verinin 0 olduğu 746 adet noktayı, kurulan model de 0 olarak doğru tahmin etmiştir. 4 adet noktayı ise 1 olarak yanlış tahmin etmiştir. Test verisinde 1 olan 1681 adet noktayı model, 1 olarak doğru tahmin etmiştir. 4 adet noktayı ise 0 olarak yanlış tahmin etmiştir. Bu durum modelin doğruluk değerinin yüksek olduğunu göstermektedir.

Çizelge 4.5. Test verilerinin bir kısmı.

Veri Sırası	Akım	F1Titreşim	F2Titreşim	F4Titreşim	F5Titreşim	RPM	Sonuç
1	348.225	1.00423	0.72338	1.13462	0.560619	325	0
2	348.75	0.735135	0.672201	0.977105	0.501483	325	0
3	348.175	0.861907	0.557726	1.11057	0.459346	325	0
4	347.1	0.858832	0.739294	1.03588	0.510344	325	0
5	347.125	0.783963	0.662073	0.944915	0.476707	325	0
...							
2431	62.475	0.892289	0.451208	0.802228	0.433666	277	0
2432	108.3	0.799334	0.462059	0.792101	0.367477	277	0
2433	109.325	0.86046	0.474175	0.838035	0.441985	277	0
2434	77.1	0.803132	0.456633	0.823929	0.431315	277	0
2435	1.2	0.843461	0.495877	0.867332	0.41956	277	0

4.5.4. Destek Vektör Makinası Uygulama Sonuçları

Çizelge 4.7. Destek vektör makinaları model sonuçları.


Doğruluk	0.9967
95% CI	(0.9935, 0.9986)
Kappa	0.9923
McNemar'ın Test P-Değeri	1
Hassaslık	0.9947
Özgünlük	0.9976
Yaygınlık	0.308
Algılama Hızı	0.3064
Algılama Yaygınlığı	0.308
Doğruluk Dengesi	0.9961

Tablodan da görüldüğü gibi modelin tahmin doğruluğu %99,67 olarak karşımıza çıkmıştır. Tabloda Accuracy olarak ifade edilen değer test başarı oranını göstermektedir. Kappa değeri de %99,23 çıkmıştır. Bu da sonucun güvenilirliğinin yüksek olduğu anlamına gelmektedir.

4.6. KARAR AĞAÇLARI TAHMİN UYGULAMASI

Karar ağacı algoritması genellikle sınıflandırma problemlerinde kullanılmaktadır. Yapı itibari ile tepeden uca inen bir yöntemle çalışmaktadır. Karar ağacı uygulanan algoritmaya belirli kurallar çerçevesinde sınıflara ayırır. Karar verme kriterleri uygulayarak verileri kümelere bölmektedir. Görsel sonuçlar vermesi itibari ile yorumlanması kolaydır. Şekilde de görüldüğü gibi veri daha küçük parçalara ayrılarak sınıflandırılır.

Üretim hattında alınmış olan veriler için arıza eşiği 2,8 mm/s olarak belirlenmiştir. Modelde kullanılmış olan veriler 2,8 mm/s üzerindeki titreşimleri arıza başlangıcı olarak kabul edecek şekilde tasarlanmıştır. Modelin sonucunda çıkacak olan veri değerleri 0, 1 olarak sınıflandırılmaktadır. Bu sebeple kurulan modelde sonuç kısmı için faktör dönüşümü yapılmıştır. Sonucun 0,1 değerlerini sahip olması nedeniyle destek vektör makinaları modeline girdilerin faktör olarak verilmesi gerekmektedir.



Şekil 4.9. Karar ağaçları yayılım sistematiği.

Modelde set seed komutu kullanılmıştır. Bu komut çıkan tahmin değerlerinin, model her çalıştırıldığında aynı olmasını sağlamaktadır. Çalışma örnek veri seti üzerinde yapıldığı için çıkan tahmin sonuçlarının, model her çalıştırıldığında aynı olması gerekmektedir. Bu kod satırı canlı sistemlerde kullanılmamaktadır. Bunun nedeni canlı sistemlere anlık veri akışı olması dolayısıyla modelden çıkacak sonucun her an değişecek ve güncellenecek olmasıdır.

Veri seti %70 ve %30 olmak üzere iki ayrı parçaya ayrılmıştır. Literatür incelendiğinde genellikle bu şekilde ayırım yapıldığı görülmüştür. Verilerin %70 i eğitim verisi, geri kalan %30 u ise eğitim verisi olarak ayrılmıştır. Kodlamada %70'lik kısmın train, - indis li kısmın yani geriye kalan %30'luk kısmın test verisi olarak ayrıldığını görüyoruz. Kodlamada cross validation olarak adlandırılan süreç işlemektedir. Burada %70 olarak ayrılmış olan eğitim verileri 10 eşit parçaya bölünmektedir.(Güven & Şimşir, 2020) Bu 10 parçadan 9 adeti eğitim verisi, 1 adedi ise test verisi olarak ayrılmıştır. Bu durum her bir iterasyonda değişmektedir. Örneğin birinci iterasyonda

1 küme test kümesi iken, ikinci iterasyonda ikinci küme test kümesi olarak seçilmektedir. Cross validation bu şekilde çalışmaktadır. Literatür incelendiğinde genellikle 10 adet parçaya ayrıldığı görülmektedir. (Köprü & Özcan, 2020)

4.6.1. Grid Arama

Şekilde gösterildiği gibi karar ağacı algoritmasına 5680 adet veri giriş yapmıştır. Bu veriler 6 ayrı parametreye aittir ve çıkan sınıflandırma sonucu iki ayrı değerde olabilmektedir. Modelde yer alan n.trees komutu ağaç sayısını ifade etmektedir. Ağaç sayısının artması eğitim setindeki hatayı azaltır fakat sayının aşırı artması modelde yanlış sonuç çıkmasına da neden olabilir. Çalışmada ağaç sayısı 150, 175, 200 ve 225 olarak belirlenmiştir. Literatür incelenmiş ve sıklıkla kullanılan değerler tercih edilmiştir.

```
Stochastic Gradient Boosting
5680 samples
 6 predictor
 2 classes: '0', '1'
```

Şekil 4.10. R studio girdi parametreleri.

Modelde interaction.depth (Maximum nodes per tree- Ağaç başına maksimum düğüm) olarak ifade edilen parametre, bir ağaca bağlı olan maksimum düğüm sayısını ifade etmektedir. Etkileşimin daha net algılanabilmesi için ikiden fazla düğüm gerekmektedir. Kurulan modelde düğüm değerleri 1, 2, 3, 4, 5 olarak belirlenmiştir. Modelde, shrinkage olarak adlandırılan parametre öğrenme oranını ifade etmektedir. Bu parametrenin temel amacı; büyük adımlar atmak yerine küçük adımlar atarak modelin doğruluğunu arttırmaktır. Modelde kullanılan shrinkage değerleri 0.075, 0.1, 0.125, 0.15, 0.2 olarak belirlenmiştir. Modelde yer alan n.minobsinnode değeri ağaçların uç düğümlerindeki minimum gözlem sayısını ifade etmektedir. Model n.minobsinnode değerleri 7, 10, 12, 15 olarak belirlenmiştir.

Model, girilmiş olan shrinkage, interaction.depth, n.minobsinnode, n.trees değerleri arasında tarama yapar. Bütün olasılıkları deneyerek en doğru tahmin değerini ait parametreleri belirler. Burada yapılan işlem grid arama olarak adlandırılır. Modelde bulunan grid arama adımı sayesinde taguchi gibi bir metodun kullanılmasına gerek kalmamasını sağlar.

Çizelge 4.8. Grid arama yapılan parametremelerin taraması.


Öğrenme Oranı	Maksimum Düğüm Sayısı	Minimum Gözlem Sayısı	Ağaç Sayısı	Doğruluk	Kappa
0.075	1	7	150	0.99947	0.99879
0.075	1	7	175	0.99947	0.99879
0.075	1	7	200	0.99947	0.99879
0.075	1	7	225	0.99947	0.99879
0.075	1	10	150	0.99982	0.9996
0.075	1	10	175	0.99965	0.9992
0.075	1	10	200	0.99965	0.9992
0.075	1	10	225	0.99965	0.9992
0.075	1	12	150	0.99982	0.9996
0.075	1	12	175	0.99982	0.9996
0.075	1	12	200	0.99982	0.9996
0.075	1	12	225	0.99982	0.9996
0.075	1	15	150	0.99965	0.99919
0.075	1	15	175	0.99982	0.9996
0.075	1	15	200	0.99982	0.9996
0.075	1	15	225	0.99965	0.9992
0.075	2	7	150	0.99982	0.9996
0.075	2	7	175	0.99965	0.9992
0.075	2	7	200	0.99965	0.9992
0.075	2	7	225	0.99965	0.9992
0.075	2	10	150	0.99982	0.9996
0.075	2	10	175	0.99982	0.9996
0.075	2	10	200	0.99982	0.9996
0.075	2	10	225	0.99982	0.9996
0.075	2	12	150	0.99965	0.9992
0.075	2	12	175	0.99965	0.9992
0.075	2	12	200	0.99965	0.9992
0.075	2	12	225	0.99965	0.9992
0.075	2	15	150	0.99982	0.9996

Çizelge 4.8. (devam ediyor).

Öğrenme Oranı	Maksimum Düğüm Sayısı	Minimum Gözlem Sayısı	Ağaç Sayısı	Doğruluk	Kappa
0.075	2	15	175	0.99982	0.9996
0.075	2	15	200	0.99982	0.9996
0.075	2	15	225	0.99982	0.9996
0.075	3	7	150	0.99965	0.9992
0.075	3	7	175	0.99965	0.9992
0.075	3	7	200	0.99947	0.99879
0.075	3	7	225	0.99947	0.99879
0.075	3	10	150	0.99965	0.9992
0.075	3	10	175	0.99947	0.99879
0.075	3	10	200	0.99947	0.99879
0.075	3	10	225	0.99947	0.99879
0.075	3	12	150	0.99965	0.9992
0.075	3	12	175	0.99965	0.9992
0.075	3	12	200	0.99965	0.9992
0.075	3	12	225	0.99965	0.9992
0.075	3	15	150	0.99947	0.99879
0.075	3	15	175	0.99947	0.99879
0.075	3	15	200	0.99947	0.99879
0.075	3	15	225	0.99947	0.99879
0.075	4	7	150	0.99947	0.99879
0.075	4	7	175	0.99947	0.99879
0.075	4	7	200	0.99947	0.99879

Grid arama sonucunda minimum hata oranı, maksimum doğru tahminleme sahip değerler belirlenmiş olur. Arama sonucunda $n.trees = 150$, $interaction.depth = 1$, $shrinkage = 0.075$ ve $n.minobsinnode = 10$ değerleri maksimum doğruluğa ulaştıran değer olarak belirlenmiştir.

4.6.2. Karar Ağaçları Test Dataseti ve Tahmin Sonuçları Karşılaştırması



Şekil 4.11. Ağaç diyagramı.

Arama sonucunda en iyi sonucu veren ağaç bilgileri `n.trees = 150`, `interaction.depth = 1`, `shrinkage = 0.075` ve `n.minobsinnode = 10` değerleri maksimum doğruluğa ulaştıran değer olarak belirlenmiştir.

4.6.3. Karar Ağaçları Uygulama Sonuçları

Çizelge 4.10. Karar ağaçları model sonuçları.

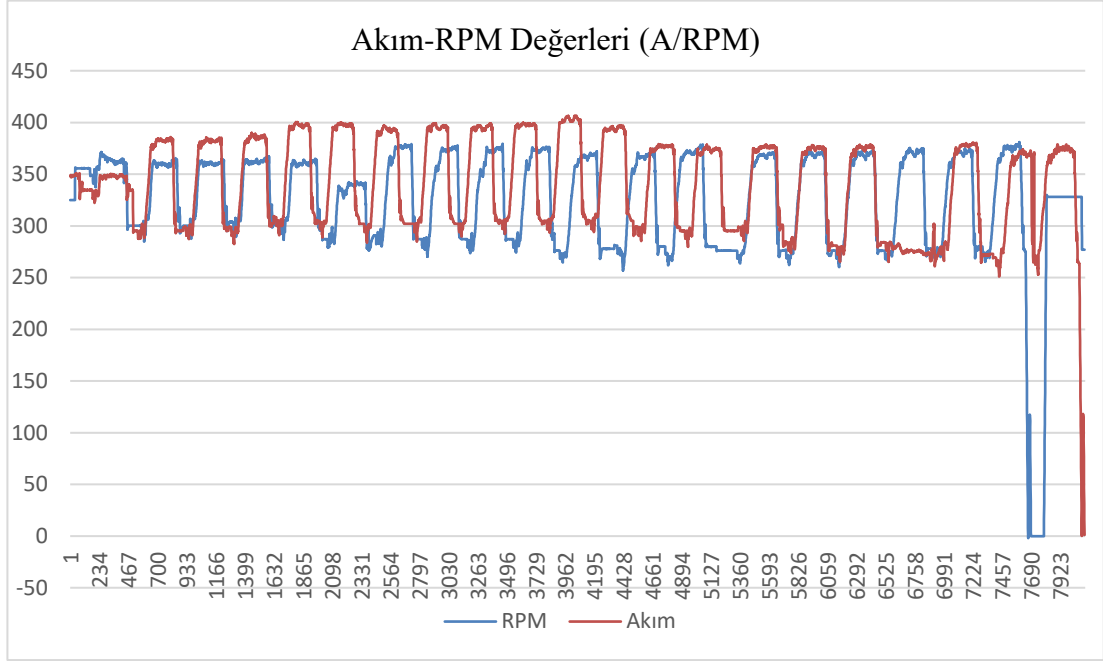
Doğruluk	0.9996
95% CI	(0.9977, 1)
Kappa	0.999
McNemar'ın Test P-Değeri	1
Hassaslık	1
Özgünlük	0.9994
Yaygınlık	0.308
Algılama Hızı	0.308
Algılama Yaygınlığı	0.3084
Doğruluk Dengesi	0.9997

Tablodan da görüldüğü gibi modelin tahmin doğruluğu %99,96 olarak karşımıza çıkmıştır. Tabloda Accuracy olarak ifade edilen değer test başarı oranını göstermektedir. Kappa değeri de %99,9 çıkmıştır. Bu da sonucun güvenilirliğinin yüksek olduğu anlamına gelmektedir.

4.7. DENEYSEL SONUÇLAR

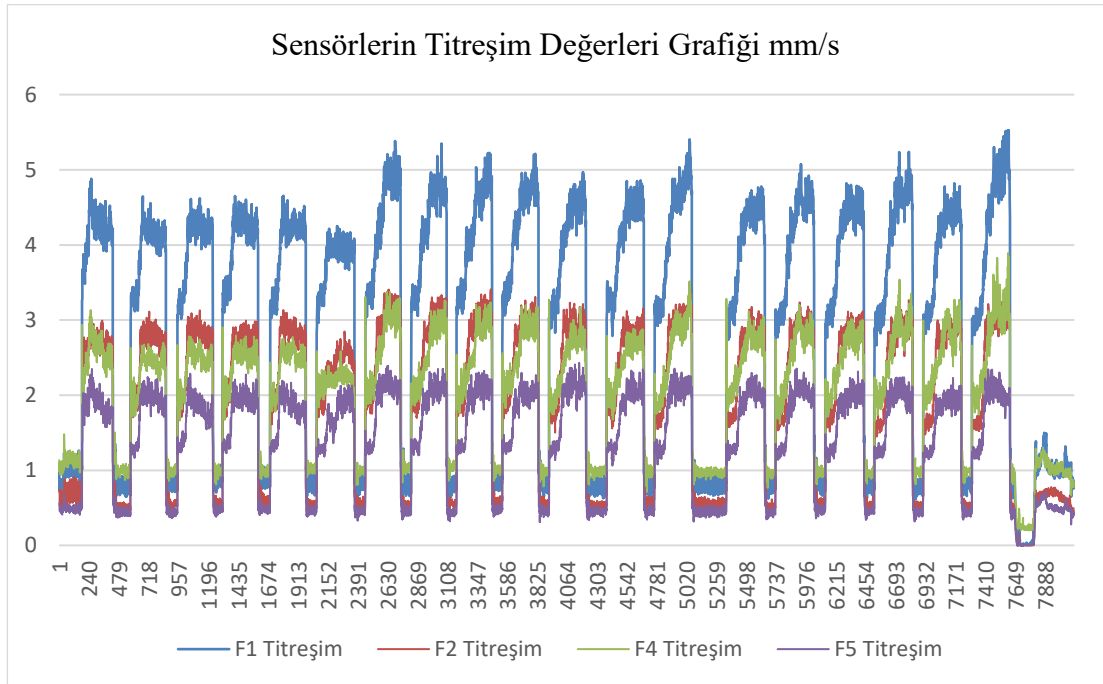
Bölüm 4.1.1 de ISO titreşim değerleri tablosu verilmiştir. Bu tablodaki parametrelere göre, üretim hattından alınmış olan veriler değerlendirilmiş ve veri alınan makinenin hangi gruba dahil edildiği kararlaştırılmıştır. Verilerin alındığı makine M grubuna dahil edilmiş ve arıza eşik değeri 2,8 mm/s olarak belirlenmiştir. Bunun anlamı, titreşim değerinin 2.8 mm/s ve üzerine çıkması arıza başlangıç eşiği olarak kabul edilecektir. Üretim hattında ilk fırsatta bu bölgenin kontrol edilmesi gerekmektedir.

Bölüm 4.1.2 de çalışmanın kapsamından ve veri setinin özelliklerinden bahsedilmiştir. 4 ayrı sensörden alınmış olan titreşim değerleri, RPM değeri ve akım değeri modelde kullanılan veri setini oluşturmuştur. Şekil 4.12’de RPM ve akım değerlerinin grafiği gösterilmektedir. Bu grafiğe göre akım ve RPM değerlerinin beraber hareket ettiği sonucuna ulaşılmaktadır.



Şekil 4.12. Akım RPM değerleri grafiği.

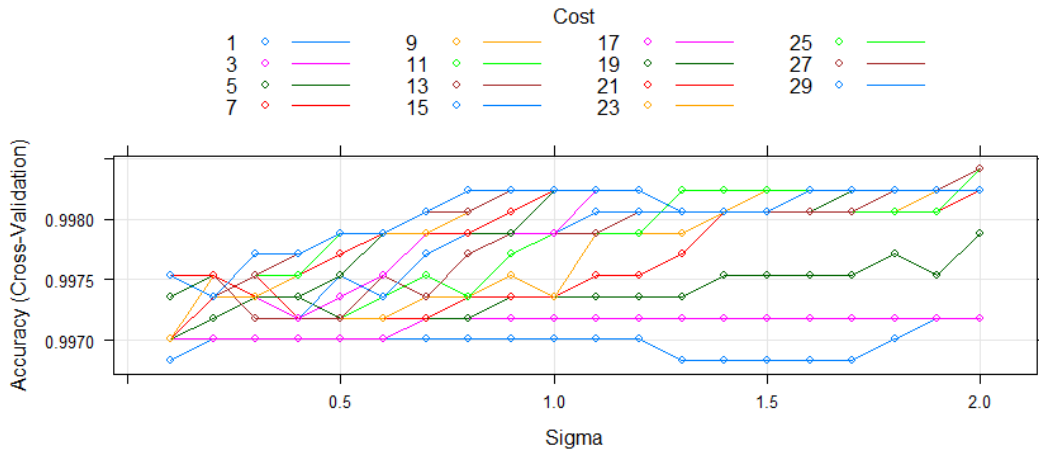
Bölüm 4.1.3 de verilerin korelasyon analizi yapılmıştır. Analizin yapılmasında SPSS istatistik programı kullanılmıştır. Korelasyon analizi yapılırken, verilerin normal dağıldığı varsayılmış ve pearson analizi yapılmıştır.



Şekil 4.13. Sensörlerin titreşim değerleri grafiği.

Two tailed analiz yapılmıştır. Bunun anlamı dağılımın her iki tarafına bakarak korelasyon analizini yapmaktır. Verilerin birbiri ile ilişkisi ölçümlenmiştir. Korelasyon analizi sonucunda verilerin birbiri ile pozitif yönlü ve anlamlı ilişkisi olduğu tespit edilmiştir. Şekil 4.13’da da görüldüğü gibi titreşim değerleri birbiri ile beraber hareket etmektedir. Dişlilerin herhangi birinde meydana gelen bir arıza, tüm sistemi çok kısa bir sürede etkileyecektir. Bu sebeple sistemde bulunan herhangi bir sensörün ölçtüğü titreşim eşiğinin aşılması arıza başlangıcı olarak kabul edilmesi için yeterlidir.

Bölüm 4.2 de uygulamada kullanılan araçlardan bahsedilmiştir. Uygulamanın yapımında R Studio programı ve R programlama dili kullanılmıştır. Çalışmada e1071, caret, gbm ve pplot2 kütüphaneleri kullanılmıştır. Çalışma kapsamında makine öğrenmesi algoritmalarından olan ve sınıflandırma problemlerinin çözümünde sıklıkla kullanılan destek vektör makinaları ve karar ağaçları algoritmalarından yararlanılmıştır. Bölüm 4.3 de destek vektör makinaları uygulamaları, kodlama adımları anlatılmıştır. Kurulan modelde 6 adet tahmin edici, 2 adet sınıf ve 5680 adet olduğu görülmektedir.



Şekil 4.14. Grid arama sonucu.


Grid arama ile en uygun tahminleme sonucuna ulaşıldığından bahsedilmiştir. Bölüm 4.3.1 de destek vektör makinaları algoritması ile kurulan modelin sonucu açıklanmıştır. %99,67 doğruluk değeri ile destek vektör makinaları algoritması tahminleme yapmıştır. Kernel metodunun uygulandığı çalışmada en iyi sigma

değerinin 2 olduğu, en iyi sonucu veren C ceza puanı değerinin de 25 olduğu görülmüştür.

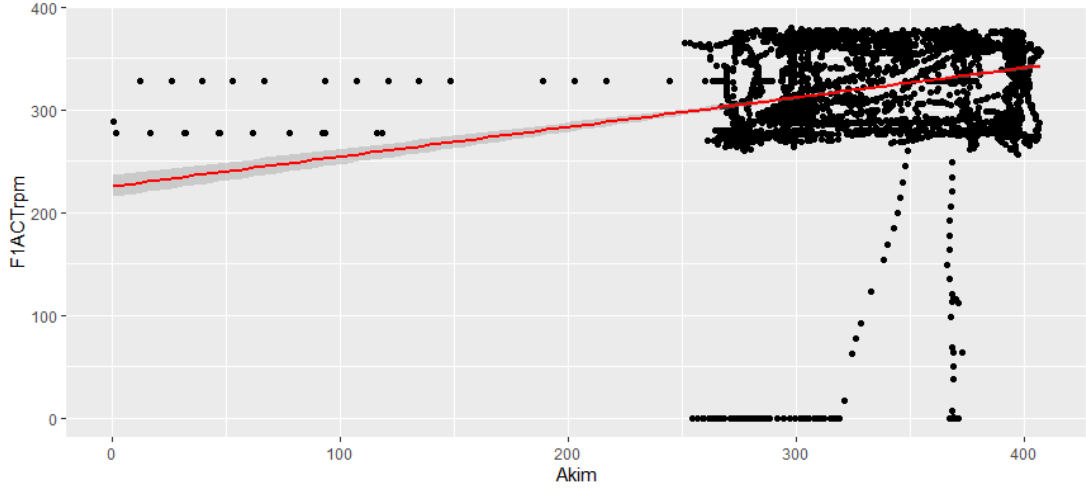
Çizelge 4.11. Destek vektör makinaları algoritması test verisi ve tahmin değerlerinin karşılaştırılması.

		Reference	
		0	1
Tahmin	0	746	4
	1	4	1681


Tabloda gösterilen referans değişkenleri işletmeden alınan verilere ait sonuç değişkenlerini ifade etmektedir. Tahmin değişkenine ait veriler ise modelin tahminlemesi ardından elde edilen sonuçlardır. 0'a 0 olan noktada, yani gerçek verinin 0 olduğu 746 adet noktayı, kurulan model de 0 olarak doğru tahmin etmiştir. Bu durum false negatif olarak adlandırılmaktadır. 4 adet noktayı ise 1 olarak yanlış tahmin etmiştir. Bu duruma ise false positive olarak adlandırılır. Diğer sütunda ise, gerçek veride 1 olan 1681 adet noktayı model, 1 olarak doğru tahmin etmiştir. Bu durum false negative' dir. 4 adet noktayı ise 0 olarak yanlış tahmin etmiştir. Bu durum false positive olarak adlandırılır. Şekil 4.15 ve Şekil 4.16'da görüldüğü gibi test ve eğitim verileri aynı doğrultuda dağılmaktadır.



Şekil 4.15. Test verisi RPM- Akım grafiği.




Şekil 4.16. Eğitim verisi RPM-Akım grafiği.



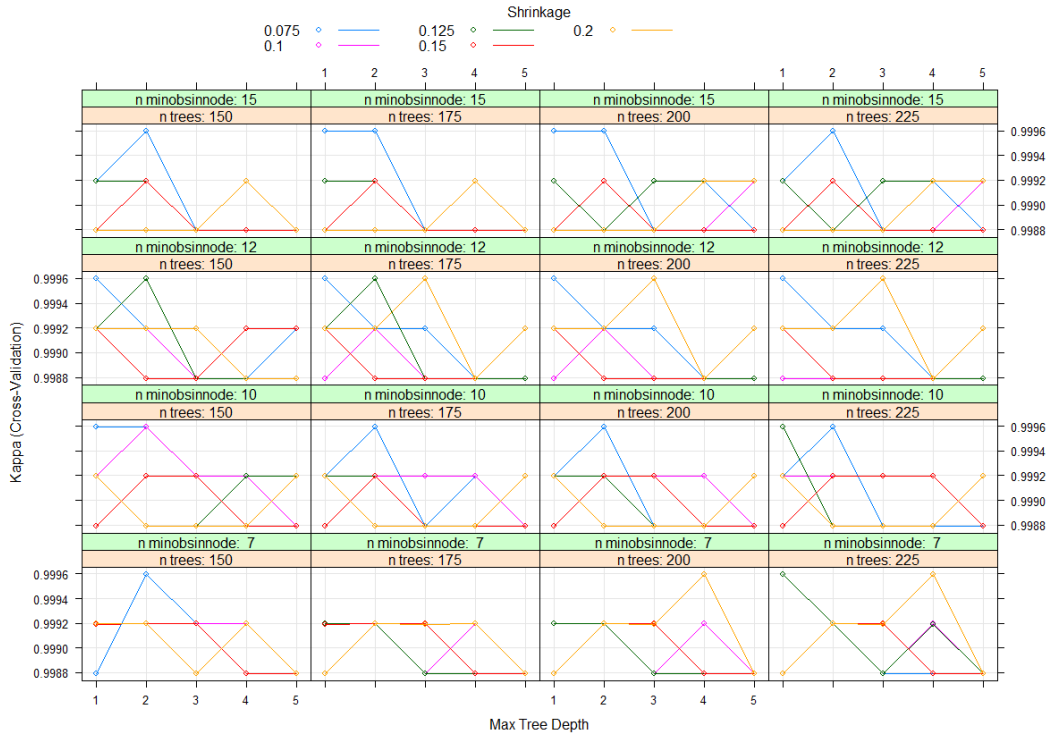
Şekil 4.17. Eğitim verisi F1 ve F2 titreşimleri grafiği.

Şekil 4.17 ve 4.18 de görüldüğü F1 ve F2 titreşimlerinin test ve eğitim verilerindeki dağılım yerleri birbirine çok yakındır. Eğitim verisinin sayısının fazla olması dolayısıyla eğitim veri grafiğinde yoğunluk fazladır.



Şekil 4.18. Test verisi F1 ve F2 titreşimleri grafiği.

Bölüm 4.4 de karar ağaçları algoritması ile modelin kurulduğu anlatılmıştır. Veri setinin %70 ve %30 olmak üzere iki ayrı parçaya ayrıldığından bahsedilmiş, kod satırları açıklanmıştır.



Şekil 4.19. Karar ağaçları grid arama.

Bölüm 4.4.1 de modelin grid arama yapma süreci anlatılmıştır. Kurulan modelde 6 adet tahmin edici, 2 adet sınıf ve 5680 adet sınıf olduğu görülmektedir. Kurulan modelde, ağaç sayısı 150, 175, 200 ve 225 olarak belirlenmiştir. Düğüm değerleri 1, 2, 3, 4, 5 olarak belirlenmiştir. Modelde kullanılan shrinkage değerleri 0.075, 0.1, 0.125, 0.15, 0.2 olarak belirlenmiştir. Model n.minobsinnode değerleri 7, 10, 12, 15 olarak belirlenmiştir. Bölüm 4.4.2 de en yüksek doğruluğa ulaşan iterasyonun parameterleri açıklanmıştır. Arama sonucunda n.trees = 150, interaction.depth = 1, shrinkage = 0.075 ve n.minobsinnode = 10 değerleri maksimum doğruluğa ulaştırın değer olarak belirtilmiştir. Bölüm 4.4.3 de karar ağaçları modelinin ulaştığı sonuçlar özetlenmiştir. Model %99,96 doğrulukla tahminleme yapmıştır.

Çizelge 4.12. Karar ağaçları test verisi ve tahmin değerlerinin karşılaştırılması.

		Reference	
		0	1
Tahmin	0	750	1
	1	0	1684

Bu tabloda gösterilen referans değişkenleri işletmeden aldığımız verilere ait sonuç değişkenlerini ifade etmektedir. Tahmin değişkenine ait veriler ise modelin tahminlemesi ardından elde edilen sonuçlardır. 0 'a 0 olan noktada, yani gerçek verinin 0 olduğu 750 adet noktayı, kurulan model de 0 olarak doğru tahmin etmiştir. Bu false negatif olarak adlandırılmaktadır. 1 adet noktayı ise 1 olarak yanlış tahmin etmiştir. Bu duruma ise false positive olarak adlandırılır. Diğer sütunda ise, gerçek veride 1 olan 1684 adet noktayı model, 1 olarak doğru tahmin etmiştir. Bu false negative olarak adlandırılır. Buna karşılık false pozitif değer bulunmamaktadır.

Yapılan çalışmalar sonucunda, SPSS istatistik programında verilerin korelasyonu, verilerin birbiri ile pozitif ve anlamlı bir ilişkisi olduğunu ortaya koymuştur. R Studio da yapılan çalışmalar sonucunda; destek vektör makinaları algoritması %99,67 doğrulukla tahminleme yaparken, karar ağacı algoritması %99,96 doğrulukla tahminleme yapmıştır. Buradan ulaşılan sonuca göre karar ağaçları algoritması, destek vektör makinaları algoritmasından daha doğru sonuçlar vermiştir.

BÖLÜM 5

TARTIŞMALAR VE ÖNERİLER

Günümüzde kaynakların daralmasına bağlı olarak artan maliyetler, üretimden hizmete bütün sektörleri tasarruf tedbirleri almaya yöneltmiştir. Bu kapsamda makina ve ekipman, enerji, iş gücü başta olmak bütün kaynakların optimal kullanımının sağlanması için işletmeler çeşitli çalışmalar yapmaktadır. Kestirimci bakım çalışmaları da artan maliyetlere karşı işletmelerin karını korumaya yönelik etkili bir çözüm olarak karşımıza çıkmaktadır. Herhangi bir makinanın arıza görmesine bağlı olarak meydana gelecek olan maliyete katlanmak yerine, belirlenen kritik noktalarda makinalara bakım yapılarak, yararlı ömürlerinin uzatılması sağlanabilir. Burada kazanç sağlanan sadece makine arıza maliyeti olmayıp, arıza kaynaklı duruşun önüne geçilmesi ile üretim kaybı ve çalışma zamanı kaybı da önlenmiş olacaktır.

Kestirimci bakım zamanlarının önceden tahminlenmesinde kullanılacak yöntemlerin başında makine öğrenmesi algoritmaları gelmektedir. Makine öğrenmesi algoritmaları üç ana başlık altında toplanmaktadır. Bunlar denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak karşımıza çıkmaktadır. Denetimli öğrenme kendi arasında sınıflandırma teknikleri ve regresyon olarak ikiye ayrılmaktadır. Sistemden alınmış olan veri seti incelendiğinde çözümde makine öğrenmesi algoritmalarından sınıflandırma yöntemlerinin uygun olduğu görülmüştür. Literatür incelendiğinde sınıflandırma algoritmalarından destek vektör makinaları ve karar ağaçları algoritmalarının sıklıkla kullanılan ve efektif sonuçlar veren yöntemler olduğu karşımıza çıkmaktadır.

Bu tez çalışması kapsamında, üretim hattından dört ayrı sensörden titreşim verisi alınmıştır. Dört ayrı titreşim verisi, motor RPM değeri ve akım değeri ile altı parametrelili veri seti oluşturulmuştur. Oluşturulmuş olan veri seti öncelikle SPSS

İstatistik programında korelasyon analizine tabi tutulmuştur. Korelasyon analizi sonucunda verilerin birbiri ile pozitif yönlü anlamlı bir ilişkisi olduğu sonucuna ulaşılmıştır. Ardından veri seti, destek vektör makinaları ve karar ağaçları algoritmaları ile işlenmiştir. R Studio programında, R yazılım dilinde kurulan modellerden tahmin sonuçları alınmıştır. Kurulan modelde öncelikle veri %30 test verisi, %70 eğitim verisi olmak üzere iki gruba ayrılmıştır. Verinin ayrılmış olan %70'lik kısmı kendi içinde on ayrı parçaya bölünmüş ve her bir parçada grid arama yöntemi ile en iyi sonuca ulaşmaya çalışılmıştır. Grid arama kısmında cross validation olarak adlandırılan çapraz arama ile en iyi sonucunu bulma işlemi yapılmıştır.

Alınan sonuçlara göre destek vektör makinaları algoritması %99,67 doğruluk oranında tahminleri gerçekleştirmiştir. Test veri setinde bulunan 746 adet 0 değerine sahip noktayı model de 0 olarak doğru tahmin etmiştir. Test veri setinde 0 olan dört noktayı da 1 olarak yanlış tahmin etmiştir. Aynı şekilde veri setinde 1 olan 1681 noktayı 1 olarak doğru tahmin ederken, 0 olan 4 noktayı da 1 olarak yanlış tahmin etmiştir. Karar ağacı algoritmasında ise durum biraz daha farklıdır. Karar ağacı algoritması %99,96 doğruluk değerinde tahminleme yapmıştır. Test veri setinde 0 olan 750 adet noktayı model 0 olarak doğru tahmin ederken, veri setinde 1 olan sadece 1 noktayı 0 olarak yanlış tahmin etmiştir. Buradan çıkarılan sonuca göre karar ağacı algoritması doğruluk değeri daha yüksek tahmin gerçekleştirmiştir.

ISO 500 listesi incelendiğinde demir çelik tesislerinin en üst sıralarda olduğu görülmektedir. Maddi getiri oranını bu kadar yüksek olduğu demir çelik sektöründe kestirimci bakım çalışmaları ile yapılabilecek küçük bir iyileştirme bile işletmelere çok büyük kazançlar sağlamaktadır. Tabi ki kestirimci bakımın kazandıracakları sadece demir çelik sektörü ile sınırlı değildir. Bütün işletmelerde uygulanması gereken hayati bir çalışmadır. Makine öğrenmesi algoritmaları da kestirimci bakım çalışmaları için adeta biçilmiş kaftan gibidir.

Kestirimci bakım çalışmalarının kapsamı işletmenin kaynak ayırdığı düzeyde gerçekleştirilebilir. Bu çalışma kapsamında işletmeden alınmış olan dört sensör verisi, motor RPM değeri ve akım değeri kullanılmıştır. Fakat doğruya daha yakın

tahminlemeler yapılması için bu veriler genişletilebilir. Ortam ısısı, hatta giren slabın kalınlığı, slabın kalitesi, yüzey kusur oranı gibi parametrelerin modele eklenmesi doğruluk değerini arttıracaktır. Ayrıca problemin çözümünde kullanılan algoritmalarda çoğaltılabilir. Yapay sinir ağıları, derin öğrenme gibi yöntemlerle doğruluk değeri daha yüksek tahminlemeler yapılabilir.

Çalışma kapsamında kurulan model incelendiğinde, modelde set. Seed olarak geçen bir kod satırının olduğu görülmektedir. Bu kod satırı model her çalıştığında aynı sonuçların elde edilmesini sağlamaktadır. Model her çalıştığında aynı sonuçlar elde edilmelidir çünkü model sabit bir veri seti üzerinde tahminleme yapmaktadır. Bu çalışma canlı sisteme taşındığında bu kod satırının kaldırılması gerekmektedir. Canlı sistemlerde modele anlık veri girişi sağlanacağı için çıktılar giren veriye göre anlık olarak şekillenecektir ve model sürekli olarak öğrenmeye devam edecektir. Modelin canlı sisteme entegre edilmesi bu çalışmayı bir adım daha ileri götürecektir.

KAYNAKLAR

- Amram, M., Dunn, J., Toledano, J. J., & Zhuo, Y. D. (2021). Interpretable predictive maintenance for hard drives. *Machine Learning with Applications*, 5, 100042.
- An, Y., Chen, X., Hu, J., Zhang, L., Li, Y., & Jiang, J. (2022). Joint optimization of preventive maintenance and production rescheduling with new machine insertion and processing speed selection. *Reliability Engineering & System Safety*, 220, 108269.
- Aremu, O. O., Cody, R. A., Hyland-Wood, D., & McAree, P. R. (2020). A relative entropy based feature selection framework for asset data in predictive maintenance. *Computers & Industrial Engineering*, 145, 106536.
- Arena, S., Florian, E., Zennaro, I., Orrù, P. F., & Sgarbossa, F. (2022). A novel decision support system for managing predictive maintenance strategies based on machine learning approaches. *Safety Science*, 146, 105529.
- Arumugam, K., Swathi, Y., Sanchez, D. T., Mustafa, M., Phoemchalard, C., Phasinam, K., & Okoronkwo, E. (2022). Towards applicability of machine learning techniques in agriculture and energy sector. *Materials Today: Proceedings*, 51, 2260–2263.
- Ashok Mahant, M., & Pellakuri, V. (2021). Innovative supervised machine learning techniques for classification of data. *Materials Today: Proceedings*, S2214785320386934.
- Bröker, F., Love, B. C., & Dayan, P. (2022). When unsupervised training benefits category learning. *Cognition*, 221, 104984.
- Çeştepe, H. (2018). Türkiye Demir Çelik Sektörünün Uluslararası Rekabet Gücü Analizi. *Journal of Turkish Studies*, 13(Volume 13 Issue 15), 113–129.
- Chatterjee, B., Walulya, I., & Tsigas, P. (2021). Concurrent linearizable nearest neighbour search in LockFree-kD-tree. *Theoretical Computer Science*, 886, 27–48.
- Choi, Y., Yoon, G., & Kim, J. (2022). Unsupervised learning algorithm for signal validation in emergency situations at nuclear power plants. *Nuclear Engineering and Technology*, 54(4), 1230–1244.

Dal, H., & Morgül, Ö. K. (2006). Yapay Sinir Ağı (Ysa) Kullanarak Titreşim Tabanlı Makina Durum İzlemesi Ve Hata Teşhisi. *Saü Fen Bilimleri Enstitüsü Dergisi*, 6.

Drakaki, M., Karnavas, Y. L., Tzionas, P., & Chasiotis, I. D. (2021). Recent Developments Towards Industry 4.0 Oriented Predictive Maintenance in Induction Motors. *Procedia Computer Science*, 180, 943–949.

Einabadi, B., Baboli, A., & Ebrahimi, M. (2019). Dynamic Predictive Maintenance in industry 4.0 based on real time information: Case study in automotive industries. *IFAC-PapersOnLine*, 52(13), 1069–1074.

Engür, A. İ. (2016). Kestirimci Bakımda Titreşim Analizi. 5.

Erkoyuncu, J. A., Khan, S., Eiroa, A. L., Butler, N., Rushton, K., & Brocklebank, S. (2017). Perspectives on trading cost and availability for corrective maintenance at the equipment type level. *Reliability Engineering & System Safety*, 168, 53–69.

Ersöz, T., Düğenci, M., Ünver, M., & EyiOl, B. (2016). Demir Çelik Sektörüne Genel Bir Bakış ve Beş Milyon Ton Üstü Demir Çelik İhracatı Yapan Ülkelerin Kümeleme Analizi ile İncelenmesi. *Nevşehir Bilim ve Teknoloji Dergisi*, 4(2), 75–75.

Fahle, S., Prinz, C., & Kuhlenkötter, B. (2020). Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application. *Procedia CIRP*, 93, 413–418.

Fernandes, M., Canito, A., Bolón-Canedo, V., Conceição, L., Praça, I., & Marreiros, G. (2019). Data analysis and feature selection for predictive maintenance: A case-study in the metallurgic industry. *International Journal of Information Management*, 46, 252–262.

Fradkov, A. L. (2020). Early History of Machine Learning. *IFAC-PapersOnLine*, 53(2), 1385–1390.

Gan, S., Song, Z., & Zhang, L. (2022). A maintenance strategy based on system reliability considering imperfect corrective maintenance and shocks. *Computers & Industrial Engineering*, 164, 107886.

Ganaie, M. A., & Tanveer, M. (2021). Fuzzy least squares projection twin support vector machines for class imbalance learning. *Applied Soft Computing*, 113, 107933.

García-Gonzalo, E., Fernández-Muñiz, Z., García Nieto, P., Bernardo Sánchez, A., & Menéndez Fernández, M. (2016). Hard-Rock Stability Analysis for Span Design in Entry-Type Excavations with Learning Classifiers. *Materials*, 9(7), 531.

GökceciK, G., & DulkadiRoğlu, H. (2021). Elektrik ark ocağı ile üretim yapan bir demir-çelik tesisinin mevcut en iyi teknikler kapsamında değerlendirilmesi. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*.

Güven, İ., & Şimşir, F. (2020). Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods. *Computers & Industrial Engineering*, 147, 106678.

Güven, İ., Uygun, Ö., & ŞİMŞİR, F. (2021). Machine Learning Algorithms with Intermittent Demand Forecasting: An Application in Retail Apparel with Plenty of Predictors.

Han, X., Wang, Z., Xie, M., He, Y., Li, Y., & Wang, W. (2021). Remaining useful life prediction and predictive maintenance strategies for multi-state manufacturing systems considering functional dependence. *Reliability Engineering & System Safety*, 210, 107560.

Hasegawa, M., Hanada, K., Idei, H., Kawasaki, S., Nagata, T., Ikezoe, R., Onchi, T., Kuroda, K., & Higashijima, A. (2020). Predictive maintenance and safety operation by device integration on the QUEST large experimental device.

Hashemi, M., Tavangar, M., & Asadi, M. (2022). Optimal preventive maintenance for coherent systems whose failure occurs due to aging or external shocks. *Computers & Industrial Engineering*, 163, 107829.

Jimenez, V. J., Bouhmala, N., & Gausdal, A. H. (2020). Developing a predictive maintenance model for vessel machinery. *Journal of Ocean Engineering and Science*, 5(4), 358–386.

Jin, P., Chen, Z., Li, R., Li, Y., & Cai, G. (2022). Opportunistic preventive maintenance scheduling for multi-unit reusable rocket engine system based on the variable maintenance task window method. *Aerospace Science and Technology*, 121, 107346.

Kammerer, C., Gaust, M., Küstner, M., Starke, P., Radtke, R., & Jesser, A. (2021).

Motor Classification with Machine Learning Methods for Predictive Maintenance. *IFAC-PapersOnLine*, 54(1), 1059–1064.

Karagöz, Ş. (2009). Sıcak Şerit Haddedeleme İş Merdane Malzemeleri ve Hadde Merdanesi Döküm Yöntemleri. *Pamukkale University Journal of Engineering Sciences*, 15(3), 7.

Köprü, E., & Özcan, C. (2020). Yapay Sinir Ağları ile Sıvı Ham Demir Tahmini ve 5.Yüksek Fırın Uygulaması. *European Journal of Science and Technology*.

Koranga, M., Pant, P., Kumar, T., Pant, D., Bhatt, A. K., & Pant, R. P. (2022). Efficient water quality prediction models based on machine learning algorithms for Nainital Lake, Uttarakhand. *Materials Today: Proceedings*, S2214785321080706.

Kumar, B., & Gupta, D. (2021). Universum based Lagrangian twin bounded support vector machine to classify EEG signals. *Computer Methods and Programs in Biomedicine*, 208, 106244.

Li, J., Zhang, Z., Wang, X., & Yan, W. (2022). Intelligent decision-making model in preventive maintenance of asphalt pavement based on PSO-GRU neural network. *Advanced Engineering Informatics*, 51, 101525.

Lolli, F., Coruzzolo, A. M., Peron, M., & Sgarbossa, F. (2022). Age-based preventive maintenance with multiple printing options. *International Journal of Production Economics*, 243, 108339.

Luo, W., Hu, T., Ye, Y., Zhang, C., & Wei, Y. (2020). A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. *Robotics and Computer-Integrated Manufacturing*, 65, 101974.

Mohammadi-Moghaddam, T., & Firoozzare, A. (2021). Investigating the effect of sensory properties of black plum peel marmalade on consumers acceptance by Discriminant Analysis. *Food Chemistry: X*, 11, 100126.

Özgür-Ünlüakın, D., Türkali, B., & Aksezer, S. Ç. (2021). Cost-effective fault diagnosis of a multi-component dynamic system under corrective maintenance. *Applied Soft Computing*, 102, 107092.

Öztürk, R. (2012). Türkiye’de Demir Çelik Sektörü’nün Yapısal Analizi. 22.

Patel, V., & Shah, M. (2021). A comprehensive study on artificial intelligence and machine learning in drug discovery and drug development. *Intelligent Medicine*, S2667102621001066.

Paullada, A., Raji, I. D., Bender, E. M., Denton, E., & Hanna, A. (2021). Data and its (dis)contents: A survey of dataset development and use in machine learning research. *Patterns*, 2(11), 100336.

Ramachandran, K. K., Apsara Saleth Mary, A., Hawladar, S., Asokk, D., Bhaskar, B., & Pitroda, J. R. (2022). Machine learning and role of artificial intelligence in optimizing work performance and employee behavior. *Materials Today: Proceedings*, 51, 2327–2331.

Ren, Q., zhang, H., Zhang, D., Zhao, X., Yan, L., & Rui, J. (2022). A novel hybrid method of lithology identification based on k-means++ algorithm and fuzzy decision tree. *Journal of Petroleum Science and Engineering*, 208, 109681.

- Rivera, D. L., Scholz, M. R., Bühl, C., Krauss, M., & Schilling, K. (2019). Is Big Data About to Retire Expert Knowledge? A Predictive Maintenance Study. *IFAC-PapersOnLine*, 52(24), 1–6.
- Rokhforoz, P., & Fink, O. (2022). Maintenance scheduling of manufacturing systems based on optimal price of the network. *Reliability Engineering & System Safety*, 217, 108088.
- Sahba, R., Radfar, R., Rajabzadeh Ghatari, A., & Pour Ebrahimi, A. (2021). Development of Industry 4.0 predictive maintenance architecture for broadcasting chain. *Advanced Engineering Informatics*, 49, 101324.
- Shanthi, J., Rani, D. G. N., & Rajaram, S. (2022). A C4.5 decision tree classifier based floorplanning algorithm for System-on-Chip design. *Microelectronics Journal*, 121, 105361.
- Şimşir, F., DemiR, H. İ., & Azdemir, S. (2018). Demir Çelik Sektöründe Hibrid DEMATEL ve TOPSİS-ELECTRE Yöntemleri ile Hata Türleri ve Etkileri Analizi. *Academic Platform Journal of Engineering and Science*, 1–1.
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2015). Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812–820.
- Tang, Q., Meng, K., Cheng, L., & Zhang, Z. (2022). An improved multi-objective multifactorial evolutionary algorithm for assembly line balancing problem considering regular production and preventive maintenance scenarios. *Swarm and Evolutionary Computation*, 68, 101021.
- Tao, X., Mårtensson, J., Warnquist, H., & Pernestål, A. (2022). Short-term maintenance planning of autonomous trucks for minimizing economic risk. *Reliability Engineering & System Safety*, 220, 108251.
- Tortorella, G. L., Fogliatto, F. S., Cauchick-Miguel, P. A., Kurnia, S., & Jurburg, D. (2021). Integration of Industry 4.0 technologies into Total Productive Maintenance practices. *International Journal of Production Economics*, 240, 108224.
- Toubeau, J.-F., Pardoën, L., Hubert, L., Marenne, N., Sprooten, J., De Grève, Z., & Vallée, F. (2022). Machine learning-assisted outage planning for maintenance activities in power systems with renewables. *Energy*, 238, 121993.
- Tukan, M., Baykal, C., Feldman, D., & Rus, D. (2021). On coresets for support vector machines. *Theoretical Computer Science*, 890, 171–191.
- Várkonyi-Kóczy, A. R., Szabó, J. Z., Nagy, I., & Rudas, I. J. (2012). Maintenance Analysis of Rotating and Moving Machines Using 3D Vibration Animation. *IFAC Proceedings Volumes*, 45(22), 584–589.

- Wellsandt, S., Klein, K., Hribernik, K., Lewandowski, M., Bousdekis, A., Mentzas, G., & Thoben, K.-D. (2021). Towards Using Digital Intelligent Assistants to Put Humans in the Loop of Predictive Maintenance Systems. *IFAC-PapersOnLine*, 54(1), 49–54.
- Wong, S. Y., Ye, X., Guo, F., & Goh, H. H. (2022). Computational intelligence for preventive maintenance of power transformers. *Applied Soft Computing*, 114, 108129.
- Yakimovich, A., Beaugnon, A., Huang, Y., & Ozkirimli, E. (2021). Labels in a haystack: Approaches beyond supervised learning in biomedical applications. *Patterns*, 2(12), 100383.
- Yaşar, O. (2013). Türk İmalat Sanayinde Lokomotif Bir Sektör: Demir Çelik Sanayi. *Marmara Coğrafya Dergisi*, 20, 42–78.
- Yudhana, A., Sulisty, D., & Mufandi, I. (2021). GIS-based and Naïve Bayes for nitrogen soil mapping in Lendah, Indonesia. *Sensing and Bio-Sensing Research*, 33, 100435.
- Zenisek, J., Holzinger, F., & Affenzeller, M. (2019). Machine learning based concept drift detection for predictive maintenance. *Computers & Industrial Engineering*, 137, 106031.
- Zhai, S., Gehring, B., & Reinhart, G. (2021). Enabling predictive maintenance integrated production scheduling by operation-specific health prognostics with generative deep learning. *Journal of Manufacturing Systems*, 61, 830–855.
- Zhou, X., Liu, H., Pourpanah, F., Zeng, T., & Wang, X. (2021). A survey on epistemic (model) uncertainty in supervised learning: Recent advances and applications.

ÖZGEÇMİŞ

İlk ve orta öğrenimini Bursa ilinde tamamlamıştır. 2013 yılında Bursa Erkek Lisesinden mezun olmuştur. Aynı yıl Karadeniz Teknik Üniversitesi Endüstri Mühendisliği Bölümüne kaydını yaptırmıştır. Endüstri Mühendisliği eğitiminin 2. Yılımı Farabi öğrenci değişim programı ile Dokuz Eylül Üniversitesinde, 3. yılını ise Erasmus öğrenci değişim programı ile Portekiz de bir teknik üniversitede tamamlamıştır.

Lisans mezuniyetinin ardından KARDEMİR demir çelik fabrikalarında ERP sistemleri mühendisi olarak göreve başlamıştır. Sonrasında Tosyalı Holding bünyesinde seviye sistemleri mühendisi olarak görev almış ve şimdilerde NTT DATA Business Solution Turkey şirketinde CX Analyst olarak çalışmaya devam etmektedir.