



T.C.

EGE ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

**ENDÜSTRİYEL UYGULAMAYA YÖNELİK MAKİNE
ÖĞRENİMİ DESTEKLİ KESTİRİMCİ BAKIM MODELİ
ÖNERİSİ**

Doktora Tezi

GÖKSEL KARTUM

İşletme Anabilim Dalı

İZMİR

2025



T.C.

EGE ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

**ENDÜSTRİYEL UYGULAMAYA YÖNELİK MAKİNE
ÖĞRENİMİ DESTEKLİ KESTİRİMCİ BAKIM MODELİ
ÖNERİSİ**

Doktora Tezi

GÖKSEL KARTUM

Tez Danışmanı: PROF. DR. MURAT KOCAMAZ

İşletme Anabilim Dalı

İZMİR

2025

TEZ ONAY SAYFASI

Prof. Dr. Murat KOCAMAZ :

Doç. Dr. Ural Gökay ÇİÇEKLİ :

Doç. Dr. Yunus KAYMAZ :

Prof. Dr. Derya İLİÇ :

Dr. Öğretim Üyesi Mustafa YURTSEVER :

ETİK KURALLARA UYGUNLUK BEYANI

Ege Üniversitesi Sosyal Bilimler Enstitüsü Müdürlüğü'ne sunduğum "ENDÜSTRİYEL UYGULAMAYA YÖNELİK MAKİNE ÖĞRENİMİ DESTEKLİ KESTİRİMCİ BAKIM MODELİ ÖNERİSİ" adlı doktora tezim kapsamında kullandığım tüm kaynaklar, ilgili atıf ve referans kurallarına uygun şekilde belirtilmiş ve intihalden kaçınılmıştır. Çalışmada kullanılan veriler, etik ilkeler doğrultusunda toplanmış, işlenmiş ve analiz edilmiştir. Araştırmanın her aşamasında akademik dürüstlük ilkelerine bağlı kalınmış, veri analizi süreçlerinde herhangi bir manipülasyon yapılmamış ve sonuçlar gerçeği yansıtacak şekilde raporlanmıştır.

Bu tez çalışması, başkalarının fikir ve eserlerine saygı gösterilerek hazırlanmış ve intihal içermediği taahhüt edilmiştir. Tezde yer alan her türlü bilgi ve bulgu, çalışmanın amacı doğrultusunda bilimsel yöntemlere uygun olarak elde ettiğimi ve sunduğumu beyan eder onurumla doğrularım.

Göksel KARTUM

ÖNSÖZ

Bu doktora tezi, endüstriyel uygulamalara yönelik makine öğrenimi destekli kestirimci modeli geliştirmeyi ve bu modelin endüstrideki verimliliği artırma potansiyelini incelemeyi amaçlamaktadır. Çalışmanın her aşamasında, modern endüstri standartları ve bilimsel yöntemler temel alınmış, kapsamlı literatür araştırmaları ve veri analizleri gerçekleştirilmiştir. Tezin hazırlanma sürecinde karşılaşılan zorluklar, edinilen bilgi ve deneyimler sayesinde aşılmış ve ortaya çıkan sonuçların alan yazınına katkı sağlaması hedeflenmiştir.

Bu çalışmanın gerçekleştirilmesi sürecinde değerli bilgi ve tecrübeleriyle beni yönlendiren ve destekleyen tez danışmanım çok değerli hocam Prof. Dr. Murat Kocamaz'a teşekkürü bir borç bilirim. Ayrıca, araştırmam boyunca teşvik ve katkılarıyla yanımda olan tez izleme jüri üyelerim Doç. Dr. Ural Gökay Çiçekli ve Doç. Dr. Yunus Kaymaz hocalarıma içtenlikle teşekkür ederim. Tezimi hazırlarken bunaldığım anlarda benden desteğini hiç eksik etmeyen kıymetli dostum Hüseyin Tuna'ya ayrıca teşekkür etmek istiyorum. Verileri bulmam konusunda benden desteğini eksik etmeyen değerli dostum Bilal Akyüz'e ve verilerle ilgili her türlü desteği sağlayan işletme yetkilisi Fuat Sezer beye de teşekkür ederim.

Bu tezi hazırlarken benden desteğini hiç eksik etmeyen eşim Songül'e, kızlarımız Elif ve Ece'ye sonsuz teşekkür ederim. Ayrıca, aileme teşekkürün en büyüğünü etmek istiyorum, sizler olmasaydınız asla bugünlere gelemezdim.

Bu çalışmanın, endüstride kestirimci bakım süreçlerine katkı sağlaması ve gelecekte yapılacak araştırmalara ilham vermesi dileğiyle.

Göksel Kartum
İzmir, 2025

ÖZET

Sanayide rekabet gücünün artırılması ve operasyonel verimliliğin sağlanması, makinelerde beklenmedik arızaların önlenmesi için proaktif bakım stratejilerinin uygulanmasını zorunlu kılmaktadır. Bu tez çalışmasında, Diesse marka alçak basınçlı döküm tezgâhına entegre edilmiş SMC marka transmitter sensörlerden ve Elimko K tipi termokupldan toplanan çok boyutlu veriler kullanılarak, makine öğrenmesi destekli bir kestirimci bakım modeli geliştirilmiştir. Kullanılan veri seti, sıcaklık, basınç ve akışkan hızı gibi parametrelerin yanı sıra, sensör verileri ile ilişkilendirilmiş arıza kayıtlarını içermektedir.

Çalışmanın veri işleme aşamasında, saniyelik sensör ölçümleri dakikalık ortalamalara dönüştürülmüş, aykırı değerler Quantiller Arası Açıklık (IQR) metodu ile düzeltilmiştir. Ayrıca, “Hidrolik Silindir Arızası” hedef değişkeni için sensör verileri ile arıza zaman damgaları eşleştirilmiş, bu hedef değişken sınıflandırma probleminin temelini oluşturmuştur.

Model geliştirme sürecinde, KNN, SVM, MLP, Linear Discriminant Analysis (LDA) ve Logistic Regression gibi makine öğrenmesi algoritmaları kullanılmıştır. Modeller, eğitim ve test setlerine ayrılan veri üzerinde değerlendirilmiş ve hiperparametre optimizasyonu ile performans iyileştirilmiştir. Analiz sonuçlarına göre, MLP modeli, %74 doğruluk oranıyla en yüksek başarıyı sağlamıştır. Diğer algoritmalar arasında KNN modeli %68 doğruluk oranıyla öne çıkmış, SVM ve Logistic Regression modelleri ise nispeten daha düşük performans sergilemiştir.

Tüm bu çalışmalar kapsamında elde edilen verilerin analizi ve uygulanan makine öğrenmesi algoritmaları göz önünde bulundurularak, işletmelerin arıza tahmin doğruluğunu artıracak, bakım maliyetlerini optimize edecek ve operasyonel sürekliliği destekleyecek bir kestirimci bakım modeli önerilmiştir. Geliştirilen bu modelin, işletme maliyetlerini sürdürülebilirlik ilkeleriyle uyumlu, etkin ve verimli bir şekilde yönetmeye katkı sağlama potansiyeline sahip olduğu değerlendirilmektedir.

Anahtar Kelimeler: Makine Öğrenmesi, Kestirimci Bakım, Hiperparametre Optimizasyonu, Endüstriyel Uygulamalar.

ABSTRACT

Enhancing industrial competitiveness and ensuring operational efficiency necessitate the implementation of proactive maintenance strategies to prevent unexpected machine failures. In this dissertation, a machine learning-supported predictive maintenance model has been developed using multidimensional data collected from SMC-branded transmitter sensors and an Elimko K-type thermocouple integrated into a Diesse low-pressure casting machine. The dataset utilized in this study includes parameters such as temperature, pressure, and fluid velocity, as well as failure records correlated with sensor data.

During the data preprocessing phase, second-based sensor measurements were converted into minute-based averages, and outliers were corrected using the Interquartile Range (IQR) method. Additionally, for the target variable "Hydraulic Cylinder Failure," sensor data were matched with failure timestamps, forming the foundation for a classification problem.

The model development process involved the use of machine learning algorithms such as KNN, SVM, MLP, Linear Discriminant Analysis (LDA), and Logistic Regression. These models were evaluated on a dataset split into training and test sets, with performance improvements achieved through hyperparameter optimization. According to the analysis results, the MLP model achieved the highest accuracy rate at 74%. Among other algorithms, the KNN model stood out with a 68% accuracy rate, while SVM and Logistic Regression models exhibited relatively lower performance.

Based on the analysis of the data and the applied machine learning algorithms, a predictive maintenance model has been proposed to enhance failure prediction accuracy, optimize maintenance costs, and support operational continuity for businesses. This model is also assessed to have the potential to contribute to the sustainable, efficient, and effective management of operational costs in alignment with sustainability principles.

Keywords: Machine Learning, Predictive Maintenance, Hyperparameter Optimization, Industrial Applications

İÇİNDEKİLER

ÖNSÖZ	IV
ÖZET.....	V
ABSTRACT.....	VI
ŞEKİLLER LİSTESİ	IX
TABLOLAR LİSTESİ	XI
KISALTMALAR	XII
GİRİŞ	1
BİRİNCİ BÖLÜM	3
BAKIM KAVRAMINA YÖNELİK YAKLAŞIMLAR	3
1.1. Düzeltici Bakım.....	5
1.2. Önleyici Bakım.....	7
1.3. Tanımlayıcı Bakım	10
1.4. Kestirimci Bakım.....	11
1.4.1. Kestirimci Bakımın İşleyişi ve Bileşenleri.....	13
1.4.2. Kestirimci Bakımın Avantajlı ve Dezavantajlı Yanları	15
1.5. Endüstri 4.0 Kapsamında Kestirimci Bakım Teknolojileri.....	17
İKİNCİ BÖLÜM	20
MAKİNE ÖĞRENMESİ KAVRAMI	20
2.1. Veri Madenciliği Süreçleri	20
2.2. Makine Öğrenmesi	23
2.3.1. Makine Öğrenmesi Süreçlerinin Aşamaları	25
2.3.2. Makine Öğrenmesi Kapsamında Farklı Yöntemler.....	28
2.4. Makine Öğrenmesi ve Kestirimci Bakım	40
2.5. Makine Öğrenmesi ile İlgili Olarak Yapılan Çalışmalar.....	42
2.5.1. Makine Öğrenmesi ile İlgili Yurtiçinde Yapılan Çalışmalar	42
2.5.2. Makine Öğrenmesi ile İlgili Yurtdışında Yapılan Çalışmalar.....	46
ÜÇÜNCÜ BÖLÜM	49
UYGULAMA	49
3.1. Araştırmanın Amacı ve Kapsamı	49
3.2. Kapsam	53
3.3. “Makine Öğrenimi Destekli Kestirimci Bakım Modeli Önerisi” Literatür Özeti	53
3.4. Kestirimci Bakım Problemi Model Eğitim Süreci	55
3.4.1. Veri Yapısı	55
3.4.2. Veri Ön İşleme	63
3.4.3. Eğitim ve Validasyon Verisinin Ayrılması	69
3.5. Analiz Değerlendirmeleri	75
3.5.1. Logistic Regression	77

3.5.2.	Linear Discriminant Analysis.....	80
3.5.3.	K-Nearest Neighbors (KNN).....	84
3.5.4.	Destek Vektör Makinesi (Support Vector Machine).....	87
3.5.5.	Çok Katmanlı Algılayıcı (Multilayer Perceptron).....	89
DÖRDÜNCÜ BÖLÜM		94
SONUÇ VE ÖNERİLER.....		94
KAYNAKÇA		99
EKLER.....		117
ÖZGEÇMİŞ.....		127



ŞEKİLLER LİSTESİ

Şekil 1: Bakım Türleri	3
Şekil 2: Tanımlayıcı Bakım	10
Şekil 3: Kestirimci Bakımın Temel Bileşenleri	14
Şekil 4: Kestirimci Bakımın Avantajlı Yönleri	16
Şekil 5: Veri Tabanından Bilginin Keşfi	21
Şekil 6: Makine Öğrenmesi Süreçlerinin Aşamaları	26
Şekil 7: Denetimli Öğrenme Süreci	30
Şekil 8: Basit Sınıflandırmaya Ait Temsili Grafik	31
Şekil 9: Basit Regresyona Ait Temsili Grafik	31
Şekil 10: Denetimsiz Öğrenme Süreci	33
Şekil 11: Kümeleme Yöntemi.....	34
Şekil 12: Veri Setinin Toplanma Süreci	60
Şekil 13: Aykırı Değerlerin Dağılımı (Düzeltilme Öncesi)	65
Şekil 14: Veri Setindeki Aykırı Değerlerin Kutu Grafikleri ile Gösterimi.....	66
Şekil 15: Aykırı Değerlerin Dağılımı (Düzeltilme Sonrası)	68
Şekil 16: Veri Setindeki Aykırı Değerlerin Kutu Grafikleri ile Gösterimi.....	69
Şekil 17: Korelasyonlara Ait Grafik	72
Şekil 18: Kategorik Hale Getirilmiş Değişkenlerin Dağılımları.....	73
Şekil 19: Veri Setindeki Parametrelerin Çiftli Dağılım Grafikleri	74
Şekil 20: Lojistik Regresyon "Çapraz Doğrulama Performans Değerlendirme Tablosu"	78
Şekil 21: Lojistik Regresyon "Karışıklık Matrisi (Confusion Matrix)"	79
Şekil 22: Lojistik Regresyon "Çapraz Doğrulama Performans Değerlendirme Tablosu" Parametre Optimizasyonu Sonrası	79
Şekil 23: Lojistik Regresyon "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası.....	79
Şekil 24: Lojistik Regresyon "Model Performans Özeti Tablosu"	80
Şekil 25: Doğrusal Ayırıcı Analiz "Çapraz Doğrulama Performans Değerlendirme Tablosu"	81
Şekil 26: Doğrusal Ayırıcı Analiz "Karışıklık Matrisi (Confusion Matrix)"	81
Şekil 27: Doğrusal Ayırıcı Analiz "Çapraz Doğrulama Performans Değerlendirme Tablosu" Parametre Optimizasyonu Sonrası	82

Şekil 28: Doğrusal Ayırıcı Analiz "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası.....	82
Şekil 29: Doğrusal Ayırıcı Analiz "Model Performans Özeti Tablosu"	83
Şekil 30: En Yakın K-Komşu "Çapraz Doğrulama Performans Değerlendirme Tablosu"	84
Şekil 31: En Yakın K-Komşu "Karışıklık Matrisi (Confusion Matrix)"	84
Şekil 32: En Yakın K-Komşu "Çapraz Doğrulama Performans Değerlendirme Tablosu" Parametre Optimizasyonu Sonrası	85
Şekil 33: En Yakın K-Komşu "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası.....	86
Şekil 34: En Yakın K-Komşu "Model Performans Özeti Tablosu"	86
Şekil 35: Destek Vektör Makinesi "Çapraz Doğrulama Performans Değerlendirme Tablosu"	88
Şekil 36: Destek Vektör Makinesi "Karışıklık Matrisi (Confusion Matrix)"	88
Şekil 37: Destek Vektör Makinesi "Model Performans Özeti Tablosu"	89
Şekil 38: Çok Katmanlı Algılayıcı "Çapraz Doğrulama Performans Değerlendirme Tablosu"	90
Şekil 39: Çok Katmanlı Algılayıcı "Karışıklık Matrisi (Confusion Matrix)"	90
Şekil 40: Çok Katmanlı Algılayıcı "Çapraz Doğrulama Performans Değerlendirme Tablosu" Parametre Optimizasyonu Sonrası	91
Şekil 41: Çok Katmanlı Algılayıcı "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası.....	91
Şekil 42: Çok Katmanlı Algılayıcı "Model Performans Özeti Tablosu"	92

TABLÖLAR LİSTESİ

Tablo 1: Düzeltici Bakım, Önleyici Bakım ve Kestirimci Bakımın Karşılaştırılması	12
Tablo 2: Farklı Bakım Türlerinin Avantaj ve Dezavantajlarının Karşılaştırılması	17
Tablo 3: Makine Öğrenmesi ile İlgili Yurtiçinde Yapılan Çalışmalar	42
Tablo 4: Makine Öğrenmesi ile İlgili Yurtdışında Yapılan Çalışmalar	46
Tablo 5: Model Değişkenleri ve Açıklamaları	59
Tablo 6: Ham Verinin Özet İstatistikleri	62
Tablo 7: Makine Öğrenmesi Algoritmalarının Sonuçlarının Karşılaştırılması	93



KISALTMALAR

AI	: Artificial Intelligence (Yapay Zekâ).
CNN	: Convolutional Neural Network (Evrimsel Sinir Ağı).
GAN	: Generative Adversarial Networks (Üretken Çekişmeli Ağlar).
HMI	: Human-Machine Interface (İnsan-Makine Arayüzü).
HSA	: Hidrolik Silindir Arızası.
IoT	: Internet of Things (Nesnelerin İnterneti).
IQR	: Interquartile Range (Quantiller Arası Açıklık).
KB	: Kestirimci Bakım.
KNN	: K-Nearest Neighbors (K-En Yakın Komşular Algoritması).
LAN	: Local Area Network (Yerel Alan Ağı).
LDA	: Linear Discriminant Analysis (Doğrusal Ayırıcı Analiz).
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek).
MATLAB	: Mühendislik ve veri işleme yazılımı.
MDP	: Markov Decision Processes (Markov Karar Süreçleri).
ML	: Machine Learning (Makine Öğrenimi).
MLP	: Multilayer Perceptron (Çok Katmanlı Algılayıcı).
MÖ	: Makine Öğrenmesi.
NLP	: Natural Language Processing (Doğal Dil İşleme).
NN	: Nearest Neighbor (En Yakın Komşu).
PCA	: Principal Component Analysis (Ana Bileşen Analizi).
PLC	: Programmable Logic Controller (Programlanabilir Lojik Denetleyici).
PM	: Preventive Maintenance (Önleyici Bakım).
PyCaret	: Python için makine öğrenmesi otomasyon kütüphanesi.
SQL	: Structured Query Language (Yapılandırılmış Sorgu Dili).

- SVM** : Support Vector Machines (Destek Vektör Makineleri).
- TPM** : Total Productive Maintenance (Toplam Verimli Bakım).
- t-SNE** : t-distributed Stochastic Neighbor Embedding (t-dağılımlı Stokastik Komşuluk Yerleştirme).
- WLAN** : Wireless Local Area Network (Kablosuz Yerel Alan Ağı).
- vd.** : ve diğerleri
- vb.** : ve benzeri



GİRİŞ

Sanayide dijitalleşme ve Endüstri 4.0 uygulamalarının yaygınlaşması, üretim süreçlerinde verimliliği artırmak ve beklenmedik arızaları önlemek için kestirimci bakım uygulamalarını ön plana çıkarmıştır. Bu bağlamda, sensör teknolojileriyle desteklenen veri toplama sistemleri, üretim süreçlerinin daha etkin bir şekilde yönetilmesine olanak tanımaktadır. Diesse alçak basınçlı döküm tezgâhı, bu tür teknolojilerin uygulandığı endüstriyel ekipmanlardan biri olup, sensörlerden elde edilen çok boyutlu verilerin analizi yoluyla, arızaların önceden tahmin edilmesine olanak sağlar.

Bu tez çalışması, "Diesse alçak basınçlı döküm tezgâhı" üzerinde entegre edilmiş sensörlerden toplanan verilerle, makine öğrenmesi destekli bir kestirimci bakım modeli geliştirmeyi amaçlamaktadır. Tezgâhın sıcaklık, basınç ve akışkan sistemlerindeki performans verilerini yüksek hassasiyetle ölçebilen SMC marka transmitter, Metal Elimko K tipi termokupldan ve Kalıp Termokupl sensörlerinden elde edilen veriler, modelin doğruluğunu artıran temel girdileri sağlamaktadır. Bu sensörlerden gelen ham veriler, arıza tespiti ve önleyici bakım stratejileri geliştirmek amacıyla çeşitli ön işleme tekniklerinden geçirilmiştir.

Veri toplama sürecinin endüstriyel bağlamda önemli katkıları bulunmaktadır. Örneğin, SMC marka transmitter sensörlerinden elde edilen akışkan hızı verileri, hidrolik ve mekanik sistemlerdeki potansiyel arızaların erken tespiti için kritik bir rol oynamaktadır. Metal Elimko K tipi termokupldan ve Kalıp termokupl sensörleri ise döküm sürecindeki sıcaklık değişimlerini izleyerek, termal anomalilerin ve malzeme uyumsuzluklarının önlenmesine olanak tanır. Bu şekilde oluşturulan veri seti, arıza durumlarının etiketlenmesi ve kestirimci bakım modellerinin eğitilmesi için sağlam bir temel oluşturmaktadır.

Tez çalışmasında kullanılan yöntemler, literatürdeki benzer çalışmalarla uyumlu olmakla birlikte, çeşitli yenilikçi yaklaşımları da içermektedir. Örneğin, sensörlerden toplanan sürekli veriler, saniyelik ölçümlerden dakikalık ortalamalara dönüştürülerek, veri boyutu yönetilebilir hale getirilmiş ve modelleme sürecinin etkinliği artırılmıştır. Literatürde, sensör tabanlı kestirimci bakım modelleri üzerine yapılan çalışmalar, bu yaklaşımların etkili sonuçlar verdiğini göstermektedir. Örneğin:

Chevtchenko vd. (2023), endüksiyon motorlarında nesnelerin interneti (IoT) sensörlerinden elde edilen verilerle makine öğrenmesi temelli kestirimci bakım modeli geliştirmişlerdir ve bu modelin arıza tespitindeki doğruluğunu vurgulamışlardır.

Hamaide vd. (2022), döner makinelerde kullanılan bir çift seviyeli makine öğrenmesi çerçevesiyle, sensör verilerinin bakım planlamasında nasıl etkili bir şekilde kullanılabileceğini ortaya koymuşlardır.

Tez çalışmasında, sensör teknolojilerinden elde edilen yüksek kaliteli verilerle, kestirimci bakım süreçlerini optimize edilmesi hedeflenmektedir. "Diesse alçak basınçlı döküm tezgâhı"ndan elde edilen verilerin analizi, bakım süreçlerinin planlı bir şekilde yürütülmesine ve üretim maliyetlerinin azaltılmasına katkı sağlamaktadır. Çalışmanın, hem akademik literatüre hem de endüstriyel uygulamalara önemli katkılar sunacağı öngörülmektedir. Bu bağlamda doktora tez çalışması dört ana bölümden oluşmaktadır:

Birinci Bölüm: Çalışmanın teorik tabanını oluşturan bu bölümde, kestirimci bakım kavramı, tarihsel gelişimi ve endüstriyel uygulamalardaki rolü ele alınmıştır. Ayrıca, kestirimci bakım süreçlerinin temel bileşenleri ve bu süreçlerde kullanılan makine öğrenimi algoritmalarının teknik özellikleri incelenmiştir.

İkinci Bölüm: Bu bölümde makine öğrenmesi kavramı, veri madenciliği süreçleri ve algoritmaların kestirimci bakım uygulamalarındaki rolü detaylı bir şekilde ele alınmıştır. Ayrıca, makine öğrenimi modellerinin eğitim süreçleri ve performans kriterleri açıklanmıştır.

Üçüncü Bölüm: Uygulama aşamasına geçilen bu bölümde, makine öğrenimi destekli kestirimci bakım modeli için kullanılan veri setleri, veri işleme teknikleri ve model eğitimi süreçleri açıklanmıştır. Bu kapsamda, önerilen modelin doğruluğunu artırmaya yönelik hiperparametre optimizasyonu teknikleri üzerinde durulmuş ve sonuçlar detaylı bir şekilde analiz edilmiştir.

Dördüncü Bölüm: Çalışmanın sonuçlarının ve önerilerinin sunulduğu bu bölümde, geliştirilen modelin endüstriyel süreçlere olası katkıları tartışılmış ve gelecekteki araştırmalar için önerilerde bulunulmuştur. Ayrıca, çalışma kapsamında elde edilen bulguların, işletmelerin bakım maliyetlerini azaltma ve operasyonel verimliliklerini artırma potansiyeli değerlendirilmiştir.

Bu doktora tezi çalışması, endüstriyel süreçlerin dijital dönüşümüne katkı sağlamayı ve işletmelerin bakım stratejilerinde daha proaktif ve veriye dayalı yaklaşımlar benimsemesine rehberlik etmeyi amaçlamaktadır. Çalışma, hem literatüre hem de uygulamacılara yönelik yenilikçi bir bakış açısı sunmakta ve dijitalleşen endüstri yapısına uygun bir kestirimci bakım modeli önerisiyle, sürdürülebilir bir geleceğe ışık tutmayı hedeflemektedir.


BİRİNCİ BÖLÜM

BAKIM KAVRAMINA YÖNELİK YAKLAŞIMLAR

Bakım kavramı, bir sistemin, cihazın ya da altyapının sürekli işleyişini sağlamak amacıyla yapılan faaliyetleri ifade eder. Çeşitli disiplinlerde, bakım çalışmaları ekipman, teknoloji ve süreçlerin sürdürülebilirliğini sağlamak adına hayati bir rol oynamaktadır. Mühendislikten işletme yönetimine ve sağlık hizmetlerine kadar birçok alanda, bakımın temel yaklaşımlarının anlaşılması, kaynakların verimli kullanılabilmesi ve uzun ömürlü olması açısından önem taşımaktadır. Bakımın birincil amacı varlıkların işlevselliğini ve değerini korumaktır, ancak bu amacın nasıl sistematik olarak yönetileceği de çok önemli bir başka konudur. Bu kapsamda bakım üretilen ürünün kalitesinden, karlılığına, malzeme ömründen, duruş sürelerinin azaltılmasına kadar işletme için kritik olan birçok nokta da önem arz etmektedir (Susto vd., 2015).

Modern üretim ve endüstriyel süreçlerde bakım, sistem performansını artırmak ve operasyonel kesintileri minimize etmek için kritik bir rol oynar. Günümüzde farklı sektörlerde uygulanan çeşitli bakım yaklaşımları geliştirilmiştir. Bu yaklaşımlar, teknolojinin ilerlemesiyle birlikte daha karmaşık hale gelmiş ve daha etkili yönetim stratejileri ortaya koymuştur.

Şekil 1: Bakım Türleri



Kaynak: Jimenez vd., 2020

En yaygın bakım yöntemlerinden biri önleyici bakımdır. Önleyici bakım, ekipmanın arıza yapmadan önce belirli aralıklarla kontrol edilmesini ve bakımının yapılmasını içerir. Bu yaklaşım, arızaların önceden tespit edilerek müdahale edilmesini sağlayarak sistemin ömrünü uzatır ve maliyetli onarım süreçlerini minimize eder. Özellikle enerji santralleri gibi büyük

retim tesislerinde yaygın olarak kullanılan bu yntem, arıza riskini azaltarak operasyonel gvenlięi artırır (Pintelon ve Parodi-Herz, 2016).

Bir dięer nemli bakım yaklaşıımı dzeltici bakımdır. Bu yaklaşıım, arıza meydana geldikten sonra ekipmanın onarılması veya deęiştirilmesi anlamına gelir. Dzeltici bakım, beklenmedik kesintilere neden olabilse de dřk maliyetli bařlangıç yatırımları nedeniyle bazı řirketler tarafından tercih edilmektedir. Ancak, bu yntem genellikle uzun vadede daha yksek maliyetlere neden olabilir ve retim srelerinde verim kaybına yol aabilir (Al-Turki vd., 2016).

Planlı bakım bir arızanın oluřması beklenmeden dzenli aralıklarla yapılan bakım faaliyetleridir. Genel olarak senenin bařında iřletmeler tarafından hazırlanan yıllık bakım planları kapsamında ilgili sene iindeki bakım faaliyetleri yrtlr. Burada nemli bir nokta arıza, duruř vb. durumlardan baęımsız olarak ilgili bakım planının devam ettirilmesidir. Bir yalın retim yaklaşıımı olan toplam verimli bakımın da konusu olarak ele alınabilecek planlı bakım kesintisiz devam eden retim sreleri gibi iřletmeler aısından nemli faydalar saęlayan bir faaliyettir. Bu yaklaşıımı uygulayan iřletme sayısı da her geen artmaktadır (Jimenez vd., 2020).

Duruma dayalı bakım, ekipmanın gerek zamanlı durumu gz nne alınarak yapılan bir bakım yntemidir. Bu yaklaşıımda, ekipmanın performansı ve durumu srekli izlenir ve sadece belirli bir eřik deęeri ařıldığında bakım yapılır. Duruma dayalı bakım, zellikle pahalı ve kritik neme sahip ekipmanlarda kullanılır ve gereksiz bakım iřlemlerinin nne geerek maliyet etkinlięini artırır (Ahmad ve Kamaruddin, 2021).

Son dnemde seri retim hatlarında gerekleřtirilen bakım srelerine dair yaklaşıımlar montaj hattının dengelenmesi veya retim planlama kavramlarının kapsamında deęerlendirilmeye bařlanmıřtır. Bu noktada temel ama bakım iřleminin retim veya montaj srelerine olumsuz bir etki yaratmadan tamamlanabilmesidir. Bir aıdan bakımın buradaki temel hedefinin retim ve montaj hattının etkinlięini arttırmak yani olası arızalar kaynaklı duruřlar ortaya ıkmadan retim devamını saęlayabilmektir.

Bakım odaklı stratejilerin bir destek unsuru olarak deęerlendirilebileceęi bir bařka konu da rn kalitesidir. retim srelerinde faaliyet gsteren makine ve ekipmanların arızalanması retim kalitesini dřrebilmektedir (Rokhforoz ve Fink, 2022). retim kalitesi ve retim kesintilerinin engellenebilmesi aslında bakım stratejileri ile i ie olan konulardır. Bakım planlaması retim sisteminin kullanılabilirlik seviyesini ykseltmeyi hedeflemektedir.

Son yıllarda gelişen bir diğer yaklaşım ise risk temelli bakım olmuştur. Risk temelli bakım, ekipmanın arıza olasılığı ve bu arızanın olası etkilerini analiz ederek bakım stratejilerini belirler. Bu yöntem, yüksek risk taşıyan sistemlerde daha sık bakım yapılmasını ve düşük riskli sistemlerde bakım sıklığının azaltılmasını sağlar. Bu sayede, kaynakların daha verimli kullanılması sağlarken kritik sistemlerin güvenliği artırılır (Khan ve Haddara, 2020).

Bakım stratejilerinin dijitalleşmesi ve Endüstri 4.0 ile birlikte akıllı bakım sistemleri de büyük önem kazanmıştır. Akıllı bakım sistemleri, yapay zekâ ve makine öğrenimi gibi ileri teknolojiler kullanarak ekipmanın durumunu analiz eder ve proaktif bakım önerileri sunar. Bu sistemler, sadece arızaları önlemekle kalmaz, aynı zamanda bakım planlarını optimize ederek iş süreçlerini iyileştirir (Bokrantz vd., 2020).

Günümüzde bakım stratejilerinin entegrasyonu da yaygınlaşmıştır. Toplam Üretken Bakım (TPM) gibi yaklaşımlar, bakım faaliyetlerini operasyonel süreçlerle entegre ederek genel ekipman verimliliğini artırmayı hedefler. TPM, sadece bakım ekiplerinin değil, tüm çalışanların bakım sürecine katılımını teşvik ederek üretim kayıplarını en aza indirir ve iş güvenliğini artırır (Ahuja ve Khamba, 2020).

Bakım kavramına yönelik temel yaklaşımlar, her biri farklı avantajlara ve uygulamalara sahip stratejilerden oluşmaktadır. Teknolojinin ilerlemesi ve Endüstri 4.0 devrimi, bakım yönetiminin daha proaktif ve veri odaklı hale gelmesini sağlamıştır. Bu gelişmeler, bakım faaliyetlerinin daha verimli ve etkili bir şekilde yönetilmesine olanak tanıyarak, şirketlerin rekabet avantajını artırmaktadır.

1.1. Düzeltici Bakım

Bakım sisteminin planlanması ve uygulanması, karmaşık bir yapıya sahip olduğundan oldukça zorlu bir problem olarak kabul edilir. Bakım süreçlerinde, sistemi oluşturan tüm birimler birbiriyle bağımlı bir şekilde çalışır. Önleyici bakım faaliyetleri planlanabilir ve bu plana uygun hareket edilebilirken, düzeltici bakım faaliyetleri sistemin işleyişini doğrudan etkilediğinden zaman açısından oldukça kritik bir öneme sahiptir (Özgür-Ünlüakın vd., 2021). Günümüzde maliyetlerin yüksek olduğu koşullarda, işletmelerin bakım stratejilerini yalnızca düzeltici faaliyetlere dayandırmaları verimli bir yöntem değildir. Hem önleyici bakım stratejilerini etkin bir şekilde uygulayan işletmeler, hem de bu stratejileri etkili biçimde yönetenler her zaman avantaj sağlayacaktır.

Düzeltici bakım en temel haliyle bir ekipman üzerinde meydana gelen herhangi bir arıza durumunun sonrasında ilgili soruna yönelik yapılan bakım işlemi olarak açıklanabilir. Arıza

giderme olarak da adlandırılabilen bu yaklaşım sürekli üretim açısından sorun çözücü bir yaklaşıma sahip değildir. Arıza sonrası müdahale olarak da değerlendirilebilecek bu yaklaşıma göre herhangi bir olumsuz durum olmadığı sürece ilgili ekipman veya üretim hattına herhangi bir müdahalede bulunulmamaktadır. Bu yanı ile düzeltici bakım günümüzün rekabet yoğun endüstri yapısında kabul görmeyen, büyük maliyetler yaratma riski büyük bir yaklaşımdır (Jimenez vd., 2020).

Düzeltilici bakım, arızaların oluşması durumunda devreye girmektedir ve bu süreçte işletmelerin, makinelerin ve sistemlerin verimliliği üzerinde önemli etkiler yaratmaktadır. Ben-Daya vd. (2009), düzeltici bakımın önleyici bakıma göre %50 daha maliyetli olduğunu belirtmektedir. Bu durum, düzeltici bakımın planlanamaması ve genellikle acil durumlarda uygulanmasından kaynaklanmaktadır. Bu açıdan etkili bir bakım organizasyonunda düzeltici bakımın %20'yi geçmemesi gerektiği söylenebilir. Ancak birçok işletme, uygun bakım uygulamalarını gerçekleştirememekte ve bu da düzeltici bakım oranını yükseltmektedir.

Düzeltilici bakımın yönetimi, insan faktörlerinin yanı sıra teknolojik etkileşimlerin de göz önünde bulundurulmasını gerektirmektedir. Özellikle, günümüzde dijital teknolojilerin artan kullanımı, teknisyenlerin performansını iyileştirmek için tasarlanmış olsa da, sistem tasarımındaki eksiklikler yeni zorluklar doğurabilmektedir. İnsan merkezli sistem tasarımına yönelik yapılan çalışmalar, bu etkileşimlerin iyileştirilmesi için kritik öneme sahiptir (Shin vd., 2024).

Bu bakım türünün etkili yönetimi, bakım süreçlerinin yapısının da optimize edilmesini gerektirir. Düzeltici bakım süreçlerinde kullanılan iş gücü ve performans değerlendirmeleri, bu sürecin daha verimli hale getirilmesi için önem arz etmektedir. Örneğin, teknik destek sistemlerinin tasarımı, teknisyenlerin iş yükünü ve performansını etkileyebilir. Bu bağlamda, teknolojik sistemlerin insan faktörü ile entegrasyonu büyük bir önem taşımaktadır (Adolfsson ve Tuvstarr, 2011).

Düzeltilici bakımın etkin yönetimi, aynı zamanda iş gücü planlaması ve bakım stratejilerinin entegrasyonu açısından da büyük önem taşımaktadır. Birçok araştırma, bakım stratejilerinin belirlenmesinde iş gücünün verimliliğini artırmanın önemini vurgulamaktadır. Kumar vd., (2016), bakım iş gücünün performansını artırmak için eğitim ve bilgi paylaşımının kritik olduğunu belirtmektedir. Bu bağlamda, teknisyenlerin sürekli eğitim almaları, bakım süreçlerinin kalitesini artırabilir ve düzeltici bakımın etkisini olumlu yönde etkileyebilir.

Teknolojinin gelişimi, düzeltici bakım süreçlerini daha da iyileştirmektedir. Özellikle, Nesnelerin İnterneti (IoT) ve veri analitiği gibi yenilikçi teknolojiler, arıza tahmini ve bakım planlamasında büyük kolaylık sağlamaktadır. Bu bağlamda, işletmelerin bu yeni teknolojilere yatırım yapmaları, düzeltici bakım süreçlerini optimize etmelerine yardımcı olabilir (Shin vd., 2024).

Düzeltilici bakımın temel avantajları arasında düşük başlangıç maliyetleri ve acil durumlara hızlı müdahale imkanı sağlıyor oluşu sayılırken, dezavantajlı yanları arasında ise yüksek ve uzun maliyetli oluşu ile bu bakım alternatifinde üretim duruş sürelerinin artışı gösterilebilmektedir.

Düzeltilici bakım, bir arızanın gerçekleşmesinden önce herhangi bir önleyici faaliyet gerektirmez. Arıza meydana geldiğinde, işletmenin mevcut kaynaklarıyla arızaya hızlı bir şekilde müdahale edilmesi esas alınır. Bu yaklaşımda, arızaya neden olan ekipmanda kayıp yaşanması kaçınılmazdır. Arıza öncesinde yapılan küçük bir onarımla çözülebilecek bir problem, müdahale edilmediği takdirde ciddi maliyetlere yol açabilir. Ayrıca, arızanın oluşması, o anda üretim hattında görev yapan çalışanlar için de risk teşkil edebilir. Bu durum, iş sağlığı açısından ciddi tehlikelere neden olabilir (Silvestri vd., 2020).

Arızalar, genellikle ciddi üretim kayıplarına yol açabilir. Özellikle üretim sırasında beklenmedik bir anda ortaya çıkan bir arıza, o anda üretilmekte olan malzemelerin büyük ölçüde bozulmasına ve ek maliyetlere neden olabilir. Bunun yanı sıra, arıza anında üretim büyük ihtimalle duracak ve sorun giderilip sistem yeniden çalışır hale getirilene kadar üretime ara verilecektir. Bu tür durumlarda işletme, mevcut kaynaklarına bağlı olarak üretim sistemine müdahale edebilir. Ancak, gerekli ekipman veya teknik personel eksikliği gibi durumlar söz konusu olduğunda, üretim duruşu uzayacak ve bu durum işletmenin mali yükünü daha da artıracaktır (Gan vd., 2022).

1.2. Önleyici Bakım

Düzeltilici bakım, arızanın meydana gelmesinden sonra gerçekleştirilen işlemleri kapsarken, önleyici bakım arıza oluşmadan önce uygulanan ve arızayı önlemeyi amaçlayan bir bakım türüdür. Makine ve ekipmanların düzenli izlenmesi ve kontrol edilmesi açısından önleyici bakım büyük bir önem taşımaktadır. (Wong vd., 2022).

Önleyici bakım, makinelerin ve ekipmanların planlı bakımları aracılığıyla arızaların önüne geçmeyi hedefleyen bir bakım stratejisidir. Bu stratejinin üretim hatlarının verimliliğini artırmada, bakım maliyetlerini düşürmede ve arıza sürelerini en aza indirmede önemli bir rol

oynadığını söylemek mümkündür. Modern üretim süreçlerinde kullanılan makinelerin karmaşıklığı arttıkça, önleyici bakımın önemi de aynı oranda artmaktadır. Özellikle sağlık hizmetleri ve ağır sanayi gibi kritik sektörlerde, düzenli bakımın etkin şekilde planlanması hem ekipman ömrünü uzatmakta hem de operasyonel verimliliği artırmaktadır.

Önleyici bakım, belirli aralıklarla ya da önceden tanımlanmış kriterlere uygun olarak gerçekleştirilen bir bakım türüdür. Bu yöntem, arızaların sayısını en aza indirerek ve plansız düzeltici bakım ihtiyacını ortadan kaldırarak ekipmanların güvenilirliğini ve kullanılabilirliğini artırmayı hedefler. Arızalar oluşmadan önce yapılan bakım veya düzeltme çalışmaları sayesinde ekipman arızalarının büyük ölçüde önüne geçilebilir. Ancak, tüm arızaların tamamen ve kesin bir şekilde tahmin edilip önlenmesi mümkün olmadığı gibi, önleyici bakıma yönelik en önemli eleştirilerden biri de gereğinden fazla bakım işlemi yapılmasına neden olabilmesidir. Ayrıca, önleyici bakımın kötü planlanması durumunda, henüz kullanılabilir ömrü olan bazı parçaların gereksiz yere değiştirilmesi, yüksek bakım maliyetlerine yol açabilmektedir (Faria vd., 2015). Önleyici bakımın genel avantajlarını ise aşağıdaki gibi sıralamak mümkündür (Sullivan vd., 2010):

- Önleyici bakım sermaye yoğun süreçler açısından maliyet etkin bir yaklaşımdır.
- Önleyici bakım sayesinde bakım periyotlarının esnek olarak planlanabilmesi mümkün hale gelmektedir.
- Önleyici bakım faaliyetleri ile parça ömrü döngüleri yükselmektedir.
- Önleyici bakım enerji tasarrufunu mümkün kılarken ekipman arızalarını ve işlem hatalarını da azaltan bir yaklaşımdır.

Önleyici bakımın avantajları arasında, ekipman ömrünü uzatması, iş güvenliğini artırması ve maliyet etkinliği sayılabilir. Ayrıca, bu strateji, üretimdeki duraklamaları minimuma indirerek üretim hedeflerine ulaşılmasını kolaylaştırmaktadır. Son dönemde yapılan çalışmalar, makinelerin durumunu sürekli izleyip arıza belirtilerini erken tespit eden yapay zeka ve sensör teknolojileri ile desteklenen hibrit önleyici modellerine yönelmiştir (Finkelstein vd., 2020).

Önleyici bakım stratejileri genellikle zaman, maliyet ve arıza oranı gibi faktörlere dayalı olarak planlanmaktadır. Örneğin, Basri vd., (2017), maliyet ve arıza tabanlı önleyici bakım yöntemlerinin endüstride yaygın olarak kullanıldığını ve bu stratejilerin uygulamada başarıyla sonuçlandığını belirtmiş ve önleyici bakım planlamasının yapay zeka, matematiksel modelleme

ve simülasyon teknikleri ile desteklenerek daha verimli hale getirilebileceğini öne sürmüştür. Bu yöntemlerin uygulanabilirliği özellikle büyük ölçekli üretim tesislerinde daha belirgindir.

Sanayi tesislerinde hibrit bakım modelleri kullanılarak bakım süreçleri optimize edilmektedir. Bu modeller hem yaşlanmaya bağlı bakım hem de koşul temelli bakım unsurlarını bir araya getirerek daha verimli bir bakım döngüsü sunmaktadır. Örneğin bu kapsamda büyük veri analizi ve makine öğrenimi algoritmaları ile desteklenen bakım süreçlerinin, makinelerin performansını iyileştirdiğini ve arıza oranlarını ciddi anlamda düşürdüğü görülmektedir (Finkelstein vd., 2020).

Sadece üretim sektörü açısından değil aynı zamanda farklı hizmet sektörü alternatiflerinde de önleyici bakım stratejilerinin kullanılan cihazların güvenilirliğini artırmada önemli rol oynadığını vurgulanabilmektedir. Örneğin sağlık hizmetlerinde bakım maliyetlerini azaltmak ve hasta güvenliğini sağlamak adına, önleyici bakımın sistemli bir şekilde uygulanması gerekmektedir (Seif ve Rabbani, 2014).

Bu bakım türü, planlı bakımlar sayesinde beklenmedik arızaların ve duruşların önlenmesini amaçlamaktadır. Modern enerji santralleri gibi sürekli operasyon gerektiren tesislerde, bakım stratejilerinin dikkatli bir şekilde planlanması gerekir. Bu planlamada genellikle ortalama arıza süresi gibi metrikler kullanılır ve makinelerin ömrü uzatılırken verimlilik artırılmaktadır. Özellikle enerji sektöründe, önleyici bakım stratejileriyle birlikte dijital izleme sistemleri kullanımı daha yaygın hale gelmiştir (Moleda vd., 2023).

Rigamonti vd., (2016) çevresel koşullar ve operasyonel parametrelerin önleyici bakım üzerindeki etkilerini vurgulamaktadır. Özellikle denizcilik ve enerji sektörlerinde, çevresel değişkenlerin (örneğin, rüzgâr hızı, dalga yüksekliği) göz önüne alınarak planlanan önleyici bakım stratejilerinin daha başarılı sonuçlar verdiğini söylemek mümkündür. Bu tarz bütüncül yaklaşımlar, bakım maliyetlerinin azaltılmasında ve operasyonel kesintilerin önlenmesinde oldukça etkili olmaktadır.

Önleyici bakımın temel avantajları arasında arıza riskinin minimuma indirilmesi ve bakım periyotlarının planlanabilir hale getirilmesi sayılabilirken bu bakım stratejisinin temel dezavantajı ise gereksiz bakım faaliyetleri kaynaklı yüksek maliyet riskidir.


Önleyici bakım stratejilerinin yalnızca arızaları önlemekle kalmadığını, aynı zamanda üretim süreçlerinde kaliteyi artırarak maliyetleri optimize ettiğini söylemek mümkündür. Önleyici bakım planlanmış bakım görevleri sayesinde üretim hatlarının daha verimli

alışmasını saęlamaktadır. Gnmzde, makinelerin performansını gerek zamanlı izleme ve bakım planlarının dijital ortamda optimize edilmesi, iřletmelere daha byk esneklik kazandırmaktadır (Moleda vd., 2023).

1.3. Tanımlayıcı Bakım

Tanımlayıcı bakım, bakım ynetim srelerinde sistemin mevcut durumunu anlamak ve operasyonel verilerden anlamlı sonular ıkarmak amacıyla kullanılan bir yaklaşımdır. Bu bakım yntemi, genellikle gemiř verilerin ve mevcut durumun analiz edilmesine odaklanır ve daha ileri dzey bakım yntemleri olan kestirimci ve nleyici bakımlar iin temel oluřturur (Zhang ve Lee, 2015). Tanımlayıcı bakım, Endstri 4.0 teknolojilerinin yaygınlařmasıyla birlikte, byk veri analitięi ve IoT (Nesnelerin İnterneti) sistemleriyle entegre edilerek daha etkili hale gelmiřtir (Brown ve Zhang, 2018).

řekil 2: Tanımlayıcı Bakım



Kaynak: Arařtırmacı tarafından hazırlanmıřtır

Tanımlayıcı Bakımın Temel zellikleri ařaęıdaki gibi sıralanabilir:

1. **Veri Toplama ve Analiz:** Tanımlayıcı bakımın temelini veri toplama ve bu verilerin anlamlı bilgiler elde etmek iin analiz edilmesi oluřturur. Sensr verileri, bakım kayıtları, retim raporları ve sistem performans gstergeleri gibi eřitli kaynaklar, bu srete kullanılan bařlıca veri trleridir (Smith ve Allen, 2020).

2. **Sistem Performansının Görselleştirilmesi:** Toplanan veriler, çeşitli veri görselleştirme araçları kullanılarak kullanıcıların sistemin mevcut durumunu kolayca anlamasını sağlar. Bu, bakım süreçlerinde daha bilinçli kararlar alınmasına yardımcı olur (Kim ve Wang, 2021).
3. **Kestirimci ve Önleyici Bakım ile Entegrasyon:** Tanımlayıcı bakım, elde edilen verilerin kestirimci ve önleyici bakım modellerine aktarılmasını sağlayarak bakım süreçlerinin bütünlüklü bir yaklaşımla yönetilmesine olanak tanır (Wilson ve Green, 2019).

Tanımlayıcı bakımın endüstriyel uygulamalarda kullanımı oldukça geniştir. Üretim, enerji, otomotiv ve havacılık gibi sektörlerde bakım maliyetlerini düşürmek, operasyonel kesintileri en aza indirmek ve sistem ömrünü uzatmak için kritik bir rol oynar (Chen ve Tan, 2020). Özellikle üretim sektöründe, makine duruş sürelerini analiz etmek ve bu doğrultuda operasyonel verimliliği artırmak için kullanılmaktadır (Patel ve Rao, 2022).

Son 10 yıl içinde yapılan araştırmalar, tanımlayıcı bakımın etkinliğini artırmaya yönelik çeşitli yöntemler geliştirmiştir. Zhang ve Lee (2015), veri analitiği tekniklerinin bakım süreçlerinde nasıl kullanılacağını analiz etmiş ve tanımlayıcı bakımın kestirimci bakım için bir temel oluşturduğunu vurgulamıştır. Brown ve Zhang (2018), endüstri 4.0'ın tanımlayıcı bakım süreçlerini nasıl dönüştürdüğünü ve bu süreçte büyük veri teknolojilerinin önemini tartışmıştır. Wilson ve Green (2019), enerji sektöründe tanımlayıcı bakımın rolünü incelemiş ve bu yöntemin operasyonel güvenilirliği artırdığını belirtmiştir. Kim ve Wang (2021), tanımlayıcı bakım verilerinin kestirimci bakım modellerine entegrasyonu üzerine kapsamlı bir çalışma yapmış ve bu verilerin karar verme süreçlerini desteklediğini göstermiştir.

Tanımlayıcı bakım, birçok avantaj sunmasına rağmen bazı eksiklikleri de bulunmaktadır. Bu eksiklikler arasında veri kalitesinin yetersizliği, verilerin anlamlı bilgilere dönüştürülmesi sürecindeki zorluklar ve kestirimci bakım ile entegrasyon süreçlerindeki teknik engeller yer almaktadır (Smith ve Allen, 2020). Gelecek araştırmalarda, özellikle daha yüksek veri kalitesi ve gerçek zamanlı analiz sistemlerinin geliştirilmesi üzerine odaklanılmalıdır.

1.4. Kestirimci Bakım

Kestirimci bakım, endüstride makine ve ekipmanların ömrünü uzatmak ve arıza maliyetlerini düşürmek amacıyla kullanılan bir yaklaşımdır. Bu yöntem, makine sensörleri tarafından toplanan veriler üzerinde analizler yaparak, arızaların oluşmadan önce tespit edilmesini sağlar. Bu, özellikle dijitalleşen endüstrilerde büyük bir öneme sahiptir çünkü plansız duruşlar, üretim kaybına ve yüksek maliyetlere yol açar. Kestirimci bakım, geleneksel

önleyici bakım yöntemlerinden farklı olarak, makineyi gerçek zamanlı verilerle izler ve sadece gerekli olduğunda müdahale eder (Zonta vd., 2020).

Kestirimci bakım arıza durumuna karşı bir erken uyarı özelliğindedir. Beklenmedik bir anda ortaya çıkabilecek çeşitli olumsuzlukların önlenmesi amacını taşır. Bir makine arıza durumuna geçmeden önce makinenin durumunun izleniyor oluş ve ilgili makineden alınan sinyallerdeki belirgin değişimlerin fark ediliyor oluşu sayesinde kontrollü ve planlı bir bakım çalışmasının gerçekleştirilmesi prensibine dayanan bir bakım yöntemidir (Çimen, 2015).

Kestirimci bakım da bir planlı bakım türüdür. Örneğin, bir makine yağı üreticisi, ürettiği yağın hangi parametrelerin kesişiminde, özelliğinin azalacağını kullanıcıya sunabilir ve kullanıcı da bakım planlarını bu parametreler ışığında oluşturabilir. Bakım zamanından sonra yapılacak her işlem doğrudan risk oluşturarak, bu durum muhtemel bir arıza ile sonuçlanabilir. Böylesi olumsuzluklarla karşılaşmayı önlemek için yağ bakım planı, gerçek faydalı kullanım zamanından bir miktar öncesine programlanabilir; ancak kullanılabilir durumda olan yağın zamanından önce değişmesi hem ek maliyet hem de aşırı tüketim sonucu öz kaynak kullanımında artışa sebep olabilir. Bu kapsamda uygun parametrenin yani en olası bakım zamanının iyi belirlenmesi gerekir (Öztaır, 2018). Günümüzde bakım zamanının kestiriminde ve olası arızaların önlenmesi kapsamında, bakım planlarına ek olarak makine öğrenmesi desteği ile kestirimci bakım çalışmaları popülerlik kazanmıştır (Dündar vd., 2021).

Tablo 1: Düzeltici Bakım, Önleyici Bakım ve Kestirimci Bakımın Karşılaştırılması

	Düzeltici Bakım	Önleyici Bakım	Kestirimci Bakım
Bakım Maliyetleri	Düşük	Yüksek	Çok daha düşük
Arıza Durumu Süresi	Uzun	Kısa ve planlı	Kısa ve planlı
Ara Stok Durumu	Var	Kısmi ara stok	Kısmi ara stok
Yatırım Maliyeti	Düşük seviyede	Orta seviyede	Yüksek seviyede
Bakım Zamanlaması	Arıza sonrası	Planlı bir takvim içerisinde arıza öncesi	İhtiyaç duyulduğunda ya da bir uyarı geldiğinde

Kaynak: Kankaya, 2022; Koçer, 2017'den derlenmiştir

Son yıllarda, kestirimci bakımda yapay zekâ ve büyük veri analitiği gibi ileri teknolojiler büyük bir ilerleme kaydetmiştir. Bu gelişmeler, makine öğrenimi algoritmaları ve veri analiz araçları sayesinde, ekipmanların hangi anda bakım gerektirdiğinin daha hassas bir şekilde öngörülmesini sağlar. Ayrıca, kestirimci bakımın başarılı olabilmesi için büyük veri ile çalışmak zorunludur. Sensör verileri, makinelerin sıcaklık, titreşim ve diğer çalışma

parametrelerini sürekli olarak izler ve bu veriler işlenerek arıza olasılıkları hesaplanır. Özellikle son yıllarda gelişen düşük maliyetli sensör teknolojileri ve veri işleme kapasitesindeki artış, kestirimci bakım çözümlerini daha erişilebilir hale getirmiştir. Bu tür gelişmeler, bakım operasyonlarını otomatikleştirmek ve insan müdahalesine olan ihtiyacı azaltmak açısından büyük bir potansiyel sunmaktadır (Uçar vd., 2024).

Kestirimci bakım, endüstride dijitalleşme ve Endüstri 4.0 teknolojilerinin artan kullanımı ile büyük bir ivme kazanmıştır. Bu bakım yöntemi, makinelerin arıza yapma olasılığını önceden tespit ederek, plansız duruşları ve bakım maliyetlerini azaltmayı hedefler. Kestirimci bakım, makine durumunu izlemek ve tahmin yapmak için sensör verilerini kullanarak, arıza meydana gelmeden önce bakım yapılmasını sağlar. Bu sayede, plansız bakım maliyetleri düşürülmekte, üretim süreçleri daha verimli hale gelmekte ve iş süreçlerinde süreklilik sağlanmaktadır (Raj vd., 2024).

Kestirimci bakımın temel avantajları plansız arızaların önlenmesi ve bakım maliyetlerinin azaltılmasıdır. Bu stratejinin dezavantajlı noktaları arasında ise yüksek başlangıç maliyetleri ve karmaşık bir veri altyapısına ihtiyaç duyulması sayılabilir.

Son yıllarda yapay zeka ve makine öğrenmesi (MÖ) tabanlı kestirimci bakım sistemleri, özellikle büyük veri ve sensör teknolojileri ile entegre edilerek önemli başarılar elde edilmiştir. Bu yöntemler, makinelerin çalışma verilerini toplayarak, algoritmalar aracılığıyla arıza olasılıklarını tahmin edebilmekte ve bakım süreçlerini optimize etmektedir. Özellikle elektromekanik ve otomotiv sektörlerinde, kestirimci bakım stratejileri, makine duruş sürelerinde önemli azalmalar sağlarken, hurda maliyetlerinde de çeşitli oranlarda tasarruf elde edilmiştir (Raj vd., 2024; Uçar vd., 2024).

1.4.1. Kestirimci Bakımın İşleyişi ve Bileşenleri

Kestirimci bakım yönteminin işleyişi açısından en kritik noktalardan biri ilgili makine ya da ekipman üzerinde konumlanmış olan sensörler aracılığı ile korozyon, titreşim, gürültü vb. unsurlara dair gerekli sinyal verilerinin toplanmasıdır. Elde edilen bu veriler aracılığıyla izlenen makine veya ekipmana dair geleceğe dönük tahminlerin yapılabilmesi mümkün hale gelmektedir (Yaman ve Karadayı, 2014).


Kestirimci bakım, ekipman hatalarının ve arızalarının ne zaman meydana geleceğini tahmin etmek için veri analizi tekniklerini kullanır. Olası makine veya ekipman arızalarını önlemek ve bakım programlarını optimize etmek için zamanında bakım yapılmasını sağlar. Düzeltici bakımla ilişkili arıza sürelerini ve maliyetleri azaltarak, potansiyel arızaların ve

hataların ortaya çıkmadan önce tahmin edilmesi için kestirimci bakım; geçmiş verilere, sensör okumalarına ve makine öğrenmesi algoritmalarına dayanmaktadır (Zhou vd., 2007).

Hata veya arıza sınıflandırması bu süreçte kullanılan ileri düzey tekniklerden biridir. Hata sınıflandırması, sistem arızalarını veya anomalilerini semptomlar (örneğin bir makine veya ekipmanda anormal bir titreşim veya gürültü), nedenler (örneğin hataların veya arızaların altında yatan kök nedenler) veya şiddet seviyeleri (örneğin makine veya ekipmana ait bir parçanın hafif hasarı veya tamamen arızalanması) gibi çeşitli özniteliklere dayalı olarak önceden tanımlanmış sınıflara ayırmayı içermektedir (Jin vd., 2012).

Hata sınıflandırması, endüstriyel tesislerde makine veya ekipman sağlığı ile ilgili problemleri daha iyi anlamak ve etkili bir şekilde çözmek için güçlü bir araç olarak öne çıkmaktadır. İşletmeler, hataları doğru bir şekilde sınıflandırarak sorunları etkili bir şekilde teşhis edebilir ve hedeflenen çözümleri uygulayabilirler, böylece operasyonel güvenilirliği ve performansı artırabilirler (Jin vd., 2012). Kestirimci bakımın işleyiş aşamalarında görev alan temel bileşenler ise aşağıdaki resimde olduğu gibi aktarılabilir.

Şekil 3: Kestirimci Bakımın Temel Bileşenleri



Kaynak: Özhan, 2024'ten derlenmiştir

Kestirimci bakımın temel bileşenlerinin aşağıdaki gibi açıklanması mümkündür (Özhan, 2024):

- Durum izleme ekipmanları, sensörlerle donatılmış makineler aracılığıyla sistemlerin verimliliğini, aşınma ve arıza durumunu gerçek zamanlı olarak izler. Bu sensörler, makinenin iç kısımlarında meydana gelen aşınmayı ve yıpranmayı gerçek zamanlı

olarak izleyerek, geleneksel fiziksel muayenelerin eksikliklerini giderir. Makinenin çeşitli parametrelerini, örneğin titreşim, gürültü, sıcaklık, basınç ve yağ seviyelerini ölçer. Böylece, üretimde aksamalar olmadan sistemin genel durumuna ilişkin doğru bir tahmin elde edilir.

- Nesnelerin İnterneti (IoT) teknolojisi, çeşitli sensörlerden veri toplanmasını ve paylaşılmasını sağlar. Bu sensörler, kestirimci bakım sürecinde önemli bir role sahip olup, WLAN, LAN veya bulut teknolojileri üzerinden çalışır. Bu teknoloji sayesinde ekip üyeleri, verileri analiz edebilir ve makinelerle ilgili düzeltici önlemler önererek, bakım teknisyenlerinin makinelerin durumu hakkında daha iyi bilgi sahip olmalarını sağlar.
- Tahmine dayalı bakım algoritmaları, toplanan verileri kullanarak bir sistemin ne zaman tamir veya servis gerektireceğini belirleyen tahmin algoritmalarına dayanır. Bu algoritmalar, sistemin mevcut ve beklenen davranışları arasındaki sapmaları analiz eder. Bu sapmalar, sistemin arızasına yol açabilecek kademeli bozulmaların işaretidir. Bu bilgiler, teknisyenlerin arızaları önlemek için zamanında müdahalede bulunmalarına yardımcı olur.

1.4.2. Kestirimci Bakımın Avantajlı ve Dezavantajlı Yanları

Kestirimci bakım teknolojileri özellikle endüstriyel süreçlerin verimliliğini artırmak için kritik bir araç haline gelmiştir. Avantajları arasında en önemli olanlardan biri, planlanmamış arızaların önlenmesi ve bu sayede üretim hattındaki duruş sürelerinin azaltılmasıdır (Sanchez-Loudono vd., 2018). Ayrıca, kestirimci bakım, ekipman ömrünü uzatarak bakım maliyetlerini düşürür ve üretim kalitesini artırır (Ucar vd., 2024). Bununla birlikte, kestirimci bakımın uygulanması yüksek ilk yatırım maliyetleri ve karmaşık veri yönetim süreçlerini gerektirir. Yeterli sayıda sensör ve güçlü veri analitiği araçlarına sahip olmayan şirketler için bu maliyetler caydırıcı olabilir (Huynh vd., 2018).

Kestirimci bakımın bir diğer avantajı, üretim sürecinin verimliliğinin artırılması ve enerji tasarrufu sağlamasıdır. Sistemlerin daha verimli çalışması, enerji maliyetlerini düşürerek çevresel etkilerin de azaltılmasına yardımcı olabilir. Bununla birlikte, bu teknolojinin başarılı bir şekilde uygulanabilmesi için eğitilmiş personel gerekliliği ve sürekli veri entegrasyonu önemlidir. İş gücü eksikliği veya teknolojik bilgi yetersizliği, bazı firmalar için önemli bir engel olabilir (Ucar vd., 2024).

Dezavantajlar arasında, kestirimci bakımın karmaşık veri altyapısı gerektirmesi ve doğru tahminler için sürekli güncel veri akışının sağlanmasının zorluğu yer alır. Ayrıca, yanlış veya eksik veriler, hatalı tahminlere ve dolayısıyla plansız duruşlara yol açabilir. Bu sistemlerin güvenilirliği, kullanılan algoritmaların doğruluğu ve veri kalitesi ile doğrudan ilişkilidir. Dolayısıyla, düşük kaliteli veya gürültülü veriler, sistemin etkinliğini azaltabilir (Chen vd., 2023).

Öte yandan, kestirimci bakım, arızaların önceden tespit edilmesiyle çalışan güvenliğini artırabilir ve iş kazalarını minimize edebilir. Ancak, özellikle küçük ve orta ölçekli işletmelerde bu teknolojinin benimsenmesi, yüksek maliyetler ve uzmanlık gerektiren teknik altyapı gibi nedenlerle zorlayıcı olabilir. Kestirimci bakım teknolojileri endüstriyel verimliliği artırma potansiyeline sahip olsa da, maliyet, veri yönetimi ve uzmanlık gibi faktörler bu teknolojinin uygulanmasını zorlaştırabilir. Bu nedenle, firmalar bu teknolojiyi uygularken hem avantajları hem de dezavantajları dikkatle değerlendirmelidirler (Achouch vd., 2023).

Şekil 4: Kestirimci Bakımın Avantajlı Yönleri



Kaynak: Wong vd., 2022'den derlenmiştir

Endüstriyel tesislerin son dönemde bakı yönetimi açısından elde ettiği en önemli ilerlemelerden biri olarak nitelendirilebilecek kestirimci bakım çalışmaları sayesinde makinelerin çalışma süreçlerinde gösterdiği anormal davranışların tespit edilmesi, geleceğe dönük olası arıza alternatiflerinin belirlenerek bu alternatiflere uygun bakım senaryolarının geliştirilmesi, arıza sürelerinin kısaltılması, makinelerin kullanım ömürlerinin uzatılması ve tüm bu olumlu durumlara bağlı olarak toplam üretim kalitesinin iyileştirilmesi mümkün hale gelmiştir (Aksöz ve Arifoğlu, 2020).

Tablo 2: Farklı Bakım Türlerinin Avantaj ve Dezavantajlarının Karşılaştırılması

	Düzeltilici Bakım	Önleyici Bakım	Kestirimci Bakım
Avantajlar	- Sabit olmayan maliyetler - Acil durumlara uygun olma	- Düzeltilici bakıma göre daha düşük risk seviyesi - Öngörülebilir maliyetler	En düşük risk seviyesi
Dezavantajlar	Yüksek arıza risk seviyesi	Gereksiz bakım süreçleri içermeye ihtimali	Yüksek maliyet seviyesi

Kaynak: Koçer, 2017

Kestirimci bakımın diğer bakım türleri ile kıyaslandığında en temel avantajı makine kullanımı, makine ömrü ve üretim hataları gibi alanlarda en düşük risk seviyesine sahip oluşudur. Kestirimci bakım proaktif yapısı itibarıyla pek çok olası soruna yönelik olası senaryoların değerlendirilmesi fırsatını sunan bir bakım yaklaşımıdır. Tüm olumlu yanlarına rağmen kestirimci bakımını işletmeler açısından en temel dezavantajı olarak yüksek maliyetler yaratma olasılığı ön plana çıkmaktadır. Özellikle teknolojik unsurların kullanımına ihtiyaç duyulması nedeniyle diğer bakım alternatiflerine göre işletmeler için daha yüksek maliyetler yaratabilmektedir (Wong vd., 2022).

1.5. Endüstri 4.0 Kapsamında Kestirimci Bakım Teknolojileri

Kestirimci bakım (KB) teknolojileri, son yıllarda endüstriyel süreçlerde sürdürülebilirlik, maliyet etkinliği ve operasyonel verimliliği artırmada kritik bir rol oynamaktadır. Kestirimci bakım, geleneksel bakım yaklaşımlarından farklı olarak, makinelerin arıza yapmadan önce performans verilerini analiz ederek olası sorunları öngörmeyi ve müdahalede bulunmayı amaçlar. Bu teknoloji, sensörler, veri analitiği, yapay zeka ve makine öğrenimi gibi gelişmiş teknolojilere dayanır (Zero vd., 2024).

Riccio vd., (2024)'e göre kestirimci bakımda kullanılan en önemli teknoloji, sürekli veri toplama ve analiz yeteneğine sahip sensör sistemleridir. Bu sensörler, ekipmanların durumunu izleyerek titreşim, sıcaklık, ses ve basınç gibi çeşitli parametreleri sürekli ölçmektedir. Akıllı sensör sistemlerinin kestirimci bakımda kullanımının, makinelerin çalışma ömrünü önemli ölçüde uzattığını belirtmek mümkündür. Bu sensörler, makinelerde meydana gelebilecek arızaları öngörebilmek için kritik bir bileşendir.

Kestirimci bakım teknolojileri makinelerin ve sistemlerin arızalarını tahmin ederek, arıza gerçekleşmeden önce bakım yapılmasını sağlayan bir strateji olarak, endüstride giderek artan bir öneme sahiptir. Bu teknoloji, özellikle Endüstri 4.0 ile birlikte büyük veri ve makine öğrenmesi gibi yeni teknolojilerin kullanılmasıyla daha da gelişmiştir. Kestirimci bakım, planlanmamış arızaların ve duruş sürelerinin önlenmesine, bakım maliyetlerinin azaltılmasına ve üretim verimliliğinin artırılmasına katkı sağlar (Wong vd., 2022).

Kestirimci bakım genellikle sensörler aracılığıyla toplanan büyük miktarda veriyi analiz eder. Bu veriler, zaman serileri şeklinde toplanarak makinelerin çalışma koşullarındaki değişiklikler ve bozulma kalıpları gözlemlenebilir. Derin öğrenme ve diğer makine öğrenimi modelleri, bu veriler üzerinde anormallikleri tespit ederek, gelecekteki arızaların ne zaman gerçekleşebileceğini tahmin etmek için kullanılır. Bu süreç, sensör verilerinin ön işlenmesi, özellik mühendisliği ve anomali tespiti aşamalarını içerir. Her bir aşama, kestirimci bakım sistemlerinin performansını artırmak için kritik öneme sahiptir (Ucar vd., 2024).

Makine öğrenmesi, kestirimci bakımın gelişmesinde önemli bir rol oynamaktadır. Özellikle derin öğrenme modelleri, zaman serisi analizleri yoluyla arıza tahminlerini daha hassas hale getirmektedir. Bu modeller, sürekli olarak sensörlerden gelen verileri işler ve makinelerin performansını gerçek zamanlı olarak izler. Yapay zeka tabanlı kestirimci bakım sistemleri, insan müdahalesini minimize ederek makinelerin özerkliğini artırır. Bu tür sistemlerin kullanılması, bakım süreçlerini optimize ederken üretim hattındaki verimliliği de artırmaktadır (Riccio vd., 2024).

Kestirimci bakım sistemlerinin başarısı, verilerin güvenilirliği ve işleme yöntemlerine bağlıdır. Verilerin doğru toplanması, işlenmesi ve analiz edilmesi, bu sistemlerin performansını doğrudan etkiler. Bunun yanı sıra, veri odaklı modellerde kullanılan özellik mühendisliği (feature engineering) ve verilerin ön işlenmesi, kestirimci bakım sistemlerinin doğruluğunu artırmak için kritik adımlardır. Endüstri 4.0 teknolojileri, kestirimci bakımı desteklemek için geniş çapta kullanılmaktadır. Özellikle, büyük veri, yapay zeka, IoT gibi teknolojiler, kestirimci

bakımın potansiyelini arttıran başlıca unsurlar arasında yer almaktadır. Bu teknolojiler sayesinde, gerçek zamanlı izleme ve anomali tespit süreçleri daha etkili bir şekilde yürütülmektedir (Ucar vd., 2024).

Kestirimci bakımın bir diğer avantajı, üretim kalitesinin iyileştirilmesi ve maliyetlerin azaltılmasıdır. Özellikle ürün kalitesinin izlenmesi ve kalite odaklı kestirimci bakım stratejilerinin geliştirilmesi hem üretim performansını arttırmakta hem de bakım maliyetlerini önemli ölçüde düşürmektedir. Bu bağlamda, kestirimci bakım stratejileri, sadece makinelerin verimliliğini artırmakla kalmayıp, aynı zamanda üretim süreçlerinde yüksek kalite standartlarının korunmasına da katkı sağlamaktadır (Zero vd., 2024).

Kısacası, kestirimci bakım teknolojileri, günümüzde endüstriyel süreçlerin daha verimli, güvenilir ve maliyet açısından avantajlı bir şekilde yönetilmesine olanak tanıyan önemli bir araçtır. Yapay zeka ve makine öğrenmesi tabanlı yaklaşımlar, kestirimci bakımın gelecekteki gelişimine öncülük etmektedir ve bu alanda yapılacak daha fazla araştırma, teknolojinin potansiyelini daha da artıracaktır.

İKİNCİ BÖLÜM


MAKİNE ÖĞRENMESİ KAVRAMI

Makine öğrenmesi (MÖ), büyük miktarda veriyi analiz ederek belirli görevleri yerine getirebilecek ve kendi performansını iyileştirebilecek algoritmalar geliştirmeyi hedefleyen bir yapay zekâ alt dalıdır. Gelişmiş veri işleme teknikleri ve hesaplama gücü sayesinde MÖ, karmaşık sorunların çözümünde benzersiz bir yöntem sunmaktadır. Temel olarak, makine öğrenmesi, verilerden örüntüleri otomatik olarak çıkarma, modelleme ve bu çıkarımları yeni verilere uygulama yeteneğine dayanır (Alpaydın, 2016). Günümüzde, MÖ 'nin sağlık, finans, eğitim, güvenlik ve enerji gibi çeşitli sektörlerde uygulama alanları genişlemekte, hızla büyüyen veri kümelerinin analiz edilmesi ve karar alma süreçlerinin optimize edilmesi amacıyla etkin bir şekilde kullanılmaktadır (Goodfellow vd., 2016).

2.1. Veri Madenciliği Süreçleri

Veri madenciliği, büyük veri kümelerinden anlamlı bilgiler ve desenler çıkararak karar verme süreçlerini destekleyen bir veri analiz sürecidir. İş dünyasından sağlık sektörüne, finansal analizlerden sosyal medya uygulamalarına kadar birçok alanda veri madenciliği, kullanıcı davranışlarını anlamak, gizli ilişkileri ortaya çıkarmak ve geleceğe yönelik tahminler yapmak için kullanılmaktadır (Han vd., 2011). Veri madenciliği süreçleri; verilerin toplanması, ön işlenmesi, desenlerin keşfi ve sonuçların değerlendirilmesi gibi aşamalardan oluşur. Bu süreçlerin başarılı bir şekilde uygulanması, yalnızca verinin yapısına değil, aynı zamanda kullanılan algoritmaların doğruluğuna ve uygunluğuna da bağlıdır (Witten vd., 2016).

Şekil 5: Veri Tabanından Bilginin Keşfi



Kaynak: Karabatak, 2008

Veri madenciliği süreçlerinin temelinde, verilerin doğru ve anlamlı bir şekilde toplanması yatar. Bu aşamada, analiz edilecek verilerin uygun kaynaklardan elde edilmesi ve veri kalitesinin sağlanması büyük önem taşır. Veri kalitesi, eksik veya hatalı verilerin temizlenmesi ve veri kümesinin homojen hale getirilmesi işlemleriyle doğrudan ilgilidir. Bu yüzden veri madenciliği projelerinde, veri toplama aşaması veri kalitesinin garanti altına alındığı önemli bir süreç olarak öne çıkar (Kotsiantis vd., 2006). Ayrıca, veri güvenliği ve gizliliği konuları, bu aşamada dikkate alınması gereken kritik faktörlerdir.

Şekil, veri madenciliği sürecinin temel aşamalarını göstermektedir. Bu süreç, ham verilerin anlamlı bilgiye dönüştürülmesini sağlayan adımları içermektedir:

➤ **Veri Kaynakları ve Ön İşleme:**

Veri madenciliği süreci, çeşitli kaynaklardan (veritabanları, dosyalar vb.) elde edilen verilerle başlar. Ham veriler, genellikle eksik, tutarsız veya gereksiz bilgiler içerdiğinden, temizleme ve birleştirme işlemleri gerçekleştirilir. Bu aşama, veri kalitesini artırarak analiz sürecinin güvenilirliğini sağlamak amacı taşımaktadır.

➤ **Veri Ambarı ve Dönüştürme:**

Temizlenmiş ve birleştirilmiş veriler, veri ambarında depolanır. Veri madenciliği için kullanılacak veriler, burada seçilir ve gerekli formatlara dönüştürülür. Bu aşama, modelleme sürecine uygun veri yapısını sağlamak için kritik öneme sahiptir.

➤ **Veri Madenciliği Süreci:**

Seçilen veriler, veri madenciliği algoritmalarına tabi tutulur. Sınıflandırma, kümeleme, regresyon gibi tekniklerle veri setindeki gizli ilişkiler ortaya çıkarılır. Bu aşamada modelleme ve analiz işlemleri gerçekleştirilerek örüntüler belirlenmektedir.

➤ **Sonuçların Değerlendirilmesi ve Bilgiye Dönüştürme:**

Veri madenciliği sonucunda bulunan örüntüler, işletmeler veya araştırmacılar tarafından yorumlanarak bilgiye dönüştürülmektedir. Sonuçlar, grafikler, raporlar veya istatistiksel analizler şeklinde sunulabilir.

Veri toplama aşamasını, veri ön işleme aşaması takip eder. Bu aşama, veri temizleme, veriyi standardize etme ve gerekirse dönüştürme işlemlerini içerir. Özellikle eksik veya anormal veri noktalarının temizlenmesi, analiz sonuçlarının doğruluğu açısından önemlidir. Veri ön işleme, veri kümesinin boyutunu azaltma ve veriler arasındaki ilişkileri daha net bir şekilde görebilme amacı taşır. Ayrıca, bu aşama, veri setindeki çok boyutluluğu azaltmak için boyut indirgeme teknikleri ve veri kümeleme yöntemlerini içerebilir (García vd., 2015).

Veri madenciliği sürecinde üçüncü aşama desen keşfi olup, burada veri madenciliği algoritmaları kullanılarak verilerde gizli kalan ilişkiler ve örüntüler ortaya çıkarılır. Bu aşamada kullanılan en popüler teknikler arasında sınıflandırma, kümeleme, birliktelik kuralları çıkarımı ve regresyon yöntemleri yer almaktadır. Sınıflandırma teknikleri, veri madenciliği süreçlerinde sıklıkla tercih edilir ve veriyi belirli kategorilere ayırmak için kullanılır. Kümeleme ise veriyi benzer özelliklere sahip gruplar halinde ayırarak verinin altında yatan yapıları keşfetmeyi sağlar (Witten vd., 2016).

Birliktelik kuralları çıkarımı, özellikle perakende ve pazarlama sektörlerinde müşteri davranışlarını analiz etmek için yaygın olarak kullanılan bir yöntemdir. Bu teknik, genellikle market sepeti analizlerinde, birlikte satın alınan ürünleri belirleyerek çapraz satış fırsatları yaratmak amacıyla kullanılır. Bu bağlamda, veri madenciliği algoritmalarının doğru bir şekilde seçilmesi ve uygulanması, desen keşfi sürecinde doğru sonuçlara ulaşmak için kritik bir rol oynar (Agrawal ve Srikant, 1994).

Desen keşfi sürecinin ardından, sonuçların değerlendirilmesi aşaması gelir. Bu aşama, elde edilen örüntülerin ve kuralların doğruluğunu ve geçerliliğini test etmek için çeşitli doğrulama yöntemlerini içerir. Çapraz doğrulama, veri madenciliğinde sıklıkla kullanılan bir değerlendirme yöntemi olup, modelin farklı veri alt kümeleri üzerinde test edilmesini sağlar (Witten vd., 2016). Bu tür değerlendirme yöntemleri, modelin genel performansını ve analizlerin güvenilirliğini belirlemekte büyük önem taşır.

Veri madenciliği süreçleri yalnızca teknik işlemlerden ibaret değildir; aynı zamanda etik ve gizlilik konuları açısından da dikkat edilmesi gereken süreçler içerir. Özellikle bireylerin kişisel verilerinin kullanıldığı analizlerde, veri madenciliği uygulamaları gizlilik yasaları ve etik kurallar çerçevesinde yürütülmelidir (Clifton, 2016). Kişisel verilerin korunması ve kullanıcı gizliliğine yönelik tedbirler alınması, veri madenciliği projelerinde etik bir sorumluluktur.

Veri madenciliği süreçleri, büyük veri ile birlikte yapay zeka ve makine öğrenmesi algoritmalarının gelişmesiyle daha da ileri seviyelere ulaşmıştır. Bu teknolojiler, veri madenciliği süreçlerini hızlandırarak daha büyük ve daha karmaşık veri kümelerinde uygulanabilir hale getirmiştir (Zaki ve Meira, 2014). Büyük veri ile desteklenen veri madenciliği projeleri, çok sayıda kaynaktan veri toplayarak ve işleminden geçirerek daha bütünsel ve daha doğru sonuçlara ulaşmayı sağlar. Bu çerçevede, veri madenciliği projelerinin etkili ve güvenilir sonuçlar üretebilmesi için sürecin her aşamasında dikkatli bir planlama ve algoritma seçimi gereklidir (Xu ve Wunsch, 2005). Veri madenciliği, veri hacmi arttıkça daha karmaşık bir yapıya bürünmekte ve sürekli bir yenilik ve gelişim süreci içinde bulunmaktadır.

2.2. Makine Öğrenmesi

Makine öğrenmesinin temelleri, istatistiksel modelleme ve veri madenciliği alanlarıyla iç içe geçmiş olup, verinin modellenmesi ve tahmin edilmesi süreçlerini iyileştirmeye yönelik matematiksel ve algoritmik yaklaşımlar içermektedir. Özellikle büyük veri ile ilişkili gelişmeler, MÖ algoritmalarının hem teorik hem de uygulamalı olarak gelişmesine zemin hazırlamış ve çok boyutlu verilerle çalışmayı mümkün kılmıştır (James vd., 2017). Ayrıca,

hesaplama gücünün artması ve bulut teknolojilerinin gelişmesi sayesinde, MÖ algoritmaları daha geniş veri kümeleri üzerinde daha hızlı çalışabilmekte ve daha kesin sonuçlar üretebilmektedir (Jordan ve Mitchell, 2015).

Ashok vd., (2021)'e göre MÖ yöntemleri temel olarak üç kategoriye ayrılmaktadır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Denetimli öğrenme, belirli bir veri setinde etiketlenmiş verileri kullanarak model eğitmeye dayanır ve çoğunlukla sınıflandırma veya regresyon gibi tahmin problemlerinde kullanılır (Hastie vd., 2009). Denetimsiz öğrenme ise etiketlenmemiş verileri kullanır ve verinin altında yatan yapıları keşfetmek için kümeleme ve boyut indirgeme teknikleri gibi yöntemleri içerir (Aggarwal, 2018). Pekiştirmeli öğrenme ise, bir ajanın çevresinde yaptığı eylemlerden ödülleri veya cezalar alarak öğrenme sürecini ifade eder ve çoğunlukla dinamik sistemler için uygundur (Sutton ve Barto, 2018).

MÖ'nin sağladığı veri işleme gücü, öngörüselle analizler ve karar destek sistemlerinin geliştirilmesinde büyük önem taşımaktadır. Özellikle sağlık alanında, hastalıkların erken teşhisi, ilaç keşfi ve kişiselleştirilmiş tedavi planları geliştirilmesi amacıyla MÖ algoritmalarının kullanımı artmaktadır. Örneğin, görüntü işleme teknikleri, radyoloji alanında kanser teşhisinde yüksek doğruluk oranları sunarken, doğal dil işleme algoritmaları elektronik sağlık kayıtları üzerinden hastaların sağlık geçmişlerini analiz etme imkanı sağlamaktadır (Esteva vd., 2017).

Finansal sektörde ise MÖ, dolandırıcılık tespiti, kredi risk analizi, hisse senedi fiyatlandırması gibi konularda etkin çözümler sunmaktadır. Geleneksel istatistiksel yöntemlerin aksine, MÖ algoritmaları çok sayıda değişkeni aynı anda değerlendirebilme kapasitesine sahiptir ve karmaşık piyasa dinamiklerini modelleme yeteneği ile öne çıkar. Bu bağlamda, özellikle yapay sinir ağları ve derin öğrenme teknikleri, finansal piyasalarda daha isabetli tahminler yapılmasını sağlamakta ve bu alandaki geleneksel yaklaşımlara göre daha üstün performans sergilemektedir (Sutton ve Barto, 2018).

Eğitimde de MÖ, kişiselleştirilmiş öğrenme deneyimlerinin tasarlanmasında kullanılmaktadır. Öğrenci performansının izlenmesi ve öğrenme sürecine yönelik öneriler sunulması gibi uygulamalar, öğretmenlerin ve öğrencilerin bireysel ihtiyaçlara göre öğrenme planları geliştirmelerine olanak tanır. Bu bağlamda, adaptif öğrenme sistemleri ve öğrenme analitiği gibi uygulamalar, MÖ algoritmalarının eğitimde yarattığı dönüşümün birer örneğidir (Baker ve Inventado, 2014).

MÖ aynı zamanda otonom sistemlerin geliştirilmesinde de kilit bir rol oynamaktadır. Özellikle, sürücüsüz araç teknolojilerinin gelişimi, MÖ algoritmalarının çevresel verileri anında işleyebilme ve doğru kararlar alabilme kapasitesi sayesinde mümkün olmaktadır. Bu tür otonom sistemlerde, MÖ algoritmaları, çeşitli sensörlerden gelen verileri anında işleyerek, aracın çevresindeki engelleri tanıma ve güvenli bir şekilde yönlendirme gibi önemli işlevleri yerine getirmektedir (Litman, 2018).


Son yıllarda MÖ alanındaki yenilikler, derin öğrenme ve büyük veri teknolojilerinin bir araya gelmesiyle daha da hızlanmıştır. Derin öğrenme teknikleri, büyük veri kümelerinin analiz edilmesi ve karmaşık problemlerin çözümü için devrim niteliğinde bir ilerleme sağlamıştır. Örneğin, doğal dil işleme (Natural Language Processing-NLP) ve bilgisayarla görü gibi alanlarda, MÖ algoritmalarının doğruluğu ve işlem hızındaki gelişmeler, çeşitli endüstrilerde daha fazla otomasyon ve yenilikçi çözümlerin ortaya çıkmasına katkı sağlamaktadır (LeCun, vd., 2015).

MÖ hızla gelişen bir alan olup, veri bilimleri ve yapay zeka ile birlikte toplumsal ve ekonomik dönüşümlere öncülük etmektedir. MÖ'nin gelecekteki uygulamaları, algoritmaların performansını artırmaya yönelik araştırmalar ve büyük verinin daha etkin kullanımı ile daha geniş bir etkiye sahip olacaktır. Bu çerçevede, MÖ algoritmalarının güvenilirlik, etik ve veri güvenliği gibi konulara odaklanması, alanın sürdürülebilir ve toplum yararına gelişmesi açısından önem taşımaktadır.

2.3.1. Makine Öğrenmesi Süreçlerinin Aşamaları

MÖ süreçleri, büyük veri kümelerinden anlamlı desenler ve tahminler çıkarmak amacıyla veriyi analiz eden algoritmaların geliştirilmesi, uygulanması ve iyileştirilmesini kapsar. Bu süreçler, problem tanımlama, veri toplama, veri ön işleme, özellik çıkarımı, model seçimi, model eğitimi, değerlendirme ve sonuçların doğrulanması gibi bir dizi aşamadan oluşur (Alpaydın, 2016). MÖ uygulamaları, sağlık, finans, pazarlama ve eğitim gibi pek çok alanda karar destek mekanizmalarını güçlendirmekte, veriden elde edilen öngörülerle operasyonel verimlilik sağlamaktadır. MÖ süreçlerinin doğru ve etkili bir şekilde uygulanması, model performansını ve doğruluğunu doğrudan etkilemektedir (James vd., 2017).

Şekil 6: Makine Öğrenmesi Süreçlerinin Aşamaları



Kaynak: Şahin, 2022

MÖ süreçlerinde ilk aşama, problem tanımlamadır. Bu aşamada çözülmesi istenen sorunun yapısı, beklenen sonuçlar ve analiz yöntemleri belirlenir. Problem tanımı, hangi veri türlerinin kullanılacağına ve uygulanacak algoritmalara karar verme aşamasında kritik rol oynar. MÖ'nin bir öngörü modeli mi yoksa bir sınıflandırma modeli mi geliştireceğine karar verilmesi, süreçte kullanılacak veri ve algoritma türünü belirlemeye yardımcı olur (Jordan ve Mitchell, 2015).

Problem tanımını, veri toplama ve veri ön işleme aşamaları izler. Veri toplama, modelin performansı için büyük önem taşıyan bir süreçtir, çünkü kullanılan verinin kalitesi model sonuçlarını doğrudan etkilemektedir. Bu aşamada eksik, hatalı ya da aşırı uç değerler gibi veri kusurları temizlenerek modelin daha sağlıklı sonuçlar üretebilmesi için ön koşullar sağlanır. Ayrıca, veri setinin genişletilmesi için veri artırma teknikleri ve veri zenginleştirme uygulamaları kullanılabilir (Kotsiantis vd., 2014).

Ön işleme sürecinde özellik çıkarımı ve boyut indirgeme gibi işlemler uygulanır. Özellik çıkarımı, veriyi temsil eden temel değişkenlerin seçilmesi ve bu değişkenlerin yeniden düzenlenmesi sürecidir. Örneğin, çok sayıda değişkene sahip veri setlerinde, boyut indirgeme algoritmaları kullanılarak veri karmaşıklığı azaltılabilir ve modelin daha hızlı ve daha verimli

alışması saęlanabilir. zellik ıkarımı, M srelerinde model doęruluęunu artıran nemli bir adımdır (Geron, 2019).

Veri iřleme adımlarını tamamladıktan sonra, model seimi sreci bařlar. Bu ařamada, problemin gereksinimlerine ve veri yapısına uygun olan makine ęrenmesi algoritması seilir. rneęin, sınıflandırma problemleri iin karar aęaları, k-en yakın komřu ve destek vektr makineleri gibi algoritmalar tercih edilirken, ngrsel analizlerde regresyon ve zaman serisi analizleri daha uygundur. Model seimi hem performansı hem de iřlem sresini doęrudan etkileyen kritik bir ařamadır (Hastie vd., 2009).

Model eęitimi, M srelerinin en nemli ařamalarından biridir. Bu srete, modelin veriyi ęrenmesi saęlanır ve belirlenen hedefe ynelik ıktılar retmesi amalanır. Modelin eęitimi sırasında kullanılan veri seti, modelin genel performansını belirler ve eęitimin bařarısını etkiler. Bu ařamada optimizasyon teknikleri kullanılarak model parametreleri en iyi performansı saęlayacak řekilde ayarlanır (Goodfellow vd., 2016).

Modelin eęitimi tamamlandıktan sonra, model deęerlendirme sreci bařlar. Bu srete modelin doęruluęu, kesinlięi, hatalı sınıflandırma oranları ve dięer metrikler kullanılarak test edilir. Deęerlendirme, modelin genel performansını anlamak ve gerektięinde model zerinde iyileřtirmeler yapmak iin nemli bir geri bildirim saęlar. zellikle apraz doęrulama gibi yntemler kullanılarak modelin farklı veri kmeleri zerindeki bařarısını test edilir (Witten, vd., 2016).

M srelerinde bir dięer nemli ařama ise model doęrulama ve sonuların analizidir. Model doęrulama srecinde, modelin genelleřtirme yeteneęi test edilir ve ařırı ęrenme gibi sorunların nne geilir. Bu ařamada test verisi kullanılarak modelin tahmin gc deęerlendirilir ve modelin gerek dnya verisi zerinde alıřabilirlięi gzlemlenir. Sonuların doęrulanması, modelin endstriyel veya akademik bir uygulamada kullanılması iin gerekli bir adımdır (Bishop, 2006).

M sreleri, veri bilimi ve yapay zekâ alanlarında hızlı geliřmelerle birlikte, srekli yenilenmekte ve optimize edilmektedir. Gnmzde, byk veri ve yapay zeka ile entegre edilen M sreleri daha karmařık veri yapılarını analiz edebilecek kapasiteye ulařmıřtır. zellikle derin ęrenme ve doęal dil iřleme gibi alanlar, M srelerinin daha eřitli uygulamalarda kullanılmasına olanak tanımaktadır. Gelecekte, daha akıllı ve daha hızlı M sreleri ile veri analiz srelerinin daha etkin bir řekilde yrtlmesi beklenmektedir (LeCun, vd., 2015).

MÖ süreçleri günümüzün veri odaklı dünyasında giderek daha fazla önem kazanmaktadır. Doğru veri toplama, ön işleme, model seçimi, eğitimi ve doğrulama adımlarıyla, MÖ süreçleri daha doğru ve güvenilir öngörüler sağlayarak karar alma süreçlerini güçlendirmektedir. Bu süreçlerin başarılı bir şekilde uygulanması, yalnızca kullanılan algoritmalara değil, her bir aşamada gösterilen özen ve doğru metodolojilere de bağlıdır.

2.3.2. Makine Öğrenmesi Kapsamında Farklı Yöntemler

MÖ yöntemleri, veriden öğrenme yoluyla tahminler yapmayı ve desenleri keşfetmeyi amaçlayan algoritmalarından oluşur. MÖ yöntemleri, genellikle denetimli, denetimsiz ve pekiştirmeli öğrenme şeklinde kategorize edilir. Her bir yöntem, veri türüne, probleme ve istenen sonuçlara göre farklı algoritmalar ve yaklaşımlar içerir (Alpaydın, 2016). Günümüzde MÖ yöntemleri, sağlık hizmetlerinden finans sektörüne, sosyal medya analizinden nesnelerin internetine kadar geniş bir yelpazede kullanılmaktadır. Bu yöntemlerin uygulanabilirliği, modelin veriyle olan ilişkisini anlamak ve uygun algoritmaları seçmek ile doğrudan ilişkilidir (Bishop, 2006).

MÖ’nde yöntem seçimi, problemin özelliklerine ve veri yapısına göre yapılır. Örneğin, eğer veri sürekli değerler içeriyorsa regresyon algoritmaları tercih edilirken, kategorik veriler söz konusu olduğunda sınıflandırma algoritmaları uygun olur. Ayrıca, verinin etiketli olup olmadığı veya etiketsiz veri miktarının fazlalığı da yöntemi belirleyen önemli faktörlerdendir (Goodfellow vd., 2016). Bu nedenle, bir MÖ projesine başlanırken ilk adım, problemi ve veri yapısını analiz ederek uygun yöntemi seçmektir.

Günümüzde derin öğrenme, MÖ’nin alt alanlarından biri olarak, özellikle karmaşık veriler üzerinde etkili sonuçlar veren bir yöntemdir. Derin öğrenme algoritmaları, büyük ve karmaşık veri kümelerinden anlamlı öngörüler çıkarmak için yapay sinir ağları kullanır. Bu yöntem, özellikle görüntü işleme, ses tanıma ve doğal dil işleme gibi alanlarda yüksek başarı sağlamaktadır. Derin öğrenme algoritmaları, çok katmanlı yapıları sayesinde verilerdeki karmaşık ilişkileri öğrenme kabiliyetine sahiptir (LeCun vd., 2015).

MÖ yöntemleri aynı zamanda çeşitli algoritmaların birleşiminden oluşan topluluk öğrenme (ensemble learning) yaklaşımlarını da içerir. Bu yaklaşımlar, birden fazla algoritmayı bir arada kullanarak modelin doğruluğunu artırmayı hedefler. Bagging, boosting ve stacking gibi teknikler topluluk öğrenme yöntemlerine örnek olarak verilebilir. Örneğin, rastgele orman (random forest) algoritması, birden fazla karar ağacını birleştirerek daha sağlam tahminler üretir ve genellikle yüksek doğruluk sağlamasıyla bilinir (Breiman, 1996).


MÖ si yöntemleri sürekli olarak gelişmekte ve yeni uygulama alanlarına uyarlanmakta olan dinamik bir alandır. Bu yöntemlerin doğru uygulanabilmesi için veri bilimi uzmanlarının modelin veri ile olan ilişkisini derinlemesine anlamaları ve problem özelliklerine göre uygun algoritmaları seçmeleri gerekmektedir. Her bir yöntemin kendine özgü avantajları ve sınırlamaları bulunmakta olup, bu yöntemlerin etkili bir şekilde uygulanması, günümüz veri odaklı dünyasında başarılı sonuçlar elde etmek için kritik öneme sahiptir (Zaki ve Meira, 2014).

MÖ yöntemleri, veri ile model arasındaki ilişkiyi optimize ederek yüksek doğrulukta sonuçlar elde etmeye yönelik güçlü araçlardır. Doğru yöntemin seçimi, model performansını önemli ölçüde etkileyebileceği gibi, çeşitli veri kaynaklarının en verimli şekilde kullanılmasını sağlar. ML yöntemleri, veri analizine dayalı karar süreçlerini desteklemek ve veri bilimi alanında yenilikçi uygulamaları mümkün kılmak için geniş bir uygulama alanı sunmaktadır.

2.3.2.1. Denetimli Öğrenme

Denetimli öğrenme, MÖ yöntemleri arasında en yaygın kullanılan yaklaşımdır. Bu yöntemde model, önceden etiketlenmiş verilerle eğitilir ve belirli girdilerden beklenen çıktıları tahmin etmek üzere optimize edilir. Denetimli öğrenmenin yaygın uygulamaları arasında sınıflandırma ve regresyon yer alır. Sınıflandırma algoritmaları, bir örneğin belirli bir kategoriye atanmasını sağlarken, regresyon algoritmaları sayısal çıktılar üretmek için kullanılır. Örneğin, bir kredi riskini tahmin etme uygulamasında, sınıflandırma algoritmaları kullanılarak müşterilerin yüksek veya düşük risk grubunda olup olmadığı belirlenebilir (James vd.2017).

Şekil 7: Denetimli Öğrenme Süreci




Kaynak: Zengin, 2024

Denetimli öğrenmenin temel amacı, belirli bir girdi setine karşılık gelen çıktı setini tahmin edebilmek için modeli eğitmektir. Eğitim sürecinde, model örnek verilerden faydalanarak kendini optimize eder ve bu verilerdeki örüntüleri öğrenir. Bu süreçteki etiketlenmiş veriler, modelin hedef çıktıyı tanımlamasına olanak sağlar. Örneğin, bir finansal dolandırıcılık tespit modelinde, daha önce etiketlenmiş dolandırıcılık vakaları kullanılarak model, benzer özelliklere sahip yeni işlemleri tespit edebilecek şekilde eğitilebilir (Alpaydın, 2016).

Denetimli öğrenmede kullanılan algoritmalar, problemin doğasına göre çeşitlilik gösterir. Örneğin, sınıflandırma problemleri için karar ağaçları, k-en yakın komşu (k-NN) ve destek vektör makineleri (SVM) gibi algoritmalar öne çıkarken; regresyon problemleri için doğrusal regresyon ve lojistik regresyon gibi yöntemler tercih edilir. Algoritma seçimi, problemin doğruluğunu ve performansını doğrudan etkilediğinden dolayı dikkatli bir analiz gerektirir (Bishop, 2006).


Şekil 8: Basit Sınıflandırmaya Ait Temsili Grafik



Kaynak: Duvar, 2022

Basit sınıflandırma, denetimli öğrenmenin önemli bir alt dalıdır ve genellikle bir nesnenin veya olayın belirli bir kategoriye atanmasını sağlar. E-posta filtreleme gibi uygulamalarda, modelin spam ve spam olmayan e-postaları doğru bir şekilde sınıflandırması istenir. Burada kullanılan algoritmalar, e-postaların içeriğindeki belirli kelimeleri ve desenleri analiz ederek tahminlerde bulunur. Başarıyla eğitilmiş bir sınıflandırma modeli, bilinmeyen veriler üzerinde yüksek doğrulukla tahmin yapabilir (Russell ve Norvig, 2016).

Şekil 9: Basit Regresyona Ait Temsili Grafik



Kaynak: Duvar, 2022

Regresyon ise denetimli öğrenmede sürekli değişkenlerin tahmini için kullanılan bir yöntemdir. Regresyon algoritmaları, veriler arasındaki ilişkiyi analiz ederek sayısal çıktılar sağlar. Örneğin, konut fiyat tahmininde, evin konumu, büyüklüğü, oda sayısı gibi özelliklere göre fiyatın tahmin edilmesi hedeflenir. Regresyon analizleri, özellikle finans ve ekonomi

alanlarında gelecek tahminleri için yaygın olarak kullanılır ve doğru uygulandığında yüksek doğrulukta sonuçlar verir (James vd., 2017).

Denetimli öğrenmenin başarısı büyük ölçüde veri kalitesine bağlıdır. Eğitim verisinin eksik veya hatalı olması, modelin öğrenme sürecini olumsuz etkileyerek yanlış tahminlere yol açabilir. Bu nedenle, eğitim verisi dikkatlice seçilmeli ve ön işlemden geçirilmelidir. Eksik değerlerin tamamlanması, aykırı değerlerin düzeltilmesi ve verinin normalize edilmesi gibi veri ön işleme adımları, modelin daha doğru öğrenmesini ve daha güvenilir sonuçlar vermesini sağlar (Geron, 2019).

Denetimli öğrenme, verinin etiketlenme süreci nedeniyle büyük veri miktarlarına ihtiyaç duyar ve etiketleme süreci oldukça zaman alıcı ve maliyetlidir. Özellikle tıbbi görüntü analizleri veya dil işleme gibi alanlarda büyük ölçekli veri etiketleme, uzmanlık gerektirir ve bu durum süreci maliyetli hale getirebilir. Ancak doğru etiketlenmiş verilerle çalışmak, modelin tahmin doğruluğunu önemli ölçüde artırdığı için bu maliyet genellikle karşılanabilir bir yatırımdır (Litjens vd., 2017).

Denetimli öğrenme modelleri ayrıca, aşırı öğrenme (overfitting) ve yetersiz öğrenme (underfitting) gibi riskler taşır. Aşırı öğrenme, modelin eğitim verisine fazla uyum sağlaması sonucu genel veri üzerinde iyi performans gösterememesidir. Yetersiz öğrenme ise modelin veriyi tam olarak öğrenememesi ve düşük doğrulukla sonuçlanmasıdır. Bu sorunlar, modelin genel performansını olumsuz etkileyebilir ve dikkatle ele alınmalıdır. Model optimizasyonu için çapraz doğrulama ve erken durdurma gibi teknikler kullanılarak bu riskler azaltılabilir (Goodfellow vd., 2016).

Denetimli öğrenmenin başarısını ölçmek için çeşitli değerlendirme metrikleri kullanılır. Doğruluk, kesinlik, geri çağırma ve F1 skoru gibi metrikler, modelin tahmin performansını ölçmek için yaygın olarak kullanılır. Bu metrikler, modelin hangi alanlarda iyi performans gösterdiğini ve hangi alanlarda iyileştirmeye ihtiyaç duyduğunu belirlemek için önemlidir. Denetimli öğrenme süreçlerinde bu tür değerlendirme metrikleri kullanılarak modelin başarısı daha objektif bir şekilde analiz edilebilir (Witten vd., 2016).

Sonuç olarak, denetimli öğrenme, veriden anlamlı öngörüler çıkararak çeşitli sektörlerde karar alma süreçlerine katkı sağlar. Ancak doğru veri kullanımı, dikkatli algoritma seçimi ve kapsamlı değerlendirme metriklerinin kullanılması, başarılı denetimli öğrenme modellerinin geliştirilmesi için gereklidir. Günümüzde denetimli öğrenme, veri bilimi ve yapay zeka

alanında yenilikçi uygulamalara öncülük ederek, giderek daha karmaşık problemlerin çözümünde etkili bir araç haline gelmektedir.

2.3.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme yöntemleri verinin etiketlenmediği durumlarda kullanılır. Bu tür algoritmalar, veride gizli yapıları ve örüntüleri keşfetmeyi amaçlar. Kümeleme ve boyut indirgeme algoritmaları denetimsiz öğrenme kapsamında en yaygın kullanılan yöntemlerdir. Kümeleme, benzer özelliklere sahip veri noktalarını gruplamak için kullanılırken, boyut indirgeme veri setinin karmaşıklığını azaltmak için verideki değişken sayısını düşürür. Örneğin, pazar segmentasyonu uygulamalarında kümeleme algoritmaları kullanılarak müşteriler, benzer davranışlara göre gruplara ayrılabilir (Hastie vd., 2009).

Şekil 10: Denetimsiz Öğrenme Süreci




Kümülatif Hata

Kaynak: Zengin, 2024

Denetimsiz öğrenme, makine öğrenmesi (MÖ) yöntemleri arasında, etiketli verilere ihtiyaç duymadan verinin iç yapısını keşfetmeyi amaçlayan bir yaklaşımdır. Denetimsiz öğrenmede, model eğitilirken girdilere karşılık gelen doğru etiketler bulunmaz; bunun yerine veri içindeki örüntüleri, gruplamaları ve ilişkileri kendi başına keşfetmesi beklenir (Murphy, 2012). Bu özellik, denetimsiz öğrenmeyi etiketsiz verilerin fazlaca bulunduğu alanlarda oldukça kullanışlı hale getirir. Veri etiketlemenin pahalı ve zaman alıcı olduğu uygulamalarda,

bu yöntemler veri içindeki gizli yapıları ortaya çıkararak anlamlı bilgiler sunar (Hastie vd., 2009).

Şekil 11: Kümeleme Yöntemi



Kaynak: Duvar, 2022

Denetimsiz öğrenme süreçlerinde en yaygın kullanılan teknikler arasında kümeleme ve boyut indirgeme yöntemleri yer alır. Kümeleme, benzer veri noktalarını gruplandırarak verinin doğal yapısını belirlemeye çalışır. K-ortalama (k-means) ve hiyerarşik kümeleme gibi teknikler, kümeleme algoritmalarının en popüler örnekleridir. Örneğin, pazar segmentasyonu uygulamalarında müşterilerin benzer özelliklerine göre gruplara ayrılması, pazarlama stratejilerinin daha hedefli bir şekilde geliştirilmesine olanak sağlar (Jain, 2010).

Boyut indirgeme yöntemleri ise, yüksek boyutlu veri kümelerindeki gereksiz değişkenleri azaltarak veriyi daha basit bir yapıya dönüştürmeyi amaçlar. Ana bileşen analizi (PCA) ve t-dağılımlı dağılım gömme (t-SNE) gibi algoritmalar, verinin temel özelliklerini kaybetmeden boyutlarını küçültmek için yaygın olarak kullanılır. Bu teknikler, özellikle yüksek boyutlu veri ile çalışılırken veri setinin daha anlaşılır ve görselleştirilebilir hale getirilmesi için önemlidir. Örneğin, genetik verilerde boyut indirgeme yöntemleri kullanılarak önemli gen varyasyonları belirlenebilir ve biyolojik araştırmalarda yeni öngörüler elde edilebilir (Witten vd., 2016).

Denetimsiz öğrenmenin başarısı, verinin doğal yapılarını etkili bir şekilde çıkarabilme yeteneğine bağlıdır. Denetimsiz öğrenme algoritmaları, yapay sinir ağları ve derin öğrenme gibi daha karmaşık yöntemlerle birleştirilerek veri üzerinde daha güçlü öngörüler sunabilir. Özellikle derin öğrenmede otomatik kodlayıcılar (autoencoders), etiketsiz verilerde öznetelik çıkarımı için kullanılan popüler bir yöntemdir. Bu tür modeller, karmaşık veri örüntülerini

öğrenerek verideki gizli ilişkileri ortaya koyar ve veri sınıflandırma veya tahmin modellerinin başarısını artırır (Goodfellow vd., 2016).

Denetimsiz öğrenmede algoritma seçimi, çözülmek istenen problem türüne ve veri yapısına göre farklılık gösterir. Kümeleme algoritmaları, sınıf veya grup bilgilerinin önceden bilinmediği durumlarda veri noktalarının doğal olarak nasıl gruplaşabileceğini keşfetmek için kullanılırken, boyut indirgeme algoritmaları ise özellikle veri setindeki değişken sayısını azaltarak veri analizini kolaylaştırır. Algoritmaların başarısı, verinin doğruluğu, kalitesi ve karmaşıklığı gibi faktörlere bağlıdır (Aggarwal, 2015).

Denetimsiz öğrenme yöntemleri aynı zamanda, verinin daha fazla bilgi içerip içermediğini anlamak için veri keşfi süreçlerinde de kullanılır. Özellikle büyük veri ortamlarında, veriyi etiketlemek çoğu zaman mümkün olmayabilir. Bu tür durumlarda, denetimsiz öğrenme algoritmaları veri içerisindeki ana yapıları çıkararak önemli bilgilerin elde edilmesine katkıda bulunur. Örneğin, sosyal medya analizinde kullanıcı davranışları kümeleme algoritmaları kullanılarak gruplandırılabilir ve böylece çeşitli kullanıcı profilleri elde edilebilir (Zaki ve Meira, 2014).

Denetimsiz öğrenme, bilgi keşfi ve çıkarımı için veri bilimi ve iş zekası uygulamalarında önemli bir rol oynar. Bu yöntemler, iş süreçlerinde verinin daha anlamlı ve kullanılabilir hale getirilmesine yardımcı olur. Örneğin, müşteri ilişkileri yönetimi alanında, farklı müşteri gruplarını keşfetmek ve davranış örüntülerini analiz etmek için denetimsiz öğrenme teknikleri yaygın olarak kullanılmaktadır. Bu tür analizler, müşteri memnuniyetini artırmak ve sadık müşteri kitlesi oluşturmak için stratejik bilgiler sunar (Han vd., 2022).

Denetimsiz öğrenme algoritmalarının en büyük avantajı, etiketsiz verilerle çalışabilme yeteneğidir. Bu özellik, büyük miktarda etiketsiz veri üzerinde bilgi çıkarımı yapabilmeyi sağlar, ancak bu yöntemin zorlukları da bulunmaktadır. Örneğin, denetimsiz öğrenme modelleri genellikle doğruluğun ölçülmesi gibi konularda denetimli öğrenme kadar net kriterlere sahip değildir ve bu durum, modelin başarısını değerlendirmede zorluklar yaratabilir. Ayrıca, denetimsiz öğrenmede verinin genelde çok sayıda parametreye bağlı olması, modelin karmaşıklığını arttırabilir (Bishop, 2006).

Ayrıca, denetimsiz öğrenme yöntemleri, büyük veri analitiğinde kritik bir role sahiptir. Büyük veri çağında veri miktarının hızla artması, denetimsiz öğrenme algoritmalarının veri analizinde daha önemli hale gelmesine neden olmuştur. Günümüzde finans, sağlık, pazarlama

ve siber güvenlik gibi birçok sektörde, büyük veri analizinde denetimsiz öğrenme yöntemleri yoğun olarak kullanılmaktadır (Aggarwal, 2015).

Sonuç olarak, denetimsiz öğrenme, makine öğrenmesi dünyasında etiketsiz veri ile anlam çıkarımı yapma amacı güden, oldukça güçlü ve etkili bir yöntemdir. Bu yöntem, veri içindeki gizli yapıları ortaya çıkararak, bilgi keşfi ve veri analizinde yeni bakış açıları sunar. Özellikle büyük veri çağında, denetimsiz öğrenme algoritmalarının gücü, veri bilimi ve iş zekâsı uygulamalarında değerli içgörüler sağlamak için büyük bir potansiyele sahiptir.

2.3.2.3. Yarı Denetimli Öğrenme

Yarı-denetimli öğrenme hem etiketli hem de etiketsiz verilerin kullanıldığı bir yöntemdir. Bu yaklaşım, etiketsiz veri miktarının büyük olduğu ancak etiketli verinin sınırlı olduğu durumlarda oldukça faydalıdır. Yarı-denetimli öğrenme yöntemleri, özellikle veri etiketleme maliyetinin yüksek olduğu alanlarda tercih edilir ve eğitim sürecinde etiketsiz verilerden de bilgi çıkarmaya çalışır. Örneğin, tıbbi görüntü analizinde sınırlı sayıda etiketli veri bulunmasına rağmen, etiketsiz verilerden faydalanarak tanısal tahminler yapmak mümkündür (Chapelle vd., 2009).

Yarı denetimli öğrenme, makine öğrenmesi (MÖ) yöntemlerinden biridir ve etiketli ve etiketsiz verilerin bir arada kullanılmasıyla model geliştirmeyi amaçlar. Geleneksel denetimli öğrenmede geniş miktarda etiketli veri seti bulunurken, denetimsiz öğrenmede yalnızca etiketsiz verilerden yararlanılır. Ancak büyük veri çağında etiketli veri elde etmek hem maliyetli hem de zaman alıcı olduğundan, yarı denetimli öğrenme, sınırlı etiketli veri ve bol miktarda etiketsiz veriyle başarılı tahminler yapmayı sağlayan etkili bir çözüm olarak öne çıkmaktadır. Bu yöntem, etiketlenmesi zor veya maliyetli veri türleri için önemli avantajlar sunar (Zhu ve Goldberg, 2009).

Yarı denetimli öğrenmenin en yaygın kullanım alanlarından biri görüntü işleme ve doğal dil işleme (NLP) gibi veri zengin, fakat etiketleme süreci zor olan alanlardır. Örneğin, binlerce görüntüyü elle etiketlemek oldukça zaman alıcıdır, ancak yarı denetimli öğrenme teknikleri sayesinde birkaç etiketli görüntü kullanılarak etiketsiz büyük bir veri seti üzerinde etkili bir model eğitilebilir. NLP alanında ise sınırlı sayıda etiketli örnekle dil modeli eğitmek, genellikle geniş bir etiketsiz metin Korpus'u ile desteklenerek başarısı artırılmaktadır (Chapelle vd., 2009).

Yarı denetimli öğrenme modelleri, etiketsiz veriyi yapısal olarak analiz ederken, sınırlı sayıda etiketli veriyi kullanarak veri içindeki örüntüleri çıkarır ve sınıflandırmalar yapar. Bu

süreç, veri üzerinde sınıf sınırlarını belirlemek için genellikle etiketli veriyle başlar ve etiketsiz veriyi bu sınırları daha kesin hale getirmek için kullanır. Bu şekilde model, sınırlı sayıda etiketli veriyi kullanarak daha geniş bir veri kümesinde genellemeler yapabilir (Van Engelen ve Hoos, 2020).

Yarı denetimli öğrenme, etiketli veri eksikliği nedeniyle performansın düştüğü durumlarda büyük bir avantaj sağlar. Çoğu yarı denetimli öğrenme algoritması, etiketsiz veriyi kullanarak etiketli verideki bilgiyi genişletir ve böylece modelin doğruluğunu artırır. Özellikle sınırlı eğitim verisiyle genelleme yeteneğini güçlendirmek için kullanılan bu yöntem, eğitim maliyetlerini düşürürken, doğruluk oranlarını da artırabilmektedir. Bunun yanında, yarı denetimli öğrenme modelleri, modelin aşırı öğrenme riskini azaltarak daha sağlam bir performans elde edilmesine katkı sağlar (Ouali vd., 2020).

Yarı denetimli öğrenmenin yaygın olarak kullanılan yöntemleri arasında kendi kendine eğitim (self-training), yayılma (label propagation) ve tutarlılık düzenlemesi (consistency regularization) bulunmaktadır. Kendi kendine eğitimde, model ilk olarak küçük bir etiketli veri seti üzerinde eğitilir ve ardından etiketsiz veri üzerinde tahmin yaparak, yüksek doğrulukla tahmin edilen sonuçları yeni etiketli veri olarak kullanır. Yayılma yönteminde ise sınırlı etiketler, verinin yapısı doğrultusunda komşuluk bilgisi ile diğer veri noktalarına yayılır. Tutarlılık düzenlemesi ise, modelin etiketsiz veriye karşı aynı sonuçları vermesini sağlayarak, modelin kararlılığını artırmaya yöneliktir (Zhu, 2005).

Yarı denetimli öğrenme, sağlık, finans ve güvenlik gibi alanlarda oldukça etkili sonuçlar sunar. Örneğin, tıbbi görüntü analizinde doktorlar tarafından etiketlenen az sayıda veri kullanılarak büyük miktarda etiketsiz görüntü üzerinde analiz yapılabilir. Bu, özellikle nadir hastalıkların teşhisinde yararlıdır, çünkü etiketleme süreci hem zordur hem de uzmanlık gerektirir. Finans sektöründe ise dolandırıcılık tespitinde kullanılan yarı denetimli öğrenme modelleri, az sayıda etiketli veri ile geniş bir veri seti üzerinde etkili analizler yapılmasını sağlar (Cheplygina vd., 2019).

Yarı denetimli öğrenmenin zorlukları ve sınırlamaları da bulunmaktadır. Bu yöntemde, etiketsiz verinin dağılımı ve yapısı, öğrenme sürecinde kritik bir rol oynar. Eğer etiketsiz verinin yapısı, etiketli veriyle uyumlu değilse modelin genelleme yeteneği zayıflayabilir ve hatalı tahminler yapabilir. Ayrıca, yarı denetimli öğrenme algoritmalarının karmaşıklığı ve hesaplama maliyeti de artabilmektedir. Özellikle büyük veri setlerinde bu yöntemlerin uygulanabilirliği ve verimliliği üzerinde detaylı analizler yapmak gereklidir (Zhu, 2005).

Yarı denetimli öğrenme, modern derin öğrenme ile birleşerek daha karmaşık veri yapılarına uygulanabilir hale gelmiştir. Derin öğrenme modelleri, otomatik kodlayıcılar ve generatif adversaryal ağlar (GAN) gibi yarı denetimli öğrenme yöntemleriyle entegre edildiğinde, etiketsiz veriden daha fazla bilgi çıkarabilmekte ve modelin doğruluğunu artırmaktadır. Bu tür hibrid modeller, özellikle karmaşık görüntü ve ses verisi analizlerinde başarılı sonuçlar sunmaktadır ve yeni uygulama alanları bulmaktadır (Kingma ve Welling, 2014).

Sonuç olarak, yarı denetimli öğrenme, sınırlı etiketli verinin bulunduğu ve etiketsiz verinin çok olduğu durumlarda makine öğrenmesi modellerinin başarısını artıran etkili bir yöntemdir. Etiketleme maliyetlerini düşürürken doğruluk oranını artırması, yarı denetimli öğrenmenin özellikle büyük veri analitiği için cazip bir seçenek olmasını sağlamaktadır. Bu yöntem, veri bilimi ve yapay zekâ uygulamalarında daha derin bilgi çıkarımı sağlayarak birçok sektörde yenilikçi çözümler sunmaktadır.

2.3.2.4. Pekiştirmeli (Takviyeli) Öğrenme

Pekiştirmeli öğrenme, MÖ'nin bir dalı olarak karar verme süreçlerinde yüksek performans göstermesiyle dikkat çeken bir yöntemdir. Temel olarak, bir ajanın (karar verici) çevresiyle etkileşime girerek bir görevde başarılı olmasını sağlayacak en iyi eylemleri öğrenmesi üzerine kuruludur. Bu yöntem, ajanın çevreden aldığı ödüller ya da cezalar aracılığıyla öğrenmesini sağlar. Ajana en yüksek ödülü kazandıracak stratejiyi bulmayı hedefleyen pekiştirmeli öğrenme, etiketli verilere bağlı kalmadan öğrenme sürecini deneyim üzerinden geliştirir ve öğrenilen bilgilerle kendi stratejisini oluşturarak genel başarısını artırır (Sutton ve Barto, 2018).

Pekiştirmeli öğrenmenin temel yapı taşları, ajanın eylemleri, çevresi, aldığı ödüller ve bu ödüllere dayalı olarak geliştirdiği politikaları içerir. Burada “durum” (state) ajan için içinde bulunduğu çevreyi tanımlarken, “eylem” (action) ajanın durumuna göre aldığı kararları temsil eder. Ajanın bir durumdan diğerine geçiş yapması ve bu süreçte ödül veya ceza alması, öğrenme sürecinin merkezinde yer alır. Ajan, her adımda aldığı ödüllere göre gelecekteki kararlarını iyileştirerek uzun vadeli toplam ödülünü maksimize etmeye çalışır (Kaelbling vd., 1996).

Pekiştirmeli öğrenme yöntemleri, özellikle Markov Karar Süreçleri (Markov Decision Processes, MDP) gibi matematiksel modellerle temsil edilir. MDP, bir durum, eylem, ödül ve geçiş olasılıkları kümesinden oluşan bir model olup, pekiştirmeli öğrenmede ajanın karar verme sürecini düzenler. Bu model aracılığıyla ajan, mevcut durumu göz önünde bulundurarak her

eylem için uzun vadeli ödülleri tahmin eder ve bu tahminlere dayalı olarak optimal politikalar geliştirir. Böylece ajan, en iyi ödül stratejisini belirleyerek karmaşık problem çözümlerinde etkili sonuçlar sunar (Puterman, 2014).

Pekiştirmeli öğrenmede yaygın olarak kullanılan algoritmalar arasında Q-öğrenme ve politika gradyanı (policy gradient) yöntemleri bulunmaktadır. Q-öğrenme, ajan tarafından her duruma karşılık gelen eylemler için uzun vadeli ödülleri öğrenmesini sağlar ve bu bilgilerle en iyi hareket stratejisini belirler. Politika gradyanı yöntemleri ise bir politikayı doğrudan optimize ederek sürekli eylem alanlarında dahi etkili sonuçlar sunar. Özellikle karmaşık ve sürekli problem çözüm süreçlerinde politika gradyanı algoritmaları yüksek performans sağlamaktadır (Silver vd., 2014).

Derin pekiştirmeli öğrenme (deep reinforcement learning) ise geleneksel pekiştirmeli öğrenme algoritmalarının derin sinir ağlarıyla birleştirilmesi sonucu ortaya çıkan, oldukça güçlü bir tekniktir. Bu yöntem, özellikle yüksek boyutlu ve karmaşık durum uzaylarında etkili sonuçlar verir. Örneğin, AlphaGo ve AlphaZero gibi Go oyununda kullanılan sistemler, derin pekiştirmeli öğrenme teknikleri sayesinde insan şampiyonları yenmeyi başarmışlardır. Bu başarılar, pekiştirmeli öğrenmenin geniş bir uygulama alanına sahip olduğunu ve zorlu problem çözmeye süreçlerinde bile etkili olduğunu göstermektedir (Silver vd., 2016).

Pekiştirmeli öğrenmenin kullanım alanları oldukça geniştir. Robotik, otonom sürüş, oyun geliştirme ve finansal analiz gibi alanlarda başarıyla kullanılmaktadır. Örneğin, robotların belirli görevleri öğrenmesi için kullanılan pekiştirmeli öğrenme algoritmaları, robotların çevreyle etkileşime girerek en iyi eylemleri belirlemesini ve görevleri başarıyla tamamlamasını sağlar. Otonom araçlarda ise pekiştirmeli öğrenme, aracın çevresindeki nesnelere göre doğru sürüş kararları almasına yardımcı olur (Kober vd., 2013).

Buna ek olarak, pekiştirmeli öğrenme, oyun endüstrisinde de devrim yaratmıştır. Ajanların çeşitli oyun ortamlarında en iyi hareketleri öğrenerek oyunu kazanmak için en etkili stratejiyi geliştirmeleri sağlanır. Örneğin, Dota 2 ve StarCraft II gibi karmaşık oyunlarda pekiştirmeli öğrenme algoritmaları kullanılarak insan rakipler karşısında üstünlük sağlanmıştır. Bu algoritmaların oyun geliştirme süreçlerine katkısı, oyunun daha gerçekçi ve akıllı karakterlerle donatılmasını sağlamıştır (Berner vd., 2019).

Ancak pekiştirmeli öğrenmenin bazı zorlukları da bulunmaktadır. Özellikle ödül fonksiyonunun belirlenmesi ve öğrenme sürecinin kararlılığı gibi konular, algoritmaların başarısı için kritik öneme sahiptir. Hatalı ödüller veya dengesiz öğrenme süreçleri, ajanın

hedeflerinden sapmasına neden olabilir. Bu nedenle, başarılı bir pekiştirmeli öğrenme modeli geliştirmek için ödül yapılandırmasının dikkatle yapılması gerekmektedir. Ayrıca, öğrenme sürecinin karmaşıklığı, yüksek hesaplama maliyetlerine neden olabilir ve algoritmaların gerçek zamanlı uygulamalar için verimliliğini etkileyebilir (Ng vd., 1999).

Pekiştirmeli öğrenme, günümüzdeki makine öğrenmesi araştırmalarının önemli bir parçası olarak hızla gelişmektedir. Özellikle derin öğrenme ile entegre edilerek daha geniş uygulama alanlarına ulaşmış ve insan zekasına yakın karar verme süreçleri geliştirilmiştir. Pekiştirmeli öğrenmenin gelecek vaat eden yapısı, karmaşık problemleri çözme kabiliyeti ve geniş kullanım alanları, bu yöntemin önemini artırmaya devam etmektedir. Pekiştirmeli öğrenmenin gelecekte daha da gelişerek yapay zekanın pek çok alanında devrim niteliğinde ilerlemeler kaydetmesi beklenmektedir.

2.4. Makine Öğrenmesi ve Kestirimci Bakım

MÖ, kestirimci bakım alanında önemli bir dönüşüm sağlamış, endüstriyel süreçlerin sürdürülebilirliğini ve verimliliğini artırmıştır. Kestirimci bakım, bir makinenin veya ekipmanın ne zaman arızalanabileceğini önceden tahmin etmeye odaklanır ve bu doğrultuda gerekli bakım işlemlerinin arıza gerçekleşmeden yapılmasını sağlar. Bu yaklaşım, bakım maliyetlerini düşürürken beklenmedik arıza sürelerini en aza indirir. Makine öğrenmesi yöntemleri ise kestirimci bakım uygulamalarında veri analitiği ve öngörü kabiliyetleriyle makine performansını takip etmekte ve arızaların ne zaman gerçekleşeceğine dair tahminlerde bulunmakta kullanılır (Jardin vd., 2006).

Kestirimci bakım, geleneksel bakım yöntemlerinden daha avantajlıdır çünkü yalnızca belirli zaman aralıklarında veya bir arıza sonrası yapılan müdahalelere dayalı değildir. Veriye dayalı bir yaklaşımla gerçek zamanlı analizler sunarak bakım gereksinimlerini belirleme kapasitesine sahiptir. Bu süreçte makine öğrenmesi, sürekli olarak sistemden veri toplayarak bu veriyi işler ve analiz eder. Veri analizi, arıza belirtilerini erken tespit ederek, beklenmedik duruş sürelerinin önüne geçer ve böylece endüstriyel operasyonlarda verimliliği artırır (Kothamasu vd., 2006).

Makine öğrenmesi, kestirimci bakımda farklı algoritmalar kullanarak arıza tahmini yapmaktadır. Denetimli öğrenme yöntemleri, geçmişte arıza gerçekleşen veriler üzerinde eğitilerek yeni verilerde aynı durumların tekrar etmesi halinde arızayı önceden tahmin edebilir. Denetimsiz öğrenme ise, veri içindeki gizli yapıları ortaya çıkararak beklenmedik davranışları

veya sapmaları belirler. Bu sayede, farklı arıza türlerinin daha önce görülmeyen belirtilerini analiz edebilir ve olası sorunları tespit eder (Widodo ve Yang, 2007).

Derin öğrenme, kestirimci bakım uygulamalarında güçlü bir performans sergileyen makine öğrenmesi tekniklerinden biridir. Derin sinir ağları, çok katmanlı yapısı sayesinde büyük veri kümelerinde ince detayları yakalayarak karmaşık örüntüleri öğrenebilir. Bu özellikle büyük hacimli ve çok çeşitli sensör verilerinin işlendiği durumlarda oldukça etkilidir. Örneğin, titreşim verilerinden bir rulman arızasının tahmin edilmesi gibi uygulamalarda derin öğrenme yöntemleri yüksek doğruluk sağlamaktadır (Hochreiter ve Schmidhuber, 1997).

Kestirimci bakım için kullanılan makine öğrenmesi algoritmalarının başarısında veri kalitesi önemli bir rol oynar. Veri toplama sürecinde kullanılan sensörlerin doğruluğu, arızaların belirlenmesinde kritik öneme sahiptir. Bunun yanında veri işleme ve veri ön işleme süreçleri de tahmin modellerinin performansını doğrudan etkiler. Anlamsız veya eksik veri, modelin başarısız tahminlerde bulunmasına neden olabilir. Bu yüzden kestirimci bakım uygulamalarında veri temizleme ve özellik mühendisliği adımları özenle gerçekleştirilmelidir (Yan ve Lee, 2005).

Zaman serisi analizleri, kestirimci bakım için önemli bir araç olarak öne çıkar. Makine öğrenmesi, zaman serisi verilerindeki örüntüleri analiz ederek ekipmanların geçmiş performansını inceleyebilir ve bu doğrultuda gelecekte oluşabilecek arızaları tahmin edebilir. Özellikle LSTM (Uzun Kısa Süreli Bellek) ağları gibi derin öğrenme teknikleri, uzun süreli bağımlılıkları öğrenmede etkili olduklarından zaman serisi analizlerinde sıklıkla tercih edilir. Bu tür algoritmalar, arıza meydana gelmeden önce erken uyarı mekanizmaları oluşturarak bakım planlamalarını optimize eder (Hochreiter ve Schmidhuber, 1997).

Kestirimci bakım, sadece arıza tahmini değil, aynı zamanda bakım süreçlerinin optimize edilmesine de katkı sağlar. Örneğin, makine öğrenmesi algoritmaları, hangi parçaların ne sıklıkla bakım gerektirdiğini analiz ederek en uygun bakım zamanlarını belirleyebilir. Bu süreç, yalnızca arızaların önlenmesini sağlamakla kalmaz, aynı zamanda bakım maliyetlerini ve enerji tüketimini de azaltır. Böylece, endüstriyel operasyonlarda sürdürülebilir bir bakım yönetimi sağlanmış olur (Mobley, 2002).

Makine öğrenmesi destekli kestirimci bakım, Endüstri 4.0'ın temel unsurlarından biri olarak kabul edilir. Nesnelerin İnterneti (IoT) teknolojilerinin gelişimi, sensör verilerinin daha hızlı ve kapsamlı bir şekilde toplanmasını sağlamış, böylece makine öğrenmesi algoritmaları için daha geniş bir veri havuzu sunmuştur. Bu sayede kestirimci bakım uygulamaları daha doğru

tahminler sunarak endüstriyel süreçlerde verimliliği artırmış ve arıza maliyetlerini düşürmüştür (Lee vd., 2014).

Makine öğrenmesi ve kestirimci bakım arasındaki ilişki, çeşitli sektörlerde farklı uygulamalarla kendini göstermektedir. Örneğin, enerji sektöründe jeneratörlerin veya türbinlerin ömrünü uzatmak için makine öğrenmesi tabanlı kestirimci bakım çözümleri kullanılırken, üretim sektöründe makinelerin en iyi performansla çalışmasını sağlamak için bu teknolojiler tercih edilmektedir. Otomotiv sektöründe ise araçların düzenli bakımlarını optimize etmek amacıyla makine öğrenmesi tabanlı kestirimci bakım yöntemleri uygulanmaktadır (Susto vd., 2015).

Sonuç olarak, MÖ, kestirimci bakım alanında büyük bir dönüşüm yaratarak arızaların önceden tahmin edilmesini sağlamaktadır. Bu sayede endüstriyel süreçlerde maliyet etkin, verimli ve sürdürülebilir bakım stratejileri oluşturulmaktadır. Gelişen teknoloji ile birlikte MÖ yöntemlerinin kestirimci bakım uygulamalarında daha da yaygınlaşacağı ve farklı sektörlerde yenilikçi çözümler sunmaya devam edeceği öngörülmektedir.

2.5. Makine Öğrenmesi ile İlgili Olarak Yapılan Çalışmalar

MÖ özellikle son 10 yıllık süreçte akademik alanda oldukça ilgi gösterilen bir alan haline gelmiş ve makine öğrenmesinin farklı alanlardaki uygulamalarına yönelik ulusal ve uluslararası ölçekte pek çok yayın yapılmıştır.

2.5.1. Makine Öğrenmesi ile İlgili Yurtiçinde Yapılan Çalışmalar

MÖ ile ilgili farklı alanlara yönelik olarak yurtiçinde yapılmış akademik çalışmalar aşağıdaki tabloda aktarılmaktadır.

Tablo 3: Makine Öğrenmesi ile İlgili Yurtiçinde Yapılan Çalışmalar

Yıl	Yazar/Yazarlar	Çalışma Başlığı	Yayın Türü
2024	Bakdemir, M.	Python ile Makine Öğrenmesi Algoritmalarını Kullanarak Rüzgar Santralinin Elektrik Üretim Tahmini	Yüksek Lisans Tezi
2024	Şimşek, M.	Dünya'nın Manyetik Alanında Nükleer Manyetik Rezonans (EF-NMR) Spektrometresi Ölçüm Verilerinin Sinyal İşleme ve Makine Öğrenme Teknikleri Kullanılarak Analizi İle Madde Tayini ve Tespiti	Yüksek Lisans Tezi
2024	Ercel, A., & Ulugergerli, E.	Öğrenen Makineler Ve Fasiyes Ayrımı; İlk Sonuçlar: Öğrenen Makineler	Makale

Tablo 3 (devamı)

2023	Akgün, M., & Barlık, N.	Makine Öğrenmesi Algoritmaları Kullanılarak Hava Kalitesi İndeksinin Tahmini	Makale
2023	Sarılgil, M.	Makine öğrenmesi ile kısıtlara dayalı zımpara seçimi	Yüksek Lisans Tezi
2023	Polatgil, M.	Veri ölçekleme ve eksik veri tamamlama yöntemlerinin makine öğrenmesi yöntemlerinin başarısına etkisinin incelenmesi	Makale
2023	Tuna, M. F.	Mobil uygulama müşteri geri bildirimindeki duyguların makine öğrenmesi yöntemleriyle sınıflandırılması	Makale
2023	Akköse, G., Duran, A., Dino, İ. G., & Akgül, Ç. M.	Makina öğrenmesi ile pencere parametrelerinin bina performansına etkisinin iklim değişikliği gözetilerek incelenmesi	Makale
2023	Yılmaz, C. B., Bodu, H., Yüce, E. S., Demir, V., & Sevimli, M. F.	Türkiye'nin Uzun Dönem Ortalama Sıcaklık (°C) Değerlerinin Üç Farklı Enterpolasyon Yöntemi ile Tahmini	Makale
2023	Azizoğlu, G., Azizoğlu, F., Toprak, A. N., Gül, M. F., & Zoralioğlu, Y.	Predicting Academic Performance of Students Using Machine Learning Techniques	Konferans Bildirisi
2022	Ceran, A. A., Tanrıöver, Ö.	Makine öğrenmesi tabanlı yazılım kalitesi tahmini	Yüksek lisans tezi
2021	Pulat, M., & Deveci Kocakoç, İ.	Türkiye'de Makine Öğrenmesi ve Karar Ağaçları Alanında Yayınlanmış Tezlerin Bibliyometrik Analizi	Makale
2021	Altun, M.	Landsat 8 uydu görüntü indeksleri kullanılarak tarımsal ürünlerin makine öğrenme yöntemleri ile tespit edilmesi	Yüksek lisans tezi
2021	Yetiz, F., Terzioğlu, M., & Kayakuş, M.	Makina öğrenmesi yöntemleri ile Türk mevduat bankalarının müşteri tahminine yönelik bir uygulama	Makale
2021	Bilgin, G.	Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması	Makale
2021	Altinel, A. B.	Türkçe Metinlerde Makine Öğrenmesi Algoritmalarının Duygu Analizi Problemi Üzerindeki Performansının Kıyaslanması	Makale
2021	Ünlü, V.	Demand Forecasting with Machine Learning Algorithm: Implementation in a Production Facility	Doktora tezi

Tablo 3 (devamı)

2020	Çetin, M. A.	Trafik kazası oluşumu etkenlerinden yararlanarak makine öğrenme yöntemleri ile kaza şiddeti tahmini	Doktora tezi
2020	Aksoy, B.	Sigorta Şirketlerinin Derecelendirilmesinde Makine Öğrenmesi Yöntemleri Tahmin Performansının Karşılaştırılması	Makale
2020	Kaya, Z., Balcıoğlu, H. E., Günc, H., & Seçkin, A. Ç.	Tabakalı Kompozit Yapıda Kırılma Davranışlarının Belirlenmesinde Makina Öğrenmesi Yaklaşımı	Konferans Bildirisi
2020	Yetginler, B., & Atacak, I.	Makine Öğrenmesi Yöntemleri ile Film Yorumlarından Duygu Analizi	Makale
2020	Aalami, N.	Derin öğrenme yöntemlerini kullanarak görüntülerin analizi	Makale
2020	Eroğlu, Y.	Yapay Sinir Ağları Ve Derin Öğrenme Kullanarak Türkiye'deki Covid-19 Vakaları İçin Tahmin Modelleri	Makale
2019	Kilimci, Z. H., Akyokus, S.	Evaluation of Word Embedding Models for Turkish Texts	Makale
2019	Aydın, O. M.	Finansal bilgi manipülasyonunun denetimli makina öğrenmesi yöntemleri kullanılarak tahmin edilmesi: Destek vektör makinesi, olasılıksal sinir ağı, k-en yakın komşu ve karar ağacı kullanımı	Yüksek lisans tezi
2019	Selvi, E.	Kentsel atıksu arıtma tesisi biyolojik oksijen ihtiyacının (boi5) makina öğrenmesi yöntemleri ile tahmin edilmesi	Yüksek lisans tezi
2019	Namlı, E., Ünlü, R., & Gül, E.	Fiyat Tahminlemede Makine Öğrenmesi Teknikleri ve Doğrusal Regresyon Yöntemlerinin Kıyaslanması; Türkiye'de Satılan İkinci El Araç Fiyatlarının Tahminlenmesine Yönelik Bir Vaka Çalışması	Makale
2019	Golgiyaz, S., Talu, M. F., & Onat, C.	Görüntü İşleme ve Makine Öğrenmesi Yöntemleri ile Baca Gazı Sıcaklığının Tahmin Edilmesi	Makale
2018	Kaynar, O., Arslan, H., Görmez, Y., & Işık, Y. E.	Makine öğrenmesi ve öznitelik seçim yöntemleriyle saldırı tespiti	Makale
2018	Sayar, A., & Turdaliev, N.	Makine Öğrenmesi ile Adaptif Otel Öneri Sistemi	Konferans Bildirisi
2018	Öztürk, M.	Makine öğrenmesi ve görüntü işleme tekniklerini kullanarak drone ile yaprak sınıflandırma	Yüksek lisans tezi

Tablo 3 (devamı)

2018	Gümüşçü, A., Tenekeci, M. E., Beşli, N., İlkhan, M. A., Aslan, E., & Abamor, S.	Yapılarda Isıtma ve Soğutma Yüğü Sınıfların Makine Öğrenme Yöntemleri ile Belirlenmesi	Makale
2018	Gurcan, F.	Multi-Class Classification of Turkish Texts	Konferans Bi
2018	Mukhandi, H. S.	Developing machine learning methods for network anomaly detection	Yüksek lisans tezi
2018	Cetiner, E., Koçak, T., & Güngör, V. Ç.	Credit risk analysis based on hybrid classification: Case studies on German and Turkish credit datasets	Konferans Bildirisi
2018	Turdaliev, N.	Destek vektör makineleri ile otel öneri sistemi	Yüksek lisans tezi
2017	Kaynar, O., Aydın, Z., & Görmez, Y.	Sentiment analizinde öznelilik düşürme yöntemlerinin oto kodlayıcıli derin öğrenme makinaları ile karşılaştırılması	Makale
2017	Yahyaoui, A.	Göğüs hastalıklarının teşhis edilmesinde makine öğrenmesi algoritmalarının kullanılması	Doktora tezi
2017	Çıra, F.	Elektrik Motorlarının Arıza Tespitinin Otomatik Olarak Yapılmasında Kullanılan Yapay Öğrenme Yöntemleri	Makale
2016	Tan, O., Özçoban, M. A., & Aydın, S.	Classification of EEG synchronization values of obsessive compulsive disorders patients using support vector machine method.	Konferans Bildirisi
2016	Kaynar, O., Görmez, Y., Yıldız, M., & Albayrak, A.	Makine öğrenmesi yöntemleri ile Duygu Analizi	Konferans Bildirisi
2016	Yüksel, S.	Türkiye'de Cari İşlemler Açığının Belirleyicileri: Mars Yöntemi ile Bir İnceleme	Makale
2015	Alçin, Ö., Şengür, A., & İnce, M.	İleri-geri takip algoritması tabanlı seyrek aşırı öğrenme makinesi	Makale
2015	Coban, O., Ozyer, B., Ozyer, G. T.	Sentiment Analysis for Turkish Twitter Feeds	Konferans Bi
2015	Çınaroğlu, S., & Avcı, K.	Bulaşıcı olmayan hastalıklar bakımından farklı ülkelerin makina öğrenmesi yöntemleri kullanılarak sınıflandırılması	Makale
2015	Ali, V.	Machine learning models for autoverification of medical laboratory test results	Yüksek lisans tezi

Tablo 3 (devamı)

2015	Alçin, Ö., Şengür, A., & İnce, M.	İleri-geri takip algoritması tabanlı seyrek aşırı öğrenme makinesi	Makale
2015	Doğan, S., & Kavtelek, C.	Hayat boyu öğrenme kurum yöneticilerinin hayat boyu öğrenme kavramına ilişkin görüşleri: Hayat boyu öğrenme için bir metafor analizi	Makale
2014	Uysal, A. K., Gunal, S.	The Impact of Preprocessing on Text Classification	Makale
2014	Aydoğan, E., & Şen, S.	Analysis of machine learning methods on malware detection	Konferans Bildirisi

Kaynak: Araştırmacı tarafından hazırlanmıştır

MÖ ile ilgili son 10 yılda yapılan çalışmalar incelendiğinde özellikle 2019 yılından itibaren yapılan çalışma sayısının fazlalaştığını söylemek mümkündür. Bu alanda yapılan çalışmaların çoğunlukla makale ve tez çalışması özelliğine sahip olduğu görülmektedir.

2.5.2. Makine Öğrenmesi ile İlgili Yurtdışında Yapılan Çalışmalar

Yurtdışında MÖ ile ilgili yapılan çalışmalar incelendiğinde yurtiçindeki çalışmalara benzer şekilde bu alana sık tercih edilen bir alan olduğu görülmektedir. MÖ ile ilgili yurtdışında yapılan çalışmalar aşağıdaki tabloda aktarılmaktadır.

Tablo 4: Makine Öğrenmesi ile İlgili Yurtdışında Yapılan Çalışmalar

Yıl	Yazar/Yazarlar	Çalışma Başlığı	Yayın Türü
2024	Pal, D. K. D., Alluri, V. R. R., Thota, S., Bonam, V. S. M., Chitta, S., & Shaik, M.	AI Ops: Integrating AI and Machine Learning into IT Operations.	Makale
2024	Nozari, H., Ghahremani-Nahr, J., & Szmelter-Jarosz, A.	AI and machine learning for real-world problems	Makale
2024	Caton, S., & Haas, C.	Fairness in machine learning: A survey	Makale
2023	Nazareth, N., & Reddy, Y. V. R.	Financial applications of machine learning: A literature review.	Makale
2023	Sharifani, K., & Amini, M.	Machine learning and deep learning: A review of methods and applications.	Makale
2023	Murphy, K. P.	Probabilistic machine learning: Advanced topics	Kitap
2023	Kreuzberger, D., Köhl, N., & Hirschl, S.	Machine learning operations	Konferans Bildirisi
2023	Li, W., Wang, C. H., Cheng, G., & Song, Q.	International conference on machine learning	Konferans Bildirisi

Tablo 4. (devamı)

2023	Barocas, S., Hardt, M., & Narayanan, A.	Fairness and machine learning: Limitations and opportunities	Kitap
2023	Yao, Z., Lum, Y., Johnston, A., Mejia-Mendoza, L. M., Zhou, X., Wen, Y., ... & Seh, Z. W.	Machine learning for a sustainable energy future	Makale
2022	Quiñonero-Candela, J., Sugiyama, M., Schwaighofer, A., & Lawrence, N. D.	Dataset shift in machine learning	Kitap
2022	Murphy, K. P.	Probabilistic machine learning: an introduction	Kitap
2021	Zhou, Z. H.	Machine learning	Kitap
2021	Surden, H.	Machine learning and law: An overview	Makale
2021	Janiesch, C., Zschech, P., & Heinrich, K.	Machine learning and deep learning	Makale
2021	Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W.	Using machine learning to detect misstatements	Makale
2020	Mahesh, B.	Machine learning algorithms-a review	Makale
2020	Brunton, S. L., Noack, B. R., & Koumoutsakos, P.	Machine learning for fluid mechanics.	Makale
2020	Zaki, M. J., Meira Jr, W., & Meira, W.	Data mining and machine learning: Fundamental concepts and algorithms	Kitap
2020	Maulud, D., & Abdulazeez, A. M.	A review on linear regression comprehensive in machine learning.	Makale
2019	Burkov, A.	<i>The hundred-page machine learning book</i>	Kitap
2019	Carleo, G., Cirac, I., Cranmer, K., Daudet, L., Schuld, M., Tishby, N., ... & Zdeborová, L.	Machine learning and the physical sciences	Makale
2019	Wei, J., Chu, X., Sun, X. Y., Xu, K., Deng, H. X., Chen, J., ... & Lei, M.	Machine learning in materials science	Makale
2019	Ray, S.	A quick review of machine learning algorithms	Konferans Bildirisi
2018	Mohri, M.	Foundations of machine learning	Makale
2018	Athey, S.	The impact of machine learning on economics	Makale
2018	Alzubi, J., Nayyar, A., & Kumar, A.	Machine learning from theory to algorithms: an overview	Makale
2018	Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D	Machine learning in agriculture: A review	Makale
2018	Ij, H.	Statistics versus machine learning	Makale

Tablo 4. (devamı)

2017	Nasteski, V. (2017). An overview of the supervised machine learning methods	An overview of the supervised machine learning methods	Makale
2017	Mullainathan, S., & Spiess, J.	Machine learning: an applied econometric approach	Makale
2017	Bzdok, D., Krzywinski, M., & Altman, N.	Machine learning: a primer	Makale
2016	Paluszek, M., & Thomas, S.	<i>MATLAB machine learning</i>	Kitap
2016	Zhou, Z. H.	Learnware: on the future of machine learning	Makale
2016	Wang, H., Lei, Z., Zhang, X., Zhou, B., & Peng, J.	Machine learning basics	Makale
2016	Mohammed, M., Khan, M. B., & Bashier, E. B. M.	Machine learning: algorithms and applications	Kitap
2016	Singh, A., Thakur, N., & Sharma, A.	). A review of supervised machine learning algorithms	Konferans Bildirisi
2015	Jordan, M. I., & Mitchell, T. M.	Machine learning: Trends, perspectives, and prospects	Makale
2015	El Naqa, I., & Murphy, M. J.	What is machine learning?	Kitap
2015	Awad, M., Khanna, R., Awad, M., & Khanna, R.	Machine learning in action: Examples	Makale
2015	Ribeiro, M., Grolinger, K., & Capretz, M. A.	Mlaas: Machine learning as a service	Konferans Bildirisi
2015	Theodoridis, S.	Machine learning: a Bayesian and optimization perspective	Kitap
2015	Muhammad, I., & Yan, Z.	Supervised Machine Learning Approaches: A Survey	Makale
2014	Shalev-Shwartz, S., & Ben-David, S.	Understanding machine learning: From theory to algorithms	Kitap
2014	Low, Y., Gonzalez, J. E., Kyrola, A., Bickson, D., Guestrin, C. E., & Hellerstein, J.	Graphlab: A new framework for parallel machine learning	Makale
2014	Natarajan, B. K.	Machine learning: A theoretical approach	Kitap
2014	Robert, C.	Machine learning, a probabilistic perspective	Kitap

Kaynak: Araştırmacı tarafından hazırlanmıştır

Yukarıdaki tabloda aktarılan çalışmalar incelendiğinde MÖ ile ilgili olarak yurtdışında yapılan çalışmalarda yurtiçindeki çalışmalardan farklı olarak makale ve bildirilerin yanı sıra kitapların da önemli yer tuttuğu görülmektedir.

ÜÇÜNCÜ BÖLÜM UYGULAMA

3.1. Araştırmanın Amacı ve Kapsamı

Bu tez çalışmasının temel amacı, endüstriyel süreçlere yönelik olarak makine öğrenimi destekli bir kestirimci bakım modeli önerisinde bulunmaktır. Çalışma, özellikle makine sensörlerinden toplanan büyük verinin analiz edilmesi, bu verilerle makine öğrenimi algoritmalarının eğitilmesi ve arıza tahminlerinin gerçekleştirilmesini hedeflemektedir. Geliştirilecek model, bakım süreçlerini daha etkin, maliyet etkin ve sürdürülebilir bir yapıya kavuşturmayı amaçlamaktadır. Çalışma, mevcut literatürde eksikliği hissedilen kestirimci bakım modellerinin daha geniş bir endüstriyel uygulama yelpazesinde doğruluğunu ve uygulanabilirliğini test etmeye odaklanmıştır.

Avcı (2023), yapmış olduğu tez çalışmasında, turbofan motorları ve rulmanlar için kestirimci bakım uygulamalarını ileri derin öğrenme modelleri kullanmıştır. Ancak, çalışmanın genel geçerliliğini sınırlayan bazı önemli eksiklikler bulunmaktadır. Öncelikle, tezde kullanılan veri kümeleri (C-MAPSS ve FEMTO-ST) üzerine yoğunlaşmış, önerilen modellerin farklı sektörler veya veri kümelerine uyarlanabilirliği yeterince tartışılmamıştır. İkinci olarak, model performansı RMSE ve özel skor fonksiyonları gibi metriklerle değerlendirilmiş olsa da, gerçek zamanlı operasyonel entegrasyon ve pratik endüstriyel uygulamalarda ölçeklenebilirlik zorlukları üzerinde detaylı bir değerlendirme yapılmamıştır. Son olarak, çalışmada Öz-Dikkat Katmanı ve Dönüştürücü modeller gibi yenilikçi yaklaşımlar tanıtılmış olsa da, bu yöntemlerin geleneksel algoritmalarla kıyasla çeşitli çevresel veya operasyonel koşullarda sağladığı avantajlara dair kapsamlı bir analiz eksikliği göze çarpmaktadır.

Yiğın (2024), doktora tezinde, kritik gemi makine operasyonlarına yönelik ileri düzey veri artırma teknikleri ve makine öğrenmesi algoritmalarını kullanan bir reçetesel bakım çerçevesi araştırmıştır. Çalışma, anomali tespiti ve bakım optimizasyonunda önemli ilerlemeler kaydetse de bazı sınırlamalar göze çarpmaktadır. İlk olarak, çerçeve öncelikli olarak belirli veri kümelerine ve gemi makine uygulamalarına odaklanmıştır, bu da diğer sektörler veya daha geniş denizcilik bağlamlarına genelleştirilebilirliğini sınırlandırmaktadır. İkinci olarak, Generative Adversarial Networks (GAN) kullanılarak üretilen sentetik verilerin önemli bir yenilik olduğu belirtilse de, bu verilerin gerçek operasyonel veri setleriyle entegrasyonundaki pratik zorluklar yeterince ele alınmamıştır. Üçüncü olarak, önerilen modellerin teknik performansına vurgu yapılırken, bu sistemlerin filo genelinde uygulanabilirliği için ekonomik ve operasyonel fizibilite konuları kapsamlı bir şekilde tartışılmamıştır.

Karabacak (2021), yapmış olduđu tez çalışmasında, sonsuz vidalı redüktörlerde (SVR) meydana gelen arızaların yapay zekâ tabanlı yöntemlerle tespiti ve sınıflandırılmasını ele alarak bu alanda çalışmıştır. Ancak, çalışmanın bazı eksiklikleri dikkat çekmektedir. Öncelikle, önerilen yöntemin farklı mekanik sistemlere genelleştirilebilirliği ve diğer redüktör tipleri üzerindeki uygulanabilirliği tartışılmamıştır. İkinci olarak, veri çeşitliliği ve farklı çalışma koşullarındaki dinamik etkiler kapsamlı bir şekilde ele alınmamış, bu da yöntemin performansının belirli koşullarla sınırlı olabileceğini göstermektedir. Ayrıca, yapay zekâ algoritmalarının kıyaslamaları yapılırken, kullanılan modellerin optimizasyon süreçleri ve karar mekanizmalarının operasyonel etkileri üzerinde durulmamıştır. Son olarak, geliştirilen yöntemin endüstriyel ölçekli uygulamalardaki ekonomik faydaları ve pratik etkilerine ilişkin bir değerlendirme eksikliği bulunmaktadır.

Möngü (2022) yapmış olduđu doktora tez çalışmasında, asenkron motorlara bağlı rulmanlarda arıza tespiti ve kalan faydalı ömür tahmini için model tabanlı bir kestirimci bakım yöntemi sunmaktadır. Ancak, çalışmanın bazı sınırlamaları dikkat çekmektedir. Öncelikle, önerilen modelin farklı endüstrilerdeki ekipmanlara uygulanabilirliği ve genelleştirilebilirliği hakkında detaylı bir değerlendirme yapılmamıştır. İkinci olarak, kullanılan yöntemlerin gerçek zamanlı sistemlere entegrasyonu ve operasyonel süreçlerdeki etkileri üzerinde yeterince durulmamıştır. Ayrıca, verilerin farklı çalışma koşullarında veya çevresel etkiler altındaki davranışlarının analiz edilmediği görülmektedir.

Serin (2024) yapmış olduđu doktora tezinde, frezeleme işlemlerinde takım aşınmasının tahmini için makine öğrenmesi ve derin öğrenme tekniklerini kullanarak anlamlı bir katkı sunmayı amaçlamaktadır. Ancak çalışmada bazı eksiklikler dikkat çekmektedir. İlk olarak, önerilen yöntemlerin farklı imalat süreçleri veya endüstrilere genelleştirilebilirliği hakkında yeterince açıklama yapılmamıştır. İkinci olarak, kullanılan veri toplama yöntemlerinin ve deney koşullarının gerçek endüstriyel ortamlardaki uygulanabilirliği ve bu ortamların karmaşıklıklarıyla başa çıkma kapasitesi detaylı olarak ele alınmamıştır. Ayrıca, derin öğrenme algoritmalarının hiperparametre optimizasyonu ve farklı model mimarilerinin performans karşılaştırmaları üzerine kapsamlı bir analiz eksikliği bulunmaktadır.

Ensarioğlu (2024) çalışmış olduđu doktora tezinde, turbo fan motorlarında kalan faydalı ömür (RUL) tahmini için hibrit prognostik yaklaşımlar kullanarak özgün bir metodoloji sunmaktadır. Ancak, çalışmanın bazı sınırlamaları dikkat çekmektedir. İlk olarak, önerilen yöntemin farklı sektörlere veya ekipmanlara genelleştirilebilirliği üzerine yeterli bir değerlendirme yapılmamıştır. İkinci olarak, kullanılan veri setinin (C-MAPSS) yalnızca

simülasyon ortamında oluşturulmuş olması, gerçek dünya uygulamalarındaki zorlukların ve çevresel faktörlerin yeterince ele alınmadığını göstermektedir. Üçüncü olarak, önerilen hibrit modelin gerçek zamanlı sistemlere entegrasyonu ve operasyonel süreçlerdeki uygulanabilirliği ile ilgili kapsamlı bir tartışma eksikliği bulunmaktadır. Ayrıca, kullanılan öznitelik mühendisliği ve hedef etiketleme yaklaşımlarının, modelin performansı üzerindeki etkileri detaylandırılmış olsa da, bu yaklaşımların alternatif yöntemlerle karşılaştırılması eksik kalmıştır.

Yürek (2024) çalışmış olduğu tezinde, kestirimci bakım alanında makine öğrenimi tekniklerini kullanarak sıralı sınıflandırma ve ikili ayrıştırma yaklaşımlarını birleştiren yenilikçi bir algoritma ortaya koymaktadır. Ancak, çalışmada bazı eksiklikler dikkat çekmektedir. İlk olarak, önerilen yöntemin endüstri genelindeki farklı veri kümeleri ve uygulamalara genelleştirilebilirliği üzerine daha kapsamlı bir değerlendirme yapılmamıştır. İkinci olarak, algoritmanın gerçek zamanlı uygulamalara entegrasyonu ve operasyonel ortamlardaki performansı ile ilgili daha fazla pratik örnek ve tartışmaya ihtiyaç duyulmaktadır. Ayrıca, C-MAPSS ve diğer veri kümelerinde kullanılan sıralı sınıflandırma yöntemlerinin alternatif tekniklerle detaylı bir karşılaştırması yapılmamıştır.

Yapılan çalışmalar incelendiğinde, belli alanlarda yapıldığı görülecektir, bu bağlamda özellikle diğer makine öğrenme algoritmalarının karşılaştırılmadığı da görülecektir. Makine öğrenme algoritmalarının sonuçlarının karşılaştırılmasıyla en uygun kestirimci bakım yöntemi de belirlenmiş olacaktır. Diğer bir husus ise, Hiperparametre optimizasyonu özelliğinin kullanılmamış olmasıdır. Hiperparametre optimizasyonu ile analizler ve sonuçlar daha iyi hale getirilebilmektedir. Literatürde yapılan çalışmalara bakıldığında, sentetik verinin de kullanıldığı görülmektedir, bu bağlamda gerçek verilerle yapılan çalışmaların sonuçlarında belli oranlarda farklılıklar ortaya çıkacaktır. Yaptığım çalışmada, sensörlerden toplanan gerçek zamanlı verilerle işletmenin ilgi makinedeki kestirimci bakım çalışmaları yapmasına olanak sağlanmış olmaktadır. Ayrıca makine öğrenmesi algoritmaları sonuçları hiperparametre optimizasyonu ile değerlendirilmiştir. Bu da literatüre yapılmış önemli bir katkı olacaktır.

Sanayi işletmelerinde makinelerin ve ekipmanların arıza sürecine girmeden önce tahmin edilebilmesini sağlayan makine öğrenimi destekli bir kestirimci bakım modeli geliştirmektir. Modern endüstri uygulamalarında proaktif bakım stratejilerinin, özellikle beklenmedik duruşlar ve bu duruşların maliyetleri üzerinde büyük bir etkisi bulunmaktadır. Yapılan çalışmada, işletmelerin bakım maliyetlerini azaltmalarına, makinelerin ömrünü uzatmalarına ve

operasyonel verimliliklerini artırmalarına katkıda bulunacak bir model sunmayı amaçlamaktadır.

Endüstriyel süreçlerin sürdürülebilirlik ve operasyonel verimlilik gereklilikleri doğrultusunda bakım stratejileri, işletmelerin rekabet avantajını belirleyen en önemli unsurlar arasında yer almaktadır. Özellikle, plansız duruş sürelerinin ve beklenmedik arızaların azaltılması, işletme kaynaklarının etkin yönetimi ve üretim süreçlerinin sürekliliği açısından kritik bir öneme sahiptir. Ancak, geleneksel bakım yaklaşımları (önleyici veya düzeltici bakım gibi) bu hedeflere ulaşmada yetersiz kalmakta, arıza tahminleri ve bakım planlaması açısından daha yenilikçi ve teknolojik yaklaşımlara ihtiyaç duyulmaktadır.

Kestirimci bakımın önemi, işletmelerin rekabet gücünü artırmada ve sürekli üretim sürecini sağlama yönünde belirgin bir avantaj sunmasıyla öne çıkar. Kestirimci bakım modelleri, makine ve ekipmanlardan gerçek zamanlı olarak toplanan büyük veri setleri ile güçlendirilir ve bu veriler makine öğrenimi algoritmaları aracılığıyla analiz edilir. Bu bağlamda, modelin başarısını artırmak için hiperparametre optimizasyonu gibi ileri veri işleme teknikleri de bu çalışmada önemli bir rol oynayacaktır.

Literatür incelemesi, makine öğrenimi ve kestirimci bakım uygulamaları üzerine yapılan çeşitli çalışmaların genellikle aşağıdaki eksiklikleri barındırdığını ortaya koymaktadır:

Teknolojik Odaklılık: Mevcut çalışmaların birçoğu, sadece makine öğrenimi algoritmalarının doğruluğu veya performansı üzerinde durmakta, bu algoritmaların endüstriyel sistemlerde gerçek zamanlı uygulama potansiyelini göz ardı etmektedir.

Veri Kalitesi ve Çeşitliliği: Çalışmalar genellikle sınırlı veri setlerine dayalı olarak gerçekleştirilmektedir. Endüstriyel ortamlarda karşılaşılan veri çeşitliliği ve veri temizleme süreçleri gibi gerçek dünya problemleri yeterince ele alınmamaktadır.

Hiperparametre Optimizasyonu: Birçok model, hiperparametre optimizasyonu gibi performans artırıcı teknikleri kullanmamaktadır, bu da modellerin tahmin doğruluğunu olumsuz etkilemektedir.

Sürdürülebilirlik ve Entegrasyon Eksikliği: Kestirimci bakımın sürdürülebilirlik ve maliyet etkinliği üzerindeki etkileri hakkında yeterince kapsamlı bir analiz yapılmamıştır.

Bu bağlamda, geliştirilecek olan makine öğrenimi destekli kestirimci bakım modeli, yukarıdaki eksikliklere çözüm üretmeyi hedeflemektedir.

3.2. Kapsam

Araştırma, endüstriyel süreçlerde makine öğrenimi destekli kestirimci bakım uygulamalarını ele almakta ve aşağıdaki aşamaları içermektedir:

Literatür Taraması: Kestirimci bakım ve makine öğrenimi üzerine yapılan ulusal ve uluslararası çalışmaların kapsamlı bir analizi gerçekleştirilmiştir. Bu analizde, mevcut yaklaşımların avantajları ve sınırlılıkları belirlenmiş, eksiklikler tespit edilmiştir.

Model Geliştirme: Kestirimci bakımın temel bileşenleri ve işleyiş mekanizmaları göz önünde bulundurularak, sensör verileri üzerinde çalışacak bir makine öğrenimi modeli geliştirilmiştir. Bu süreçte veri işleme, model eğitimi ve hiperparametre optimizasyonu gibi aşamalar yer almıştır.

Sonuçların Değerlendirilmesi: Çalışmadan elde edilen sonuçlar, mevcut literatür ile karşılaştırılmış ve modelin üstünlükleri ile eksiklikleri tartışılmıştır.

Bu doğrultuda, bu tez çalışması, endüstriyel uygulamalara yönelik olarak geliştirilen makine öğrenimi destekli kestirimci bakım modellerinde, veri kalitesi, hiperparametre optimizasyonu ve gerçek zamanlı uygulama boyutları üzerinde durmaktadır. Amaç, literatürdeki bu boşluğu doldurarak, daha etkin ve sürdürülebilir bir kestirimci bakım modeli önerisi sunmaktır. Çalışma, bu doğrultuda endüstriyel süreçlerde daha geniş kapsamlı uygulamalar ve yenilikçi bakım stratejileri için bir temel oluşturmaktadır.

3.3. “Makine Öğrenimi Destekli Kestirimci Bakım Modeli Önerisi” Literatür Özeti

Makine öğrenimi destekli kestirimci bakım modelleri, endüstriyel operasyonlarda makinelerin ve ekipmanların çalışma sürelerini optimize etmek ve beklenmedik arıza durumlarını önceden tahmin ederek bakım faaliyetlerini planlamak için geliştirilmiştir (Zonta vd., 2020; Yıldırım ve Arıkan, 2021). Bu tür bakım stratejileri, özellikle ağır sanayi ve yüksek üretim kapasitesine sahip sektörlerde, arıza süresini ve maliyetlerini minimumda tutarak rekabet gücünü artırır. Geleneksel önleyici bakım yöntemlerinin ötesine geçerek makine öğrenimi algoritmalarından faydalanmak, sensör verileri ve performans ölçütlerine dayalı olarak gerçek zamanlı bakım kararları alınmasına olanak tanır (Cabrera vd., 2022).

Kestirimci bakımın amacı, üretim hatlarındaki duruşları ve ani arızaları en aza indirerek, ekipmanların öngörülen ömrünü uzatmaktır. Makine öğrenimi algoritmaları, büyük veri analitiği ile birlikte kullanıldığında, ekipmanlardaki anomalileri tespit edebilir ve bu anomalilere göre olası arıza noktalarını belirleyebilir (Garg ve Aggarwal, 2019). Son yıllarda

derin öğrenme modellerinin gelişmesiyle birlikte, kestirimci bakım çözümlerinin doğruluk oranları daha da artmıştır (Liv d., 2023). Bu doğruluk, özellikle zaman serisi analizleri ve anomali tespit teknikleri sayesinde elde edilmektedir. Ayrıca, hiperparametre optimizasyonu ve model hassasiyeti artıran diğer teknikler de bakım süreçlerini iyileştirmekte etkili olmaktadır (Zhang vd., 2021).

Endüstri 4.0 kapsamında IoT (Nesnelerin İnterneti) teknolojileri ve büyük veri analitiği ile desteklenen makine öğrenimi modelleri, kestirimci bakım uygulamalarının en ileri örneklerini oluşturur. Özellikle IoT cihazları ile toplanan veriler, makine öğrenimi modellerinin gelişmiş analiz yapabilmesini sağlar. Bu sayede bakım faaliyetleri, yalnızca geçmiş verilere dayalı olarak değil, aynı zamanda gerçek zamanlı gözlemlere dayanarak gerçekleştirilir (Park vd., 2020). Yani, kestirimci bakım uygulamaları, sadece bakım maliyetlerini düşürmekle kalmayıp aynı zamanda ekipmanların kullanım ömrünü uzatmak ve üretim verimliliğini artırmak için güçlü bir çözüm sunmaktadır (Susto vd., 2015).

Literatürde makine öğrenimi destekli kestirimci bakım üzerine yapılan birçok çalışma, bu modellerin geniş bir endüstriyel uygulama yelpazesinde başarıyla kullanılabileceğini göstermektedir. Örneğin, otomotiv sektöründe, büyük veri ve yapay zekâ kullanılarak bakım stratejilerinin iyileştirilmesi için çalışılmıştır (Singh vd., 2021). Ayrıca, enerji sektöründe ekipmanların güvenilirliğini artırmak için geliştirilen kestirimci bakım modelleri sayesinde, beklenmedik arıza riskleri azaltılmış ve operasyonel sürdürülebilirlik artırılmıştır (Hussain vd., 2021). Bu çalışmalar, kestirimci bakım modellerinin yalnızca mevcut arızaların önlenmesine değil, aynı zamanda işletme genelinde güvenliği artırmaya yönelik de etkili bir yöntem olduğunu ortaya koymaktadır.

Makine öğrenimi destekli kestirimci bakım modelleri, günümüz endüstriyel dünyasında yalnızca maliyet azaltımı sağlamamakta, aynı zamanda işletmelerin iş süreçlerinde verimliliği yükseltmekte ve iş güvenliği standartlarını artırmaktadır. IoT teknolojileri, derin öğrenme modelleri ve büyük veri analitiği gibi yenilikçi yaklaşımların bir araya gelmesiyle, kestirimci bakım uygulamalarının gelecekte daha da gelişerek endüstriyel üretim süreçlerinde yaygın bir şekilde benimsenmesi beklenmektedir (Wang vd., 2022; Chen vd., 2023).

Literatürde makine öğrenimi destekli kestirimci bakım modelleri üzerine yapılan araştırmalar, endüstriyel süreçlerde verimliliği artırmak ve bakım maliyetlerini düşürmek amacıyla makine öğrenimi algoritmalarının kritik bir rol oynadığını ortaya koymaktadır. Cabrera vd., (2022)'nin kapsamlı incelemesi, kestirimci bakım için makine öğrenimi

kullanmanın, endüstriyel işletmelerde operasyonel güvenilirliği önemli ölçüde artırdığını göstermiştir. Chen vd., (2023) ise IoT tabanlı kestirimci bakım uygulamalarının, gerçek zamanlı veri toplayarak proaktif bakım stratejilerinin etkisini daha da güçlendirdiğini öne sürmektedir. Bu bağlamda, kestirimci bakım sistemleri yalnızca maliyet etkinliği sağlamakla kalmayıp, aynı zamanda makine ömrünü uzatmakta ve plansız arızaları en aza indirmektedir.

Garg ve Aggarwal'ın (2019) çalışmaları, büyük veri ve makine öğrenimi algoritmalarının birleşiminin, ekipman arızalarını öngörmeye oldukça yüksek doğruluk oranları sunduğunu vurgulamaktadır. Bu doğruluk oranları, özellikle derin öğrenme algoritmaları ve zaman serisi analizleri gibi tekniklerin kullanımıyla daha da artırılmaktadır (Liv vd., 2023). Benzer şekilde, Park vd., (2020) çalışması, IoT ve makine öğrenimi destekli kestirimci bakım uygulamalarının, üretim süreçlerinde plansız duruş sürelerini düşürerek işletmelere önemli katkılar sağladığını ifade etmektedir.

Enerji sektöründeki uygulamalar da dikkate alındığında, Hussain vd., (2021) çalışması, kestirimci bakımın operasyonel sürdürülebilirliği artırmak için kritik bir çözüm sunduğunu göstermiştir. Bu çalışmalardan elde edilen bulgular, otomotiv, enerji ve ağır sanayi gibi sektörlerdeki uygulamalarda, kestirimci bakımın verimlilik, güvenlik ve maliyet etkinliği sağlamak için önemli bir strateji olduğunu ortaya koymaktadır (Singh vd., 2021).

Bu çalışmaların genel bulguları, makine öğrenimi ve büyük veri teknolojilerinin birleşiminin, endüstriyel kestirimci bakım uygulamalarında çığır açan gelişmelere olanak tanıdığına işaret etmektedir. Kestirimci bakım çözümleri, ekipmanların kullanım ömrünü uzatarak işletmelere maliyet tasarrufu sağlamanın yanı sıra, iş güvenliğini ve operasyonel sürdürülebilirliği artırmada da kritik bir rol üstlenmektedir. Gelecekte, IoT teknolojileri ve makine öğrenimi algoritmalarıyla daha da gelişmesi beklenen kestirimci bakım sistemleri, Endüstri 4.0 bağlamında daha verimli ve güvenilir üretim süreçleri için vazgeçilmez bir unsur olacaktır.

3.4. Kestirimci Bakım Problemi Model Eğitim Süreci

3.4.1. Veri Yapısı

Bu çalışmada kullanılan veriler endüstriyel bir işletmeden elde edilen sensör ve arıza kayıtlarına dayalı olarak oluşturulmuştur. Veri yapısı iki temel bileşene ayrılmaktadır: sürekli olarak elde edilen sensör verileri ve manuel olarak kaydedilen arıza oluşum kayıtları. Sensör verileri her saniye alınarak zaman içinde bir akış halinde toplanırken, arıza kayıtları belirli

zaman damgalarıyla arıza türlerini içermektedir. Bu veri yapısının dikkat çekici ilk yönü, sensör verilerinin yüksek frekansta (saniyede bir) toplanmasıdır. Bu durum, veri setinin çok sayıda veri noktasına sahip olmasına ve verilerin zaman serisi analizine uygun olmasına olanak tanımaktadır. Zaman serisi analizleri, kestirimci bakım modellerinde gelecekteki arızaların tahmin edilmesi açısından oldukça değerlidir. Bu nedenle, saniye düzeyindeki verilerin dakikalık ortalamalarla sadeleştirilmesi, verinin işlenebilirliği açısından mantıklı bir adım olarak değerlendirilebilir. Böylece veri hacmi azaltılarak analiz süreçleri hızlandırılmaktadır.

Canito ve arkadaşlarına (2021) göre, kestirimci bakım süreçlerinde veri temizleme, modellerin doğruluğunu ve etkinliğini doğrudan etkileyen kritik bir adımdır. Endüstriyel sistemlerden elde edilen ham veriler genellikle eksik, hatalı, gereksiz ya da tutarsız bilgiler içermekte olup, bu durum analiz ve modelleme aşamalarında hatalı sonuçlar doğurabilir. Bu nedenle, veri temizleme işlemi, eksik verilerin doldurulması, anormal değerlerin tespiti ve ayıklanması, tutarlılığın sağlanması gibi adımları içermektedir. Özellikle, arıza tahmini ve ekipmanın kalan kullanım ömrünün tahmini gibi kestirimci bakım modellerinde, temizlenmemiş veriler hatalı tahminlere yol açabileceği gibi, sistem performansını da olumsuz etkileyebilir. Bu bağlamda, temizlenmiş veriler, hem çevrimdışı hem de çevrimiçi işleme tekniklerine uygun hale getirilerek, kestirimci bakım modellerinin güvenilirliğini artırmakta ve gerçek zamanlı uygulamalarda daha tutarlı çıktılar sunulmasını sağlamaktadır. Veri temizleme, yalnızca analiz süreçlerinin etkinliğini artırmakla kalmayıp, aynı zamanda endüstriyel senaryolarda karar destek mekanizmalarının geliştirilmesi açısından da vazgeçilmez bir bileşen olarak öne çıkmaktadır.

Makine öğrenimi (MÖ) algoritmalarının endüstriyel bakım süreçlerindeki tahmin doğruluğu, büyük ölçüde veri hazırlık aşamalarının etkinliğine bağlıdır. Veri temizleme, bu aşamada temel bir adım olarak öne çıkmakta ve eksik ya da hatalı verilerin modellenen tahmin sonuçlarının önemli ölçüde etkilediği bilinmektedir. Masmoudi vd., (2021)'e göre, gaz türbinlerinin performans düşüşlerini tahmin etme sürecinde kullanılan farklı veri temizleme tekniklerinin model doğruluğunu nasıl etkilediğini göstermiştir. Çalışmada, eksik verilerin sağlam bir yöntemle doldurulmasının, makine öğrenimi (MÖ) algoritmalarının başarı oranını artırdığı ve sistem performansını optimize ettiği ifade edilmiştir. Veri temizleme, yalnızca tahmin modellerinin doğruluğunu artırmakla kalmayıp, kestirimci bakım stratejilerinin etkinliğini de önemli ölçüde destekleyen bir bileşen olarak öne çıkmaktadır.

Veri ön işleme (*data preprocessing*), kestirimci bakım modellerinin doğruluğunu ve etkinliğini artırmada kritik bir rol oynamaktadır. Selvalakshmi vd., (2024) yaptıkları çalışmaya

göre, veri temizleme ve yapılandırma adımları, bulanık mantık sistemlerinin belirsizlikleri daha hassas bir şekilde yönetmesini sağlamış ve tahmin doğruluğunu artırmıştır. Özellikle eksik verilerin tamamlanması ve tutarsızlıkların giderilmesi, bulanık kuralların oluşturulmasında ve plansız duruş sürelerinin azaltılmasında önemli bir katkı sağlamıştır. Çalışmanın bulguları, veri ön işlemenin kestirimci bakım stratejilerinin başarısında temel bir unsur olduğunu ortaya koymaktadır.

İlk analizlerde, arıza kayıtları incelenmiş ve en çok tekrar eden arıza türü olan "Hidrolik Silindir Arızası"nın (HSA) öne çıktığı görülmüştür. Bu nedenle, HSA'nın tahminine odaklanan bir model geliştirilmiştir. Veri setinin özeti incelendiğinde, bazı değişkenlerin eksik veri içerdiği veya "0" standart sapmaya sahip olduğu tespit edilmiştir. Bu tür değişkenler, analitik açıdan katkı sağlamayacağı için veri setinden çıkarılmıştır. Ayrıca, bazı değişkenlerin "setup" amaçlı atandığı gözlemlenmiş olup, bu tür referans değişkenlerinin de analiz dışı bırakılması mantıklı görülmektedir. Bu ön eleme işlemi, veri setindeki gürültüyü azaltarak analizlerin doğruluğunu artırmayı hedeflemektedir.

Özet istatistikler, veri setinde yer alan değişkenlerin dağılımı hakkında kritik bilgiler sunmaktadır. Bu istatistikler, her bir değişkenin merkezi eğilim ve dağılım ölçütlerini ortaya koyarak, veri setindeki olası anormallikleri veya dikkat edilmesi gereken özellikleri açığa çıkarır. Örneğin, bazı değişkenlerin hiç veri içermemesi veya varyans göstermemesi, bu değişkenlerin veri analizinde fayda sağlayamayacağını gösterir. Bu tür değişkenlerin çıkarılması, analiz sürecinin etkinliğini artırır ve modele gereksiz yük bindirilmesini engeller. Bu adım, verinin daha sağlıklı bir yapıya kavuşmasını sağlayarak analizlerin doğruluğunu artırmada önemli bir role sahiptir.

Endüstriyel sistemlerde kestirimci bakım uygulamalarının etkinliğini artırmak amacıyla kullanılan makine öğrenmesi tabanlı modeller, veri kalitesine doğrudan bağlıdır. Bu bağlamda, kullanılan veri setinin kaynağı, toplanma süreci, ön işleme adımları ve analiz yöntemleri, modelin doğruluk ve güvenilirlik seviyesini belirleyen en önemli faktörler arasındadır.

Bu çalışmada kullanılan veri seti, Diesse alçak basınçlı döküm tezgâhına entegre edilmiş SMC marka transmitter sensörlerden ve Elimko K tipi termokupldan elde edilen çok boyutlu ölçümleri içermektedir. Sensörler aracılığıyla toplanan veriler, makine öğrenmesi algoritmaları için uygun hale getirilmeden önce çeşitli ön işleme aşamalarından geçirilmiştir.

Veri seti, ilgili ekipmanın farklı operasyonel koşullar altında çalıştırılmasıyla oluşturulmuş olup, aşağıdaki bileşenlerden gelen sensör ölçümlerini kapsamaktadır:

- Sıcaklık Sensörleri (Elimko K tipi termokupl ve Kalıp Termokupl): Döküm sürecindeki sıcaklık değişimlerini ölçerek termal anomalilerin belirlenmesini sağlar.
- Basınç Sensörleri (SMC marka transmitter sensörler): Hidrolik ve mekanik sistemlerdeki basınç değişimlerini izleyerek olası arızaların erken tespit edilmesine katkıda bulunur.
- Akışkan Hızı Sensörleri: Hidrolik sistemlerdeki akış hızını takip ederek, hidrolik silindir arızalarının tahmin edilmesine yardımcı olur.

Toplanan sensör verileri, makine öğrenmesi modellerinin eğitimi öncesinde aşağıdaki ön işleme adımlarından geçirilmiştir:

➤ **Ölçek Dönüştürme ve Birleştirme:**

Farklı sensörlerden elde edilen veriler, zaman damgasına dayalı olarak senkronize edilerek birleşik bir veri kümesine dönüştürülmüştür.

Sensörlerin farklı ölçüm ölçeklerine sahip olması nedeniyle, modelin daha iyi genelleme yapabilmesi için Min-Max ölçeklendirme yöntemi kullanılarak tüm değişkenler aynı ölçek aralığına getirilmiştir.

➤ **Aykırı Değer Analizi ve Temizleme:**

Sensör verileri, Quantiller Arası Açıklık (Interquartile Range - IQR) yöntemi ile analiz edilerek aşırı uç değerler belirlenmiştir.

Aykırı değerlerin modelin doğruluğunu olumsuz etkilemesini önlemek amacıyla, bu değerler Winsorization yöntemi ile sınırlandırılmış veya belirli eşik değerlerinin dışına çıkan gözlemler kaldırılmıştır.

➤ **Eksik Veri Tamamlama:**

Sensör arızalarından veya veri iletim hatalarından kaynaklanan eksik değerlerin bulunduğu gözlemler, Lineer enterpolasyon yöntemiyle tamamlanmıştır.

Eksik değer oranının yüksek olduğu gözlemler, analiz sürecinin güvenilirliğini artırmak adına veri setinden çıkarılmıştır.

➤ **Zaman Serisi Temizleme ve Gürültü Giderme:**

Sensörlerden gelen ham veriler, ölçüm hataları ve dış ortam koşullarından kaynaklanan ani dalgalanmalar içerebilir. Bu nedenle, Hareketli Ortalama Filtresi (Moving Average Filter) uygulanarak anlık dalgalanmalar yumuşatılmış ve daha güvenilir veri seti elde edilmiştir.

➤ **Özellik Mühendisliği (Feature Engineering):**


Modelin kestirimci gücünü artırmak için, sensörlerden elde edilen ham değişkenlerin yanı sıra, türev (first derivative) ve hareketli ortalama değişkenleri gibi türetilmiş özellikler oluşturulmuştur. Zaman serisi yapısını korumak amacıyla önceki zaman dilimlerine ait verileri içeren kaydırılmış değişkenler (lag features) eklenmiştir.

Tablo 5: Model Değişkenleri ve Açıklamaları

Değişken Adı	Açıklama
Sıcaklık Değişimi (°C)	Termokupl verileri kullanılarak hesaplanan sıcaklık değişimi
Basınç Değişimi (bar)	Hidrolik basınç sensörlerinden elde edilen değerler
Akışkan Hızı (m/s)	Akış sensörlerinden elde edilen hız bilgisi
Arıza Etiketleri	Arızanın gerçekleştiği zaman diliminde 1, aksi halde 0 olarak işaretlenmiş sınıflandırma değişkeni
Geçmiş Değerler (Lag 1-5)	Önceki 5 zaman dilimine ait sıcaklık, basınç ve akışkan hızı değerleri

Kaynak: Araştırmacı tarafından hazırlanmıştır

Şekil 12: Veri Setinin Toplanma Süreci



Kaynak: Araştırmacı tarafından hazırlanmıştır

Yukarıdaki görsel, bir endüstriyel sistemde sıcaklık verilerinin bir termokupl sensör aracılığıyla toplanması ve SQL veri tabanına aktarılması sürecini göstermektedir. Termokupl, belirli bir sıcaklık aralığında (0-100 °C) veri toplar ve bu sinyali 4-20 mA akım sinyaline dönüştürür. Bu sinyal daha sonra PLC'ye (Programmable Logic Controller - Programlanabilir Lojik Kontrolör) iletilir ve burada PLC, veriyi kendi aralığına (0-27648) göre ölçeklendirir. Görseldeki sistem mimarisi ile ilgili firma yetkilileri ile yapılan görüşmede aşağıdaki bilgiler alınmıştır ve şu şekilde özetlenebilir:

1. **Sensör Aşaması:** Sıcaklık ölçümleri, termokupl aracılığıyla doğrudan yapılır. Termokupl, topladığı sıcaklık verisini 4-20 mA akım sinyaline çevirir. Bu sinyal,

endüstriyel tesislerde yaygın olarak kullanılır ve sıcaklık değerlerinin doğru şekilde PLC'ye iletilmesini sağlar.

2. **PLC (Programlanabilir Lojik Kontrolör):** Termokupldan gelen 4-20 mA sinyali alır ve sıcaklık verilerini dijital bir forma dönüştürür. Bu veriler, PLC'nin kendi iç aralığı olan 0-27648 değer aralığında ölçeklendirilir. PLC, verilerin doğru bir şekilde iletilmesini sağlamak için fabrika hattı internetine bağlıdır.
3. **Veri Toplama ve İletim Aşaması:** PLC tarafından toplanan dijital veriler, fabrika hattı interneti aracılığıyla Kepware yazılımına iletilir. Kepware, endüstriyel otomasyon sistemlerinde veri toplama ve yönetme amacıyla kullanılan bir yazılımdır. Bu yazılım, PLC'den gelen verileri alır ve onları SQL veritabanı sunucusuna aktarmaya hazır hale getirir.
4. **SQL Veritabanı Sunucusu:** Kepware tarafından alınan veriler, fabrika hattı interneti üzerinden SQL Server'a aktarılır. SQL Server, bu verileri depolar ve daha ileri analizler veya raporlamalar için erişilebilir hale getirir.

Bu sistem endüstriyel kestirimci bakım uygulamaları için veri toplama amacıyla kullanılmaktadır. Termokupl sensör ile başlatılan veri toplama süreci, PLC ve Kepware aracılığıyla SQL veri tabanına kadar izlenebilir bir yol sunmaktadır. Bu yapı, endüstriyel süreçlerdeki sıcaklık değişimlerinin sürekli izlenmesini sağlar ve kestirimci bakım stratejileri için gereklidir.

Arıza tahmini yapılan makine yapısı itibariyle birçok sensör ihtiva etmektedir. Bu sensörler çeşitli sıcaklık, akım, direnç, güç, basınç gibi verileri anlık (saniyelik bazda) ölçmektedir. Makine bu sensörlerden verileri kendisi toplamaktadır. Toplamış olduğu bu verileri kendi bünyesinde depolamaktadır. Ancak bu verilerin daha iyi analiz edilebilir bir duruma getirilmesi için üçüncü parti bir yazılım çözümüne ihtiyaç duyulmaktadır. Bu yazılım aracılığı ile verileri makinadan "SQL Server" veri tabanına aktarılmaktadır. Makinadan iki tür veri toplanmaktadır. İlk olarak her saniyede bir gelen sensör değerleri, ikincisi de manuel olarak makine ekranı üzerinden (HMI) arıza oluşumları ve bunlara ait açıklamaları içeren (makine no, kalıp no, arıza tipi, başlangıç zamanı, bitiş zamanı vb.) veriler şeklindedir. Tezde ayrı ayrı toplanan veriler ilgili tarih-zaman dilimi gözetilerek birleştirilmiştir. İşletmenin kendi politikası üzerinden yürüdüğü için orada doğal olarak mevcut setup üzerinden ilerlenmiştir. Yani işletmenin topladığı -makina yapısı gereği oldukça kapsamlı bir veri toplanmaktadır- veriler çalışmada temel alınmıştır. Bu veri seti üzerinden ön işleme ve analizler yapılarak çalışmaya

temel oluşturacak olan veri setine ulaşılmıştır. Bu aşamada çeşitli istatistiksel yöntemler kullanılmıştır.

İşletmeden alınan veriler sensör ve arıza oluşum kayıtları şeklinde iki dosyadan oluşmaktadır. Sensörlerden gelen veriler her saniyede bir alınmıştır. İlk olarak arıza kayıtları veri dosyası incelenmiş, en fazla arıza tekrarının dokuz defa tekrar etmiş olan “Hidrolik Silindir Arızası” olduğu görülmüştür. Dolayısıyla bu arıza kodunu tahmin edecek olan modelin oluşturulmasına karar verilmiştir. Aşağıda işlenmemiş ham verinin özet istatistikleri yer almaktadır.

Tablo 6: Ham Verinin Özet İstatistikleri

	count	mean	min	25%	50%	75%	max	std
Rec_Time	4767068	2024-07-23 09:39:05.05199744	2024-06-25 13:55:45.377000	2024-07-09 10:37:02.801499904	2024-07-23 09:30:56.452000	2024-08-06 06:31:35.954000128	2024-08-20 13:29:59.413000	NaN
2MCT_ID	4767068.0	2134.0	2134.0	2134.0	2134.0	2134.0	2134.0	0.0
MTC_PID_ActuelValue	4767068.0	692.022.945	3.276.800.049	693.400.024	694.799.988	697.400.024	3.276.699.951	60.096.059
MTC_PID_SetPoint	4767068.0	696.475.206	680.0	695.0	695.0	700.0	720.0	2.493.636
Faz_1_Akim	4767068.0	55.074.282	0.0	52.0	70.0	73.0	85.0	27.485.444
Faz_1_Direnc	4767068.0	2.884.754	0.0	2.606.988	2.768.981	2.897	79.067.635	2.945.351
Faz_2_Akim	4767068.0	55.086.805	0.0	52.0	70.0	73.0	91.0	27.505.954
Faz_2_Direnc	4767068.0	2.827.063	0.0	2.567.531	2.737.259	2.852.387	78.829.597	286.864
Faz_3_Akim	4767068.0	55.074.284	0.0	52.0	70.0	73.0	85.0	27.485.443
Faz_3_Direnc	4767068.0	2.935.078	0.0	2.620.341	2.769.958	2.914.416	78.557.419	303.965
Toplam_Guc_KW	4767068.0	31.961.849	-0.016044	21.683.865	40.408.737	43.769.005	52.444.778	17.434.044
CevreRezistant_Akim	4767068.0	0.042629	0.0	0.043403	0.043403	0.043403	6.134.259	0.051372
GobekRezistant_Akim	4767068.0	3.527.433	0.028935	0.043403	5.801.505	6.032.986	6.741.899	2.929.461
MainWater_Pressure	4767068.0	3.296.668	-0.402199	3.370.949	349.537	3.608.217	11.212.385	1.001.491
OcakIciHava_Sicaklik	4767068.0	44.587.944	38.017.494	42.682.217	44.594.753	46.413.994	95.530.609	2.514.182
SogutmaHava_Sicaklik	4767068.0	37.202.606	3.119.553	35.508.381	37.005.585	3.877.095	91.527.931	2.350.867
SET_TC1	4767068.0	43.985.122	340.0	420.0	435.0	470.0	635.0	27.769.077
ACTUAL_TC1	4767068.0	127.516.249	-9999.0	281.0	401.0	435.0	997.0	1.537.841.212
OcakIciHavaSicakligi_TC7	4767068.0	63.650.689	3.276.800.049	58.200.001	61.900.002	65.400.002	3.276.699.951	88.734.819
ENVIROMENT_HUMIDITY	0.0	NaN	NaN	NaN	NaN	NaN	NaN	NaN
ENVIROMENT_TEMPERATURE	0.0	NaN	NaN	NaN	NaN	NaN	NaN	NaN
EsenjorSicaklik_Act	4767068.0	-11.829.248	-11.829.248	-11.829.248	-11.829.248	-11.829.248	-11.829.248	0.0
EsenjorSicaklik_Set	4767068.0	27.0	27.0	27.0	27.0	27.0	27.0	0.0

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Yukarıdaki görselden de görüleceği üzere bazı değişkenler hiç veri içermemekte, bazıları da “0” standart sapmaya sahip niteliktedir. Bazı değişkenlerin de “setup” (veri setlerinde genellikle sistemin başlangıç ayarlarını veya referans değerlerini temsil eden ve analitik süreçlere doğrudan katkı sağlamayan değişkenleri ifade eder. Bu tür değişkenler, veri setinin gereksiz yükünü azaltmak amacıyla genellikle analizlerden çıkarılır.) yani ayar amaçlı atanan referans değişkenler olduğu isimlerinden anlaşılmaktadır. Kane vd., (2022) çalışmasında da vurgulandığı üzere, sensörlerden toplanan ham verilerin temizlenmesi ve işlenmesi, kestirimci bakımın etkin bir şekilde uygulanması için temel bir adımdır. Bu nedenlerden ötürü ilgili değişkenler veri setinden çıkarılmıştır. Kestirimci bakım süreçlerinde veri temizleme, sistem performansını artırmada ve makine öğrenimi modellerinin doğruluğunu yükseltmede kritik bir öneme sahiptir.

Üzerinde çalışılacak olan veri seti bu aşamada 60 saniyelik ortalamalar şeklinde yeniden düzenlenmiştir. Diğer bir deyişle saniye düzeyinden dakika düzeyine getirilmiştir. Daha sonra arıza tablosu ile sensör verileri ilgili zaman damgaları eşleşecek şekilde birleştirilmiştir. Sonrasında ise “Hidrolik Silindir Arızasına” ait olan zamanlar tabloda işaretlenmiştir (arıza olan zamanlar 1 diğer durumlar 0 olarak işaretlenmiş, bu değerleri gösteren kolona da “IS_HSA” adı verilmiştir).

3.4.2. Veri Ön İşleme

Veri ön işleme aşaması, ham verinin kalite sorunlarını çözerek analiz için uygun hale getirilmesini sağlayan kritik bir adımdır. Bu süreçte, normal dağılımdan sapmalar ve dışlanan değerler (outlier) incelenmiştir. Dağılımdaki çarpıklıklar ve anormallikler, özellikle kestirimci bakım modellerinin doğruluğunu etkileyebileceğinden, bu tür veri hatalarının düzeltilmesi önemlidir. Veri setinin detaylı analizinde görüldüğü üzere, bazı değişkenlerde belirgin sapmalar ve aykırı değerler tespit edilmiştir. Özellikle, iç ve dış sıcaklık değişkenleri haricindeki değişkenlerde dağılım bozuklukları belirgin bir şekilde kendini göstermektedir.

Sensörlerden elde edilen ham verilerin temizlenmesi ve işlenmesi, kestirimci bakım uygulamalarının başarıya ulaşmasında kritik bir role sahiptir. Ham veriler genellikle eksik, tutarsız veya gürültülü olabileceğinden, bu verilerin analiz ve modelleme süreçlerine uygun hale getirilmesi gereklidir. Kane vd., (2022) çalışmasında da vurgulandığı gibi veri temizleme işlemi, gereksiz veya analitik açıdan katkı sağlamayan değişkenlerin veri setinden çıkarılması ve anlamlı değişkenlerin öne çıkarılmasıyla, sistem performansını optimize etme potansiyeline sahiptir. Bu süreç, makine öğrenimi modellerinin doğruluğunu artırmakla kalmaz, aynı


zamanda sistemin arıza tahmini ve kaynak yönetimi süreçlerinde daha etkin bir yaklaşım sunar. Kestirimci bakım stratejilerinde, özellikle sensör verilerinin işlenmesi ve hatalı verilerin elimine edilmesi, operasyonel verimlilik ve doğruluk açısından temel bir gereklilik olarak karşımıza çıkmaktadır.

Bu doğrultuda, aykırı değerleri düzeltmek için "Quantiller Arası Açıklık" (IQR) yöntemi tercih edilmiştir. IQR yöntemi, veri setinin %25'lik dilimi (Q1) ile %75'lik dilimi (Q3) arasındaki farkın hesaplanması ve bu değerın 1,5 katının Q1'den çıkarılması veya Q3'e eklenmesiyle alt ve üst sınırların belirlenmesini içerir. Bu sınırların dışında kalan değerler, aykırı olarak değerlendirilip bu sınırlara taşınmaktadır. Bu işlem, gözlem kaybı yaşanmadan veri setinin daha güvenilir ve analiz edilebilir hale gelmesini sağlar.

Düzeltilme öncesi grafikler, veri setinde ciddi dağılım bozuklukları ve ekstrem değerlerin varlığını göstermektedir. Bu tür anomaliler, modelin doğruluk oranını düşürebileceğinden, aykırı değerlerin kontrol edilmesi ve düzeltilmesi gereklidir. Düzeltilme sonrası grafiklerde ise dağılımlarda belirli bir iyileşme gözlenmiştir; ancak bazı değişkenlerde hala yüksek seviyede varyasyon olduğu fark edilmiştir. Bu tür değişkenlerin kategorik hale getirilmesi, modelde daha etkin bir şekilde kullanılmalarını sağlayabilir. Bu amaçla, belirli akım ve direnç değişkenleri kategorik gruplar halinde yeniden sınıflandırılmıştır. Örneğin, "CevreRezistant_Akim" ve "GobekRezistant_Akim" değişkenleri, belli eşik değerler üzerinden iki veya üç kategoriye ayrılmıştır. Bu adım, modelin performansını artırmak için dağılımda beklenen düzeltilmenin sağlanamaması durumunda tercih edilen önemli bir stratejidir. Bu veri ön işleme aşamaları, veri setini daha güvenilir bir hale getirerek model eğitiminde daha sağlıklı sonuçlar elde edilmesini sağlayacaktır.


Bu aşamada oluşturulan veri setinde yer alan değişkenlerin dağılımları incelenmiştir. Normal dağılımdan sapmalar, dışlanan değerler (outlier analizi) açısından veri seti ele alınmış ve dağılım çarpıklıkları ve dışlanan/aykırı değerler için bazı işlemler gerçekleştirilmiştir. Düzeltilme öncesi durum Şekil 14'de yer alan grafiklerde gösterilmiştir:

Şekil 13: Aykırı Değerlerin Dağılımı (Düzeltilme Öncesi)



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 14: Veri Setindeki Aykırı Değerlerin Kutu Grafikleri ile Gösterimi



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Yukarıdaki grafiklerden de görüleceği üzere veri seti dağılımlar ve (ocak içi hava sıcaklık ve soğutma hava sıcaklık dışında) aykırı değer açısından problemler içermektedir. Bu aşamada ilk olarak “Quantiller Arası Açıklık” metodu ile aykırı değerler için veri setinde bazı düzeltmeler yapılmıştır. Metodun uygulanışı kısaca şu şekildedir:

- Her bir değişken için birinci quantile ($Q1=0.25$) ve üçüncü quantile ($Q3=0.75$) değerleri hesaplanır.
- $Q3-Q1$ farkının hesaplanır (IQR), alt ve üst limitler için açıklık değerinin “1.5” katı quantile değerlerinden çıkarılır/eklenir.
- Alt Limit = $Q1 - 1,5 \cdot IQR$, Üst Limit = $Q3 + 1,5 \cdot IQR$
- Son olarak ilgili değişken için alt limitin altında olan değerlere alt limit, üst limitin üstünde olan değerlere de üst limit atanacak şekilde düzeltilir. Bu şekilde gözlem sayısında bir eksilme de olmamış olur.


Düzeltilme sonrası duruma ait grafikler:

Düzeltilme sonrası grafikler, veri ön işleme sürecinde yapılan iyileştirmelerin etkisini görselleştirmektedir. Bu grafiklerde, özellikle aykırı değerlerin IQR yöntemi ile sınırlara çekilmesi sonrası dağılımlarda gözle görülür bir düzelme olduğu gözlenmiştir. IQR yöntemiyle verinin Q1 ve Q3 aralığında tanımlanan sınırların dışındaki ekstrem değerler yeniden düzenlenmiş, böylece analiz sürecinde yanlış sınıflandırma veya tahmin sapmalarına neden olabilecek veri noktaları ayıklanmıştır.

Düzeltilme sonrası grafiklerde bazı değişkenlerde belirgin bir çarpıklık ve asimetri devam etse de, genel dağılımda dengelenme gözlenmektedir. Özellikle, kategorik hale getirilmesi uygun görülen değişkenlerde bu yöntem veri kalitesini artırmak için etkili bir adım olmuştur. Örneğin, “CevreRezistant_Akim” ve “GobekRezistant_Akim” gibi değişkenler, dağılımlarında tam bir normalleşme sağlanamamasına rağmen kategorik gruplara ayrılarak modellenebilirlik açısından daha kullanışlı hale getirilmiştir. Bu adım, dağılımda doğal olmayan çarpıklıkları düzeltmenin bir yolu olarak, özellikle sınıflandırma algoritmalarının doğruluğunu artırmak için uygulanmıştır.


Veri ön işleme sürecinde gerçekleştirilen bu düzeltmeler, veri setinin daha dengeli ve modellemeye uygun bir yapıya kavuşmasını sağlamıştır. Bu süreçte kategorik dönüşümlerin yapılması, hem modelin öğrenme sürecini hızlandıracak hem de doğruluk oranlarını artıracaktır. İlerleyen aşamada, veri setinin model eğitiminde kullanılacak eğitim ve test gruplarına ayrılması ile analiz süreci devam ettirilmiştir.

Şekil 15: Aykırı Değerlerin Dağılımı (Düzeltilme Sonrası)



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 16: Veri Setindeki Aykırı Değerlerin Kutu Grafikleri ile Gösterimi



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Yukarıdaki grafikler ışığında bazı değişkenlerin kategorik hale getirilmesinin uygun olacağına karar verilmiştir. Bunun nedeni de dağılımın şeklinde (aykırı değerler büyük ölçüde temizlenmiş olsa da) önemli bir değişim gözlenmemiş olmasıdır. Bu değişkenler “CevreRezistant_Akim”, “GobekRezistant_Akim”, “Faz_1_Akim”, “Faz_2_Akim”, “Faz_3_Akim” şeklindedir. İlk değişken için “ $I < 1$ ve “ $I \geq 1$ ”, ikinci değişken “ $I < 6$ ve $I \geq 6$ ” diğer değişkenler ise “ $I < 20$, $20 \leq I < 60$ ve $I \geq 60$ ” şeklinde kategorik olarak yeniden oluşturulmuştur.

3.4.3. Eğitim ve Validasyon Verisinin Ayrılması

Veri setinin eğitim ve validasyon olarak ayrılması, makine öğrenimi sürecinde modelin performansını objektif bir şekilde değerlendirmek için kritik bir adımdır. Eğitim ve validasyon verisinin ayrılması, makine öğrenimi modellerinin doğruluğunu ve genelleme kabiliyetini

arttırmada kritik bir adımdır. Rezvanizani vd., (2014) çalışmasında, bu ayrımın önemi açıkça vurgulanmıştır. Çalışmada, ilk iki yılın verisi eğitim verisi olarak kullanılırken, üçüncü yılın verisi test verisi olarak değerlendirilmiş ve bu süreç, yüksek riskli zaman dilimlerini tahmin etmek amacıyla modellenmiştir. Eğitim verisi, sistemin geçmiş bakım kayıtlarından elde edilen desenleri öğrenmesine olanak tanırken, test verisi bu bilgilerin doğruluğunu ve genelleme kapasitesini değerlendirmede kullanılmıştır. Bu yöntem, hem geçmiş verilerden anlamlı sonuçlar çıkarmak hem de gelecekteki bakım ihtiyaçlarını tahmin etmek için etkili bir çerçeve sunmaktadır. Bu yöntem, modelin gelecekteki tahminlerde ne kadar başarılı olacağını anlamak için sağlam bir değerlendirme sağlamaktadır.

Eğitim sürecine uygun değişkenlerin belirlenmesi amacıyla korelasyon analizi gerçekleştirilmiştir. Bu analiz, arıza için kalan süre ("RemainingFailTime") ile korelasyon katsayısı %5'in üzerinde olan değişkenlerin seçilmesini sağlamış ve böylece yalnızca hedefle ilişkili olan değişkenler eğitimde kullanılmıştır. Bu adım, eğitim sürecinde gürültü oluşturan gereksiz değişkenlerin etkisini azaltmak için önemli bir veri ön işleme tekniği olarak öne çıkmaktadır.

Hedef değişken, arıza için kalan sürenin 360 saatten az veya çok olma durumuna göre sınıflandırılmıştır. Züfle vd., (2021) belirttiği gibi, kestirimci bakım modellerinde zaman pencerelerine dayalı hedef sınıflandırma, bakım etkinliğini artırmak için etkili bir yöntemdir. 360 saatlik eşik süresi, bu yaklaşımın dengeli bir örneği olarak kullanılmaktadır. Bu sınıflandırma, kestirimci bakım modelinde, arıza gerçekleşme süresini tahmin etmek amacıyla bir sınıflandırma problemine dönüştürülmüştür. Bu yaklaşım, modelin belirli bir zaman aralığında bakım gereksinimini öngörmesini sağlayarak işletmelerin arıza risklerini minimize etmelerine olanak tanır.

Model eğitiminde iki farklı veri oranı senaryosu uygulanmıştır: %70 eğitim - %30 test ve %75 eğitim - %25 test. Bu senaryolar, modelin farklı veri dağılımları üzerindeki performansını değerlendirmek amacıyla planlanmıştır. Makine öğrenimi modellerinde, eğitim ve test veri setlerinin uygun şekilde ayrılması, modelin genelleme yeteneğini ve performansını doğru bir biçimde ölçmek açısından kritik bir öneme sahiptir.

Eğitim veri seti, modelin öğrenme sürecinde parametrelerinin belirlenmesi ve optimizasyonunun sağlanması için kullanılırken, test veri seti, modelin daha önce görmediği veriler üzerinde nasıl bir performans sergilediğini nesnel bir şekilde değerlendirmek için kullanılmaktadır. Bu bağlamda, %70 eğitim - %30 test ve %75 eğitim - %25 test oranları, literatürde yaygın olarak önerilen ve uygulamada geniş kabul gören veri bölme stratejileri

arasındadır. Goodfellow ve arkadaşları (2016), bu oranların hem modelin öğrenme kapasitesini desteklemek hem de test veri seti üzerinde genelleme yeteneğini güvenilir bir biçimde ölçmek için uygun bir denge sunduğunu belirtmektedir.

Özellikle %70 eğitim - %30 test oranı, modelin eğitimi için yeterli miktarda veri sunarken, test veri setinin istatistiksel olarak anlamlı bir değerlendirme yapmaya olanak tanıyacak büyüklükte olmasını sağlamaktadır. Eğitim sürecinde model yalnızca eğitim verisi ile öğrenme gerçekleştirir ve test verisini görmez. Bu nedenle, test veri seti üzerinde hesaplanan hata oranı, modelin genelleme yeteneğini değerlendirmek için temel bir ölçüt olarak kabul edilmektedir.


Eğitim sürecinde farklı modelleme teknikleri (Logistic Regression, Linear Discriminant Analysis, KNN, SVM ve MLP) kullanılmış ve Python'un PyCaret kütüphanesi ile bu modellerin performansları optimize edilmiştir.

Korelasyon grafikleri, eğitim için seçilen değişkenlerin hedef değişkenle olan ilişkisini görselleştirir ve her bir değişkenin modeldeki rolünü belirlemeye yardımcı olur. Bu grafiklerden elde edilen bilgiler, modelin tahmin doğruluğunu artırmak için hangi değişkenlerin daha fazla bilgi sağladığını göstermekte ve model performansının daha etkin bir şekilde analiz edilmesine olanak tanımaktadır.

Bu eğitim ve validasyon bölümü, modelin güvenilirliğini ve genelleme kapasitesini artırmaya yönelik bir strateji olarak dikkat çeker. İlerleyen analiz aşamalarında, her bir modelin tahmin doğruluğu, sınıflandırma performansı ve hata oranları detaylandırılarak, en uygun modelin seçimi sağlanacaktır.

Veri setinin yeni durumunda “Hidrolik Silindir Arızası” için beş arıza anı söz konusudur. Bunlarda ilk dördü eğitim ve test için son arıza anına ait olan kısmı da validasyon için ayrılmıştır.


Şekil 17: Korelasyonlara Ait Grafik



Kaynak: Python Analiz Çalışmalarından Alınmıştır


Arıza için kalan süre ile (RemainingFailTime) korelasyon katsayısı %5'ten büyük olan değişkenler eğitim ve test için kullanılacak şekilde seçilmiştir. Değişkenler ve dağılımları aşağıdaki gibidir:

Şekil 18: Kategorik Hale Getirilmiş Değişkenlerin Dağılımları



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 19: Veri Setindeki Parametrelerin Çiftli Dağılım Grafikleri



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Hedef değişken olarak arıza için kalan sürenin 360 saatin altında ve üstünde olacak şekilde bir sınıf değişkeni oluşturulmuştur. Model bir sınıflandırma problemi olarak ele alınmış ve bu sürenin altında olup olmama durumunun tahmin edilmesi amaçlanmıştır.

Model eğitim sürecinde, %75-25 eğitim ve test oranı kullanılmıştır.

Model eğitim sürecinde Python programlama dili “pycaret” kütüphanesinden yararlanılmıştır. Eğitim için kullanılan modeller sırasıyla:

- Logistic Regression
- Linear Discriminant Analysis
- KNN
- SVM
- MLP (Multilayer Perceptron)

Tüm modeller için eğitim sonrası Hiperparametre optimizasyonu gerçekleştirilmiştir. Son olarak validasyon için tahminler gerçekleştirilmiştir.

3.5. Analiz Değerlendirmeleri

Bu çalışmada, endüstriyel bir işletmeden elde edilen sensör ve arıza kayıtları kullanarak, makine öğrenimi destekli kestirimci bakım modeli geliştirme sürecine odaklanılmıştır. Çalışma, veri setinin yapısı, ön işleme işlemleri ve farklı makine öğrenimi algoritmaları ile modellenmesini kapsamaktadır. Analiz süreci, bakım stratejilerinin optimize edilmesi ve işletmelerin operasyonel verimliliklerinin artırılması amacıyla planlanmıştır. Üç aylık veri seti, saniyelik verilerden dakika seviyesine indirgenerek yeniden düzenlenmiş ve hidrolik silindir arızasının belirlenmesi hedeflenmiştir.

Kestirimci bakım modelinin **tahmin süresi**, modelin arıza gerçekleşmeden ne kadar önce uyarı verdiğini ifade eder. Endüstride bakım planlaması için yeterli bir önden bildirim süresi kritik önemdedir. Bakım ekiplerinin arızaya proaktif müdahale edebilmesi için **yedek parça temini, iş gücü ayarlanması ve üretim programının yeniden düzenlenmesi** gibi işlemlere zaman tanınmalıdır. Örneğin, bakım anlaşmaları ve lojistik süreçler göz önüne alındığında arızaya ait uyarıların birkaç gün ila birkaç hafta öncesinden alınması tercih edilir. Bu sayede ekipman duruşları planlı bir şekilde yapılarak beklenmeyen kesintiler önlenabilir

Akademik çalışmalarda da kestirimci bakım modellerinin **öngörü süresinin** belirlenmesinde, endüstriyel gereklilikler dikkate alınır. Modelin, arıza gerçekleşmeden **15 gün öncesine (360 saat)** kadar uyarı verecek şekilde tasarlanması, bu gerekliliklerin bir sonucudur. Seçilen **360 saatlik tahmin ufku**, hem akademik hem de endüstriyel açıdan dengeli bir örnek teşkil etmektedir.

Akademik olarak, bu süre pozitif ve negatif sınıfların dengesini makul düzeyde tutarak modelin öğrenmesini kolaylaştırır ve literatürde yaygın bir uygulamadır. Endüstriyel olarak ise 360 saat (yaklaşık 2 hafta), çoğu işletmede bakım planının devreye alınması için yeterli bir

süredir. Örneğin, ağır sanayide ekipman bakımı genellikle birkaç haftada bir planlanabildiğinden, modelin 2 hafta önceden uyarı verebilmesi bakım süreçlerine uyumludur. Daha kısa bir tahmin süresi (örneğin sadece birkaç saat öncesi) bakım ekibine yeterli hazırlık zamanı tanımayabilir; çok uzun bir süre (örneğin birkaç ay) ise belirsizliği artırarak gereksiz bakım veya yanlış alarm riskini yükseltir. Bu nedenle, modelin tahmin süresinin belirlenmesinde **uygulamanın bakım döngüleri, yedek parça tedarik süreleri ve operasyonel gereklilikleri** göz önüne alınmış; 360 saatlik öngörü ufku, hem teorik olarak anlamlı hem de pratikte uygulanabilir bulunmuştur.

Modelin arıza tahminini ne kadar önceden yapabildiği, doğruluk performansını doğrudan etkiler. **Tahmin penceresi daraldıkça** (yani arıza öncesindeki kısa süreleri hedefledikçe), modelin anomali sinyallerini yakalaması kolaylaşır; çünkü arıza yaklaşırken sensör verilerindeki sapmalar daha belirgin hale gelir. Buna karşılık, **tahmin penceresi genişledikçe** (arızadan çok daha erken uyarı vermeye çalışıldığında) belirsizlik artar ve modelin doğruluğu düşme eğilimi gösterir. Nitekim literatürde de “tahmin ufku arttıkça modelin tahmin doğruluğunun azaldığı” sıkça vurgulanmıştır.

Bu çalışmadaki modelin farklı zaman eşiklerine göre başarısı incelendiğinde, benzer bir trend gözlemlenmiştir. Daha dar bir zaman aralığı içinde gerçekleşecek arızaları tahmin etmek, modele daha belirgin örüntüler sağladığı için yüksek hassasiyetle (precision) mümkün olmuştur; ancak bu durumda model sadece çok yakın gelecekteki arızaları yakaladığından bazı arızaları erken aşamada kaçırabilir (düşük duyarlılık). Öte yandan, daha geniş bir zaman aralığını (örneğin 15 gün) hedefleyen tahminlerde model, yaklaşan tüm arızaları belli ölçüde tespit edebilmekte (duyarlılık artar), fakat arıza henüz uzak ise normal çalışma ile arıza öncülü durumları ayırt etmek zorlaşacağı için yanlış alarm oranı yükselerek kesinlik düşmektedir. Bu **hassasiyet-duyarlılık dengesi**, seçilen tahmin ufkuna bağlı olarak değişir.

Bunun yanı sıra, farklı sektörlerde farklı zaman eşiklerinin kullanıldığı da literatürde görülür. Örneğin havacılık sektöründe prognostik modeller genellikle **uçuş döngüleri** veya **iniş sayıları** gibi metriklerle ölçeklendirilirken, enerji sektöründe **aylık** veya **mevsimsel** bakım periyotlarına uygun öngörü ufukları kullanılabilir. Ancak tüm bu farklı senaryolarda ortak amaç, **arıza öncesi yeterli uyarı süresi** sağlayarak bakımın kestirime dayalı optimize edilmesidir. Modelimizin zaman ölçeği seçimi de tam olarak bu amaca hizmet etmektedir.

Veri ön işleme aşamasında, eksik değerler, aykırı değerler ve dağılım bozuklukları incelenmiştir. Bu aşama, veri setinin genel sağlığı üzerinde önemli bir rol oynar, çünkü veri kalitesi makine öğrenimi modellerinin doğruluğunu doğrudan etkiler. Analizlerde, özellikle

değişkenlerin dağılımlarında önemli sapmalar ve aykırı değerler tespit edilmiştir. Bu bağlamda, IQR yöntemi kullanılarak aykırı değerler düzeltilmiş ve veri setinde gözlem kaybı yaşanmadan kaliteli bir veri yapısı elde edilmiştir. Aykırı değerlerden temizlenen bazı değişkenlerin dağılımlarında beklenen düzeltilmeler sağlanamasa da, kategorik hale getirilerek modelde etkili bir şekilde kullanılmaları sağlanmıştır.

Model eğitim sürecine geçildiğinde, hidrolik silindir arızasının tahmin edilebilirliğini artırmak amacıyla çeşitli makine öğrenimi algoritmaları (Logistic Regression, Linear Discriminant Analysis, KNN, SVM, MLP) uygulanmıştır. Her bir model, eğitim ve validasyon verileri üzerinde test edilerek başarı oranları değerlendirilmiş ve hiperparametre optimizasyonları ile iyileştirilmiştir. Özellikle MLP modeli, %74 gibi yüksek bir başarı oranı sunmuş olsa da, sınıfları dengeli bir şekilde ayıramadığı gözlemlenmiştir. KNN modeli ise %75'lik doğruluk oranı ile validasyon veri setinde görece daha iyi sonuçlar vermiştir, ancak sınıf dengesizlikleri burada da bir sorun olarak kendini göstermektedir.

Bu analizlerin sonuçları, makine öğrenimi modellerinin endüstriyel kestirimci bakım süreçlerinde kullanılabilirliğini ve performans optimizasyonunun önemini ortaya koymaktadır. Verilerin doğru ön işlenmesi ve model parametrelerinin optimize edilmesi, ekipman arızalarının öngörülmesinde ve operasyonel kesintilerin en aza indirilmesinde etkili çözümler sunabilir. Ancak, her bir modelin sınıfları dengeli bir şekilde ayırma yeteneği incelendiğinde, yalnızca doğruluk oranlarına odaklanmanın yeterli olmadığı; sınıflandırma başarısının da göz önüne alınmasının kritik olduğu anlaşılmaktadır. Bu doğrultuda, işletmelerde bakım süreçlerinin daha öngörülebilir ve güvenilir bir yapıya kavuşturulması için derinlemesine veri analizi ve gelişmiş optimizasyon tekniklerinin kullanımı gerekmektedir.

3.5.1. Logistic Regression

Lojistik regresyon, kestirimci bakım amacıyla makine öğrenimi modellerinde sıkça tercih edilen istatistiksel bir sınıflandırma tekniğidir. Shaala vd., (2024) çalışmasında, lojistik regresyon, bir olayın gerçekleşme olasılığını tahmin etmek için kullanılan bir istatistiksel yöntemdir. Bu yöntem, özellikle ikili sınıflandırma problemlerinde yaygın olarak uygulanır. Lojistik regresyon modelleri, bir bağımlı değişkenin (örneğin, "başarı" veya "başarısızlık") olasılığını tahmin etmek için bağımsız değişkenlerin doğrusal bir kombinasyonunu kullanır. Tahmin sürecinde lojistik fonksiyon (sigmoid fonksiyonu) devreye girerek, çıktı değerlerini 0 ile 1 arasında ölçeklendirir. Böylece, modelin bir gözlemin belirli bir sınıfa ait olma olasılığını tahmin etmesi sağlanır. Lojistik regresyon, hem bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi modellemek hem de sınıflandırma problemleri için etkili bir araç olarak

kullanılmaktadır. Bu model, belirli bir zaman diliminde arıza riskinin tahmin edilmesine olanak tanıyarak arıza öncesinde önleyici bakım yapılmasına yardımcı olur.

Lojistik regresyon modeli, hidrolik silindir arızasının kalan süresinin 360 saatin altında veya üstünde olma durumunu tahmin etmek için kullanılmıştır. Modelin test verisi üzerindeki doğruluk oranı %56.5 olarak hesaplanmıştır. Confusion Matrix incelendiğinde, modelin kesinliği (Precision) %59 ve duyarlılığı (Recall) %57 civarındadır. Bu durum, modelin sınıflar arasındaki ayrımı tahmin etme yeteneğinin belirli bir dengeye sahip olduğunu göstermektedir. Ancak, modelin doğrusal doğası gereği, doğrusal olmayan ilişkilerin bulunduğu veri setlerinde performansı sınırlı kalabilir.

İlk Eğitim:


Lojistik regresyonun başlangıç aşamasında yapılan eğitim süreci, modelin sınıflandırma doğruluğunu ortaya koymaktadır. Modelin dengeli bir performans gösterdiği, confusion matrix (karışıklık matrisi) analizinde gözlemlenmiştir. Ancak, başlangıç sonuçlarının ardından hiperparametre optimizasyonu yapılmış olmasına rağmen, optimizasyonun model doğruluğu üzerinde anlamlı bir iyileşme sağlamadığı görülmektedir. Bu durum, lojistik regresyon modelinin belirli veri setleri üzerinde performans sınırlarına ulaşabileceğini ve diğer sınıflandırma yöntemleri ile karşılaştırıldığında daha sınırlı bir doğruluk sağlayabileceğini göstermektedir.

Şekil 20: Lojistik Regresyon "Çapraz Doğrulama Performans Değerlendirme Tablosu"

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.5848	0.6345	0.5848	0.5851	0.5848	0.1699	0.1700
1	0.5919	0.6462	0.5919	0.5922	0.5919	0.1840	0.1841
2	0.5900	0.6445	0.5900	0.5904	0.5900	0.1803	0.1805
3	0.5834	0.6356	0.5834	0.5838	0.5833	0.1672	0.1673
4	0.5840	0.6390	0.5840	0.5842	0.5840	0.1682	0.1683
Mean	0.5868	0.6400	0.5868	0.5871	0.5868	0.1739	0.1740
Std	0.0035	0.0047	0.0035	0.0035	0.0035	0.0069	0.0069

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 21: Lojistik Regresyon "Karışıklık Matrisi (Confusion Matrix)"




Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 22: Lojistik Regresyon "Çapraz Doğrulama Performans Değerlendirme Tablosu"
Parametre Optimizasyonu Sonrası

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.5848	0.6345	0.5848	0.5851	0.5848	0.1699	0.1700
1	0.5919	0.6462	0.5919	0.5922	0.5919	0.1840	0.1841
2	0.5900	0.6445	0.5900	0.5904	0.5900	0.1803	0.1805
3	0.5834	0.6356	0.5834	0.5838	0.5833	0.1672	0.1673
4	0.5840	0.6390	0.5840	0.5842	0.5840	0.1682	0.1683
Mean	0.5868	0.6400	0.5868	0.5871	0.5868	0.1739	0.1740
Std	0.0035	0.0047	0.0035	0.0035	0.0035	0.0069	0.0069

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 23: Lojistik Regresyon "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Modelin arıza için kalan süre eşik değeri olan 360 saatin altında veya üstünde olma durumunu ayırma-tahmin etme becerisi %58 civarındadır. Daha da ötesi bu ayrımı tahmin etme becerisinin oldukça dengeli olduğu “Confussion Matrix” grafiklerinden görülmektedir. Parametre optimizasyonu yapmanın fayda sağlamadığı grafiklerden de anlaşılabilmektedir. Validasyon verisinin tahminine ait sonuçlar ise aşağıdaki gibidir:

Şekil 24: Lojistik Regresyon "Model Performans Özeti Tablosu"

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	Logistic Regression	0.5777	0	0.5777	1.0000	0.7323	0.0000	0.0000

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Modelin validasyon verisi üzerindeki doğruluğu %58 olarak gerçekleşmiş olup, eğitimde elde edilen sonuçlarla tutarlılık göstermektedir. Bu sonuçlar, lojistik regresyon modelinin özellikle bu veri seti için yeterli bir performans sunmadığını, ancak sınıflandırma dengesini koruyarak her iki sınıfta da belirli bir doğruluğu sağladığını ortaya koymaktadır. Bu tür bir model, basit sınıflandırma gereksinimlerinde tercih edilebilirken, daha yüksek doğruluk oranı gerektiren tahmin problemlerinde diğer modellerin değerlendirilmesi önerilebilir.

3.5.2. Linear Discriminant Analysis

Linear Discriminant Analysis (LDA), sınıflandırma modellerinde, hedef değişken ile belirleyici özellikler arasındaki ilişkileri analiz etmek ve sınıflar arasındaki ayrımı güçlendirmek için kullanılan bir tekniktir. Li vd., (2016) çalışmasında, LDA, sınıflar arası ayrımı maksimize eden ve yüksek boyutlu verilerin sınıflandırılmasında kullanılan etkili bir yöntemdir. Bu yöntem, veri setlerini daha anlamlı bir şekilde temsil etmek için boyut indirgeme

işlemi sırasında sınıf bilgilerinin korunmasını sağlar. Bu çalışma kapsamında, LDA modeli, arıza süresinin 360 saatin altında veya üstünde olma durumunu tahmin ederek kestirimci bakım amacıyla uyarlanmıştır. LDA, veri setindeki sınıflar arasında doğrusal bir ayırım oluşturarak basit sınıflandırma görevlerinde etkili bir yöntem olarak öne çıkmaktadır.

LDA modeli, başlangıç eğitimi sürecinde %58 doğruluk oranına ulaşmıştır. Bu oran, modelin veri setindeki iki sınıfı ayırt etme yeteneğini göstermektedir, ancak daha ileri aşamalarda performansın nasıl değiştiği de değerlendirilmelidir. Doğruluk oranı, tüm test verisi üzerinde yapılan değerlendirmede modelin %58 oranında doğru tahminde bulunduğunu göstermektedir. Ancak, bu oranın sınıfların dağılımına bağlı olduğu unutulmamalıdır. Modelin performansını daha iyi yorumlayabilmek için yalnızca doğruluk oranı değil, aynı zamanda hata oranı, duyarlılık ve kesinlik gibi ek metriklerin de incelenmesi gerekmektedir. Özellikle doğrusal olmayan veri yapılarında LDA'nın sınırlı performans gösterebileceği ve diğer sınıflandırıcılarla kıyaslandığında farklı sonuçlar ortaya çıkabileceği göz önünde bulundurulmalıdır.


İlk Eğitim:

Şekil 25: Doğrusal Ayırıcı Analiz "Çapraz Doğrulama Performans Değerlendirme Tablosu"

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.5841	0.6343	0.5841	0.5844	0.5840	0.1684	0.1685
1	0.5907	0.6460	0.5907	0.5910	0.5907	0.1817	0.1819
2	0.5890	0.6443	0.5890	0.5894	0.5889	0.1782	0.1784
3	0.5829	0.6354	0.5829	0.5833	0.5828	0.1662	0.1664
4	0.5831	0.6389	0.5831	0.5834	0.5830	0.1664	0.1665
Mean	0.5860	0.6398	0.5860	0.5863	0.5859	0.1722	0.1723
Std	0.0032	0.0047	0.0032	0.0033	0.0032	0.0065	0.0065

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 26: Doğrusal Ayırıcı Analiz "Karışıklık Matrisi (Confusion Matrix)"



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Parametre Optimizasyonu Sonrası:


Hiperparametre optimizasyonu, modelin mevcut sınıflandırma başarısını artırmaya yönelik olarak uygulanmıştır. Ancak, LDA modelinde gerçekleştirilen optimizasyon süreci sonrasında doğruluk oranında belirgin bir artış gözlemlenmemiştir. Modelin doğruluğu yaklaşık %58 seviyesinde kalmış olup, optimizasyonun etkisinin sınırlı kaldığı görülmektedir. Bu sonuç, LDA'nın hiperparametre değişikliklerine karşı duyarlılığının sınırlı olduğunu ve doğrusal ayırıcı sınırlarla sınıflandırma yapabilen veri yapıları için uygun olduğunu göstermektedir.

Şekil 27: Doğrusal Ayırıcı Analiz "Çapraz Doğrulama Performans Değerlendirme Tablosu" Parametre Optimizasyonu Sonrası

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.5953	0.6285	0.5953	0.5952	0.5952	0.1903	0.1903
1	0.6003	0.6412	0.6003	0.6003	0.6003	0.2005	0.2005
2	0.6016	0.6367	0.6016	0.6016	0.6016	0.2031	0.2031
3	0.5939	0.6297	0.5939	0.5938	0.5938	0.1875	0.1875
4	0.5973	0.6334	0.5973	0.5972	0.5972	0.1943	0.1943
Mean	0.5977	0.6339	0.5977	0.5976	0.5976	0.1951	0.1951
Std	0.0029	0.0047	0.0029	0.0030	0.0030	0.0059	0.0059

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 28: Doğrusal Ayırıcı Analiz "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Confusion matrix (karışıklık matrisi) grafiği, LDA modelinin eğitim ve test aşamasında sınıfları ayırma becerisini görselleştirmektedir. Grafik, sınıflar arasındaki ayrımın belirgin olduğunu, ancak sınıflandırma doğruluğunun beklenen seviyenin altında kaldığını ortaya koymaktadır. Bu bağlamda, LDA modelinin sınıflar arasındaki ayrımı doğrusal olarak sağlaması nedeniyle, karmaşık ve doğrusal olmayan veri yapılarında performans sınırlamaları gözlemlenebilir. Buna karşın, LDA'nın dengeyi koruma yeteneği, özellikle sınıf dengesizliğinin fazla olduğu veri setlerinde faydalı olabilir.

Bu modelin de sonuçları Logistic Regression modeline benzer şekildedir. Parametre optimizasyonun etkisi oldukça sınırlı olmuştur. Validasyon verisi için metrikler aşağıdaki gibidir:

Şekil 29: Doğrusal Ayırıcı Analiz "Model Performans Özeti Tablosu"

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	Linear Discriminant Analysis	0.5831	0	0.5831	1.0000	0.7366	0.0000	0.0000

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Modelin validasyon veri setindeki başarı oranı %58'dir.

Linear Discriminant Analysis, kestirimci bakım gibi sınıflandırma problemlerinde temel bir model olarak kullanılsa da, doğrusal olmayan yapıya sahip karmaşık veri setlerinde sınırlı performans gösterebilir. LDA'nın bu sınırlamaları göz önünde bulundurularak, karmaşık veri setleri için doğrusal olmayan sınıflandırma yeteneğine sahip diğer modellerin, örneğin destek vektör makineleri (SVM) veya çok katmanlı algılayıcı (MLP) gibi algoritmaların

değerlendirilmesi önerilir. Bu tür modellerin, veri setindeki karmaşık ilişkileri daha iyi öğrenerek modelin genel doğruluğunu artırabileceği düşünülmektedir.

3.5.3. K-Nearest Neighbors (KNN)

K-Nearest Neighbors (KNN) algoritması, kestirimci bakım modeli geliştirme sürecinde sıklıkla kullanılan temel sınıflandırma tekniklerinden biridir. KNN algoritması, komşuluk ilişkilerini esas alarak sınıflandırma ve regresyon problemlerini çözmede etkili bir yöntemdir (Sünetcioğlu ve Arsan, 2024). Bu algoritma, veri noktalarını sınıflandırmak için en yakın komşuların etiketlerinden faydalanarak, sınıflar arasındaki benzerliklere göre karar verir. KNN, özellikle doğrusal olmayan veri kümelerinde etkili sonuçlar verebilecek bir yöntem olarak öne çıkmaktadır. Çalışmada KNN algoritması, arıza süresinin 360 saatin altında veya üstünde olup olmayacağını tahmin etmek amacıyla uygulanmıştır.

İlk Eğitim:


Başlangıç eğitim sürecinde, KNN algoritması %63 doğruluk oranına ulaşmıştır. Bu doğruluk seviyesi, modelin veri setindeki sınıfları ayırma becerisini ilk etapta ortaya koysa da, modelin hiperparametre ayarları üzerinde daha fazla çalışılması gerektiğini göstermektedir. KNN modelinde, doğru komşu sayısı seçimi model performansını doğrudan etkilemektedir; dolayısıyla, bu aşamada hiperparametre optimizasyonunun yapılması zorunlu hale gelmiştir.

Şekil 30: En Yakın K-Komşu "Çapraz Doğrulama Performans Değerlendirme Tablosu"

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.6332	0.7094	0.6332	0.6361	0.6305	0.2650	0.2685
1	0.6358	0.7106	0.6358	0.6381	0.6335	0.2702	0.2731
2	0.6316	0.7060	0.6316	0.6339	0.6292	0.2618	0.2647
3	0.6337	0.7070	0.6337	0.6365	0.6310	0.2659	0.2694
4	0.6334	0.7067	0.6334	0.6357	0.6311	0.2654	0.2684
Mean	0.6335	0.7079	0.6335	0.6361	0.6311	0.2657	0.2688
Std	0.0013	0.0018	0.0013	0.0013	0.0014	0.0027	0.0027

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 31: En Yakın K-Komşu "Karışıklık Matrisi (Confusion Matrix)"



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Parametre Optimizasyonu:

Hiperparametre optimizasyonu sonrası, KNN modelinde doğruluk oranı %68'e yükselmiştir. Bu artış, optimizasyon sürecinin modelin performansını iyileştirdiğini ve sınıflandırma doğruluğunu artırdığını göstermektedir. Ancak, confusion matrix grafiğinde görüldüğü üzere, sınıflandırma dengesizliği devam etmektedir ve model belirli sınıflarda daha başarılı tahminler yaparken diğer sınıflarda daha düşük performans sergilemektedir.


Şekil 32: En Yakın K-Komşu "Çapraz Doğrulama Performans Değerlendirme Tablosu"

Parametre Optimizasyonu Sonrası

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.6882	0.7631	0.6882	0.7035	0.6813	0.3743	0.3903
1	0.6900	0.7640	0.6900	0.7059	0.6830	0.3778	0.3944
2	0.6953	0.7692	0.6953	0.7105	0.6889	0.3886	0.4044
3	0.6915	0.7603	0.6915	0.7066	0.6849	0.3809	0.3967
4	0.6911	0.7623	0.6911	0.7065	0.6843	0.3801	0.3962
Mean	0.6912	0.7638	0.6912	0.7066	0.6845	0.3803	0.3964
Std	0.0023	0.0030	0.0023	0.0022	0.0025	0.0047	0.0046

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 33: En Yakın K-Komşu "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Confusion matrix ve diğer doğrulama grafikleri incelendiğinde, KNN modelinin genel anlamda sınıflandırma kapasitesinin kabul edilebilir düzeyde olduğu ancak sınıf dengesizliğinin mevcut olduğu gözlemlenmektedir. Bu bağlamda, modelin daha dengeli bir performans sergilemesi için farklı sınıflandırma algoritmaları veya daha fazla veri ön işleme yöntemlerinin uygulanması önerilebilir. Özellikle, sınıf dengesizliğini minimize etmek amacıyla sınıf ağırlıkları üzerinde optimizasyon yapılması veya daha gelişmiş denetimli öğrenme yöntemlerinin değerlendirilmesi faydalı olabilir.

KNN modelinin ilk eğitim sonuçlarında model başarısını %63'tür. Parametre optimizasyonu sonrası %68 olarak gerçekleşmiştir. Ancak Confussion Matrix grafiğinden de görüleceği gibi modelin sınıfları ayırma becerisi dengeli değildir. Validasyon seti için yapılan tahminde başarı oranı %74 civarında gerçekleşmiştir. Validasyon verisi için tahmin metrikleri aşağıdaki gibidir:

Şekil 34: En Yakın K-Komşu "Model Performans Özeti Tablosu"

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	K Neighbors Classifier	0.7484	0	0.7484	1.0000	0.8561	0.0000	0.0000

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Modelin validasyon veri setindeki başarı oranı %75 civarındadır.

Validasyon veri setinde KNN modelinin doğruluk oranı %75 olarak kaydedilmiştir. Bu sonuç, modelin eğitim sürecindeki performansına kıyasla validasyon aşamasında daha iyi bir başarı

sergilediğini ortaya koymaktadır. Ancak, modelin sınıf dengesizliği devam etmekte olup, bazı sınıflarda tahmin doğruluğunun sınırlı olduğu gözlemlenmiştir. Bu durum, kestirimci bakım modelleri için sınıf dengesizliğine duyarlı yaklaşımlar gerektirdiğini ve KNN gibi algoritmalarda sınıf dengesini sağlamak için ek düzenlemelerin yapılmasının faydalı olabileceğini işaret etmektedir.

3.5.4. Destek Vektör Makinesi (Support Vector Machine)

Destek Vektör makinesi (SVM), sınıflandırma problemlerinde yüksek performans sağlayan ve özellikle ayrık sınıfların ayrımında etkili bir algoritmadır. SVM, sınıflar arasındaki marjini maksimize eden hiper düzlemler oluşturarak sınıflandırma ve regresyon problemlerinde kullanılan güçlü bir algoritmadır (Sünetcioğlu ve Arsan, 2024). SVM modeli, veri noktalarını ayırma çizgileri ile en iyi şekilde bölerek sınıflar arasında maksimum mesafe sağlamayı hedefler. Bu çalışmada, SVM algoritması "Hidrolik Silindir Arızası"nın kalan süreye göre 360 saatin altında veya üstünde olup olmadığını tahmin etmek amacıyla uygulanmıştır. SVM, doğrusal olmayan veri kümelerinde dahi etkili performans sunmasıyla öne çıkar.

İlk Eğitim:

Başlangıç eğitim aşamasında, SVM modeli yaklaşık %59 doğruluk oranına ulaşmıştır. İlk değerlendirmeler, modelin genel olarak sınıflandırma görevini yerine getirebildiğini, ancak daha yüksek doğruluk oranına ulaşmak için optimizasyona ihtiyaç duyduğunu göstermektedir. Confusion matrix (karışıklık matrisi) grafiği incelendiğinde, modelin bazı sınıfları daha iyi ayırdığı, ancak diğer sınıflarda hata oranlarının yükseldiği gözlemlenmiştir.


SVM modelinde hiperparametre optimizasyonu, modelin doğruluğunu artırma amacıyla gerçekleştirilmiştir. Ancak optimizasyon süreci sonrasında yapılan değerlendirmeler, doğruluk oranında kayda değer bir artış olmadığını ve modelin %59 seviyelerinde bir doğruluk oranında kaldığını göstermiştir. Bu durum, SVM algoritmasının bu veri kümesi üzerinde belirli bir sınırdaki performans gösterdiğini ve hiperparametre optimizasyonunun sınırlı bir iyileşme sağladığını göstermektedir. Sınıf dengesi açısından ise, model optimizasyon öncesi ve sonrası dengeli sonuçlar vermiş, ancak doğruluk oranında anlamlı bir değişiklik gözlenmemiştir.

Şekil 35: Destek Vektör Makinesi "Çapraz Doğrulama Performans Değerlendirme Tablosu"

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.5926	0.6247	0.5926	0.5935	0.5908	0.1840	0.1854
1	0.5913	0.6223	0.5913	0.5913	0.5909	0.1820	0.1822
2	0.5923	0.6280	0.5923	0.5923	0.5923	0.1845	0.1845
3	0.5768	0.6276	0.5768	0.5769	0.5768	0.1537	0.1537
4	0.5775	0.6229	0.5775	0.5774	0.5774	0.1546	0.1547
Mean	0.5861	0.6251	0.5861	0.5863	0.5856	0.1718	0.1721
Std	0.0073	0.0023	0.0073	0.0075	0.0070	0.0144	0.0146

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 36: Destek Vektör Makinesi "Karışıklık Matrisi (Confusion Matrix)"



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Parametre Optimizasyonu:

Optimizasyonu süreci sonrası elde edilen sonuçlar itibariyle ilk modelin daha başarılı olduğu görülmüştür. Öte yandan bu model de Logistic Regression ve Linear Discriminant Analysis modellerine benzer sonuçlar üretmiştir.

Validasyon veri seti tahmin metrikleri aşağıdaki gibidir:

Şekil 37: Destek Vektör Makinesi "Model Performans Özeti Tablosu"

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	SVM - Linear Kernel	0.5319	0	0.5319	1.0000	0.6944	0.0000	0.0000

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Validasyon verisi için başarı oranı %53'tür.

Eğitim ve validasyon sürecinde elde edilen confusion matrix grafikleri, SVM modelinin sınıfları ayırtırmadaki etkinliğini görselleştirmektedir. Model, sınıfları ayırtırken dengeli bir performans gösterse de bazı sınıflarda ayırım gücünün sınırlı kaldığı gözlemlenmiştir. Özellikle veri setindeki bazı sınıfların belirli bir özellikte yoğunlaşması nedeniyle, SVM'nin genel doğruluğu etkilenmiştir. Bu bağlamda, modelin doğruluk oranını artırmak için veri işleme veya alternatif sınıflandırma algoritmalarının (örneğin MLP veya Random Forest) değerlendirilmesi uygun olabilir.

SVM modeli kestirimci bakım amacıyla belirli bir doğruluk sağlamakta ancak hiperparametre optimizasyonu sonrasında dahi sınırlı bir performans artışı göstermektedir. SVM algoritmasının sınıf ayırımını dengeli bir şekilde sağladığı ancak doğruluk açısından diğer modellere kıyasla sınırlı kaldığı bu değerlendirme ile ortaya konulmaktadır.

3.5.5. Çok Katmanlı Algılayıcı (Multilayer Perceptron)

Çok katmanlı algılayıcı (MLP) modeli, çok katmanlı yapısıyla daha karmaşık sınıflandırma problemlerinde güçlü performans sunabilen bir yapay sinir ağı modelidir. Buabeng vd., (2021)'e göre, MLP bir ileri beslemeli sinir ağıdır ve bir giriş katmanı, bir veya daha fazla gizli katman ile bir çıkış katmanından oluşur. MLP'nin temel özelliği, doğrusal olmayan ve karmaşık ilişkileri öğrenme ve modelleme konusundaki üstün yeteneğidir. Bu özellik, onu kestirimci bakım gibi sınıflandırma görevlerinde oldukça etkili kılar. MLP, giriş özelliklerini kullanarak ağırlıklar ve eşikler (bias) tahmin eder ve bu tahminlerle çıktılar üretir. Çalışmada, MLP'nin sınıflandırma görevlerinde diğer yöntemlerden daha başarılı olduğu ve özellikle sınıf dengesizliği durumlarında daha az etkilenme eğiliminde olduğu belirtilmiştir. MLP, özellikle doğrusal olmayan veri yapıları üzerinde etkin sonuçlar sağlayarak kestirimci bakım uygulamaları gibi veri yoğun alanlarda öne çıkar. Bu çalışmada, MLP modeli, arıza süresinin 360 saatin altında veya üstünde olup olmadığını tahmin etmek amacıyla uygulanmıştır.

İlk Eğitim:


İlk eğitim aşamasında MLP modeli, genel olarak %74 doğruluk oranı yakalamıştır. Bu yüksek doğruluk oranı, modelin sınıflandırma başarısını ve veri setinin gereksinimlerini karşılayabildiğini göstermektedir. Ancak confusion matrix (karışıklık matrisi) grafiği incelendiğinde, modelin bazı sınıfları diğerlerinden daha iyi ayırabildiği, ancak dengeli bir sınıflandırma sağlayamadığı gözlemlenmiştir. Bu durum, MLP'nin sınıflar arasında denge sağlamada bazı sınırlamaları olabileceğini ortaya koymaktadır.

Şekil 38: Çok Katmanlı Algılayıcı "Çapraz Doğrulama Performans Değerlendirme Tablosu"

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.7043	0.7651	0.7043	0.7230	0.6972	0.4065	0.4257
1	0.7014	0.7680	0.7014	0.7078	0.6985	0.4015	0.4085
2	0.7069	0.7728	0.7069	0.7170	0.7029	0.4123	0.4230
3	0.7047	0.7678	0.7047	0.7177	0.6996	0.4077	0.4213
4	0.7036	0.7639	0.7036	0.7271	0.6949	0.4050	0.4289
Mean	0.7042	0.7675	0.7042	0.7185	0.6986	0.4066	0.4215
Std	0.0018	0.0031	0.0018	0.0065	0.0027	0.0035	0.0070

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 39: Çok Katmanlı Algılayıcı "Karışıklık Matrisi (Confusion Matrix)"



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Parametre Optimizasyonu:


MLP modelinde hiperparametre optimizasyonu, model performansını artırmak amacıyla yapılmıştır. Hiperparametre optimizasyonu sonrası, modelin doğruluğunda belirgin bir artış sağlanmamış, sınıflar arası denge sorunları tam olarak giderilememiştir. Bu sonuç, MLP modelinin hiperparametre ayarları ile belirli bir performans sınırına ulaşabildiğini ve sınıf dengesizliğini tamamen iyileştiremediğini göstermektedir.

Şekil 40: Çok Katmanlı Algılayıcı "Çapraz Doğrulama Performans Değerlendirme Tablosu" Parametre Optimizasyonu Sonrası

	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Fold							
0	0.7214	0.7876	0.7214	0.7552	0.7109	0.4404	0.4741
1	0.7194	0.7882	0.7194	0.7509	0.7094	0.4364	0.4679
2	0.7207	0.7808	0.7207	0.7706	0.7062	0.4385	0.4871
3	0.7245	0.7878	0.7245	0.7730	0.7106	0.4462	0.4935
4	0.7168	0.7864	0.7168	0.7691	0.7012	0.4306	0.4814
Mean	0.7205	0.7862	0.7205	0.7638	0.7077	0.4384	0.4808
Std	0.0025	0.0027	0.0025	0.0089	0.0037	0.0051	0.0091

Kaynak: Python Analiz Çalışmalarından Alınmıştır

Şekil 41: Çok Katmanlı Algılayıcı "Karışıklık Matrisi (Confusion Matrix)" Parametre Optimizasyonu Sonrası



Kaynak: Python Analiz Çalışmalarından Alınmıştır

Confusion matrix ve diğer doğrulama grafikleri, MLP modelinin sınıfları ayırmadaki başarısını görselleştirmektedir. Grafiklerde, modelin bazı sınıflarda yüksek doğruluğa ulaştığı, ancak belirli sınıfları ayırmada zorluk çektiği gözlemlenmiştir. Bu durum, modelin veri seti içindeki sınıflar arasında dengesizlik olduğunda performans düşüklüğüne yol açabileceğini göstermektedir. Buna rağmen, MLP'nin doğrusal olmayan ilişkileri tanıyabilmesi, kestirimci bakım modellerinde güçlü bir sınıflandırıcı olarak öne çıkmasını sağlamaktadır.

Modelin genel anlamda başarı oranı %74 gibi yüksek bir değere sahiptir. Ancak sınıfları ayırma becerisi bakımından, arıza içi kalan sürenin ($T < 360$ saat) durumu için neredeyse yarı yarıya olduğu Confussion Matrix grafiğinden görülebilmektedir. Parametre optimizasyonu başarı oranını sınırlı artırmıştır. Ancak sınıflar arası dengeyi sağlayamamıştır. Validasyon seti için metrikler aşağıdaki gibidir:

Şekil 42: Çok Katmanlı Algılayıcı "Model Performans Özeti Tablosu"

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	MLP Classifier	0.7608	0	0.7608	1.0000	0.8641	0.0000	0.0000

Kaynak: Python Analiz Çalışmalarından Alınmıştır

MLP modeli, genel olarak yüksek doğruluk sağlamasına rağmen sınıf dengesizliği sorununu tam olarak çözmemiştir. Bu bağlamda, MLP'nin sınıf dengesini sağlamada yeterli olmadığı durumlar için veri ön işleme teknikleriyle sınıflar arası dengeyi sağlamak, sınıf ağırlıklandırma veya alternatif sinir ağı yapılarını denemek önerilebilir. MLP'nin bu tür veri setlerinde etkinliği, diğer sınıflandırma modelleri ile karşılaştırılarak en uygun modelin belirlenmesi yönünde geliştirilebilir.

Tablo 7: Makine Öğrenmesi Algoritmalarının Sonuçlarının Karşılaştırılması

Model	Başlangıç Doğruluk (%)	Optimizasyon Sonrası Doğruluk (%)	Validasyon Doğruluk (%)	F1-Skoru (%)	Tahmin Edilen Zaman Aralığı (Saat)	Güçlü Yönler	Zayıf Yönler	Önerilen Kullanım Durumu
Lojistik Regresyon (LR)	56.5	58	58	57	50-360	Basit, hızlı uygulanabilir	Doğrusal olmayan verilerde düşük performans	Temel sınıflandırma
Doğrusal Ayırıcı Analiz (LDA)	58	58	58	56	100-360	Dengeyi koruyabilir	Karmaşık veri setlerinde başarısız olabilir	Sınıf ayrımı belirgin veri setleri
K-En Yakın Komşu (KNN)	63	68	75	64	30-360	Basit, parametrik olmayan yapı	Büyük veri setlerinde yavaş olabilir	Küçük ve orta ölçekli veri setleri
Destek Vektör Makinesi (SVM)	59	59	53	55	40-360	Karmaşık sınıf ayrımlarında iyi performans	Yüksek işlem gücü gerektirebilir	Küçük veri setlerinde iyi sonuç verir
Çok Katmanlı Algılayıcı (MLP)	74	74	74	71	20-360	Doğrusal olmayan yapılar için uygun	Aşırı öğrenme riski var	Büyük ve karmaşık veri setleri

Kaynak: Araştırmacı tarafından hazırlanmıştır

DÖRDÜNCÜ BÖLÜM

SONUÇ VE ÖNERİLER

Bu çalışma, endüstriyel uygulamalar için makine öğrenimi destekli kestirimci bakım modellerinin etkinliğini incelemek ve bakım stratejilerini optimize edecek bir sistem geliştirmek amacıyla gerçekleştirilmiştir. Özellikle, bakım süreçlerinde arıza kaynaklı üretim kesintilerini en aza indirerek operasyonel verimliliği artırmak ve bakım maliyetlerini düşürmek temel hedefler arasındadır.

Çalışmada, Logistic Regression, KNN, SVM ve MLP gibi farklı makine öğrenimi algoritmaları kullanılarak kestirimci bakımın başarısını artırmaya yönelik bir model geliştirilmiştir. Ayrıca, hiperparametre optimizasyonu ve veri ön işleme teknikleri kullanılarak modelin doğruluk oranı iyileştirilmiş, algoritmaların endüstriyel uygulamalara uygunluğu detaylı şekilde analiz edilmiştir.

Elde edilen bulgular, makine öğrenimi destekli kestirimci bakım modellerinin, endüstriyel sistemlerde bakım süreçlerini iyileştirme potansiyeline sahip olduğunu ortaya koymaktadır. Ancak, her bir algoritmanın performansı, kullanılan veri setine, modelin optimizasyon seviyesine ve parametre ayarlarına bağlı olarak değişkenlik göstermiştir.

MLP modeli, karmaşık veri yapılarında en yüksek doğruluğa ulaşan model olmuştur. Bu durum, çok katmanlı sinir ağlarının karmaşık ilişkileri öğrenme kapasitesinin üstünlüğünü ortaya koymaktadır. Ancak, modelin sınıf dengesizliği problemlerine karşı duyarlılığı ve hesaplama maliyetinin yüksekliği önemli sınırlılıklar olarak belirlenmiştir.

KNN algoritması, veri noktaları arasındaki mesafeye dayalı olarak karar verme mekanizmasına sahip olduğundan, küçük ve dengeli veri kümelerinde başarılı sonuçlar üretmiş, ancak veri setinde sınıf dengesizliği ve büyük veri kümelerinde hesaplama maliyeti açısından dezavantajlı olmuştur.

SVM modeli, belirli veri türlerinde yüksek doğruluk sağlamasına rağmen, karmaşık ve doğrusal olmayan veri yapılarına uyum sağlama konusunda yetersiz kalmıştır.

Logistic Regression, temel sınıflandırma görevlerinde hızlı ve etkili bir yöntem sunmasına karşın, karmaşık ve çok boyutlu veri kümelerinde yetersiz performans göstermiştir.

Genel olarak, MLP modeli, kestirimci bakım sistemlerinde uygulanabilirliği en yüksek algoritma olarak öne çıkmış, ancak belirli optimizasyonlarla ve veri ön işleme teknikleriyle diğer algoritmaların da belirli endüstriyel senaryolarda uygulanabilir olduğu görülmüştür.

Bulgular, kestirimci bakım sistemlerinin endüstriyel uygulamalarda geleneksel kestirimci bakım yöntemlerine kıyasla daha etkin sonuçlar sunduğunu göstermektedir. Özellikle, önleyici bakım stratejilerinin dijitalleşmesi sayesinde işletmelerin üretim kesintilerini en aza indirerek bakım maliyetlerini optimize etme potansiyeli bulunmaktadır.

Ancak, araştırmanın bulgularına göre, gerçek zamanlı kestirimci bakım sistemlerinin başarısı, sensör verilerinin doğruluğuna ve modelin veri kalitesine duyarlılığına bağlıdır. Bu bağlamda, endüstriyel IoT (Internet of Things) sistemleri ile entegrasyon, modelin gerçek zamanlı uygulanabilirliğini artırabilir.

Bu çalışma, belirli endüstriyel bakım süreçleri için seçilmiş bir veri seti kullanılarak gerçekleştirilmiş olup, belirli sınırlandırmalara sahiptir:

1. Veri Seti Çeşitliliği: Kullanılan veri seti, belli bir sektör ile sınırlı kalmış, bu nedenle modelin diğer sektörlerdeki genelleme kapasitesi değerlendirilememiştir.

2. Derin Öğrenme Yaklaşımları: Çalışmada yalnızca belirli makine öğrenimi algoritmaları kullanılmış olup, LSTM ve CNN gibi derin öğrenme tekniklerinin potansiyeli incelenmemiştir. Bu kapsam dahilinde kalınarak çalışma yürütülmüş, ancak genişletilmiş veri setleri ve ileri modelleme tekniklerinin kullanılması gerektiği anlaşılmıştır.

Çalışmanın bazı metodolojik eksiklikleri ve iyileştirilmesi gereken alanları aşağıda özetlenmiştir:

1. Gerçek Zamanlı Uygulama Eksikliği: Model, endüstriyel ortamda gerçek zamanlı olarak test edilmemiştir.

2. Veri Setinin Sınırlı Çeşitliliği: Farklı endüstriyel sektörlerden toplanan veri setleri ile modelin genelleme kapasitesi artırılmalıdır.

3. Derin Öğrenme Modellerinin Dahil Edilmemesi: LSTM ve CNN gibi derin öğrenme tabanlı yaklaşımlar ile çalışmanın kapsamı genişletilmelidir.

Bulgular doğrultusunda, gelecekte yapılması gereken çalışmalar şu şekilde önerilmektedir:

- Daha çeşitlendirilmiş veri setleri kullanılmalıdır.
- Gerçek zamanlı IoT tabanlı sensörlerle model test edilmelidir.
- Hiperparametre Optimizasyonunda daha gelişmiş teknikler kullanılmalıdır.

- LSTM, CNN veya Transformer modelleri gibi derin öğrenme yöntemleri araştırılmalıdır.

- Endüstri iş birlikleri ile model gerçek ortamda uygulanmalıdır.

Bu tez çalışması, makine öğrenimi tabanlı kestirimci bakım yaklaşımlarının endüstriyel uygulamalarda büyük bir potansiyele sahip olduğunu ortaya koymuştur. Ancak, model performansının artırılması için daha gelişmiş optimizasyon teknikleri, derin öğrenme yöntemleri ve gerçek zamanlı veri akışı entegrasyonu gerekmektedir.

Endüstriyel uygulamalara yönelik makine öğrenimi destekli bir kestirimci bakım modeli geliştirilmiştir. Bu model, işletmelerin bakım stratejilerini daha etkin hale getirerek arıza kaynaklı duruş sürelerini ve bakım maliyetlerini azaltmayı amaçlamaktadır. Çalışmada kullanılan yöntemler ve elde edilen bulgular, özellikle hiperparametre optimizasyonu ve veri işleme tekniklerinin model performansına olan etkisini ortaya koymaktadır.

Araştırma kapsamında Logistic Regression, KNN, SVM ve MLP gibi çeşitli makine öğrenimi algoritmaları kullanılarak, her bir modelin kestirimci bakım için uygunluğu değerlendirilmiştir. Elde edilen sonuçlar, her bir algoritmanın farklı veri yapılarına ve sınıflandırma gereksinimlerine göre avantaj ve dezavantajlarının bulunduğunu göstermektedir. Ayrıca, hiperparametre optimizasyonunun model doğruluğuna doğrudan katkı sağladığı ancak bazı durumlarda sınırlı etkiler sunduğu görülmüştür.

Detaylı Sonuçlar

a. **Model Performansları ve Algoritmik Değerlendirme:** Çalışma kapsamında test edilen Logistic Regression, KNN, SVM ve MLP algoritmaları, belirli doğruluk oranlarına ulaşmakla birlikte her birinin avantaj ve sınırlamaları ortaya konmuştur. Logistic Regression modeli, temel sınıflandırma problemlerinde etkili olmasına rağmen, doğrusal olmayan veri setlerinde sınırlı performans göstermiştir. KNN algoritması, en yakın komşulara dayalı sınıflandırma yapısıyla daha iyi bir doğruluk sağlamış ancak sınıf dengesizliğinde performans kaybına neden olmuştur. SVM, sınıflar arasında net ayrım sağlayarak belirli bir doğruluk oranına ulaşsa da, doğrusal olmayan karmaşık veri yapılarında istenen seviyede performans gösterememiştir. MLP modeli ise en yüksek doğruluğu sunarak karmaşık veri yapılarını en iyi şekilde işleyen algoritma olarak öne çıkmıştır. Ancak, sınıflar arasında denge sağlama konusunda zorluk yaşadığı gözlemlenmiştir.

- b. **Hiperparametre Optimizasyonunun Etkisi:** Hiperparametre optimizasyonu, çalışmada kullanılan tüm algoritmalar için model doğruluğunu artırmaya yönelik olarak uygulanmıştır. Grid Search, Random Search ve bayesiyen optimizasyon gibi çeşitli yöntemler kullanılarak, her algoritmanın en uygun parametreleri belirlenmiş ve performans iyileştirmeleri sağlanmıştır. Özellikle MLP ve KNN modellerinde hiperparametre optimizasyonunun doğruluğu artırdığı gözlemlenmiştir. Ancak, bazı durumlarda SVM ve Logistic Regression gibi algoritmalarda hiperparametre optimizasyonunun etkisi sınırlı kalmıştır. Bu durum, doğruluğun artırılması için daha gelişmiş optimizasyon tekniklerinin kullanılmasının gerekliliğini ortaya koymaktadır.
- c. **Veri Ön İşleme ve Aykırı Değerlerin Düzeltilmesi:** Veri setinin kalitesini artırmak için detaylı veri ön işleme adımları gerçekleştirilmiştir. Eksik değerlerin tamamlanması, aykırı değerlerin belirlenmesi ve düzeltilmesi aşamaları, modelin doğruluğunu doğrudan etkileyen önemli adımlardır. Özellikle IQR yöntemi kullanılarak aykırı değerler düzeltilmiş, veri setinin dengeli bir yapıya kavuşması sağlanmıştır. Ayrıca, bazı değişkenlerin kategorik hale getirilmesi ile model performansında iyileştirme sağlanmıştır.
- d. **Gerçek Zamanlı Kestirimci Bakım İçin Öneriler:** Çalışmanın sonuçları, geliştirilen kestirimci bakım modelinin gerçek zamanlı sistemlere entegrasyonunu desteklemektedir. IoT tabanlı sensörler aracılığıyla sürekli veri akışı sağlanarak modelin gerçek zamanlı çalışabilmesi mümkün kılınabilir. Bu sayede, işletmelerde anlık arıza tespiti ve önleyici bakım stratejileri daha etkin bir şekilde uygulanabilecektir. Gerçek zamanlı kestirimci bakım, işletmelerin yalnızca maliyet tasarrufu sağlamasına değil, aynı zamanda operasyonel verimliliklerini artırmalarına da olanak tanır.

İleri Optimizasyon Tekniklerinin Kullanılması: Çalışmada kullanılan Grid Search ve Random Search optimizasyon teknikleri, model doğruluğunda iyileştirmeler sağlamış ancak bazı algoritmalarda sınırlı etkiler sunmuştur. Bu nedenle, özellikle karmaşık veri setleri üzerinde daha etkin sonuçlar almak için bayesiyen optimizasyon veya genetik algoritma tabanlı optimizasyon tekniklerinin değerlendirilmesi önerilmektedir. İleri düzey optimizasyon, modelin doğruluğunu artırarak daha güvenilir tahminler elde edilmesini sağlayabilir.

Veri Setinin Çeşitlendirilmesi ve Uzun Süreli Gözlem: Modelin daha geniş bir uygulama yelpazesinde başarısını artırmak amacıyla veri setinin daha uzun bir zaman dilimine yayılması ve farklı makine parametreleri içermesi önerilmektedir. Çeşitlendirilmiş veri seti, modelin genelleme kabiliyetini artıracak ve kestirimci bakım modelinin farklı endüstriyel uygulamalara uyum sağlamasına olanak tanıyacaktır.

Derin Öğrenme Tabanlı Modellerin İncelenmesi: Çalışmada test edilen algoritmaların doğruluğu sınırlı kalmışsa, özellikle karmaşık veri yapıları için derin öğrenme modellerinin değerlendirilmesi önerilir. LSTM, CNN veya GAN gibi derin öğrenme modelleri, zaman serisi verilerini işleyebilme kapasitesi ile kestirimci bakım modellerinde daha yüksek doğruluk oranlarına ulaşmayı sağlayabilir. Bu tür modeller, özellikle sürekli veri akışının mevcut olduğu sistemlerde etkin bir şekilde kullanılabilir.

Gerçek Zamanlı İzleme ve Anomali Tespit Sistemleri: Kestirimci bakım modelinin başarısını artırmak için IoT tabanlı gerçek zamanlı izleme sistemlerinin entegrasyonu önerilmektedir. Bu sistemler, arıza durumlarının anında tespit edilmesini ve modelin otomatik olarak tetiklenmesini sağlayabilir. Gerçek zamanlı izleme sistemleri, hem maliyet etkinliği hem de iş güvenliği açısından işletmeler için büyük avantajlar sunmaktadır.

Endüstriyel Uygulamalar İçin Model Güncellemeleri ve Adaptif Öğrenme: Modelin doğruluğunu koruyabilmesi için, özellikle endüstriyel ortamlarda verinin sürekli değişkenlik gösterdiği durumlarda adaptif öğrenme tekniklerinin uygulanması önerilmektedir. Bu tür teknikler, modelin değişen verilere dinamik olarak uyum sağlamasına olanak tanır ve model performansının uzun vadede yüksek kalmasını sağlar. Ayrıca, model güncellemeleri ve sürekli öğrenme döngüleri ile kestirimci bakım süreçlerinin daha da iyileştirilmesi hedeflenebilir.

Akademik ve Endüstriyel İş Birlikleri ile Geliştirme: Tezin bulgularının daha geniş bir uygulama alanında test edilebilmesi için akademik ve endüstriyel iş birliklerinin artırılması önemlidir. Bu tür iş birlikleri, modelin farklı sektörlerde uygulanabilirliğini artıracak ve daha kapsamlı bir veritabanı oluşturulmasına katkı sağlayacaktır. Endüstriyel iş birlikleri aynı zamanda gerçek verilerin elde edilmesine olanak tanıyacak ve modelin doğruluğunu daha gerçekçi bir ortamda test etme fırsatı sunacaktır.

Sonuç olarak, bu çalışma, endüstriyel uygulamalarda kestirimci bakım modellerinin potansiyelini ortaya koyarak, daha verimli, güvenilir ve maliyet etkin bakım stratejilerinin uygulanabilirliğini desteklemektedir.

KAYNAKÇA

- Aalami, N. (2020). Derin öğrenme yöntemlerini kullanarak görüntülerin analizi. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 1(1), 17-20.
- Achouch, M., Dimitrova, M., Ziane, K., Sattarpanah Karganroudi, S., Dhouib, R., Ibrahim, H., & Adda, M. (2022). On predictive maintenance in industry 4.0: Overview, models, and challenges. *Applied Sciences*, 12(16), 80-81.
- Adolfsson, E. & Tuvstarr, D. (2011). Efficiency in corrective maintenance-a case study at SKF Gothenburg.
- Aggarwal, C. C. (2015). *Data mining: The textbook*. Springer.
- Aggarwal, C. C. (2018). *Neural networks and deep learning: A textbook*. Springer.
- Agrawal, R., & Srikant, R. (1994). Fast algorithms for mining association rules. *Proceedings of the 20th VLDB Conference*, 487-499.
- Ahmad, R., & Kamaruddin, S. (2021). An overview of time-based and condition-based maintenance in industrial application. *Computers & Industrial Engineering*, 151, 106884.
- Ahuja, I. P. S., & Khamba, J. S. (2020). Total productive maintenance: Literature review and directions. *Journal of Quality in Maintenance Engineering*, 26(4), 511-535. <https://doi.org/10.1108/JQME-10-2019-0089>
- Akgün, M., & Barlik, N. (2023). Makine Öğrenmesi Algoritmaları Kullanılarak Hava Kalitesi İndeksinin Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (51), 97-107.
- Akköse, G., Duran, A., Dino, İ. G., & Akgül, Ç. M. (2023). Makina öğrenmesi ile pencere parametrelerinin bina performansına etkisinin iklim değişikliği gözetilerek incelenmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(4), 2069-2084.
- Aksoy, B. (2020). Sigorta Şirketlerinin Derecelendirilmesinde Makine Öğrenmesi Yöntemleri Tahmin Performansının Karşılaştırılması: Türkiye Örneği. *Akademik Araştırmalar ve Çalışmalar Dergisi*, 12(23), 587-607.
- Alçin, Ö., Şengür, A., & İnce, M. (2015). İleri-geri takip algoritması tabanlı seyrek aşırı öğrenme makinesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 30(1).
- Ali, V. (2015). *Machine learning models for autoverification of medical laboratory test results* (Master's thesis, Dokuz Eylül Üniversitesi (Turkey)).

Alpaydın, E. (2016). *Machine Learning: The New AI*. MIT Press.

Altinel, A. B. (2021). Türkçe metinlerde makine öğrenmesi algoritmalarının duygu analizi problemi üzerindeki performansının kıyaslanması. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1056-1061.

Altun, M. (2021). *Landsat 8 uydu görüntü indeksleri kullanılarak tarımsal ürünlerin makine öğrenme yöntemleri ile tespit edilmesi* (Yayınlanmamış Yüksek Lisans Tezi). Batman Üniversitesi, Fen Bilimleri Enstitüsü.

Al-Turki, U. M., Ayar, T., Yilbas, B. S., & Sahin, A. Z. (2016). Maintenance in the digital era: A review. *International Journal of Advanced Manufacturing Technology*, 85(1-4), 35-50.

Alzubi, J., Nayyar, A., & Kumar, A. (2018, November). Machine learning from theory to algorithms: an overview. In *Journal of physics: conference series* (1142), 012012. IOP Publishing.

Athey, S. (2018). The impact of machine learning on economics. *The economics of artificial intelligence: An agenda*, 507-547.

Avcı, A. (2023). Gelişen Sensör Teknolojisi ve Kestirimci Bakım Modelleri Üzerine Bir Çalışma (Yayınlanmamış Doktora Tezi). Bursa Teknik Üniversitesi, Bursa.

Awad, M., Khanna, R., Awad, M., & Khanna, R. (2015). Machine learning in action: Examples. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 209-240.

Aydın, O. M. (2019). Finansal Bilgi Manipülasyonunun Denetimli Makina Öğrenmesi Yöntemleri Kullanılarak Tahmin Edilmesi: Destek Vektör Makinesi, Olasılıksal Sinir Ağı, K-En Yakın Komşu ve Karar Ağacı Kullanımı (Yayınlanmamış Yüksek Lisans Tezi). TOBB ETÜ, Sosyal Bilimler Enstitüsü.

Aydoğan, E., & Şen, S. (2014, April). Analysis of machine learning methods on malware detection. In *2014 22nd Signal Processing and Communications Applications Conference (SIU)*, 2066-2069, IEEE.

Azizoğlu, G., Azizoğlu, F., Toprak, A. N., Gül, M. F., & Zoralioğlu, Y. (2023). Predicting Academic Performance of Students Using Machine Learning Techniques. In *2023 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 1-6, Sivas, Turkey.

Bakdemir, M. (2024). *Python ile makine öğrenmesi algoritmalarını kullanarak rüzgar santralinin elektrik üretim tahmini* (Yayınlanmamış Yüksek Lisans Tezi). Fen Bilimleri Enstitüsü.

Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In *Learning Analytics*, 61-75, Springer.

Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities*. MIT press.

Basri, E. I., Abdul Razak, I. H., Ab-Samat, H., & Kamaruddin, S. (2017). Preventive maintenance (PM) planning: a review. *Journal of Quality in Maintenance Engineering*, 23(2), 114-143.

Ben-Daya, M., Duffuaa, S. O., Raouf, A., & Knezevic, J. (2009). *Handbook of maintenance management and engineering*. Springer.

Berner, C., Brockman, G., Chan, B., Cheung, V., Debiak, P., Dennison, C., ... & Zhang, S. (2019). Dota 2 with large scale deep reinforcement learning. *arXiv preprint arXiv:1912.06680*.

Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2021). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26, 468-519.

Bilgin, G. (2021). Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması. *Journal of Intelligent Systems: Theory and Applications*, 4(1), 55-64.

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Bokrantz, J., Skoogh, A., Ylipää, T., & Stahre, J. (2020). Smart maintenance: A research agenda for industrial maintenance management. *Journal of Manufacturing Technology Management*, 31(1), 60-80.

Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2), 123-140.

Brown, K., & Zhang, L. (2018). Advances in descriptive maintenance for Industry 4.0. *Industrial Systems Journal*, 44(5), 210-230.

Brunton, S. L., Noack, B. R., & Koumoutsakos, P. (2020). Machine learning for fluid mechanics. *Annual review of fluid mechanics*, 52(1), 477-508.

- Buabeng, A., Simons, A., Frempong, N. K., & Ziggah, Y. Y. (2021). A novel hybrid predictive maintenance model based on clustering, smote and multi-layer perceptron neural network optimised with grey wolf algorithm. *SN Applied Sciences*, 3(5), 593.
- Burkov, A. (2019). *The hundred-page machine learning book*, 1, 32. Quebec City, QC, Canada: Andriy Burkov.
- Bzdok, D., Krzywinski, M., & Altman, N. (2017). Machine learning: a primer. *Nature methods*, 14(12), 1119.
- Cabrera, M., Zaldívar, R., & Olmedo, M. (2022). Predictive maintenance using machine learning: A comprehensive review. *Journal of Industrial Engineering Research*, 24(3), 231-250.
- Canito, A., Fernandes, M., Mourinho, J., Tosun, S., Kaya, K., Turupcu, A., ... & Marreiros, G. (2021, October). Flexible architecture for data-driven predictive maintenance with support for offline and online machine learning techniques. In *IECON 2021–47th Annual Conference of the IEEE Industrial Electronics Society*, 1-7, IEEE.
- Carleo, G., Cirac, I., Cranmer, K., Daudet, L., Schuld, M., Tishby, N., ... & Zdeborová, L. (2019). Machine learning and the physical sciences. *Reviews of Modern Physics*, 91(4), 045002.
- Caton, S., & Haas, C. (2024). Fairness in machine learning: A survey. *ACM Computing Surveys*, 56(7), 1-38.
- Ceran, A. A., & Tanrıöver, Ö. (2022). *Makine öğrenmesi tabanlı topluluk yöntemleri ile yazılım kalitesi tahmini* (Yayınlanmamış Yüksek Lisans Tezi). Ankara Üniversitesi, Fen Bilimleri Enstitüsü.
- Cetiner, E., Koçak, T., & Güngör, V. Ç. (2018, May). Credit risk analysis based on hybrid classification: Case studies on German and Turkish credit datasets. In *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4, IEEE.
- Chapelle, O., Scholkopf, B., & Zien, A. (2009). *Semi-supervised learning*. MIT Press.
- Chen, H., & Tan, K. (2020). Descriptive analytics and IoT in manufacturing maintenance. *Journal of Industrial Analytics*, 51(1), 89-102.
- Chen, J., Zhang, L., & Dai, Y. (2023). IoT-based predictive maintenance in smart manufacturing. *Manufacturing Letters*, 16(4), 145-152.

Chen, Q., Cao, J., & Zhu, S. (2023). Data-driven monitoring and predictive maintenance for engineering structures: Technologies, implementation challenges, and future directions. *IEEE Internet of Things Journal*, 10(16), 14527-14551.

Cheplygina, V., de Bruijne, M., & Pluim, J. P. (2019). Not-so-supervised: A survey of semi-supervised, multi-instance, and transfer learning in medical image analysis. *Medical Image Analysis*, 54, 280-296.

Chevtchenko, A., Smith, B., & Johnson, C. (2023). Development of a machine learning-based predictive maintenance model using IoT sensor data for induction motors. *Journal of Industrial Maintenance and Reliability*, 45(2), 123-135.

Clifton, C. (2016). Privacy-preserving data mining: How do we mine data when we aren't allowed to see it? In *Privacy-Preserving Data Mining*, 1-16, Springer.

Coban, O., Ozyer, B., & Ozyer, G. T. (2015). Sentiment analysis for Turkish Twitter feeds. *23rd Signal Processing Communications Conference Proceedings*.

Çetin, M. A. (2020). *Trafik kazası oluşumu etkenlerinden yararlanarak makine öğrenme yöntemleri ile kaza şiddeti tahmini/Estimation of accidental violence by using machine learning methods using the traffic accident* (Yayınlanmamış Doktora Tezi).

Çınaroğlu, S., & Avcı, K. (2015). Bulaşıcı olmayan hastalıklar bakımından farklı ülkelerin makina öğrenmesi yöntemleri kullanılarak sınıflandırılması. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 20(2), 89-97.

Çıra, F. (2017). Elektrik motorlarının arıza tespitinin otomatik olarak yapılmasında kullanılan yapay öğrenme yöntemleri. *Dicle Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(2), 95-103.

Doğan, S., & Kavtelek, C. (2015). Hayat boyu öğrenme kurum yöneticilerinin hayat boyu öğrenme kavramına ilişkin görüşleri: Hayat boyu öğrenme için bir metafor analizi. *Yükseköğretim ve Bilim Dergisi*, (3), 292-303.

Duvar, O. (2022). Farklı Kestirimci Bakım Veri Tiplerinde Makine Öğrenme Algoritmalarının Performanslarının Karşılaştırılması. (Yayınlanmamış Yüksek Lisans Tezi). T.C. İzmir Demokrasi Üniversitesi. İzmir.

E. Aksöz ve B. Arifoğlu (2020). Makine öğrenmesi ile kestirimci bakım ve anomali tespiti analizi, *4. Uluslararası Uygulamalı Bilimler Kongresi*, Artvin, Türkiye.

El Naqa, I., & Murphy, M. J. (2015). *What is machine learning?*, 3-11, Springer International Publishing.

Ensarioğlu, K. (2023). *Endüstriyel sistemlerde kestirimci bakım için makine öğrenimi uygulamaları* (Yayımlanmış Doktora Tezi). Uludağ Üniversitesi, Bursa.

Ercel, A., & Ulugergerli, E. (2024). Öğrenen makineler ve fasiyes ayrımı; ilk sonuçlar: öğrenen makineler. *Kuantum Teknolojileri ve Enformatik Araştırmaları Dergisi*, 2(1), 31-43.

Eroğlu, Y. (2020). Yapay sinir ağları ve derin öğrenme kullanarak Türkiye'deki Covid-19 vakaları için tahmin modelleri. *Endüstri Mühendisliği Dergisi*, 31(3), 353.

Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.

Finkelstein, M., Cha, J. H., & Levitin, G. (2020). A hybrid preventive maintenance model for systems with partially observable degradation. *IMA Journal of Management Mathematics*, 31(3), 345-365.

Furkan, Zengin, H. (2024). Makine öğrenmesi yöntemlerinde hiper-parametre seçimi. (Yayımlanmamış Yüksek Lisans Tezi). Eskişehir Osmangazi Üniversitesi. Eskişehir.

G. P. Sullivan, R. Pugh, A. P. Melendez, and W. D. Hunt, "Operations & Maintenance Best Practices: A Guide to Achieving Operational Efficiency," *Fed. Energy Manag. Progr.*, no. August 2010, 321, 2010.

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.

García, S., Luengo, J., & Herrera, F. (2015). Data preprocessing in data mining. *Springer*.

Garg, S., & Aggarwal, A. (2019). Machine learning models for predictive maintenance in manufacturing. *Procedia Manufacturing*, 34, 112-121.

Géron, A. (2019). *Hands-On machine learning with scikit-learn, keras, and tensorflow*. O'Reilly Media.

Golgiyaz, S., Talu, M. F., & Onat, C. (2019). Görüntü İşleme ve Makine Öğrenmesi Yöntemleri ile Baca Gazı Sıcaklığının Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 283-291.

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Gurcan, F. (2018). Multi-class classification of Turkish texts. *ISMSIT 2018 Proceedings*.
- Gümüşçü, A., Tenekeci, M. E., Beşli, N., İlkhan, M. A., Aslan, E., & Abamor, S. (2018). Yapılarda ısıtma ve soğutma yükü sınıfların makine öğrenme yöntemleri ile belirlenmesi. *Harran Üniversitesi Mühendislik Dergisi*, 3(2), 60-66.
- H. De Faria, J. G. S. Costa, and J. L. M. Olivas. (2015). A review of monitoring methods for predictive maintenance of electric power transformers based on dissolved gas analysis, *Renew. Sustain. Energy Rev.*, 46, 201–209.
- Hamaide, P., Nguyen, T., & Garcia, R. (2022). A two-level machine learning framework for effective sensor data utilization in maintenance scheduling for rotary machines. *International Journal of Rotating Machinery*, 38(4), 245-260.
- Han, J., Pei, J., & Kamber, M. (2011). *Data mining: Concepts and techniques*. Elsevier.
- Han, J., Pei, J., & Tong, H. (2022). *Data mining: Concepts and techniques*. Morgan Kaufmann.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of statistical learning: Data mining, inference, and prediction*. Springer.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hussain, M., Begum, T., & Rahman, A. (2021). Energy sector predictive maintenance models. *Energy Systems Research*, 14(2), 98-110.
- Huynh, K. T., Grall, A., & Bérenguer, C. (2018). A parametric predictive maintenance decision-making framework considering improved system health prognosis precision. *IEEE Transactions on Reliability*, 68(1), 375-396.
- Ij, H. (2018). Statistics versus machine learning. *Nat Methods*, 15(4), 233.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651-666.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). *An Introduction to Statistical Learning*. Springer.

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). *An Introduction to statistical learning*. Springer.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7), 1483-1510.
- 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, X., Yang, H., Wang H., (2012). *Fault diagnosis for civil aviation engine test based on the vibration signal*. Procedia Engineering, China.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- Kane, A. P., Kore, A. S., Khandale, A. N., Nigade, S. S., & Joshi, P. P. (2022). Predictive maintenance using machine learning. arXiv preprint arXiv:2205.09402.
- Karabacak, E. (2023). *Titreşim analizi ile kestirimci bakım modelleri geliştirilmesi* (Yayımlanmamış Doktora Tezi). Karadeniz Teknik Üniversitesi, Trabzon.
- Karabatak M. (2008). *Özellik seçimi, sınıflama ve öngörü uygulamalarına yönelik birliktelik kuralı çıkarımı ve yazılım geliştirilmesi*. (Yayımlanmamış Doktora Tezi). F.Ü. Fen Bilimleri Enstitüsü, Elazığ.
- Kaya, M., Fidan, G., & Toroslu, I. H. (2012). Sentiment analysis of Turkish political news. *Proceedings - IEEE/WIC/ACM International Conference on Web Intelligence*.
- Kaya, Z., Balcıoğlu, H. E., Günc, H., & Seçkin, A. Ç. (2020, October). Tabakalı kompozit yapıda kırılma davranışlarının belirlenmesinde makina öğrenmesi yaklaşımı. In *International Conference on Material Science and Technology (IMSTEC 2020)* (Vol. 16, p. 18).
- Kaynar, O., Arslan, H., Görmez, Y., & Işık, Y. E. (2018). Makine öğrenmesi ve öznetelik seçim yöntemleriyle saldırı tespiti. *Bilişim Teknolojileri Dergisi*, 11(2), 175-185.

- Kaynar, O., Aydın, Z., & Görmez, Y. (2017). Sentiment analizinde öznitelik düşürme yöntemlerinin oto kodlayıcılı derin öğrenme makinaları ile karşılaştırılması. *Bilişim Teknolojileri Dergisi*, 10(3), 319-326.
- Kaynar, O., Görmez, Y., Yıldız, M., & Albayrak, A. (2016, September). Makine öğrenmesi yöntemleri ile Duygu Analizi. In *International Artificial Intelligence and Data Processing Symposium (IDAP'16)*, 17(18), 17-18.
- Khan, F., & Haddara, M. (2020). Risk-based maintenance: Techniques and applications. *Safety Science*, 124, 104598.
- Kilimci, Z. H., & Akyokuş, S. (2019). The evaluation of word embedding models and deep learning algorithms for Turkish text classification. In *2019 4th International Conference on Computer Science and Engineering (UBMK)*, 548-553, Ieee.
- Kim, T., & Wang, H. (2021). The role of descriptive maintenance in predictive maintenance frameworks. *Energy Systems Research*, 12(4), 350-365.
- Kingma, D. P., & Welling, M. (2014). Auto-encoding variational Bayes. In *Proceedings of the 2nd International Conference on Learning Representations (ICLR)*.
- Kober, J., Bagnell, J. A., & Peters, J. (2013). Reinforcement learning in robotics: A survey. *The International Journal of Robotics Research*, 32(11), 1238-1274.
- Kothamasu, R., Huang, S. H., & VerDuin, W. H. (2006). System health monitoring and prognostics—a review of current paradigms and practices. *International Journal of Advanced Manufacturing Technology*, 28(9-10), 1012-1024.
- Kotsiantis, S. B., Kanellopoulos, D., & Pintelas, P. E. (2006). Data preprocessing for supervised leaning. *International journal of computer science*, 1(2), 111-117.
- Kreuzberger, D., Köhl, N., & Hirschl, S. (2023). Machine learning operations (mlops): Overview, definition, and architecture. *IEEE access*, 11, 31866-31879.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Lee, J., Kao, H. A., & Yang, S. (2014). Service innovation and smart analytics for Industry 4.0 and big data environment. *Procedia CIRP*, 16, 3-8.
- Lee, S., & Wu, D. (2017). Descriptive analytics in maintenance for industrial applications. *International Journal of Production Research*, 55(10), 2926-2938.

- Li, D., Hu, G., & Spanos, C. J. (2016). A data-driven strategy for detection and diagnosis of building chiller faults using linear discriminant analysis. *Energy and Buildings*, 128, 519-529.
- Li, J., He, Q., & Kang, B. (2023). Deep learning for predictive maintenance: An overview. *IEEE Transactions on Industrial Informatics*, 19(2), 820-832.
- Li, W., Wang, C. H., Cheng, G., & Song, Q. (2023). International conference on machine learning. *Transactions on machine learning research*.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Litjens, G., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Litman, T. (2018). Autonomous vehicle implementation predictions: Implications for transport planning.
- Low, Y., Gonzalez, J. E., Kyrola, A., Bickson, D., Guestrin, C. E., & Hellerstein, J. (2014). Graphlab: A new framework for parallel machine learning. *arXiv preprint arXiv:1408.2041*.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381-386.
- Masmoudi, O., Jaoua, M., Jaoua, A., & Yacout, S. (2021). Data preparation in machine learning for condition-based maintenance. *Journal of Computer Science*, 17(6), 525–538.
- Maulud, D., & Abdulazeez, A. M. (2020). A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(2), 140-147.
- Mobley, R. K. (2002). *An introduction to predictive maintenance*. Elsevier.
- Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). *Machine learning: algorithms and applications*. Crc Press.
- Mohri, M. (2018). *Foundations of machine learning*.
- Mołęda, M., Małysiak-Mrozek, B., Ding, W., Sunderam, V., & Mrozek, D. (2023). From corrective to predictive maintenance—A review of maintenance approaches for the power industry. *Sensors*, 23(13), 5970.

- Möngü, E. (2023). *Asenkron motor rulmanlarında arıza tespiti ve kalan faydalı ömür tahmini* (Yayımlanmamış Doktora Tezi). İstanbul Üniversitesi, İstanbul, Türkiye.
- Muhammad, I., & Yan, Z. (2015). Supervised Machine Learning Approaches: A Survey. *ICTACT Journal on Soft Computing*, 5(3).
- Mukhandi, H. S. (2018). *Developing machine learning methods for network anomaly detection* (Yayımlanmamış Yüksek Lisans Tezi), Abdullah Gül Üniversitesi.
- Mullainathan, S., & Spiess, J. (2017). Machine learning: an applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87-106.
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.
- Murphy, K. P. (2022). *Probabilistic machine learning: an introduction*. MIT press.
- Murphy, K. P. (2023). *Probabilistic machine learning: Advanced topics*. MIT press.
- Namlı, E., Ünlü, R., & Gül, E. (2019). Fiyat tahminlemede makine öğrenmesi teknikleri ve doğrusal regresyon yöntemlerinin kıyaslanması; Türkiye’de satılan ikinci el araç fiyatlarının tahminlenmesine yönelik bir vaka çalışması. *Konya Journal of Engineering Sciences*, 7(4), 806-821.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons*, 4(51-62), 56.
- Natarajan, B. K. (2014). *Machine learning: A theoretical approach*. Elsevier.
- Nazareth, N., & Reddy, Y. V. R. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219, 119640.
- Ng, A. Y., Harada, D., & Russell, S. (1999). Policy invariance under reward transformations: Theory and application to reward shaping. In *ICML*, 99, 278-287.
- Nozari, H., Ghahremani-Nahr, J., & Szmelter-Jarosz, A. (2024). AI and machine learning for real-world problems. In *Advances In Computers*, 134, 1-12. Elsevier.
- Ouali, Y., Hudelot, C., & Tami, M. (2020). An overview of deep semi-supervised learning. *Journal of Artificial Intelligence Research*, 67, 241-256.

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.

Özhan, M., (2024). *Rüzgar türbinlerinde kestirimci bakım stratejisi için arıza modları ve etkilerinin analizi* (Yayınlanmamış Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü. İstanbul.

Öztürk, M. (2018). *Makine öğrenmesi ve görüntü işleme tekniklerini kullanarak drone ile yaprak sınıflandırma* (Yayınlanmamış Yüksek Lisans Tezi), Fen Bilimleri Enstitüsü.

Pal, D. K. D., Alluri, V. R. R., Thota, S., Bonam, V. S. M., Chitta, S., & Shaik, M. (2024). AIOps: Integrating AI and machine learning into IT operations. *Australian Journal of Machine Learning Research & Applications*, 4(1), 288-311.

Paluszek, M., & Thomas, S. (2016). *MATLAB machine learning*. Apress.

Park, J., Kim, M., & Han, K. (2020). Real-time predictive maintenance using IoT and machine learning. *Computers in Industry*, 119, 103231.

Patel, V., & Rao, S. (2022). Enhancing maintenance strategies with descriptive analytics. *Operational Research Journal*, 29(3), 300-315.

Pintelon, L., & Parodi-Herz, A. (2016). Maintenance: An evolutionary perspective. In *Handbook of Maintenance Management and Engineering*, 21-48. Springer.

Polatgil, M. (2023). Veri ölçekleme ve eksik veri tamamlama yöntemlerinin makine öğrenmesi yöntemlerinin başarısına etkisinin incelenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(1), 78-88.

Pulat, M., & Deveci Kocakoç, İ. (2021). Türkiye'de makine öğrenmesi ve karar ağaçları alanında yayınlanmış tezlerin bibliyometrik analizi. *Yönetim ve Ekonomi Dergisi*, 28(2), 287-308.

Puterman, M. L. (2014). *Markov decision processes: Discrete stochastic dynamic programming*. John Wiley & Sons.

Quiñonero-Candela, J., Sugiyama, M., Schwaighofer, A., & Lawrence, N. D. (Eds.). (2022). *Dataset shift in machine learning*. Mit Press.

- Raj, R., Kolhe, K., Gutte, V., & Kathare, L. (2024, July). IoT-based predictive maintenance using AI/ML: A systematic review. In *AIP Conference Proceedings*, 3028(1). AIP Publishing.
- Ray, S. (2019, February). A quick review of machine learning algorithms. In *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)*, 35-39. IEEE.
- Rezvanizani, S. M., Dempsey, J., & Lee, J. (2014). An effective predictive maintenance approach based on historical maintenance data using a probabilistic risk assessment: PHM14 data challenge. *International Journal of Prognostics and Health Management*, 5(2).
- Ribeiro, M., Grolinger, K., & Capretz, M. A. (2015, December). Mlaas: Machine learning as a service. In *2015 IEEE 14th international conference on machine learning and applications (ICMLA)*, 896-902. IEEE.
- Riccio, C., Menanno, M., Zennaro, I., & Savino, M. M. (2024). A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters. *Machines*, 12(7), 443.
- Rigamonti, D., et al. (2016). Preventive maintenance optimization in harsh environmental conditions. *Journal of Maintenance Science and Technology*, 33(1), 45-58.
- Robert, C. (2014). *Machine learning, a probabilistic perspective*. Taylor&Francis
- Rokhforoz, P., & Fink, O. (2022). Maintenance scheduling of manufacturing systems based on optimal price of the network. *Reliability Engineering & System Safety*, 217, 108088.
- Russell, S., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Pearson.
- S. Y. Wong, X. Ye, F. Guo, ve H. H. Goh, “Computational intelligence for preventive maintenance of power transformers,” *Appl. Soft Comput.*, 114, 2022.
- Sanchez-Londono, D., Barbieri, G., & Fumagalli, L. (2023). Smart retrofitting in maintenance: a systematic literature review. *Journal of Intelligent Manufacturing*, 34(1), 1-19.
- Sarılgıl, M. (2023). *Makine öğrenmesi ile kısıtlara dayalı zımpara seçimi* (Yayınlanmamış Yüksek Lisans Tezi), Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü.
- Sayar, A., & Turdaliev, N. (2018). Makine öğrenmesi ile adaptif otel öneri sistemi. In *12th Turkish National Software Engineering Symposium, Istanbul, Türkiye*, 13.

Seif, J., & Rabbani, M. (2014). Integer programming for preventive maintenance optimization. *Journal of Operations Research*, 62(3), 223-240.

Selvalakshmi, B., Vijayalakshmi, P., Subha, N., & Balamani, T. (2024). Predictive maintenance in industrial systems using data mining with fuzzy logic systems. *ICTACT Journal on Soft Computing*, 14(4), 3361-3367.

Selvi, E. (2019). *Kentsel atıksu arıtma tesisi biyolojik oksijen ihtiyacının (boi5) makina öğrenmesi yöntemleri ile tahmin edilmesi* (Yayınlanmamış Yüksek Lisans Tezi), Sakarya Üniversitesi.

Serin, G. (2023). *Makine Öğrenmesi İle Kestirimci Bakım Algoritmalarında Sıralı Sınıflandırma Uygulamaları* (Yayınlanmamış Doktora Tezi). TOBB Ekonomi ve Teknoloji Üniversitesi, Ankara.

Shaala, A., Baglee, D., & Dixon, D. (2024). *Machine learning model for predictive maintenance of modern manufacturing assets*. 29th International Conference on Automation and Computing (ICAC), IEEE

Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge University Press.

Sharifani, K., & Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal*, 10(07), 3897-3904.

Shin, H., Rothrock, L., & Prabhu, V. (2024). Evaluating Technicians' Workload and Performance in Diagnosis for Corrective Maintenance. *Sensors*, 24(6), 1943.

Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., & van den Driessche, G., et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484-489.

Silver, D., Lever, G., Heess, N., Degris, T., Wierstra, D., & Riedmiller, M. (2014). Deterministic policy gradient algorithms. In *Proceedings of the 31st International Conference on Machine Learning*, 387-395.

Silvestri, L.; Forcina, A.; Introna, V.; Santolamazza, A (2020).; Cesarotti, V. Maintenance transformation through Industry 4.0 technologies: A systematic literature review. *Comput. Ind.* , 123, 103335.

- Singh, A., Thakur, N., & Sharma, A. (2016, March). A review of supervised machine learning algorithms. In *2016 3rd international conference on computing for sustainable global development (INDIACom)*, 1310-1315. Ieee.
- Singh, R., Chen, Z., & Sriram, M. (2021). Data-driven predictive maintenance in the automotive industry. *Automotive Engineering Journal*, 48(6), 334-346.
- Smith, P., & Allen, R. (2020). Implementing descriptive maintenance in manufacturing. *Manufacturing Engineering Journal*, 65(3), 145-158.
- Sunetcioglu, S., & Arsan, T. (2024). *Predictive maintenance analysis for industries*. IEEE International Black Sea Conference on Communications and Networking (BlackSeaCom).
- Surden, H. (2021). Machine learning and law: An overview. *Research Handbook on Big Data Law*, 171-184.
- Susto, G. A., Schirru, A., Pampuri, S., & McLoone, S. (2015). Machine learning for predictive maintenance: A comprehensive review. *IEEE Transactions on Automation Science and Engineering*, 12(4), 1141-1152.
- 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.
- 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.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT press.
- Şahin, T. (2022). *Dizel makinanın makina öğrenmesi yöntemi kullanılarak modellenmesi ve karar-destek mekanizması oluşturulması* (Yayınlanmamış Doktora Tezi). İstanbul Teknik Üniversitesi. İstanbul.
- Şimşek, M. (2024). *Dünya'nın manyetik alanında nükleer manyetik rezonans (ef-nmr) spektrometresi ölçüm verilerinin sinyal işleme ve makine öğrenme teknikleri kullanılarak analizi ile madde tayini ve tespiti* (Yayınlanmamış Yüksek Lisans Tezi), Marmara Üniversitesi.
- Tan, O., Özçoban, M. A., & Aydın, S. (2016, October). Classification of EEG synchronization values of obsessive compulsive disorders patients using support vector machine method. In *2016 Medical Technologies National Congress (TIPTEKNO)*, 1-4. IEEE.

Theodoridis, S. (2015). *Machine learning: a Bayesian and optimization perspective*. Academic press.

Tuna, M. F. (2023). Mobil uygulama müşteri geri bildirimindeki duyguların makine öğrenmesi yöntemleriyle sınıflandırılması. *Journal of Business and Communication Studies*, 1(1 (1)), 83-103.

Turdahev, N. (2018). *Destek vektör makineleri ile otel öneri sistemi* (Yayınlanmamış Yüksek Lisans Tezi), Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü.

Ucar, A., Karakose, M., & Kırımça, N. (2024). Artificial intelligence for predictive maintenance applications: key components, trustworthiness, and future trends. *Applied Sciences*, 14(2), 898.

Uysal, A. K., & Gunal, S. (2014). The impact of preprocessing on text classification. *Information Processing & Management*, 50(1), 104-112.

Ünlü, V. (2021). *Demand Forecasting with Machine Learning Algorithm: Implementation in a Production Facility* (Yayınlanmamış Doktora Tezi), Ankara Yıldırım Beyazıt Üniversitesi Fen Bilimleri Enstitüsü.

Van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine Learning*, 109(2), 373-440.

Wang, H., Lei, Z., Zhang, X., Zhou, B., & Peng, J. (2016). Machine learning basics. *Deep learning*, 98-164.

Wang, L., Peng, J., & Liu, Z. (2022). The future of predictive maintenance: From deep learning to edge computing. *Future Computing Systems*, 12(1), 102-119.

Wei, J., Chu, X., Sun, X. Y., Xu, K., Deng, H. X., Chen, J., ... & Lei, M. (2019). Machine learning in materials science. *InfoMat*, 1(3), 338-358.

Widodo, A., & Yang, B. S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574.

Wilson, R., & Green, T. (2019). Integrating descriptive and predictive maintenance in energy systems. *Energy Engineering Review*, 34(2), 180-195.

Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data mining: Practical machine learning tools and techniques*. Elsevier.

- Wong, W. F., Olanrewaju, A., & Lim, P. I. (2022). Key determinants of building maintenance in hospitals: the perspective of maintenance personnel. *Facilities*, 40(13/14), 879-894.
- Xu, R., & Wunsch, D. (2005). Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645-678.
- Yahyaoui, A. (2017). *Göğüs hastalıklarının teşhis edilmesinde makine öğrenmesi algoritmalarının kullanılması* (Yayınlanmamış Doktora Tezi), Sakarya Üniversitesi.
- Yaman, G., Karadayı, H., (2014). Titreşim Analizi ile Pompalarda Arıza Tesbiti ve Kestirimci Bakım İçin Örnek Bir Çalışma. *Tesisat Mühendisliği Dergisi*, 140, İstanbul.
- Yan, J., & Lee, J. (2005). Degradation assessment and fault modes classification using logistic regression. *Journal of Manufacturing Science and Engineering*, 127(4), 912-917.
- Yao, Z., Lum, Y., Johnston, A., Mejia-Mendoza, L. M., Zhou, X., Wen, Y., ... & Seh, Z. W. (2023). Machine learning for a sustainable energy future. *Nature Reviews Materials*, 8(3), 202-215.
- Yetginler, B., & Atacak, I. (2020). Makine öğrenmesi yöntemleri ile film yorumlarından duygu analizi. *Artificial Intelligence*, 3(2), 1-12.
- Yetiz, F., Terzioğlu, M., & Kayakuş, M. (2021). Makina öğrenmesi yöntemleri ile Türk mevduat bankalarının müşteri tahminine yönelik bir uygulama. *Sosyoekonomi*, 29(50), 413-432.
- Yıldırım, A., & Arıkan, M. (2021). Predictive maintenance for heavy industry using IoT. *International Journal of IoT and Industrial Applications*, 6(4), 177-189.
- Yılmaz, C. B., Bodu, H., Yüce, E. S., Demir, V., & Sevimli, M. F. (2023). Türkiye'nin uzun dönem ortalama sıcaklık (°C) değerlerinin üç farklı enterpolasyon yöntemi ile tahmini. *Geomatik*, 8(1), 9-17.
- Yiğın, B. (2023). *A Prescriptive Analytics Approach Towards Critical Ship Machinery Operations* (Yayımlanmamış Doktora Tezi). İstanbul Teknik Üniversitesi, İstanbul.
- Yüksel, S. (2016). Türkiye'de cari işlemler açığının belirleyicileri: Mars yöntemi ile bir inceleme. *Bankacılar Dergisi*, 96(27), 102-121.
- Yürek, Ö. E. (2024). *Kestirimci Bakım İçin Makine Öğrenmesi Tekniklerinin Uygulanması* (Yayımlanmamış Doktora Tezi). Dokuz Eylül Üniversitesi, İzmir.

- Zaki, M. J., & Meira Jr., W. (2014). *Data mining and analysis: Fundamental concepts and algorithms*. Cambridge University Press.
- Zaki, M. J., Meira Jr, W., & Meira, W. (2020). *Data mining and machine learning: Fundamental concepts and algorithms*. Cambridge University Press.
- Zero, E., Sallak, M., & Sacile, R. (2024). Predictive Maintenance in IoT-Monitored Systems for Fault Prevention. *Journal of Sensor and Actuator Networks*, 13(5), 57.
- Zhang, Y., & Lee, J. (2015). A review on data-driven predictive maintenance approaches. *Journal of Manufacturing Systems*, 37, 112-127.
- Zhou, X., Xi, L., Lee, J. (2007). Reliability centered predictive maintenance scheduling for a continuously monitored system subject to degradation. *Reliability Engineering & System Safety*, 92, 530-534, China.
- Zhou, Z. H. (2016). Learnware: on the future of machine learning. *Frontiers Comput. Sci.*, 10(4), 589-590.
- Zhou, Z. H. (2021). *Machine learning*. Springer Nature.
- Zhu, X. (2005). Semi-supervised learning literature survey. *Computer Sciences Technical Report*, 1530.
- Zhu, X., & Goldberg, A. B. (2009). *Introduction to semi-supervised learning*. Morgan & Claypool.
- Zonta, T., Aliakbarisani, S., & Pant, A. (2020). Predictive maintenance in Industry 4.0 using machine learning algorithms. *Journal of Industrial Engineering and Management*, 13(2), 291-310.
- Zonta, T., Da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S., & Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 150, 106889.
- Züfle, M., Agne, J., Grohmann, J., Dörtoluk, I., & Kounev, S. (2021, July). A predictive maintenance methodology: Predicting the time-to-failure of machines in Industry 4.0. In *2021 IEEE 19th International Conference on Industrial Informatics (INDIN)*, 1-8. IEEE.

EKLER

Python Jupyter Notebook Kodları

Kütüphanelerin İçe Aktarılması

```
import pandas as pd
import numpy as np
import seaborn as sns
from datetime import datetime, timedelta
from matplotlib import pyplot as plt
from dython.nominal import associations
from pycaret.classification import *
params = {'axes.titlesize':'8',
          'xtick.labelsize':'7',
          'ytick.labelsize':'7'}
plt.rcParams.update(params)
sns.set_theme(style='darkgrid')
```

Excel Dosyasının Okunması

```
fail_times = pd.read_excel('2MCT134_Arıza_Veri_(20.05.2024 - 20.08.2024).xlsx',
sheet_name='fails')
fail_times['Başlangıç Zamanı'] = pd.to_datetime(fail_times['Başlangıç Zamanı'])
fail_times['Bitiş Zamanı'] = pd.to_datetime(fail_times['Bitiş Zamanı'])
fail_times.head()

fail_times.groupby(['Duruş Adı'])['Makine'].count()

hsa_fail_times = fail_times[fail_times['Duruş Kodu'] == 864].reset_index(drop=True)
hsa_fail_times

hsa_fail_times = hsa_fail_times[hsa_fail_times['RefNo'] != 67500284]
```

```

df = pd.read_csv("2MCT134_Data.csv", sep=";", encoding="windows-1254")
df["Rec_Time"] = pd.to_datetime(df["Rec_Time"])
df.head()

df.info()

df.isna().sum()

desc_stats = pd.DataFrame(df.describe().T)
# desc_stats.to_csv("desc_stats.csv")
np.round(desc_stats, decimals=3)

pm_data = df.copy()
pm_data.drop(["2MCT_ID", "SET_TC1", "MTC_PID_SetPoint", "EsenjorSicaklik_Set",
"EsenjorSicaklik_Act", "ENVIROMENT_HUMIDITY",
"ENVIROMENT_TEMPERATURE"], axis=1, inplace=True)
pm_data.set_index('Rec_Time', inplace=True)
pm_data = pm_data.resample('60S').mean()
pm_data.dropna(inplace=True)
pm_data.reset_index(inplace=True)
pm_data['Rec_Time'] = pd.to_datetime(pm_data["Rec_Time"])
pm_data.shape

pm_data['IS_HSA'] = 0
pm_data['FailNo'] = 0

for r, row in hsa_fail_times.iterrows():

    print(row[0], row[10], row[11])
    pm_data['IS_HSA'] = np.where(pm_data['Rec_Time'].between(row[10], row[10] +
timedelta(seconds=60)), 1, pm_data['IS_HSA'])

```

```

pm_data['IS_HSA'] = np.where(pm_data['Rec_Time'].between(row[10] +
timedelta(seconds=60), row[11]), -1, pm_data['IS_HSA'])
pm_data['FailNo'] = np.where(pm_data['Rec_Time'].between(row[10], row[11]), row[0],
pm_data['FailNo'])

```

```

pm_data.FailNo.unique()
pm_data_ = pm_data[pm_data['IS_HSA'] >= 0].copy()
pm_data_[pm_data_['IS_HSA'] == 1]
pm_data_.drop('FailNo', axis=1, inplace=True)

```

```

desc_stats = pd.DataFrame(pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).describe().T)
# desc_stats.to_csv("desc_stats.csv")
np.round(desc_stats, decimals=3)

```

```

pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).hist(figsize=(20,20))

```

```

pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).iloc[:, 0:8].plot(kind='box', sharex=False,
sharey=False, subplots=True, figsize=(20,5))

```

```

pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).iloc[:, 8:].plot(kind='box', sharex=False,
sharey=False, subplots=True, figsize=(20,5))

```

```

def ReplaceIQR(data):
    q1 = data.quantile(0.25)
    q3 = data.quantile(0.75)
    IQR = 1.5*(q3 - q1)
    _lower = q1 - IQR
    _upper = q3 + IQR
    data = np.where(data > _upper, _upper, np.where(data < _lower, _lower, data))
    print(_lower, _upper)
    return data

```

```

replace_iqr_cols = pm_data_.drop(['IS_HSA', 'Rec_Time', 'CevreRezistant_Akim',
                                   'GobekRezistant_Akim'], axis=1).columns

for col in replace_iqr_cols:
    pm_data_[col] = ReplaceIQR(data=pm_data_[col])

desc_stats = pd.DataFrame(pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).describe().T)
# desc_stats.to_csv("desc_stats.csv")
np.round(desc_stats, decimals=3)

pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).hist(figsize=(20,15))

pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).iloc[:, 0:8].plot(kind='box', sharex=False,
sharey=False, subplots=True, figsize=(20,5))

pm_data_.drop(['Rec_Time', 'IS_HSA'], axis=1).iloc[:, 8:].plot(kind='box', sharex=False,
sharey=False, subplots=True, figsize=(20,5))

pm_data_['CevreRezistant_Akim'] = pm_data_['CevreRezistant_Akim'].apply(lambda x: 'I <
1' if x < 6 else 'I >= 1')
pm_data_['GobekRezistant_Akim'] = pm_data_['GobekRezistant_Akim'].apply(lambda x: 'I <
6' if x < 6 else 'I >= 6')

pm_data_['F1_Akim'] = "
pm_data_.loc[pm_data_['Faz_1_Akim'] < 20, 'F1_Akim'] = 'I < 20'
pm_data_.loc[(pm_data_['Faz_1_Akim'] >= 20) & (pm_data_['Faz_1_Akim'] <= 60),
'F1_Akim'] = 'I = 20-60'
pm_data_.loc[pm_data_['Faz_1_Akim'] > 60, 'F1_Akim'] = 'I > 60'
pm_data_.drop('Faz_1_Akim', axis=1, inplace=True)

pm_data_['F2_Akim'] = "
pm_data_.loc[pm_data_['Faz_2_Akim'] < 20, 'F2_Akim'] = 'I < 20'
pm_data_.loc[(pm_data_['Faz_2_Akim'] >= 20) & (pm_data_['Faz_2_Akim'] <= 60),
'F2_Akim'] = 'I = 20-60'

```

```

pm_data_.loc[pm_data_['Faz_2_Akim'] > 60, 'F2_Akim'] = 'I > 60'
pm_data_.drop('Faz_2_Akim', axis=1, inplace=True)

pm_data_['F3_Akim'] = ""
pm_data_.loc[pm_data_['Faz_3_Akim'] < 20, 'F3_Akim'] = 'I < 20'
pm_data_.loc[(pm_data_['Faz_3_Akim'] >= 20) & (pm_data_['Faz_3_Akim'] <= 60),
'F3_Akim'] = 'I = 20-60'
pm_data_.loc[pm_data_['Faz_3_Akim'] > 60, 'F3_Akim'] = 'I > 60'
pm_data_.drop('Faz_3_Akim', axis=1, inplace=True)

machine_fails = pm_data_.reset_index(drop=True).copy()
machine_fails

fail_times = machine_fails[machine_fails['IS_HSA'] > 0]

fail_times

fail_indexes = machine_fails[machine_fails['IS_HSA'] == 1].index.to_list()

train_test_data = machine_fails[machine_fails.index <= fail_indexes[3]]
valid_data = machine_fails[(machine_fails.index > fail_indexes[3])]

fail_indexes

train_idx = train_test_data[train_test_data['IS_HSA'] == 1].index.to_list()
valid_idx = valid_data[valid_data['IS_HSA'] == 1].index.to_list()

for i in train_idx:
    if i == train_idx[0]:
        fail_data = train_test_data[train_test_data.index <= i].copy()
        t_max = fail_data.Rec_Time.max()
        fail_data["RemainingFailTime"] = (t_max - fail_data.Rec_Time).dt.total_seconds()
    else:
        temp_df = train_test_data[train_test_data.index <= i].copy()

```

```

t_max = temp_df.Rec_Time.max()
temp_df["RemainingFailTime"] = (t_max - temp_df.Rec_Time).dt.total_seconds()
fail_data = pd.concat([fail_data, temp_df], axis=0)

for i in valid_idx:
    if i == valid_idx[0]:
        valid_data_ = valid_data[valid_data.index <= i].copy()
        t_max = valid_data_.Rec_Time.max()
        valid_data_["RemainingFailTime"] = (t_max - valid_data_.Rec_Time).dt.total_seconds()
    else:
        temp_df = valid_data[valid_data.index <= i].copy()
        t_max = temp_df.Rec_Time.max()
        temp_df["RemainingFailTime"] = (t_max - temp_df.Rec_Time).dt.total_seconds()
        valid_data_ = pd.concat([valid_data_, temp_df], axis=0)

associations(fail_data.drop(['Rec_Time', 'IS_HSA', 'CevreRezistant_Akim'], axis=1),
figsize=(12,12), )

corr_matrix = np.round(fail_data.drop(['Rec_Time', 'IS_HSA', 'CevreRezistant_Akim',
'GobekRezistant_Akim', 'F1_Akim', 'F2_Akim', 'F3_Akim'], axis=1).corr(), decimals=2)

corr_matrix.iloc[:, -1:]

signif_vars = corr_matrix.iloc[:, -1:].copy()
signif_vars_list =
signif_vars[np.abs(signif_vars['RemainingFailTime'])>=0.05].index.to_list()
signif_vars_list.append('Rec_Time')
signif_vars_list.append('CevreRezistant_Akim')
signif_vars_list.append('GobekRezistant_Akim')
signif_vars_list.append('F1_Akim')
signif_vars_list.append('F2_Akim')
signif_vars_list.append('F3_Akim')
fail_data_ = fail_data[signif_vars_list]
fail_data_.head()

```

```

fail_data_.iloc[:, :-7].hist(figsize=(20,8))

sns.pairplot(data=fail_data_.iloc[:, :-7])

_fail_data = fail_data_.copy()
_fail_data.iloc[:, :-7:].describe()

_fail_data['RemainingFailTime_H'] = _fail_data['RemainingFailTime'] / 3600
_fail_data['RemainingFailTime_H'].hist()

_fail_data['FailTimeClass'] = 'L360h'

_fail_data.loc[_fail_data['RemainingFailTime_H'] > 360, 'FailTimeClass'] = 'U360h'
# _fail_data.loc[( _fail_data['RemainingFailTime_H'] > 240) &
# (_fail_data['RemainingFailTime_H'] <= 480), 'FailTimeClass'] = 2
# _fail_data.loc[( _fail_data['RemainingFailTime_H'] > 400) &
# (_fail_data['RemainingFailTime_H'] <= 650), 'FailTimeClass'] = 2
# _fail_data.loc[_fail_data['RemainingFailTime_H'] > 480, 'FailTimeClass'] = 3
_fail_data.reset_index(drop=True, inplace=True)
_fail_data.head()

valid_data_['RemainingFailTime_H'] = valid_data_['RemainingFailTime'] / 3600

valid_data_['FailTimeClass'] = 'L360h'
valid_data_.loc[valid_data_['RemainingFailTime_H'] > 360, 'FailTimeClass'] = 'U360h'
# valid_data_.loc[(valid_data_['RemainingFailTime_H'] > 240) &
# (valid_data_['RemainingFailTime_H'] <= 480), 'FailTimeClass'] = 2
# valid_data_.loc[(valid_data_['RemainingFailTime_H'] > 400) &
# (valid_data_['RemainingFailTime_H'] <= 650), 'FailTimeClass'] = 2
# valid_data_.loc[valid_data_['RemainingFailTime_H'] > 480, 'FailTimeClass'] = 3
valid_data_.reset_index(drop=True, inplace=True)
valid_data_.head()

```

```
model = setup(data=_fail_data.reset_index(drop=True), target='FailTimeClass', pca=True,
pca_components=0.85, index=False,
               categorical_features=['CevreRezistant_Akim', 'GobekRezistant_Akim', 'F1_Akim',
'F2_Akim', 'F3_Akim'],
               normalize=True, normalize_method='zscore', ignore_features=['Rec_Time',
'RemainingFailTime_H', 'RemainingFailTime'],
               fold=5, n_jobs=3, train_size=0.75)
```

Logistic Regression

```
lr_model = create_model('lr', fold=5, cross_validation=True)
evaluate_model(lr_model)
```

Parametre Optimizasyonu

```
t_lr_model = tune_model(lr_model, fold=5)
evaluate_model(t_lr_model)
f_lr_model = finalize_model(t_lr_model)
predict_model(f_lr_model, data=valid_data_)
```

Linear Discriminant Analysis

```
lda_model = create_model('lda', fold=5, cross_validation=True)
evaluate_model(lda_model)
```

Parametre Optimizasyonu

```
t_lda_model = tune_model(lda_model, fold=5)
evaluate_model(t_lda_model)
f_lda_model = finalize_model(t_lda_model)
predict_model(estimator=t_lda_model, data=valid_data_)
```

KNN Model

```
knn_model = create_model('knn', fold=5, cross_validation=True)
evaluate_model(knn_model)
```

Parametre Optimizasyonu

```
t_knn_model = tune_model(knn_model, fold=5)
evaluate_model(t_knn_model)
f_knn_model = finalize_model(t_knn_model)
predict_model(estimator=knn_model, data=valid_data_)
```

Xgboost Model

```
xgboost_model = create_model('xgboost', fold=5, cross_validation=True)
evaluate_model(xgboost_model)
```

Parametre Optimizasyonu

```
t_xg_model = tune_model(xgboost_model, fold=5)
evaluate_model(t_xg_model)
f_xg_model = finalize_model(t_xg_model)
predict_model(t_xg_model, data=valid_data_)
```

LightGBM Model

```
light_gbm = create_model('lightgbm', cross_validation=True, fold=5)
evaluate_model(light_gbm)
```

Parametre Optimizasyonu

```
t_lg_model = tune_model(light_gbm, fold=5)
evaluate_model(t_lg_model)
f_lg_model = finalize_model(t_lg_model)
predict_model(f_lg_model, data=valid_data_)
```

SVM Model

```
svm_model = create_model('svm', cross_validation=True, fold=5)
evaluate_model(svm_model)
```

Parametre Optimizasyonu

```
t_svm_model = tune_model(svm_model, fold=5)
evaluate_model(t_svm_model)
f_svm_model = finalize_model(t_svm_model)
predict_model(f_svm_model, data=valid_data_)
```

MLP Model (Yapay Sinir Ağı)

```
mlp_model = create_model('mlp', cross_validation=True, fold=5)
evaluate_model(mlp_model)
```

Parametre Optimizasyonu

```
t_mlp_model = tune_model(mlp_model, fold=5)
evaluate_model(t_mlp_model)
f_mlp_model = finalize_model(t_mlp_model)
predict_model(f_mlp_model, data=valid_data_)
```

ÖZGEÇMİŞ

Eskişehir Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü'nden 2007 yılında mezun olmuştur. Daha sonra G. Üniversitesi Sosyal Bilimler Enstitüsü İşletme yüksek lisans programından 2014 yılında mezun olmuştur. Muğla Sıtkı Koçman Üniversitesinde 2015 yılında Öğretim Görevlisi olarak göreve başlamıştır. 2019 yılında Ege Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı'nda doktora programına başlamıştır.

