

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**MAKİNE ÖĞRENMESİ KULLANILARAK ENDÜSTRİYEL PRES
MAKİNESİ İÇİN KESTİRİMCİ BAKIM UYGULAMASI**

ERKUT YİĞİT

KOCAELİ 2021

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**MAKİNE ÖĞRENMESİ KULLANILARAK ENDÜSTRİYEL
PRES MAKİNESİ İÇİN KESTİRİMCİ BAKIM UYGULAMASI**

ERKUT YİĞİT

Doç.Dr. Mehmet Zeki BİLGİN
Danışman, Kocaeli Üniv.

.....

Prof.Dr. Nejat YUMUŞAK
Jüri Üyesi, Sakarya Üniv.

.....

Dr.Öğr.Üyesi Tarık ERFİDAN
Jüri Üyesi, Kocaeli Üniv.

.....

Tezin Savunulduğu Tarih: 25.06.2021

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında, endüstriyel pres makinesinden anlık olarak toplanan veriler ile arıza teşhisi yapabilmek için çalışmalar yapılmıştır. Toplanan verilerden makine öğrenmesi algoritmaları ile arıza modellemeleri yapılmış, bu sayede kestirimci bakım çalışmaları gerçekleştirilmiştir.

Bu çalışmanın yürütülmesi sırasında değerli yardım ve yönlendirmelerini esirgemeyen, çalışmalarına yön veren ve bana güvenen danışmanım Doç.Dr. Mehmet Zeki BİLGİN'e sonsuz teşekkürlerimi sunarım.

Akademik çalışmalarımı gerçekleştirmem konusunda beni teşvik ederek destekleri ile yanımda olan Toyotetsu Otomotiv A.Ş. çalışanlarına teşekkürlerimi sunarım.

Yüksek lisans sürecimde ve hayatımın her anında sabır ve anlayışıyla her zaman yanımda olan eşim Burcu TOKLU YİĞİT'e, bu süreçte çalışmama izin verdiği için motivasyon kaynağım oğlum Uraz Efe YİĞİT'e ve her zaman koşulsuz yanımda olduklarını bildiğim annem ve babama teşekkür ederim.

Mayıs – 2021

Erkut YİĞİT

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
TABLolar DİZİNİ	iv
SİMGELER VE KISALTMALAR DİZİNİ	v
ÖZET.....	vii
ABSTRACT.....	viii
GİRİŞ	1
1. BAKIM VE KESTİRİMCİ BAKIM	3
1.1. Bakım Yaklaşımları	3
1.1.1. Düzeltici bakım	4
1.1.2. Önleyici bakım	4
1.1.3. Kestirimci bakım	5
1.2. Kestirimci Bakım Yöntemleri.....	6
1.2.1. Titreşim ölçümü.....	6
1.2.2. Termal ölçüm.....	7
1.2.3. Yağ analizi.....	7
1.2.4. Ultrasonik ölçüm.....	7
1.3. Makine Öğrenmesi Yöntemleriyle Kestirimci Bakım	8
2. MAKİNE ÖĞRENMESİ.....	12
2.1. Denetimli Öğrenme.....	13
2.1.1. Sınıflandırma yöntemi	13
2.1.1.1. Naive bayes algoritması	14
2.1.1.2. K-en yakın komşu algoritması	14
2.1.1.3. Destek vektör makineleri algoritması	15
2.1.1.4. Karar ağacı algoritmaları.....	16
2.1.1.5. Rastgele orman algoritması.....	17
2.1.2. Regresyon yöntemi	18
2.2. Denetimsiz Öğrenme	18
2.2.1. Kümeleme yöntemi.....	19
2.2.1.1. K-means algoritması	19
2.2.1.2. Hiyerarşik kümeleme algoritması	20
2.2.2. Boyut azaltma	21
2.3. Özellik Mühendisliği	21
2.3.1. Öznitelik seçimi	22
2.3.2. Öznitelik çıkarımı	22
2.4. Model Performansının Değerlendirilmesi.....	23
3. MATERYAL VE YÖNTEM	26
3.1. Endüstriyel Pres Makinelerinin Yapısı	27
3.2. Arıza Analizi ve Algılayıcı Seçimi	29
3.3. Verilerin Toplanması ve Görselleştirilmesi	32
3.4. Veri Analizi ve Sistem Mimarisi Tasarımı	35
3.5. Makine Öğrenmesi Modelinin Oluşturulması	36

4. BULGULAR VE TARTIŞMA	38
4.1. Hidrolik Pompa Motor Makine Öğrenmesi Modeli.....	38
4.1.1. Hidrolik pompa arızası	45
4.2. Yağlama Motoru Makine Öğrenmesi Modeli.....	46
5. SONUÇLAR VE ÖNERİLER	53
KAYNAKLAR	55
EKLER.....	61
KİŞİSEL YAYINLAR VE ESERLER	65
ÖZGEÇMİŞ	66



ŞEKİLLER DİZİNİ

Şekil 1.1.	Bakım Türleri (EN-13306: 2017'ye göre)	3
Şekil 1.2.	Kestirimci bakım akış şeması.....	5
Şekil 2.1.	Makine öğrenmesi aşamaları.....	12
Şekil 2.2.	K-en yakın komşu örneği	15
Şekil 2.3.	Destek vektörü ve hiper düzlem.....	16
Şekil 2.4.	Karar ağacı yapısı örneği.....	17
Şekil 2.5.	K-means kümeleme örneği.....	19
Şekil 2.6.	Hiyerarşik kümeleme dendogram örneği	20
Şekil 2.7.	AUC – ROC Eğrisi.....	25
Şekil 3.1.	Çalışma yapılan transfer pres makinesi.....	28
Şekil 3.2.	Titreşim ve sıcaklık sensörü	31
Şekil 3.3.	Çalışma yapılan sensörlerin montajı	32
Şekil 3.4.	Gerçek zamanlı sıcaklık ve titreşim sensör verileri	33
Şekil 3.5.	Yağ kirlilik ölçüm cihazı ve parametreleri.....	34
Şekil 3.6.	Veri analiz ve kestirimci bakım sistem mimarisi	36
Şekil 3.7.	Makine öğrenmesi model oluşturma akış şeması.....	36
Şekil 4.1.	Hidrolik pompa motoru ilk 5 veri örneği	38
Şekil 4.2.	Hidrolik pompa motoru arıza verisi etiketlenmesi	39
Şekil 4.3.	Hidrolik pompa motoru korelasyon matrisi	39
Şekil 4.4.	Hidrolik pompa motoru öznitelik seçimi	40
Şekil 4.5.	Hidrolik pompa motoru 1.arıza titreşim ve sıcaklık verileri dağılımı.....	40
Şekil 4.6.	Hidrolik pompa motoru verilerinin dağılım grafipleri	41
Şekil 4.7.	Hidrolik pompa motoru modelleri karışıklık matrisi	42
Şekil 4.8.	Hidrolik pompa motoru model performansları	44
Şekil 4.9.	Hidrolik pompa motoru 2.arıza ilk 5 veri örneği	45
Şekil 4.10.	Hidrolik pompa motoru 2. arıza verisi etiketlenmesi.....	45
Şekil 4.11.	Hidrolik pompa motoru 2.arıza titreşim ve sıcaklık verileri dağılımı.....	45
Şekil 4.12.	Hidrolik pompa motoru 2. arıza model başarısı	46
Şekil 4.13.	Yağlama motoru ilk 5 veri örneği	46
Şekil 4.14.	Yağlama motoru arıza verisi etiketlenmesi.....	47
Şekil 4.15.	Yağlama motoru korelasyon matrisi	47
Şekil 4.16.	Yağlama motoru öznitelik seçimi	48
Şekil 4.17.	Yağlama motoru titreşim ve 4 µm partikül verileri dağılımı	49
Şekil 4.18.	Yağlama motoru modelleri karışıklık matrisi	50
Şekil 4.19.	Yağlama motoru model performansları	52

TABLULAR DİZİNİ

Tablo 1.1. Makine öğrenmesi yöntemleriyle kestirimci bakım.....	8
Tablo 2.1. Karışıklık matrisi.....	24
Tablo 3.1. Pres makinesi motor bilgileri	28
Tablo 3.2. Arızalar ve kestirimci bakım ekipmanları.....	29
Tablo 3.3. Titreşim sensörü verileri ve arıza teşhisi.....	30
Tablo 3.4. Titreşim limitleri (ISO 10816-3'e göre).....	32
Tablo 3.5. Partikül sayısına göre yağ kirlilik seviyesi (ISO 4406'e göre)	34
Tablo 3.6. Gerçek zamanlı yağ kirlilik ölçüm verileri	35
Tablo 4.1. Hidrolik pompa motoru model performans özet tablosu	44
Tablo 4.2. Yağlama motoru model performans özet tablosu	51

SİMGELER VE KISALTMALAR DİZİNİ

f	: Cismin frekansı (Hz)
g	: Yer çekimi ivmesi (m/s^2)
t	: Zaman (sn)
μ	: Mikron

Kısaltmalar

ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
AUC	: Area Under Curve (Eğri Altındaki Alan)
BBA	: Bağımsız Bileşen Analizi
CART	: Classification And Regression Trees (Sınıflandırma ve Regresyon Ağacı)
DDA	: Doğrusal Diskriminant Analizi
DN	: Doğru Negatif
DP	: Doğru Pozitif
DT	: Decision Tree (Karar Ağacı)
DVM	: Destek Vektör Makineleri
IoT	: Internet of Things (Nesnelerin İnterneti)
IIoT	: Industrial Internet of Things (Endüstriyel Nesnelerin İnterneti)
ISO	: International Organization for Standardization (Uluslararası Standartlar Teşkilatı)
JIT	: Just in Time (Tam Zamanlı Üretim)
KNN	: K-Nearest Neighbor (K-En Yakın Komşuluk)
kW	: Kilowatt
LR	: Logistic Regression (Lojistik Regresyon)
ML	: Machine Learning (Makine Öğrenmesi)
PCA	: Principal Components Analysis (Temel Bileşenler Analizi)
PdM	: Predictive Maintenance (Kestirimci Bakım)
PLC	: Programmable Logic Control (Programlanabilir Lojik Kontrol)
RF	: Random Forest (Rastgele Orman)
RMS	: Root Mean Square (Etkin Değer)
ROC	: Receiver Operating Characteristics (Alıcı İşletim Karakteristiği)
rpm	: Revolutions Per Minute (Dakikadaki Devir Sayısı)
TBA	: Temel Bileşenler Analizi
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

MAKİNE ÖĞRENMESİ KULLANILARAK ENDÜSTRİYEL PRES MAKİNESİ İÇİN KESTİRİMCİ BAKIM UYGULAMASI

ÖZET

Endüstri 4.0 uygulamalarının temel amacı üretim zinciri boyunca maksimum çalışma süresini sağlamak, üretim maliyetlerini düşürmek ve verimliliği artırmaktır. Endüstri 4.0 teknolojilerinden olan Büyük Veri, Nesnelerin İnterneti (IoT) ve Makine Öğrenmesi (ML) sayesinde Kestirimci Bakım çalışmaları hız kazanmıştır. Endüstride Kestirimci Bakım uygulamak, bakım ve onarım süresi uzun süren arıza sayısını azaltmakta, üretim kayıplarını ve maliyetlerini minimum seviyeye indirmektedir.

Makine öğrenmesinin kullanımıyla, ekipmanlarda bilinmeyen sebeplerle yaşanan arızalar ve ekipmanın bakım ihtiyacı tahmin edilebilmektedir. Makine öğrenmesi ile tahmin modelleri oluşturmak için doğru bilgi toplamak ve farklı sistemlerden gelen birçok veriyi kullanabilmek gerekmektedir. Kestirimci bakımla ilgili büyük miktardaki verinin varlığı ve gerçek zamanlı bu verileri izleme ihtiyacı, veri toplarken yaşanan gecikmeler, ağ ve sunucu problemleri bu süreçte yaşanan büyük zorluklardır. Bir diğer önemli hususta yapay zekanın kullanımı ile ilgilidir. Örneğin eğitim verilerini elde etme, değişken çevre şartları ile başa çıkma, belirli bir senaryoya daha iyi uyan ML algoritmasının seçilmesi, operasyonel koşullara ve üretim ortamına duyarlı bilginin gerekliliği yapılacak analizler için büyük önem taşımaktadır.

Bu çalışmada otomotiv endüstrisinde kullanılan transfer pres makinesi için bakım ihtiyacı zamanı tahmininde bulunan ve anormal durumlar yaklaştığında ilgili kişilere uyarı mesajı verebilen kestirimci bakım çalışmaları incelenmiştir. Öncelikle makineye geçmişte meydana gelen arızaların tespitine yönelik çeşitli sensörler yerleştirilmiş ve bu sensörlerden hangi verilerin toplanacağı belirlenmiştir. Toplanan verilerle anomali tespiti yapabilmek ve geçmişteki arızaları modellemek için kullanılan makine öğrenmesi algoritmaları oluşturularak otomotiv parçaları üreten bir fabrikada uygulama yapılmıştır. Gerçek üretim koşullarında toplanan ham verilerin eksik ve yanlış kısımları temizlenerek model için hazır hale getirilmesi sağlanmıştır. Geçmişte yaşanan iki farklı motor arızası için veriler arızaya yakın ve arızaya uzak olarak etiketlenmiş, makine öğrenmesi algoritmaları ile arıza tahmini yapılmıştır. Kullanılan denetimli makine öğrenmesi algoritmalarından Rastgele Orman algoritması en yüksek performansı göstermiştir.

Anahtar Kelimeler: Endüstriyel Nesnelerin İnterneti, Kestirimci Bakım, Makine Öğrenmesi, Otomotiv Endüstrisi.

PREDICTIVE MAINTENANCE APPLICATION FOR INDUSTRIAL PRESS MACHINE USING MACHINE LEARNING

ABSTRACT

The main purpose of Industry 4.0 applications is to provide maximum uptime throughout the production chain, to reduce production costs and to increase productivity. Thanks to Big Data, Internet of Things (IoT) and Machine Learning (ML), which are among the Industry 4.0 technologies, Predictive Maintenance studies have gained speed. Applying Predictive Maintenance in the industry reduces the number of breakdowns with long maintenance and repair times, and minimizes production losses and costs.

With the use of machine learning, malfunctions in equipment due to unknown reasons and the need for maintenance of the equipment can be predicted. In order to create prediction models with machine learning, it is necessary to collect accurate information and to use many data from different systems. The existence of a large amount of data related to predictive maintenance and the need to monitor this data in real time, delays in data collection, network and server problems are major difficulties in this process. Another important issue concerns the use of artificial intelligence. For example, obtaining training data, dealing with variable environmental conditions, choosing the ML algorithm better suited to a specific scenario, necessity of information sensitive to operational conditions and production environment are of great importance for analysis.

In this study, predictive maintenance studies for the transfer press machine used in the automotive industry, which can predict the maintenance need time and give warning messages to the relevant people when abnormal situations approach, are examined. First of all, various sensors have been placed in the machine for the detection of past malfunctions and it has been determined which data will be collected from these sensors. Then, machine learning algorithms used to detect anomalies with the collected data and model past failures were created and an application was made in a factory that produces automotive parts. The missing and incorrect parts of the raw data collected under real production conditions were cleaned and made ready for the model. For two different engine failures in the past, the data were labeled as near to failure and far from failure, and failure prediction was made with machine learning algorithms. Among the supervised machine learning algorithms used, the Random Forest algorithm showed the highest performance.

Keywords: Industrial Internet of Things-IIoT, Predictive Maintenance, Machine Learning, Automotive Industry.

GİRİŞ

Nesnelerin İnterneti (Internet of Things-IoT) teknolojisi, fiziksel nesnelerin birbirleriyle veya diğer sistemlerle veri alışverişi yapmak için bağlantılı olduğu iletişim ağıdır. Bu iletişim ağı cihazların ve bilgisayarların veri toplamasını ve paylaşmasını sağlamaktadır. Toplanan veriler yerel veritabanlarında veya bulut platformlarında depolanmaktadır. IoT sayesinde cihazlar uzaktan algılanmakta ve izlenebilmektedir. Endüstri ve IoT'nin birleştirilmesi ile birlikte Endüstriyel Nesnelerin İnterneti (Industrial Internet of Things-IIoT) kavramı da ortaya çıkmıştır. IIoT, makine verilerinin izlenmesini ve çeşitli sinyaller kullanarak makinenin kontrol edilmesini sağlar. Bu sayede üretim sürecini iyileştirmeye ve makinelerin bakım faaliyetlerini planlamaya yardımcı olur [1]. Şirketler verimliliklerini artırmak ve yönetsel kararları doğru şekilde verebilmek için gerçek zamanlı olarak sistemlerini izlemeye önem vermektedir [2].

Endüstride önemli olan bir diğer konu da makinelerin maliyet ve zaman açısından verimli bakımı ve onarımıdır. Bakım faaliyetlerini, ihtiyaç duyulan yedek parça, personel ve üretim kesinti sürelerini göz önünde bulundurarak çok iyi planlamak gerekmektedir [3]. Bunun için gerçek zamanlı olarak makine hakkında güvenilir ve doğru bilgiler sağlanması gerekir. Özellikle Tam Zamanlı Üretim (Just in Time-JIT), yani stoksuz üretim yapan fabrikalarda bu durum kritik önem taşımaktadır. Makine arızaları üretimi durdurma noktasına getirip sevkiyat problemlerine neden olmaktadır.

Uygulama yapılan makede, bakım ve onarım, geleneksel yöntemde deneyimli kişilerin bilgisi dahilinde yapılmakta ve bu kişiler bir makinenin bakıma ihtiyaç duyup duymadığını çeşitli faktörlerden (gürültü, titreşim, ısı, nem vb.) anlayabilmektedir. Sonradan ekipman ömürlerinin ne zaman biteceği ve belirlenen sınırlar içinde çalışıp çalışmadığını değerlendirmek için standartlara dayalı çeşitli kontroller eklenmiştir. Son yıllarda, kestirimci bakım olarak da bildiğimiz makine öğrenimi kullanan veriye dayalı yöntemler de sisteme eklenmiştir.

Bir transfer pres makinesi, farklı arıza türlerine sahip birçok farklı parçaya sahiptir. Arızalara genel olarak motor arızaları, mekanik aktarma organı ve dişli arızaları, dengesiz yükler, aşınma problemleri, metal yorgunluğu, sıcaklık değişimleri veya elektrikle ilgili problemler neden olmaktadır. Bu durum, birçok farklı parametrenin ölçülmesini ve analiz edilmesini gerektirmektedir. Pres makinesinin klasik bakım faaliyetleri, arıza yaşandıktan sonra hatalı parçaların tespitini ve depoda hazır tutulan yüksek maliyetli yedek parça stoğundan parçaların değiştirilmesi şeklinde yapılmaktadır. Bu süreç oldukça zaman alıcıdır, verimsizdir ve yüksek maliyetlere neden olmaktadır.

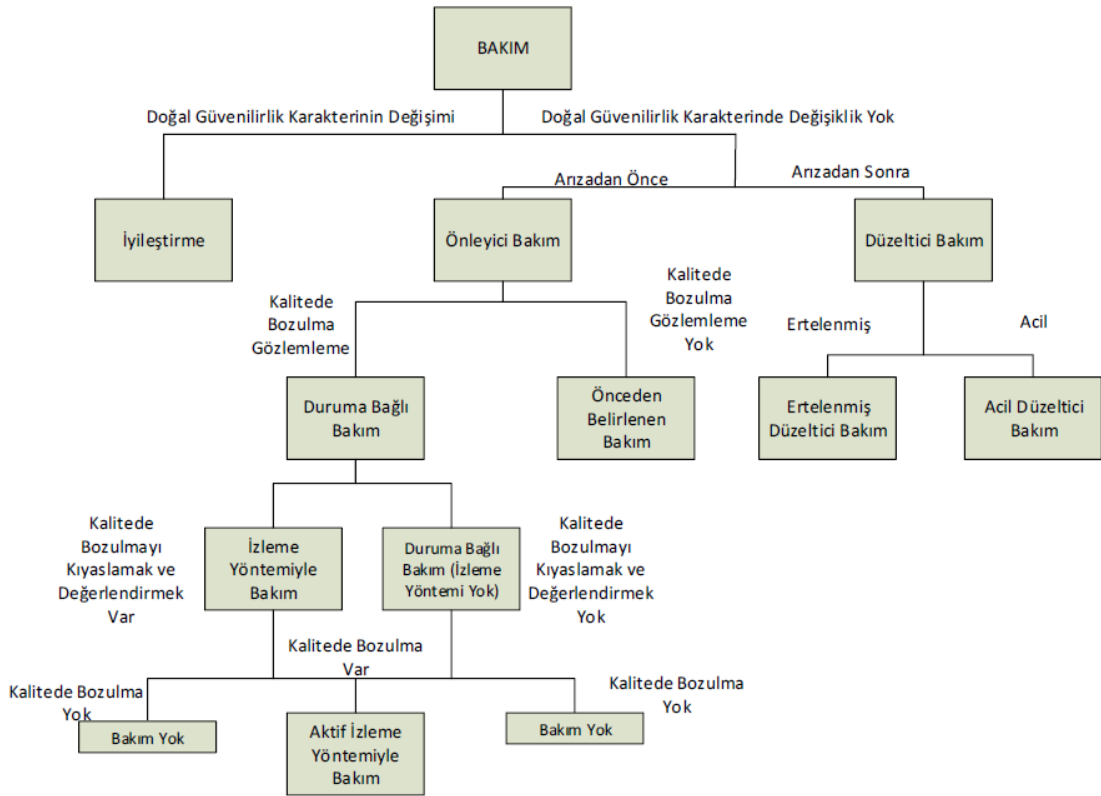
Tez kapsamında, otomotiv sac parçaları şekillendirme işlemini yapan endüstriyel transfer pres makinesindeki kestirimci bakım çalışmalarından bahsedilmektedir. Arıza zamanını tespit etmek için Makine Kontrolcüsü (Programmable Logic Controller-PLC) ve sensörlerden toplanan veriler Makine Öğrenmesi (Machine Learning-ML) algoritmaları ile analiz edilmektedir. Makine arızalanmadan önce arızalanacağı bilgisini otomatik olarak uyarı verecek bir sistem kurulması hedeflenmiştir. Makine öğrenmesi algoritmaları ile yapılan kestirimci bakım modellerinin sonuçları birbirleriyle ve literatürdeki diğer çalışmalar ile karşılaştırılmış, çalışmanın sonucunda en yüksek performans gösteren yöntem önerilmiştir.

Tez çalışmasının akışı şu şekilde düzenlenmiştir: Giriş bölümünde çalışmanın genel çerçevesinden bahsettikten sonra, tezin birinci bölümünde bakım türleri hakkında bilgi verilmiş, klasik bakım ve kestirimci bakım arasındaki farklara değinilmiş, kestirimci bakımın yöntemlerinden ve makine öğrenmesiyle yapılan kestirimci bakım çalışmalarından bahsedilmiştir. Bölüm 2 makine öğrenmesi yöntemleri konusunda literatür araştırmasını içermektedir. Bölüm 3'de arıza analizi, uygun algılayıcı seçimi ve veri analizi sistem mimarisinden bahsedilmiştir. Bölüm 4, pres makinesinden toplanan verilerin makine öğrenmesi algoritmaları ile modellerinin gerçekleştirildiği ve elde edilen sonuçların birbiriyle karşılaştırıldığı bölümdür. Yapılan karşılaştırmada performansı yüksek olan yöntemler seçilmiştir. Bu bölümün sonunda denetimli makine öğrenmesi algoritmalarının model başarı sonuçları tek bir tabloda sunulmuştur. Beşinci ve son bölümde, sonuçlar farklı açılardan değerlendirilmiş ve gelecekte yapılabilecek çalışmalar hakkında önerilerde bulunulmuştur.

1. BAKIM VE KESTİRİMCİ BAKIM

1.1. Bakım Yaklaşımları

EN 13306:2017 standartına göre bakım yaklaşımları Şekil 1.1’de gösterildiği gibi genel çerçevede sınıflandırılmıştır. 2010 yılındaki standartta düzeltici ve önleyici bakım olarak iki kategori altında incelenen geleneksel bakım yaklaşımı, 2017 yılında güncellenen standartla birlikte bakım kategorilerine iyileştirme yöntemi de eklenerek, bakım sınıfları İyileştirme, Önleyici Bakım ve Düzeltici Bakım olmak üzere 3 ana gruba ayrılmıştır.



Şekil 1.1. Bakım türleri (EN-13306: 2017’ye göre) [4]

Arıza teşhisi veya arıza tahmini yapabilmek için ekipman durumlarını izleyen bakım yaklaşımları üç ayrı sınıfta gruplandırılabilir. Bunlar, istatistiksel yöntem yaklaşımları, yapay zeka yaklaşımları ve model tabanlı yaklaşımlardır. Yapay zeka teknolojisinde yaşanan son gelişmeler, bu teknolojiyi yaşamın her alanında uygulanabilir kılmıştır.

Özellikle sanayideki Kestirimci Bakım (Predictive Maintenance-PdM) çalışmalarında giderek daha fazla uygulanmaktadır [5].

Yapay zeka çalışmalarında önemli bir yere sahip olan makine öğrenmesi, birçok uygulamada akıllı tahminlemeler yapan algoritmaları geliştirmek için kullanılmaya başlanmıştır. ML yaklaşımları, boyutları çok yüksek seviyelere ulaşan verileri kullanma ve çeşitli ortamlardaki verilerde gizli ilişkileri ortaya çıkarma yeteneğine sahiptir [6].

Geleneksel olarak sistematik, düzenli ve yaygın bir şekilde yapılan bakım yöntemlerini üç gruba ayırabiliriz. Bunlar; düzeltici bakım, önleyici bakım ve kestirimci bakımdır.

1.1.1. Düzeltici Bakım

Düzeltici bakım, plansız bir bakım türüdür. Beklenmeyen bir anda yaşanan hatayı çözmek için yapılan müdahaleyi kapsamaktadır. Kullanılan ekipmanları arıza meydana gelene kadar çalıştırarak, arıza yaşandıktan sonra bakım ve onarımını yapmaktadır. Üretimde büyük kayıplar olmayacaksa ve bakım maliyetleri de düşükse bu yöntem uygulanabilir [7]. Düzeltici bakım, “Arızı bakım” olarak da adlandırılmaktadır.

1.1.2. Önleyici Bakım

Önleyici bakım, planlı bir bakım türüdür. Kullanılan ekipmanların arıza olasılığını azaltmak için zamana veya kullanıma dayalı olarak belli başlı kriterlere göre bakım yapılması sağlanmaktadır. Önleyici bakım ile, arızaların azaltılması, planlanmamış yüksek maliyetli düzeltici bakımların engellenmesi ve ekipmanların güvenilir şekilde çalışması amaçlanmıştır [8].

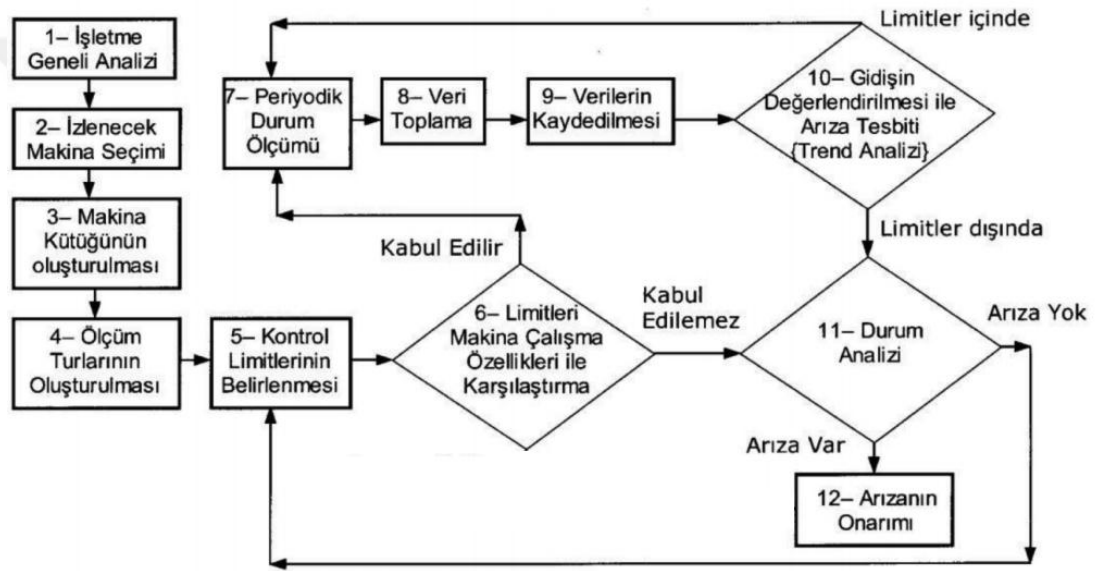
1.1.3. Kestirimci Bakım

Kestirimci bakım, ekipmanlardan sürekli olarak toplanan verilerin kayıt altına alınıp, makine arızalanmadan önce ne zaman arızalanacağını tahminleyerek hızlı aksiyon almayı sağlamaktadır. Eldeki verilerin analiz edilmesiyle yaşanabilecek bir arıza için ipuçları toplanarak maliyet ve zaman kazancı sağlanabilmektedir.

Bakım ve onarım çalışmalarında yaşanan üretim kayıplarını azaltmak, ekipmanın kullanılabilirliğini ve verimliliğini arttırmak için kullanılmaktadır.

Kestirimci bakımın amacı tam zamanında bakım yapmaktır. Bu amaca ulaşırken ekipmanları durdurmadan sensörler vasıtasıyla izlemek, durumları hakkında gerçek zamanlı olarak bilgi toplamak ve zamanla oluşabilecek değişimleri incelemek gerekmektedir [9]. Bu sayede arıza zamanı tahmin edilerek tam zamanında bakım yapılması sağlanmaktadır.

Şekil 1.2’de kestirimci bakım faaliyetlerinin nasıl planlanıp yürütüldüğü gösterilmiştir.



Şekil 1.2. Kestirimci bakım akış şeması [10].

Kestirimci bakımda ekipmanın gerçek durumunu gösteren fiziksel verilerle çalışılmakta, bakım planları bu veriler ışığında gerçekleştirilmekte ve güncellenmektedir. Bu sayede bakım gerekmeyen çalışan makineler gereksiz yere durdurulmamaktadır [11].

Bununla birlikte kestirimci bakım sistemlerinde çeşitli zorluklar bulunmaktadır. Veri toplamak için kullanılan algılayıcıların güvenilirliği ve çalışma koşulları veri kalitesini doğrudan etkilemektedir. Özellikle fabrika ortamında sensörler ile üst sistemler arasındaki entegrasyon problemleri olabilmektedir. Saha personelinin bakım ve onarım çalışmalarında yaptığı fiziksel müdahaleler verilerin toplandığı ekipmanları etkileyebilmektedir. Farklı kaynaklardan toplanan birçok veri türünü işletmenin

kestirimci bakım amaçları doğrultusunda kullanabilme yetkinliđi gerekmektedir [12]. Büyük veri yapılarını depolayacak sunucular için bilgi işlem altyapısına, depolandıktan sonra verileri işleyebilecek sistemlere ve etkin bir şekilde kullanabilme yetkisine sahip personele sahip olunması gerekir [13]. Yanlış tahmin edilen arıza sonucunda yapılan gereksiz bakım veya beklenmedik bir anda yaşanan makine arızası, üretim kayıplarına yol açabilir.

1.2. Kestirimci Bakım Yöntemleri

Geleneksel kestirimci bakım yöntemleri, çalışan makinelerden toplanan verilerin, üretici firmaların belirlediđi kriterlere göre değerlendirilmesi sonucunda alınacak önlemlerin tespiti ilkesine dayanmaktadır [14].

Günümüzde yapay zeka sistemleri ile veriler analiz edilerek uygulanan kestirimci bakım yöntemleri hız kazanmıştır.

Tezde incelenen sistemin kestirimci bakımında titreşim ölçümü, termal kamera ölçümü, yağ analizi ve ultrasonik ölçümler olmak üzere dört temel yöntem kullanılır.

1.2.1. Titreşim Ölçümü

Titreşim ölçümü, makinenin gerçek zamanlı olarak mekaniksel durumunu analiz etmemizi sağlar. Makinelerin ölçüm alınan noktalarından belirli aralıklarla toplanan veriler devamlı izlenir ve yorumlanır [9]. Makinelerdeki rulman ve dişli arızaları, balanssızlık ve gevşeklik gibi problemler arıza meydana gelmeden önce titreşimdeki değişimlerden tespit edilebilir.

Bir titreşim analiz sisteminde; titreşim sensörü, sinyal toplayıcı, analiz yazılımı ve bilgisayar olmak üzere dört ekipman kullanılır. Bu ekipmanlar sayesinde anlık olarak titreşim takip sistemi kurulabilir, taşınabilir bir titreşim analizörü ile periyodik titreşim ölçümleri alınabilir ya da belirli zaman aralıklarında titreşim ölçümü yapan çoklu bir izleme sistemi kurulabilir. Sistemin dezavantajı, ölçüm yapılan makine haricindeki dış sistemlerden kaynaklanan titreşimler ve sensör montaj konumları ölçümün kalitesini doğrudan değiştirebilir.

1.2.2. Termal Ölçüm

Termal kamera ile yapılan ısı ölçümleri kızılötesi ışınlardan faydalanılarak sistem çalışırken duruş olmadan yapılmaktadır. Gözle görülemeyen sıcaklık artışları tespit edilerek arızalı ekipmanlar belirlenir ve beklenmedik duruşlar engellenir. Bu sayede bakım planları yapılarak üretim kayıplarının azaltılması sağlanabilir [9].

Elektrik motorları, herhangi bir anormal durum esnasında olumsuz koşullarda mevcut çalışma sıcaklığının üzerine çıkabilirler. Döner makine elemanlarının birbirlerine sürtünmesinden kaynaklı beklenmedik sıcaklıklar oluşabilir. Gevşek elektriksel bağlantılarda direnç artışı sebebiyle aşırı ısınmalar da olabilir.

1.2.3. Yağ Analizi

Makine çalışırken yağ kalitesi düştüğünde mekanik sistemde aşınmalar meydana gelir ve yağ içerisine metal partiküller karışır. Yağ analizi sistemleri ile yağın kalitesi ölçülerek numune içerisindeki metal partiküller incelenir ve hangi parçalarda aşınma olduğu tespit edilir. Bu partiküllerin büyüklüğü ve sayısı bize arıza kaynağı hakkında bilgi verebilir. Yağın viskozitesi (akmazlık) düştükçe metallerde sürtünme meydana gelir [14]. Yağ analizi sayesinde yağ içerisindeki partiküller, yağ sıcaklığı ve yağdaki su miktarı incelenerek arıza tespiti yapılabilir.

1.2.4. Ultrasonik Ölçüm

İnsan kulağının duyamayacağı 20 kHz frekans değeri üstündeki ses dalgaları ultrasonik ses olarak tanımlanmaktadır. 20 - 100 kHz arasındaki ses dalgalarının ölçümünde temassız ultrasonik algılayıcılar kullanılır. Hareketli makine ekipmanlarında ve akışkan sistemlerde ultrasonik frekanslardaki ses dalgaları bulunmaktadır. Ölçülen dalga boyları sistemin durumu hakkında bilgi verir [9]. Ultrasonik ölçümler endüstride motor, dişli kutusu, transformatör ve kesici gibi birçok uygulamada kullanılmaktadır.

1.3. Makine Öğrenmesi Yöntemleriyle Kestirimci Bakım

Bu bölümde, kestirimci bakım ve yapay zeka uygulamaları üzerine geçmişten günümüze yapılan bazı çalışmalara yer verilmiştir.

Tablo 1.1’de PdM ile ilgili son yıllarda yayınlanan makaleler yer almaktadır.

Tablo 1.1. Makine öğrenmesi yöntemleriyle kestirimci bakım [5].

Referans	Makine Öğ. Yöntemi	Ekipman	Kestirimci bakım için uygulanan verilerin açıklaması	Veri Tipi*
(Onanena ve ark., 2009)	LR	Yakıt hücresi	Elektrokimyasal empedans spektroskopisi ölçümleri	Gerçek
(Hong & Zhou, 2012)	GPR	Rulman	Titreşim Verisi	Gerçek
(Susto ve ark., 2012)	Lineer Düzenleştirme, Ridge Regresyon	-	İyon Işını Aşındırma işlemi	Gerçek
(Schopka ve ark., 2013)	LR, RF, BN	Filament	İmplanter iyon kaynağındaki işlem verileri, ekipman verileri ve arıza lojistik verileri	Gerçek
(Susto ve ark., 2013)	SVM	Tungsten filament	Geçmiş dönük bakım döngüleri	Gerçek
(Li ve ark., 2014)	SVM	Demiryolu ağı	Geçmiş dedektör verileri, arıza verileri, bakım işlemi verileri, denetim programı verileri, eğitim verileri ve hava durumu verileri	Gerçek
(Praveenkumar ve ark., 2014)	SVM	Otomobil şanzıman	Titreşim Sinyalleri	Gerçek
(Abu-Samah ve ark., 2015)	BN	-	Olay odaklı bakım	Gerçek
(Garg ve ark., 2015)	MGGP	Metal torna tezgahı	Titreşim ve akustik sinyaller	Gerçek
(Prytz ve ark., 2015)	RF	Kamyon ve otobüslerde hava kompresörleri	Araçlarda toplanan veriler ve ekipman üreticilerinden toplanan servis kayıtları	Gerçek
(Biswal & Sabareesh, 2015)	ANN	Rüzgar türbini	İvme ölçer verileri	Gerçek
(Machado & Mota, 2015)	ANN, SVM	Elektrik güç sistemleri	Elektrik sinyalleri	Sanal
(Susto ve ark., 2015)	SVM, k-NN	Tungsten filament	Yarı iletken üretiminin bakım karşılaştırması	Gerçek
(Durbhaka & Selvaraj, 2016)	k-NN, SVM, k-means	Rulman	Titreşim sinyali	Gerçek
(Susto & Beghi, 2016)	SAFE	Yarı iletken üretimi	Bakım döngüsü verileri	Gerçek
(Aydin & Guldamlasioglu, 2017)	LSTM	Motor	Operasyonel ve sensör ölçüm verileri	Gerçek
(Canizo ve ark., 2017)	RF	Rüzgar türbini	Rüzgar türbinlerinin durum verileri	Gerçek

Tablo 1.1.(Devam) Makine öğrenmesi yöntemleriyle kestirimci bakım [5].

Referans	Makine Öğ. Yöntemi	Ekipman	Kestirimci bakım için uygulanan verilerin açıklaması	Veri Tipi*
(Dos Santos ve ark., 2017)	RF	Sincap kafesli asenkron motorlar	Akım ve gerilim dalga biçimleri	Sanal
(Eke et al., 2017)	k-means	Yağlı güç trafosu	Çözünmüş gaz konsantrasyonları	Gerçek
(Kanawaday & Sane, 2017)	ARIMA	Dilimleme makinesi	Dilimleme makinesinden gelen sensör verileri	Gerçek
(Mathew ve ark., 2017a)	SVM		Zaman serisi sensör ölçümleri	Sanal
(Mathew ve ark., 2017b)	LR, DT, SVM, RF, k- NN, k-means, Gradyan Artırma, AdaBoost, Derin Öğrenme,	Turbofan motoru	NASA'nın prognostik veri havuzundan turbo fan motoru verileri	Gerçek
(Pan ve ark., 2017) [31]	CNN	-	Sezgisel olmayan ve yapılandırılmamış akustik sensör verileri	Gerçek
(Kumar ve ark., 2018)	FURIA	Gaz türbini	Bir gaz türbini tahrik tesisi simülatöründen oluşturulan büyük veri seti	Sanal
(Lasisi & Atttoh-Okine, 2018)	LDA, SVM, RF	Örnek mil parkuru	Geometrik verilerin izlenmesi	Gerçek
(Su & Huang, 2018)	RF	Sabit disk sürücüsü	Geçmiş veriler (titreşim, sıcaklık ve diğer değişkenler)	Gerçek
(Uhlmann ve ark., 2018)	k-means	Lazer eritme	Takım tezgahı sensör verileri	Gerçek
(Amihai ve ark., 2018a)	Derin Öğrenme	-	Titreşim verileri	Gerçek
(Amihai ve ark., 2018b)	RF	Endüstriyel pompalar	Titreşim verileri	Gerçek
(Amruthnath & Gupta, 2018)	PCA, Hiyerarşik kümeleme, k-means,	Egzoz fanı	Titreşim verileri	Gerçek
(Butte ve ark., 2018)	GLM, RF, Gradyan Artırma, Derin Öğrenme	Yarı iletken	Kritik bir ekipman bileşeninde proses sensörleri, proses tarifi parametreleri	Gerçek
(Huuhtanen & Jung, 2018)	CNN	Fotovoltaik paneller	Günlük elektrik gücü sinyali	Gerçek
(Kolokas ve ark., 2018)	DT, RF, NB-G, NB-B, ANN	Endüstriyel ekipman anot üretimi	Çalışma dönemlerinden gelen proses sensörü verileri	Gerçek
(Kulkarni ve ark., 2018)	RF	Süpermarket soğutma sistemleri	Sıcaklık ve buz çözme durumu sensörü	Gerçek

Tablo 1.1, en çok tercih edilen ML metotlarını ortaya koymaktadır. En çok kullanılan ML algoritması % 33 oranla Rastgele Orman (Random Forest-RF) algoritmasıdır. Yapay Sinir Ağları (Artificial Neural Network-ANN), Evrimsel Sinir Ağları (Convolutional Neural Network-CNN) ve Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN) modellerinden olan Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM) yöntemleri % 27 oranla en çok kullanılan ikinci yöntemlerdir. Destek Vektör Makineleri (Support Vector Machines-SVM) algoritması % 25 ve K-Means algoritması % 13 oranla sıralamayı takip etmektedir. Tablo 1.1, her bir PdM uygulamasının özel belirli bir ekipman için kullanıldığını göstermektedir. Ekipmanlar genellikle türbinler, motorlar, kompresörler, pompalar ve fanlardır. Tablo 1.1'den çıkan diğer ilginç özellik, ekipmandaki anormallikleri saptamak için titreşim sinyallerinin çok sık kullanıldığıdır. Makine öğrenmesi ile kestirimci bakım çalışmaları geçmişten günümüze birçok farklı alanda uygulanmıştır.

Titreşim ve ses verileri kullanılarak dişli arızalarının tespiti için geri beslemeli bir yapay sinir ağı modeli kullanılmıştır [15]. Farklı işletme koşullarında dişli kutuları ve motordan toplanan titreşim verilerinin yapay sinir ağları ile öğrenilmesini sağlayan erken teşhis yöntemi geliştirilmiştir [16]. Çimento endüstrisinde faaliyet gösteren bir fabrikanın ana baca gazı fanında yaşanan rulman arızası titreşim analizi metoduyla incelenmiş ve fanın çalışmasında büyük tehlikelere sebep olmadan arızaların tespit edilmesi sağlanmıştır [7]. Farklı hata karakteristiklerine sahip rulmanlardan alınan titreşim verilerinin öznitelik matrisi çıkarılarak yapay sinir ağları ile analiz edilmiş, rulmanlardaki hatalar kestirilmeye çalışılmıştır [22]. Rulman kusurlarının gelişimini literatürde çok karşılaşılan bir yöntem olan zamana bağlı olarak incelemek yerine durum bazlı izleme teknolojisiyle rulman arızalarına neden olabilecek hasar ana sebeplerindeki hassas değişimlerini incelemiştir. Ayrıca titreşim analiz tekniği ile elektiriksel tüketim analiz tekniğini karşılaştırılmıştır [17]. Bilyalı rulmanın dış bilezik, iç bilezik ve yuvarlanma elemanındaki hata durumları modellenmiş ve temas noktasındaki deformasyonlar incelenmiştir [23].

Uçak motorunun kalan faydalı ömrünü kestirmek için eğitilen LSTM ağı modeli ile yapılan tahminleme çalışmaları ile motorlar arızaya girmeden bakıma alınması sağlanabilmiştir. [18, 19]. Uçak arızalarını tahmin etmek için Oto-Regresif Hareketli Ortalama (Autoregressive Moving Averages-ARMA) yöntemi veri odaklı tekniklerle

entegre edilerek kullanılmıştır [24]. Yapay Sinir Ağı kullanılarak, AC (Alternatif Akım) güç üretimini tahmin etmek için tasarlanan model, güneş enerjisi ve PV (Fotovoltaik) panel sıcaklık ölçüm verilerini kullanmıştır [17].

100 adet farklı motordaki 21 adet farklı sensör sayesinde toplanan veriler ile motorun anlık durumu takip edilmeye çalışılmıştır. Elde edilen verilerle bazı sensörler anlamlı bilgilere sahip olmadığından veri kümesinden çıkarılmıştır. Anlamlı veriler Dempster-Shafer Regresyonu (DSR), SVM ve RNN'den oluşan karma bir sistem ile kestirilmiştir [21]. Makinelerde meydana gelen arızaları belirlemek için SVM ile K-En Yakın Komşu algoritmaları ile çalışma yapılmıştır [29]. Otomotivde kullanılan presleme işleminde anomali durumlarını tespit etmek için SVM, İzolasyon Ormanı ve ANN metodlarını karşılaştırılmış ve üç metodun hepsinin iyi performans gösterdiği, en yüksek puanı ise ANN metodunun aldığı tespit edilmiştir [28]. Otomotiv şanzıman kutularındaki arızaları tespit etmek için SVM modeli önerilmiştir.

Rüzgar türbinlerindeki arızaları tahmin etmek [25], ticari araçların çeşitli bileşenlerinin onarımını tahmin etmek [26], demiryolu raylarındaki geometri kusurlarını tespit etmek [27] için Rastgele Orman algoritması kullanılmıştır.


Akustik sensörlerdeki hataları tahmin etmek için bir derin öğrenme algoritma sınıfı olan CNN metodu önerilmiştir [31].

IoT teknolojisinden yararlanarak, verilerin bilgisayar üzerinden uzaktan izlenebilirliği sağlanarak; sıcaklık, frekans, voltaj ve akım gibi verileri anlık olarak toplanmış ve elde edilen veri tabanının bulanık mantık temelli kestirimci bakım çözümlerinde kullanılabileceği gösterilmiştir [32].

2. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, geçmiş verilere ve bilgilere dayalı sorunları çözmek için bilgisayarlı teknikler kullanan yapay zekanın bir alt kümesidir. Genel anlamda denetimli ve denetimsiz öğrenme olarak ikiye ayrılır. Denetimli öğrenmede algoritmalar, girdiler ve çıktılar arasındaki ilişkiyi öğrenmek için etiketli veriler üzerinde eğitilir. Algoritma eğitildikten sonra, yeni girdi verileri için çıktı değerlerini hesaplamak üzere tahmin yapabilir. Denetimsiz makine öğrenimi teknikleri, girdiler ve çıktılar arasındaki ilişkiyi belirlemeye çalışmak yerine, bir veri kümesinde bulunan doğal yapıyı anlamaya çalışır. Denetimsiz teknikler, etiketli veri veya eğitim veri setleri gerektirmez, bu nedenle veri keşfi için faydalıdır.

Makine öğrenmesi bazı adımlar içerir. Bunlar, veri toplama adımı, veri ön işleme adımı, model seçimi, model eğitimi ve model doğrulama adımı, son olarak da model bakım adımıdır [33]. Şekil 2.1’de bu adımlar gösterilmektedir.



Şekil 2.1. Makine öğrenmesi aşamaları [33]

Tarihsel veri seçim adımında, verilerin nasıl toplanıp saklanacağı ve böylece ML model tasarımı için hangi değerli verilerin seçileceği tanımlanır. PdM’de, bu adım aynı zamanda veri toplama adımı olarak da adlandırılır [34]. Veri ön işleme adımında, ML modeli tarafından verimli bir şekilde işlenebilmeleri için veriler işlenir ve dönüştürülür. Bu adım, veri dönüşümü (örn. normalizasyon), veri temizliği (örn. eksik veri işleme) ve veri azaltma (örn. boyutsallık azaltma ve saydamlık azaltma) içerir. PdM’de, veri ön işleme adımı, verilerin daha iyi anlaşılması ve yorumlanması için toplanan verilerin işlenmesini ve analiz edilmesini kapsar.

Modelin seçilmesi, eğitilmesi ve doğrulanması adımı, kestirimci bakımda karar verme aşaması olarak adlandırılabilir. Bu adımda PdM uygulaması için en iyi algoritmaya karar verilmesi amaçlanır. Model bakım adımında, model performansının zaman geçtikçe sürdürülebilir olması amaçlanır. Bunun nedeni, endüstriyel uygulamaların zaman içinde değişmesi ve model performansının düşmesine neden olmasıdır [5].

Makine öğrenmesi modelleriyle, büyük veri kümeleri içerisindeki metriklerin birbirleriyle arasındaki ilişkiler kolaylıkla analiz edilebilmekte ve belirli görevler için kısa sürede bilgi sahibi olunabilmektedir.

2.1. Denetimli Öğrenme

Denetimli öğrenme algoritmaları sınıflandırma ve regresyon algoritmaları olarak ikiye ayrılır [36].

Denetimli öğrenme etiketlenmiş verileri kullanarak yeni veriler için tahmin ya da sınıflandırma yapmaktadır. Veri kümesindeki hangi girdiler sonucunda hangi çıktılar alındığı bilgileri gerekmektedir. Oluşturulan model bu verileri analiz ederek girdiler ve çıktılar arasındaki ilişkiyi öğrenmektedir. Denetimli öğrenmede giriş verileri ile etiketlenen çıktı verileri arasındaki ilişki incelenir ve bu sayede veriye dayalı bir makine öğrenmesi modeli oluşturur. Elde edilen yeni verilerin, modelin geçmişte öğrendiği verilerle ilişkisi kurularak en iyi sonuca ulaşılır. Bu sayede yeni girdi verileri olduğunda, bu veriler için çıktı değişkenleri tahmin edilir.

Denetimli öğrenmede veriler, eğitim, test ve doğrulama kümesi olmak üzere üç ayrı veri kümesine ayrılmaktadır. Eğitim veri kümesi seçilen modeli eğitmek için kullanılan verilerden oluşur. Test veri kümesi, modelin performansını test etmek için kullanılmaktadır. Doğrulama veri kümesi ise model gelişimi tamamlandıktan sonra sonuç kısmında genel performansı değerlendirmek için kullanılır.

2.1.1. Sınıflandırma Yöntemi

Bu bölümde sınıflandırma yöntemi için en yaygın olarak kullanılan makine öğrenmesi algoritmalarına değinilecektir. Her bir algoritmanın avantajları ve dezavantajlarından bahsedilecektir.

2.1.1.1. Naive Bayes Algoritması

Naive Bayes algoritmasının temeli Bayes teoremine dayanır. Naive Bayes algoritması tembel bir sınıflandırıcıdır ve dengeli olmayan veri kümelerinde de çalışabilir.

Algoritmada girdi değerleri için her durumun olasılığı hesaplanarak, olasılık değeri en yüksek olan duruma göre sınıflandırma yapılır. Eldeki eğitim verilerinin boyutu az olsa dahi çok başarılı sonuçlar alınabilir.

Naive Bayes algoritmasında, veri kümesindeki değerlerin tekrar sayısı ve birbirleriyle olan kombinasyonları sayılarak bir olasılık kümesi hesaplanır. Veri kümesindeki tüm değişkenlerin bağımsız olduğunu kabul edilir. Gerçek ortam şartlarında değişkenler tamamen birbirinden bağımsız olamayacağı için, bu durum algoritmanın dezavantajıdır. En büyük avantajı ise model eğitimi için hesaplama süresinin kısa olmasıdır [37].

Bayes teoreminde kullanılan matematiksel formül Denklem 2.1 'de açıklanmıştır.

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)} \quad (2.1)$$

$P(A|B)$: B olayı gerçekleştiğinde A olayının meydana gelme olasılığı

$P(B|A)$: A olayı gerçekleştiğinde B olayının meydana gelme olasılığı

$P(A)$ ve $P(B)$: Veriden bağımsız olarak A ve B olaylarının olasılıklarıdır.

2.1.1.2. K-En Yakın Komşu Algoritması

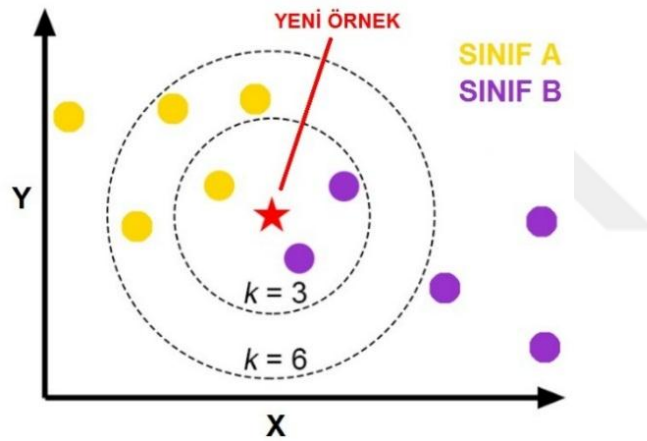
K-en yakın komşu, sınıflandırma için yaygın olarak kullanılan sezgisel bir yöntemdir. Mesafe hesaplamasına dayalı olarak en yakın K verisini bulmak için eğitim verisi ve önceden tanımlanmış bir K değeri ile sınıflandırma yapan bir algoritmadır. K verisinin farklı sınıfları varsa, algoritma bilinmeyen verilerin sınıfının çoğunluktaki verilerin sınıfıyla aynı olacağını tahmin eder. K-en yakın komşu algoritmasında K, en yakın komşu sayısıdır [38].

Genel olarak, yeni bir kayıt sınıfını tahmin etmek için, algoritma eğitim kayıtları kümesi arasında benzer kayıtları arar, böylece kayıtlar n özniteliğe sahipse, bunları n

boyutlu uzayda bir vektör olarak kabul eder ve sınıf etiketini tahmin eder. Sınıflandırıcı, kayıtların birbirine olan mesafesini yakınlıkları için bir kriter olarak varsayar ve en benzer kayıtları seçer. Bu mesafeler hesaplanırken Eukledian, Hamming ve Manhattan gibi hesaplama metrikleri kullanır. Eukledian mesafesi yöntemi kullanılan en yaygın yöntemlerden biridir.

Algoritma aşağıda verilen üç adımdan oluşmaktadır [39]:

- 1. adım: Tüm eğitim kayıtlarından giriş kaydının mesafesinin hesaplanması
- 2. adım: K-en yakın komşunun mesafesine ve seçimine göre eğitim kayıtlarının düzenlenmesi
- 3. adım: K-en yakın komşular arasında çoğunluğa sahip olan sınıfın kullanması



Şekil 2.2. K-en yakın komşu örneği


K değerinin modelin oluşturulması sırasında belirlenmesi gerekir. Hiper parametre olarak belirlenen optimum komşu sayısı veri kümesine göre değişkenlik göstermekte ve veri boyutu az olursa yüksek performansta çalışabilmektedir.

2.1.1.3. Destek Vektör Makineleri Algoritması

Destek vektör makineleri, Vapnik tarafından geliştirilen istatistiksel öğrenme teorisine dayalı bir hesaplamalı öğrenme yöntemidir [40]. Genellikle verileri iki sınıfa ayırmak için kullanılan bir yöntemdir. SVM modeli, sağlıklı bir sistemi hatalı olandan ayıran bir çıktı üretmek için prensipte kullanılabilir. Buna ek olarak, her bir sınıfın diğerleriyle karşılaştırıldığı çoklu sınıflandırma yapma özelliğine de sahiptir.

SVM modelinin temel özelliği, verileri birbirinden ayırarak optimal ayırma hiper düzlemini elde etmesidir. Destek vektörlerine en yakın olan noktalar arasındaki mesafeyi en üst düzeye çıkarmayı amaçlamaktadır. Doğrusal olarak ayrılamayan verileri, yüksek boyutlu bir özellik uzayına eşleştirerek yapmaktadır [40].

Şekil 2.3’de hiper düzlem yapısı gösterilmektedir.



Şekil 2.3. Destek vektörü ve hiper düzlem [42]

Destek vektörü hiper düzleme en yakın olan noktadır. Bu yöntemin amacı, destek vektörleri arasında en fazla uzaklığa sahip olan bir hiper düzlem oluşturmaktır.

SVM modelinin eğitim süresinin örnek sayısı arttıkça artması ve nihai SVM modelinin anlaşılması ve yorumlanmasının zor olması bu modelin dezavantajlarıdır [43].

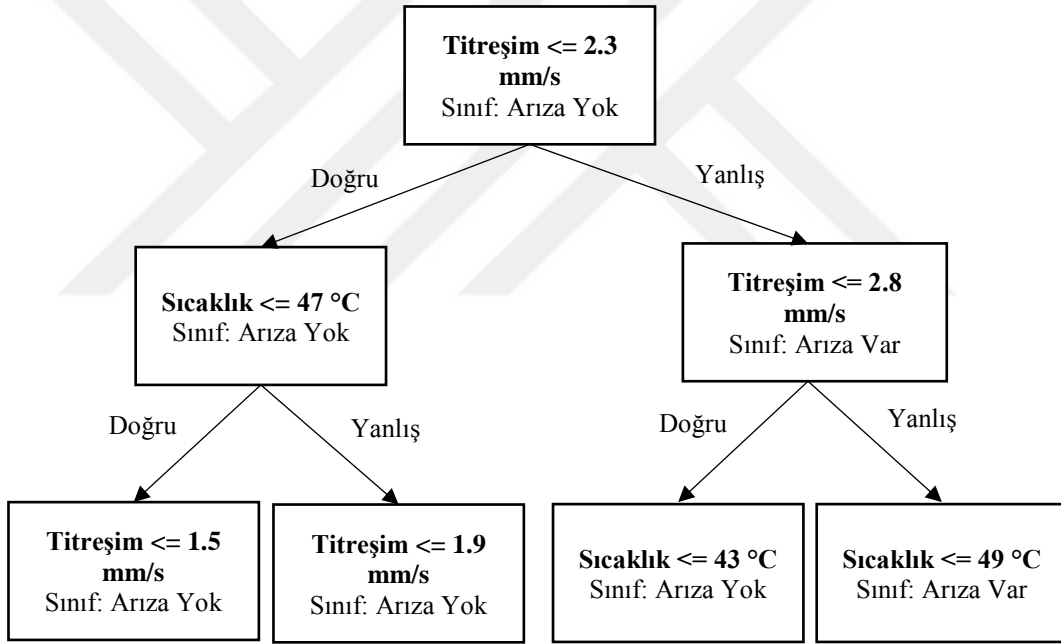
2.1.1.4. Karar Ağacı Algoritmaları

Karar ağacı algoritmaları regresyon ve sınıflandırma problemleri için kullanılabilir ancak çoğunlukla sınıflandırma problemleri için kullanılmaktadır. Adından da anlaşılacağı gibi, ağaç benzeri bir karar modeli kullanır ve yapısında düğüm, dal ve yapraklar bulunur.

Karar ağacı yönteminde, ağacın yapraklarında sınıf etiketleri bulunur ve bu yapraklara giden dallar da verilen kararları ifade etmektedir. Hiyerarşik bir düzen içindeki adımlara karar düğümü denir. Karar ağacının amacı, veri kümesini belirli kararlara dayanarak daha küçük sınıflara bölmektir.

Karar ağacı algoritmasının temel avantajları, yüksek sınıflandırma doğruluğu ve güvenilirliğidir. Dezavantajları ise, aşırı uyum eğiliminde olması, karar ağacının örneklerden kolayca etkilenmesi ve alt ağacın karar ağacında birçok kez tekrarlanabilmesidir. Aşırı uyum problemi, budama teknolojisi ve k-kat çapraz doğrulama teknolojileri ile çözülebilmektedir. Budama yoluyla fazla dallar önceden kesilebilir ve aşırı uyum önlenir. Veri ön işleme aşamasında bazı ilgisiz özelliklerin kaldırılması karar ağacının boyutunu küçültebilir ve hatalı karar ağaçları sorununu ortadan kaldırabilir [44].

Yapılarına bakıldığında yukarıdan aşağıya doğru inen bir strateji sunmaktadırlar. Şekil 2.4’de karar ağacı yapısı titreşim ve sıcaklık verileri ile gösterilmiştir.



Şekil 2.4. Karar ağacı yapısı örneği

2.1.1.5. Rastgele Orman Algoritması

Rastgele Orman, sınıflandırma ve regresyon ağacı tabanlı makine öğrenimi algoritmasıdır [45]. Eğitim verisinde karar ağaçları (Decision Tree-DT) topluluğu oluşturur ve ortalama değerlerini alır. Ormanı oluşturan maksimum ağaç sayısını belirler ve her ağaç, eğitim veri setinden rastgele bir örnek kullanılarak oluşturulur [46].

Tek bir karar ağacının kendi başına yanlış tahminler üretme olasılığı yüksektir. Rastgele orman, tek bir karar ağacından daha yüksek bir doğrulukta tahmin olasılığı ve daha düşük hata oranları sunar. RF modelinde orman oluşturma aşaması ve karar verme aşaması olmak üzere iki aşama vardır. RF'nin sonucu, DT'nin sonuçlarının oylanması veya ortalaması alınarak yapılır. Başka bir deyişle, RF algoritması sonuca ulaşmak için DT sonuçlarını birleştirir. RF algoritması genellikle karar ağacı algoritmasından daha iyi sonuçlar verir ve birçok uygulamada başarıyla kullanılmıştır [47]. Son araştırmalar RF algoritmalarının yüksek boyutlu doğrusal olmayan problemlerde daha iyi sonuçlar ürettiğini göstermiştir [48].

RF algoritması genellikle DT algoritmalarından daha iyi sonuçlar üretmesine rağmen, performansı eğitim veri setinde kullanılan etiketli veri miktarına bağlıdır. RF algoritması, doğru sonuçlar üretmek için önemli miktarda etiketlenmiş veri gerektirir.

2.1.2. Regresyon Yöntemi

Regresyon, iki veya daha fazla değişken arasındaki ilişkiyi ortaya koyan yöntem olarak bilinmektedir. Çeşitli faktörlerin herhangi bir olayın meydana gelme olasılığı üzerindeki etkisini dikkate alan Lojistik Regresyon (LR), yaygın olarak kullanılan çok değişkenli istatistiksel analiz algoritmasıdır. LR modelinin en büyük avantajı, normal dağılım gerektirmemesi ve nedensel değişkenlerin sürekli, ayrık veya her ikisinin kombinasyonu olabilmesidir. LR modelinin bir diğer önemli avantajı, bağımlı ve birkaç bağımsız değişken arasındaki ilişkinin derecesini gösterme yeteneğidir.

Model doğruluğunu artırmak için LR modeline birkaç koşullandırma değişkeni dahil edilebilir, ancak bu açıklayıcı değişkenlerin bağımlı değişkenle güçlü bir bağlantısı olmalıdır. [49]

2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketlenmemiş verilerden belirlenen bir özelliği öğrenmek için algoritmaların kullanıldığı bir makine öğrenimi yaklaşımıdır. Veri etiketlerinin bilinmediği sınıflandırma problemlerinde kullanılmakta ve denetimli öğrenmedeki gibi hedef çıktılara ihtiyaç duymamaktadır. Bu nedenle, önceden bilgi edinmenin zor olduğu karmaşık verileri modellemek için kullanışlıdır. Bu yaklaşımın arkasındaki

temel düşünce, etiketlenmemiş ham veriler kullanılarak öğrenilen özelliklerin modeli daha iyi temsil edecektir.

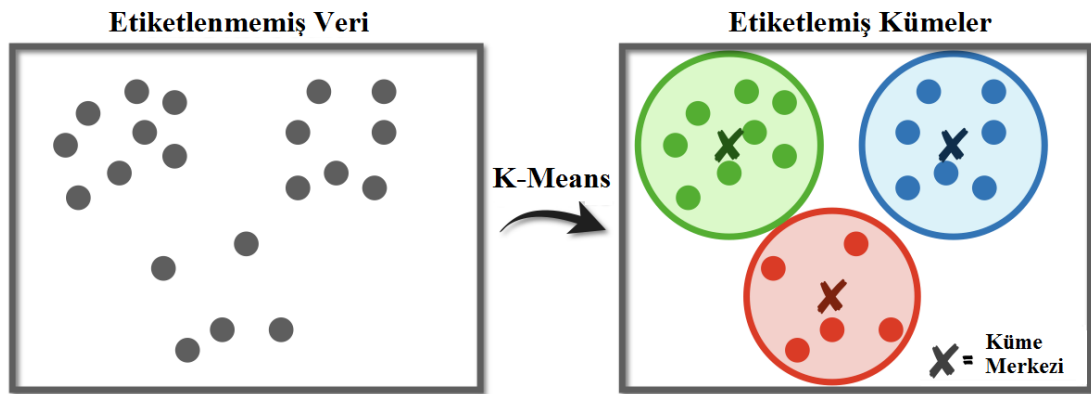
Etiketlenmemiş veriler bulunan veri kümesindeki bilinmeyen ilişkiler, denetimsiz öğrenme algoritması ile işlenerek analiz edilir. Öğrenilen özellikler, yeni verilerden farklı koşulları tahmin etmek için kullanılır [50].

2.2.1. Kümeleme Yöntemi

Kümeleme yöntemi yaygın bir denetimsiz makine öğrenimi tekniği olarak bilinir. Veri içerisindeki özelliklerin kümeler halinde gruplandırıldığı, aynı kümedeki özelliklerin diğerlerine göre birbirine daha çok benzediği ve aralarında ilişki olduğu kabul edilir [51].

2.2.1.1. K-Means Algoritması

Kümeleme yöntemleri, benzer özelliklere sahip veri alt kümelerini tanımlamak için kullanılır. Bu nedenle amaç, her bir gruptaki nesnelere arasındaki benzerliğin yüksek ve farklı gruplardaki nesnelere arasındaki benzerliğin düşük olacağı şekilde bir n nesneyi K gruplarına bölmektir [52]. K-means, popüler ve basit bir kümeleme algoritmasıdır. Farklı veri noktaları arasındaki mesafeyi ölçmek için Euclidean, Manhattan, Minkowski ve Cosine gibi yöntemler kullanılmaktadır.




Şekil 2.5. K-means kümeleme örneği [63].

K-means algoritmasının uygulanması nispeten basittir. Sınıflar arasındaki ortalama mesafeye dayalı olarak etiketlenmemiş veri kümelerinde gruplar veya sınıflar oluşturmak için farklı çalışmalarda kullanılmıştır [53]. Döner elemanlı yataklarda

arıza tespiti de dahil olmak üzere çeşitli problemler bu algoritma ile ele alınmıştır. Ham titreşim sinyalleri kullanılarak bir arızanın var olup olmadığı ve arıza noktası tespiti yapılabilmektedir [54].

2.2.1.2. Hiyerarşik Kümeleme Algoritması

K-means algoritmasında küme sayısının önceden belirlenmesi gerekirken bir diğer yöntem olan hiyerarşik kümelemede bu dezavantaj ortadan kaldırılmıştır. Temel mantık olarak benzer özellikli verileri bir araya getirerek diğer verileri ayırmaktadır. Hiyerarşik kümeleme sonuçları dendogramlar ile görselleştirilmekte, bu sayede değişkenlerin birbirine olan yakınlıkları kolaylıkla anlaşılabilir. Hiyerarşik kümeleme algoritmaları toplayıcı ve bölücü olmak üzere iki kategoriye ayrılır. Toplayıcı kümelemede, her veri noktası bir küme kabul edilir ve benzer kümeler birleştirilerek aşağıdan yukarıya doğru bir stratejiden yararlanır. Buna karşılık, bölücü kümelemede başlangıçta tüm veri noktaları tek bir küme olarak kabul edilir ve yinelemeli olarak kümeler benzer özelliklerine göre alt kümelere bölünür [64].



Şekil 2.6. Hiyerarşik kümeleme dendogram örneği

Hiyerarşik ilişkiler nedeniyle, alt kümelere ait nesnelere kavramsal olarak üst kümelere aittir, bu nedenle kök kısımları tüm nesnelere temsil ederken, yapraklar yalnızca kendilerine ait olan özellikleri temsil eder.

2.2.2. Boyut Azaltma Yöntemi

Gerçek ortamda toplanan veriler yüksek boyutlu olduğundan, veriyi temizlemeden model kurmak istendiğinde daha fazla zaman ve kaynak harcanır. Ne kadar çok boyuta sahip olunursa verinin işlenmesi ve görselleştirmesi o kadar zor olmaktadır.

Boyut azaltma yönteminde veri kümesindeki giriş değişkenlerinin boyutu azaltılır. Özellik sayısı arttıkça model üzerindeki işlemler zorlaşabilir. Rastgele değişkenlerin sayısı azaltılarak temel özelliklerin elde edilmesi sağlanır.

En yaygın olarak bilinen boyut azaltma tekniği, Temel Bileşenler Analizidir (TBA). TBA, bir dizi girdi verisini, verilerdeki varyansın çoğunu hesaba kattığı yeni bir temele dönüştürür [55]. Temel vektörler, temel bileşenler olarak adlandırılır. TBA, makine öğreniminde özellik çıkarımı için de kullanılır. TBA ile çıkarılan özellikler ile varolan özellik kümesinin eğitim hatasını karşılaştırıldığında, TBA tabanlı özelliklerle daha düşük eğitim hatası elde edildiği görülmüştür [56].

2.3. Özellik Mühendisliği

Özellik mühendisliğinde özellik seçimi ve özellik çıkarımı olmak üzere iki temel yaklaşım bulunmaktadır. Özellik mühendisliği verilerin ön işleme aşamasında kritik öneme sahiptir. Özellik seçimi, veri kümesindeki oldukça ayırt edici olan özelliklerin seçildiği aşamadır. Yapılacak analizlerde veri kümesinin hangi yönlerinin önemli, hangi yönlerinin önemsiz olduğunu seçilir. Özellik çıkarımı ise genellikle varolan özelliklerin birleşimini oluşturan yeni özellikler üretmeyi içerir.

Özellik mühendisliği eldeki verilerden daha anlamlı veriler çıkarabilmek için yapılan bir dizi işlemdir. Oluşturulacak modelin maksimum performans gösterebilmesi için mevcut verilerin detaylı bir şekilde analiz edilmesi süreci büyük ölçüde etkilemektedir. Düşük maliyetli ve yüksek performanslı bir kestirimci bakım sisteminde sadece arızayı bildirebilecek anlamlı veriler toplanması gerekir.

2.3.1. Öznitelik Seçimi

Öznitelik seçiminde, veriler dönüştürülmeden mevcut özelliklerin bir alt kümesi seçilir. Bir makine öğrenimi tekniğinin başarısı yeterli özellik seçimine bağlıdır. Bu özellikler

bir sinyali modellemek veya sınıflandırmak için etkili olan parametrelerdir [57]. Prensipite seçilebilecek potansiyel özelliklerin sayısı sonsuzdur. Bu nedenle, kullanılacak özelliklerin sayısı ve türünün uygun bir şekilde seçilmesi için bir strateji gereklidir. Özellik mühendisliği, alan bilgisinin, veri analizi araçlarının ve makine öğreniminin bir uygulamasına temel teşkil edecek özellikleri seçmek için kullanıldığı süreçtir. Bir makine öğrenimi projesinin başarısı veya başarısızlığı büyük ölçüde kullanılan özelliklere bağlıdır [58].

Bununla birlikte, kullanılan özelliklerin sayısı, bir makine öğrenimi yönteminin başarısını doğrudan belirlemez çünkü göreve zayıf bir şekilde uyarlanmış ek özellikler eklemek, özellik kümesini daha da kötüleştirir. Kullanılan özelliklerin sayısı, makine öğrenimi modelini eğitmek için gereken veri miktarını etkiler. Veri boyutu ve kullanılacak özellikler model performansını belirlemede etkin rol oynarlar [59].

2.3.2. Öznitelik Çıkarımı

Öznitelik çıkarımının amacı, oluşturulacak model için toplanan verilerin, yararlı ve ölçülebilir bir dizi özelliğini belirlemektir. Özellik ve boyut terimleri bazen birbirinin yerine kullanılır [60]. Boyut indirgeme, ilgilenilen verilerin daha düşük boyutlu bir alt uzaya dönüştürülmesi ile elde edilir [59]. Öznitelik çıkarımı, veri değişkenlerinin birbiriyle ilintisiz olduğu ancak yine de verilerin özünü açıkladığı daha düşük boyutlu bir veri kümesi oluşturmak için verilerin farklı boyutları arasındaki korelasyonların bir tür analizini içerir. Veri kümesindeki çok boyutlu uzay azaltılarak sıkıştırılabilir ve alakasız verilerden kaynaklanan varyans azaltılabilir.

2.4. Model Performansının Değerlendirilmesi

Sınıflandırma modellerinin değerlendirilmesinde temel kavram, hata kavramıdır. Oluşturulan model, gerçek sınıf örneklerinden farklı bir sınıfın tahminine yol açıyorsa, sınıflandırmada bir hata vardır. Herhangi bir hata eşit derecede önemliyse, gözlem yapılan verideki toplam hata sayısı, sınıflandırma başarısı için bir ölçüt olabilir.

Doğruluk kavramı en yaygın olarak kullanılan performans göstergesidir. Kesinlik, Duyarlılık, F1 Skor ve AUC-ROC eğrisi göstergeleri de mevcuttur.

1-Doğruluk kavramı: Modelde doğru tahmin ettiğimiz alanların toplam veri kümesine oranı olarak hesaplanmaktadır. Eşit dağılmayan dengesiz veri kümelerinde doğruluk, yeterli bir ölçüt değildir. Doğruluk çok yüksek olsa da veriler dengeli olmadığı için az sayıda sınıfa sahip verileri temsil etmeyecektir. Doğruluk değeri Denklem (2.2)'de verilen ifade ile hesaplanabilir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (2.2)$$

Denklem 2.2'de belirtilen DP, YP, DN ve YN parametreleri aşağıda açıklanmıştır.

-DP (Doğru Pozitif): Arıza durumunda arıza var demek.

-YP (Yanlış Pozitif): Arıza olmayan durumda arıza var demek.

-DN (Doğru Negatif): Arıza olmayan durumda arıza yok demek.

-YN (Yanlış Negatif): Arıza durumunda arıza yok demek.

Doğruluk değeri model performansını değerlendirirken tek başına yeterli bir kriter değildir. Bu sebeple sınıflandırmaya dayalı makine öğrenmesi modellerinin performansını değerlendirmek için tahminlerin ve gerçek değerlerin karşılaştırıldığı karışıklık matrisi kullanılmaktadır.

Karışıklık matrisi, farklı başarı türlerini ve sınıflandırma hatalarını ayırt etmeyi sağlar. Sınıf dengesizliği probleminin üstesinden gelmek için kullanılır. Matrisin köşegeninde doğru sınıflandırılmış örneklerin sayısı bulunurken, matrisin diğer öğeleri, hatalı şekilde sınıflandırılan örneklerin sayısını gösterir. Tablo 2.1.'de ikili sınıflandırma için karışıklık matrisi örneği verilmiştir.

Bir sınıflandırmada doğru pozitifler, doğru negatifler, yanlış pozitifler ve yanlış negatifler olarak tanımlanan değerler hesaplanarak modelin performansı ölçülebilir. Karışıklık matrisinden yararlanarak, Kesinlik, Duyarlılık ve F1 Skor gibi performans değerlendirme kriterleri de kullanılmaktadır. Birçok performans değerlendirme kriterinin kullanılmasının sebebi, oluşturulacak modelin performansı ölçülürken kullanım yeri ve amacına göre değişkenlik göstermesinden kaynaklanır.

Tablo 2.1. Karışıklık matrisi

		Tahmin Edilen Değer	
		Pozitif	Negatif
Gerçek Değer	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

2-Kesinlik kavramı: Pozitif olarak tahmin edilen değerlerin aslında ne kadarının pozitif olduğunu ortaya koymaktadır. Yanlış pozitif olarak tahminlenen sonuçların önemli olduğu durumlarda kullanılır. Örneğin, e-postadaki önemsiz olan postaları ayırt eden bir model için, önemli bir postanın önemsiz olarak sınıflandırılması istenmeyen durumdur. Böyle durumlarda kesinlik değerinin yüksek olması beklenir [65].

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2.3)$$

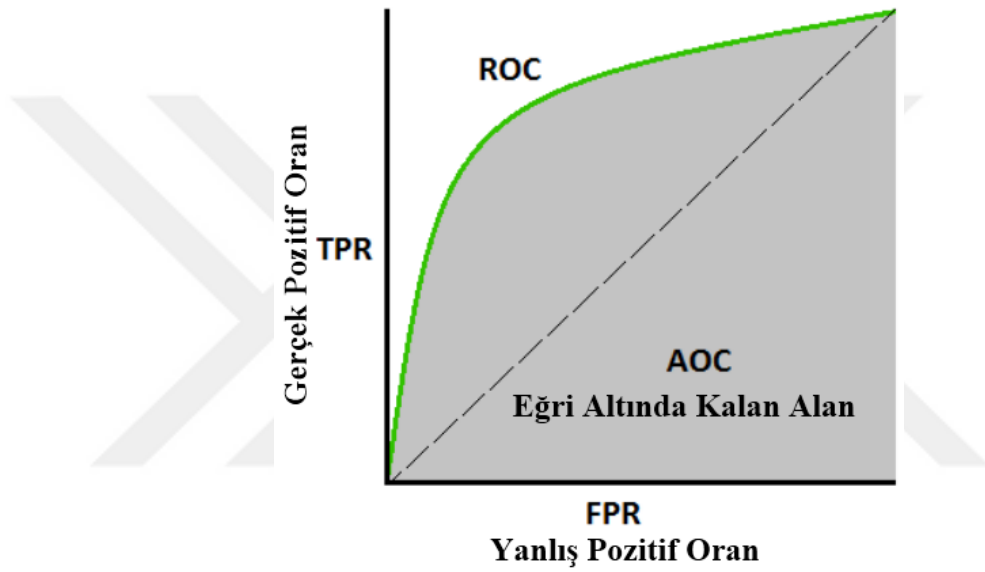
3-Duyarlılık kavramı: Pozitif olarak tahmin edilmesi gereken sonuçların ne kadarının pozitif olarak tahmin edildiğini gösterir. Yanlış negatif olarak tahminlemenin maliyetinin yüksek olduğu durumlarda kullanılmaktadır. Örneğin, dolandırıcılık tespiti için oluşturulan model, riskli olan bir transfer işlemini risksiz olarak işaretlerse yanlış bir tespitte bulunmuş olur.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (2.4)$$

4-F1 Skor kavramı: Dengesiz dağılıma sahip veri kümelerinde kullanılmaktadır. Kesinlik ve Duyarlılık parametrelerinin harmonik ortalaması alınarak hesaplanır. Bu iki parametreyi beraber ele alıp tek bir ölçüde birleştirmenin bir yolunu sunar [65].

$$\text{F1 Skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (2.5)$$

5-AUC-ROC Eğrisi kavramı: Model performansının ölçülmesinde yararlanılan bir diğer yöntem de AUC (Area Under Curve) ve ROC (Receiver Operating Characteristics) eğrisi göstergeleridir. AUC, ROC eğrisi altında kalan alanı ifade etmektedir. Bu alan, kullanılan modelin sınıfları tahmin etme becerisini gösterir. ROC eğrisi y eksenine yaklaştıkça sınıflandırmanın genel doğruluğu da artmaktadır. Eğri altında kalan alan ne kadar büyükse, makine öğrenme modelleri sınıfları ayırt etmede o kadar daha iyidir. ROC eğrisi X ekseninde, Yanlış Pozitif Oran (False Positive Rate-FPR) ve Y ekseninde, Gerçek Pozitif Oran (True Positive Rate-TPR) vardır.



Şekil 2.7. AUC – ROC Eğrisi

3. MATERYAL VE YÖNTEM

Arıza yapan makine elemanlarının bakım ve onarımları hem zahmetli hem de maliyetlidir. Beklenmeyen arızalardaki bakım ve onarım çalışmaları uzun zaman alabilmekte ve kısa sürede yedek parça temini zorlaşabilmektedir. Bu durum, üretim kayıplarına ve maliyetlerin artmasına neden olmaktadır. Bir makineden yüksek verim almak ve bakım kaynaklı üretim kayıplarını azaltmak için geçmişten günümüze farklı çalışmalar yapılmıştır. Bunlardan biri de, durum izlemeye dayalı bakım ya da kestirimci bakım olarak adlandırılan yaklaşımdır [61]. Bu anlayışın benimsendiği uygulamalarda, bakım maliyetleri ve üretim kayıplarında çok önemli azalmalar kaydedildiği görülmektedir [62].

Bu tez çalışmasında transfer pres makinesinden ilgili verileri toplayıp, bu verileri işleyerek istenilen formatta anlık olarak izlenmesini sağlamak, toplanan verileri makine öğrenmesi algoritmaları ile analiz etmek ve makinenin arıza zamanlarını önceden tespit edebilecek kestirimci bakımın çalışmaları yapmak hedeflenmiştir. Arıza zamanı tespiti için veriye dayalı modeller ile çalışmalar yapılmıştır. Bu çalışmayla, anlık olarak makine durumunun izlenmesi ve yaşanabilecek arızalar için önceden uyarı verebilen bir sistem kurulması amaçlanmıştır. Transfer pres makinesinin ürettiği ürün ve proses kalitesinin iyileştirilmesinden veya tasarımından kaynaklı bir problemin çözümünden öte, periyodik ve otonom bakım faaliyetlerinin optimize edilmesi, geliştirilmesi ve böylece üretim verimliliğinin artırılması amaçlanmıştır.

Bu çalışmada titreşim, sıcaklık ve yağ analizi verilerine ilave olarak pres makinesinde kullanılan kalıbın tonajı ve dakikaki vuruş sayısı gibi bilgiler de kullanılarak büyük veri tabanı oluşturulmuştur. Veriler doğru şekilde analiz edilerek makine elemanlarındaki arızalar meydana gelmeden önce uyarı verebilen bir arıza tespit modeli geliştirilmiştir.

Uygulamada öncelikle makinede yaşanan arıza geçmişi incelenmiş ve arızalara çözüm olabilecek uygun algılayıcı seçimleri yapılmıştır. Sektörde kullanılan çok fazla farklı

özellikte algılayıcı olduğundan, seçimler titizlikle yapılmıştır. Bu aşamada yapılacak yanlış seçimler tüm çalışmayı olumsuz etkileyeceği değerlendirilmiştir. Arıza analizlerini yapabilmek için algılayıcılar en optimum noktaya konumlandırılmış ve sabitlenmiştir. Gerçek zamanlı olarak verilerin toplanması ve analiz edilebilmesi için bir sistem mimarisi oluşturulmuştur. Toplanan veriler makine öğrenmesi modeli ön işleme aşamasında gereksiz sinyallerden temizlenmiş ve öznelik seçimleri yapılmıştır. Arıza zamanına yakın veriler etiketlenerek, makine öğrenmesi denetimli öğrenme algoritmaları ile arıza tahminleri yapılmıştır.

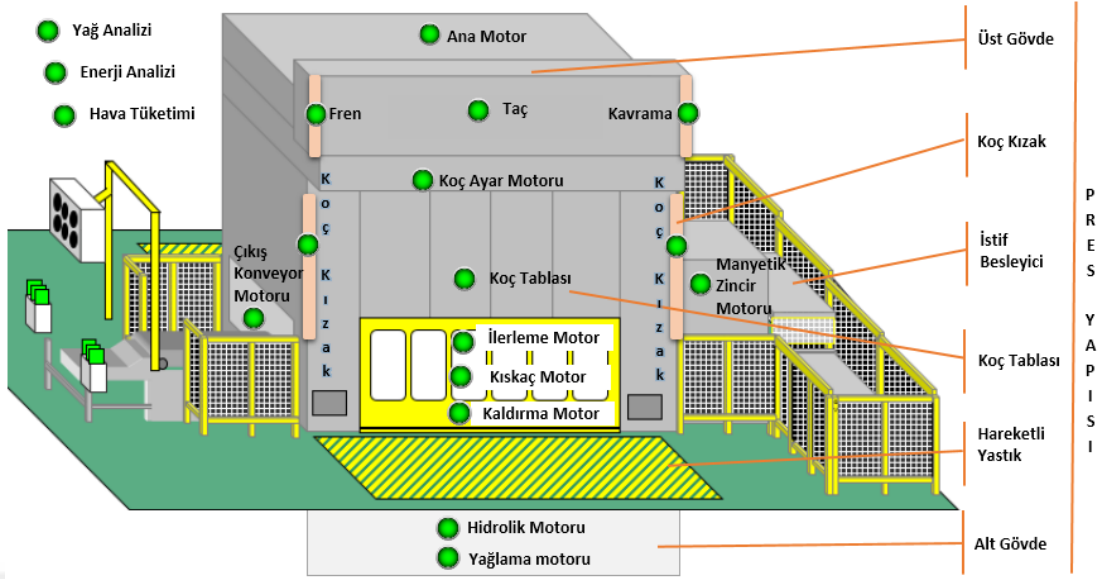
3.1. Endüstriyel Pres Makinelerinin Yapısı

Bu çalışmada 2500 ton basma kapasitesine sahip mekanik transfer pres üzerinde kestirimci bakım çalışmaları yapılacaktır.

Presler, elektrik motorundan aldıkları dönme hareketini mekanik enerjiye çeviren makinelerdir. Elektrik motoru ile elde edilen dönme hareketi kayışlar vasıtasıyla volana aktarılır. Makinenin aşağı ve yukarı yönlü doğrusal hareketine strok denir. Preslerin parça üretim hızı, dakikadaki strok sayısı (SPM) ile belirtilmektedir. Çalışma yapılan makine standart üretim koşullarında 23 SPM ile parça üretmektedir. Çalışmanın yapıldığı işletmede 1200 ton, 1600 ton ve 2000 ton gibi farklı basma kapasitesine sahip birçok pres mevcuttur. Diğer preslerin baskı kapasitesinin yeterli olmadığı özel kalıplar daha yüksek tonajlı preslerde basılmaktadır. Yüksek tonajlı preslerin ikamesi olmadığından bu preslerde arıza yaşanması tüm işletmenin üretimini durdurabilmektedir. Bu sebeple kestirimci bakım çalışmaları için ilk olarak 2500 ton transfer pres makinesi seçilmiştir.

Çalışmanın yapıldığı transfer pres makinesi Şekil 3.1’de görüldüğü gibi genel olarak üst gövde, koç tablası, koç-kızak, istif besleyici, hareketli yastık, alt gövde ve konveyör olarak isimlendirilen 7 ana bölgeden oluşmaktadır.

İstif besleyici kısmından sac malzemeler beslenmekte ve pres içerisinde farklı şekillendirme prosesleri olan kalıplarda şekillendirilmektedir. Şekillendirilen sac parçalar, kısıkaç, kaldırma ve ilerleme motorlarının tahrik ettiği transfer kollar sayesinde bir sonraki prosese aktarılmaktadır. Son olarak çıkış konveyör bölgesinden son ürün çıkmaktadır.



Şekil 3.1. Çalışma yapılan transfer pres makinesi

Kalıbın içindeki parça, 2 adet kol yardımıyla bir sonraki operasyona taşınır. Baskı yapılan parçaların bir sonraki prosese aktarımını gerçekleştiren kıskaç, kaldırma ve ilerleme işlemlerini yapan transfer sisteminde servo motorlar kullanılmaktadır. Bu motorlar 2-3 saniyelik periyotlarda ileri-geri çalışmaktadır. Transfer sistemi, tamamen presle uyumlu çalışır ve tüm operasyonlar servo sistemlerle kontrol altındadır. Makine üzerinde Tablo 3.1’de belirtilen motorlar bulunmaktadır.

Tablo 3.1. Pres makinesi motor bilgileri

No	Motor Tanımı	Motor Tipi	Motor Kutup Sayısı	Motor Çalışma Tipi	Motor Gücü (kW)
1	Ana Motor	Asenkron	6	Sürücü	280
2	Sağ Kıskaç Motoru	Servo	-	Sürücü	11
3	Sol Kıskaç Motoru	Servo	-	Sürücü	11
4	İlerleme Motoru	Servo	-	Sürücü	55
5	Sağ Kaldırma Motoru	Servo	-	Sürücü	11
6	Sol Kaldırma Motoru	Servo	-	Sürücü	11
7	Manyetik Zincir Motoru	Servo	-	Sürücü	7
8	Hidrolik Pompa Motoru	Asenkron	6	Kontaktör	15
9	Yağlama Pompası Motoru	Asenkron	6	Kontaktör	7
10	Koç Ayar Motoru	Asenkron	4	Kontaktör	7.5
11	Çıkış Konveyör Motoru	Asenkron	4	Sürücü	2.2

3.2. Arıza Analizi ve Algılayıcı Seçimi

Makine öğrenmesi algoritmaları ile arızaların önceden tahmin edilebilmesi için öncelikle geçmişte yaşanan arızalar incelenerek bu arızaların hangi yöntemlerle algılanacağı araştırılmıştır. 2010 ve 2017 yılları içerisinde kayıt altına alınmış geçmişteki arızalar için arıza yoğunluğu analizi yapılmıştır. Özellikle çalışmada arıza yoğunluğunun yüksek olduğu bölgeler için önlemler alınmaya çalışılmıştır. Arıza yoğunluğu analizine ek olarak benzer makinelerde meydana gelen önemli arızalar için de ne gibi önlemler alınacağı üzerine çalışmalar yapılmıştır. Toplanan veriler Tablo 3.2'de belirtilen, 2325 arızanın çözümüne %95 seviyede etki edecek şekilde tasarlanmıştır.

Tablo 3.2. Arızalar ve kestirimci bakım ekipmanları

Arıza Bölgesi	Arıza Adeti	Kestirimci Bakım Ekipmanları
İstif Besleyici	726	<ul style="list-style-type: none">• PLC Genel Makine Verileri• Kızılötesi Sıcaklık Sensörleri• Titreşim Sensörleri• Lazer Mesafe Sensörleri• Hava Akış Sensörü• Yağlama Analiz Sistemi• Yağ Filtreleme Sistemi• Enerji Analizörleri• Tonaj İzleme Sistemi• Strengaç (Strain Gauge)
Alt Gövde	353	
Transfer Sistemi	336	
Hareketli Yastık	268	
Other	214	
Konveyör	190	
Koç Tablası	79	
Genel Elektrik	72	
Emniyet	37	
Üst Gövde	29	
Çıkış Bölgesi	20	
Soğutma Ünitesi	1	
Toplam	2325	

Arıza türleri incelenerek sensörlerin yerleştirileceği yerlere karar verilmiştir. Aşınma kontrolü yapacak lazer sensörler, aşırı ısınma ve metal yorgunluğunu tespit edecek sıcaklık sensörleri, motorların ve aktarma organlarının kontrolü için titreşim ve sıcaklığı birlikte ölçebilen sensörler, yağ kirlilik seviyesini ölçen ve yağı filtreleyen cihazlar sisteme yerleştirilmiştir. Sensör seçimi, yüksek performans ve sağlıklı sonuçlar elde edebilmek için çok önemlidir ve yapılacak analizlerin etkinliğini de arttıracaktır.

Makinenin genel işlevleri için kullanılan kontrolcüler (PLC), ağırlıklı olarak proses sırası ve alt üst limitlerle alarm oluşturan bir yapıdadır. Bu yapıda sinyaller genellikle

dijital olduğundan veri analizi yapmak mümkün değildir. Eklenen yeni sensörler sayesinde pres üzerindeki ve hat destek ekipmanlarındaki temel yapı izlenebilir hale getirilmiştir. Anlık olarak makine üzerinden veriler toplanmakta ve görselleştirilmektedir. PLC'den pres üzerindeki motorların çalışma bilgisi, üretilen parça bilgisi, pres parça basma hızı ve tonaj bilgisi gibi temel parametreler de toplanmıştır.

Titreşim, döner makine elemanlarının arıza teşhisi için güçlü bir araçtır. Düşük frekanslı RMS (Root Mean Square) titreşim (mm/s) verileri, hizalama, yük dengesizliği, eksen kayması gibi sorunların tespitine yöneliktir. Yüksek frekanslı Basıklık (Kurtosis), Tepe Faktörü (Crest Factor) ve İvme (G) verileri ise rulman arızalarının tespitine yönelik değişkenler üretmektedir. Kurtosis, verinin normal dağılıp dağılmadığına ilişkin ipuçlarına sahip göstergelerden biridir. Makinenin dönme hızları ve yüklerindeki değişimlerden bağımsız olma avantajına sahiptir. Normal dağılımın Kurtosis değeri 3'tür. Tepe Faktörü, tepe değer ile etkin değer arasındaki oran olarak tanımlanır. Bu değer 6'yı geçmesi olası bir arızanın işaretidir.

Tablo 3.3. Titreşim sensörü verileri ve arıza teşhisi

Ölçülen Parametre		Ekseni	Frekansı	Yakalayabildiği Sorun
Sıcaklık (°C)	Temperature	-	-	Rulman Arızaları, Hizalama Sorunları, Yük Dengesizliği Sorunları, Montaj Gevşekliliği, Kayış Yıpranması, Şaft Bükülmesi, Rulman Kayıklığı, Kayış Hizalanması
Titreşim Etkin Değer (mm/s)	RMS Velocity	Radyal	Düşük Frekans	Paralel Hizalama, Montaj Gevşekliliği, Kayış Yıpranması
Titreşim Etkin Değer (mm/s)	RMS Velocity	Eksenel	Düşük Frekans	Açısal Hizalama, Yük Dengesizliği, Şaft Bükülmesi, Rulman Kayıklığı, Kayış Hizalanması
Pik İvme (G)	Peak Acceleration	Radyal	Yüksek Frekans	Rulman
RMS İvme (G)	RMS Acceleration	Radyal	Yüksek Frekans	Rulman
Basıklık	Kurtosis	Radyal	Yüksek Frekans	Rulman
Tepe Faktörü	Crest Factor	Radyal	Yüksek Frekans	Rulman

Sensörden 4 saniyede bir toplanan 7 farklı ölçüm verisi kayıt altına alınmaktadır. Sensor özellikleri ve her bir parametrenin tespit edebildiği arıza türleri Tablo 3.3'de gösterilmiştir.

Ölçüm sırasında, makinenin frekansına göre farklı değişkenler önem kazanır: 10 – 1000 Hz arasındaki frekanslar düşük frekans bölgesi, 1000 – 4000 Hz arasındaki frekanslar yüksek frekans bölgesi olarak kabul edilir. Düşük frekanslı değişkenler; hizalama, yük dengesizliği, eksen kayması gibi sorunların tespitine yönelik değişkenler üretir. Yüksek frekanslı değişkenler ise rulman arızalarının tespitine yönelik değişkenler üretir. Kestirimci bakımın amaçlarından biri, rulman arızalanmadan önce ortaya çıkacak bozulmaları yakalamak olmalıdır.



QM42VT1 Titreşim ve Sıcaklık Sensörü

- Takılı taban rezonansı: 4,5 kHz nominal
- Ölçüm Aralığı: 0 ila 46 mm / sn RMS
- Frekans Aralığı: 10 Hz - 4 kHz
- Doğruluk: 25 ° C'de ±% 10
- Örnekleme Frekansı: 20 kHz
- Kayıt Uzunluğu: 8192 puan
- Örnek Süresi: 0,4 sn

Şekil 3.2. Titreşim ve sıcaklık sensörü

Titreşim ölçümünde frekans ve genlik olmak üzere kabul edilen iki tip değişken vardır. Frekans belirli bir zaman periyodunda olayın gerçekleşme sayısıdır ve arızanın tipini gösterir. Genlik ise titreşim sinyalinin boyutudur ve arızanın şiddetini gösterir. Bu çalışmadaki sensörler genlik bileşeni üzerinde değişkenlere sahiptir. Frekansa göre dezavantajı, ortamdaki diğer titreşimlerin sensör verilerini olumsuz etkilemesidir.

Motorlardaki titreşim, rulman ve dişli hasarları, yük dengesizliği, hatalı hizalama gibi problemlerden kaynaklanabilmektedir. ISO 10816-3 mekanik titreşim standardına göre motorların titreşim aralıkları motor gücüne ve montaj yöntemine göre sınıflandırılmıştır. Tablo 3.4'de mavi, yeşil, sarı ve kırmızı renk ile RMS (mm/s) titreşim aralıkları gösterilmektedir.

-A bölgesi (mavi renk): Yeni kurulmuş olan bir makinedeki titreşim aralığı

-B bölgesi (yeşil renk): Makinenin titreşim değeri bu aralıkta olduğu sürece, makine sınırsız sürede çalıştırılabilir.

-C bölgesi (sarı renk): Makinenin titreşim değeri bu aralıkta ise, makine sınırlı süre bu şekilde çalışabilir.

-D bölgesi (kırmızı renk): Makinenin titreşim değeri bu aralıkta ise hemen durdurulmalıdır.

Tablo 3.4. Titreşim limitleri (ISO 10816-3'e göre)

ISO 10816-3 Limitleri									
		Grup 1 P > 300 kW, şaft > 315 mm, 120 rpm – 15000 rpm		Grup 2 15 kW < P < 300 kW, 160 mm < şaft < 315 mm > 600 rpm		Grup 3 Ayrı Sürücülü Pompa > 15 kW		Grup 4 Dahili Sürücülü Pompa > 15 kW	
		Sabit Montaj	Esnek Montaj	Sabit Montaj	Esnek Montaj	Sabit Montaj	Esnek Montaj	Sabit Montaj	Esnek Montaj
RMS Hız (mm/s)	> 11.0	D	D	D	D	D	D	D	D
	7.1 - 11.0	D	C	D	D	D	C	D	D
	4.5 - 7.1	C	B	D	C	C	B	D	C
	3.5 - 4.5	B	B	C	B	B	B	C	B
	2.8 - 3.5	B	A	C	B	B	A	C	B
	2.3 - 2.8	B	A	B	B	B	A	B	B
	1.4 - 2.3	A	A	B	A	A	A	B	A
0.00 - 1.4	A	A	A	A	A	A	A	A	


3.3. Verilerin Toplanması ve Görselleştirilmesi

Titreşim verilerinin alınması için kullanılan sensörler Şekil 3.3'de gösterilen konuma yerleştirilmiştir. Sensör konumu, verilerin ölçümünü ve analizini doğrudan etkilemektedir. Sensörün sağlıklı bir ölçüm yapabilmesi için ölçüm eksenine sıkıca sabitlenmesi gerekmektedir. Sensör; Z eksenini motor rulmanlarına, X eksenini kaplin/redüktör bağlantısına bakacak şekilde monte edilmelidir.



Şekil 3.3. Çalışma yapılan sensörlerin montajı

Şekil 3.4.'de makine üzerinden 4 saniyede bir gerçek zamanlı olarak toplanan verilerden bir kısmı gösterilmiştir. Her bir verinin minimum, maksimum, ortalama ve gerçek değeri izlenebilmektedir.



Şekil 3.4. Gerçek zamanlı sıcaklık ve titreşim sensör verileri

Şekil 3.4'de motordan 4 saniyelik periyotlarda gerçek zamanlı olarak toplanan sıcaklık, titreşim X eksen, titreşim Z eksen, Kurtosis ve Crest Factor verilerin 10 dakikalık kısmı gösterilmiştir. Titreşim verileri 2-3 mm/s aralığında değişmektedir. ISO 10816-3 standardına göre 2-4 mm/s normal çalışma aralığıdır. İstatistiksel veriler olan Kurtosis ve Crest Factor değeri normal dağılıma yakın "5" olarak görünmektedir. Sıcaklık verisi de 32-34°C normal çalışma aralığında görünmektedir. Veriler limit değerinin dışına çıktığında uyarı verebilecek bir yapı da ayrıca kurulmuştur.

Bir diğerk önemli kestirimci bakım parametresi de yağ kirliliđi ölçüm sisteminden toplanan verilerdir. Pres makine ekipmanlarının üzerinde çalıştığı yağ kalitesi düştüğünde makinenin çeşitli yerlerinde aşınma meydana geldiđi anlaşılmaktadır. Yağ analizi sayesinde yağ sıcaklığı, yağ içindeki su miktarı, farklı büyüklüklerdeki partikül sayıları incelenerek arıza analizi yapılmıştır. Şekil 3.5’de gösterilen cihazdan ilgili parametreler 5 dakikalık periyotlar ile toplanmıştır.



Stauff LPM II Yağ Kirlilik Ölçüm Cihazı

Ölçülen Parametre
Sıcaklık (°C)
Bağıl Nem (%)
4 mikron partikül sayısı
6 mikron partikül sayısı
14 mikron partikül sayısı

Şekil 3.5. Yağ kirlilik ölçüm cihazı ve parametreleri

Tablo 3.5. Partikül sayısına göre yağ kirlilik seviyesi (ISO 4406’ e göre)

ISO 4406 Kodu	Partikül Sayısı / 100 ml			NAS 1638
	≥ 4 µm	≥ 6 µm	≥ 14 µm	
12/10/06	4.000	1.000	64	
12/10/07	4.000	1.000	130	1
12/10/08	4.000	1.000	250	
13/11/08	8.000	2.000	250	2
14/12/09	16.000	4.000	500	3
15/13/10	32.000	8.000	1.000	4
16/14/11	64.000	16.000	2.000	5
16/14/12	64.000	16.000	4.000	
17/15/12	130.000	32.000	4.000	6
18/16/13	250.000	64.000	8.000	7
19/17/14	500.000	130.000	16.000	8
20/18/15	1.000.000	250.000	32.000	9
21/19/16	2.000.000	500.000	64.000	10
22/20/16	4.000.000	1.000.000	64.000	
22/20/17	4.000.000	1.000.000	130.000	11
22/20/18	4.000.000	1.000.000	250.000	
23/21/18	8.000.000	2.000.000	250.000	12

Tablo 3.5’de belirtilen ISO 4406’ya göre motorlar ve pompalar için yağ temizlik standardı “ISO 18/16/13” den küçük olmalıdır. Bu standarda göre yağ içerisindeki partiküllerden 4 mikron olanlar en fazla 250 bin adet, 6 mikron olanlar en fazla 64 bin adet, 14 mikron olanlar ise en fazla 8 bin adet olmalıdır. Yapılacak modellemelerde ISO standartları da göz önünde bulundurulması gerekmektedir.

Tablo 3.6’da yağ kirlilik ölçüm cihazından 5 dakikalık periyotlarla toplanan partikül büyüklükleri, ISO standardı bilgisi, sıcaklık ve nem bilgileri gösterilmiştir.

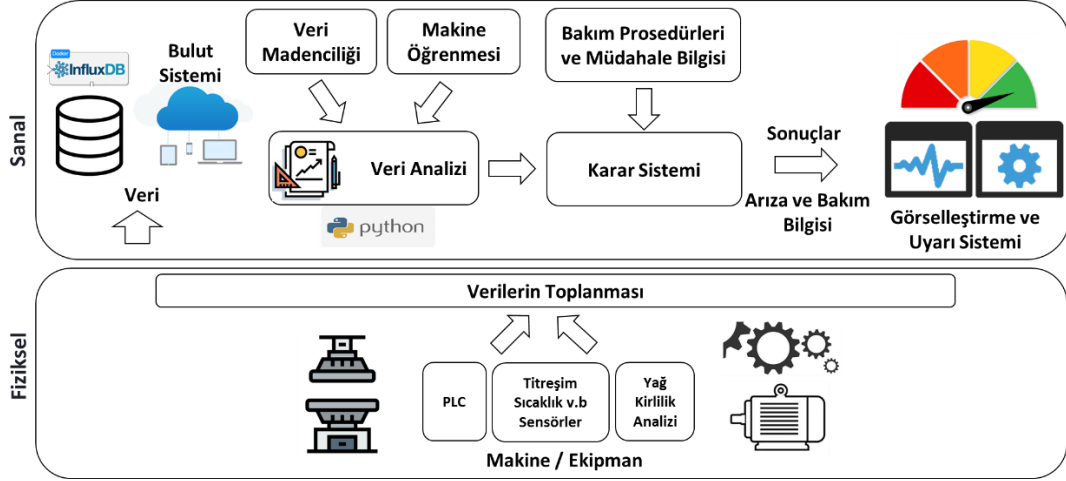
Tablo 3.6. Gerçek zamanlı yağ kirlilik ölçüm verileri

Yağ İzleyici Test Raporu / Oil Monitor Test Report							
Time	Test No	ISO	4um Count	6um Count	14um Count	Temperature	RH
2021-01-16 05:55:12	452	15/14/3	31495	12792	7	29.36 °C	9.68 %H
2021-01-16 05:50:12	451	15/13/6	20065	5579	44	29.28 °C	9.91 %H
2021-01-16 05:45:13	450	16/13/8	52415	7583	190	28.33 °C	10.11 %H
2021-01-16 05:40:13	449	16/13/7	43668	4487	107	28.83 °C	9.82 %H
2021-01-16 05:35:13	448	15/13/7	27312	6401	124	28.89 °C	9.86 %H
2021-01-16 05:30:11	447	16/12/0	34360	2732	0	28.90 °C	9.90 %H
2021-01-16 05:25:12	446	15/13/9	28580	5646	356	28.90 °C	9.90 %H
2021-01-16 05:20:12	445	15/13/6	21326	4551	51	28.96 °C	9.90 %H
2021-01-16 05:15:12	444	15/13/8	19614	4571	230	28.98 °C	9.94 %H
2021-01-16 05:10:13	443	16/15/7	51787	31903	86	28.99 °C	9.98 %H
2021-01-16 05:05:12	442	15/13/9	20402	5063	329	29.03 °C	9.98 %H

3.4. Veri Analizi ve Sistem Mimarisi Tasarımı

Kestirimci bakım ve arıza teşhis uygulamalarında ilk adım verilerin elde edilmesidir. Bu uygulamalar için en önemli veri kaynağı temel makine verileri ve sensör verileridir.

Şekil 3.6’da, oluşturulan veri analiz sisteminin genel yapısı gösterilmektedir. Sensörlerden ve kontrol ünitesinden toplanan tüm veriler InfluxDB gerçek zamanlı veri tabanında kayıt altına alınmaktadır. Verilerin analizi ve depolanması konusunda yerel veritabanları sınırlı kapasiteye sahip olduğundan, veriler eşzamanlı olarak bulut sisteminde de depolanmaktadır. Toplanan verilerin kişiler tarafından izlenebilirliğini sağlamak için veri görselleştirme platformu kullanılmaktadır. ML algoritmaları ile verilerin analiz edilmesi için de açık kaynak kodlu Python yazılımı kullanılmıştır.

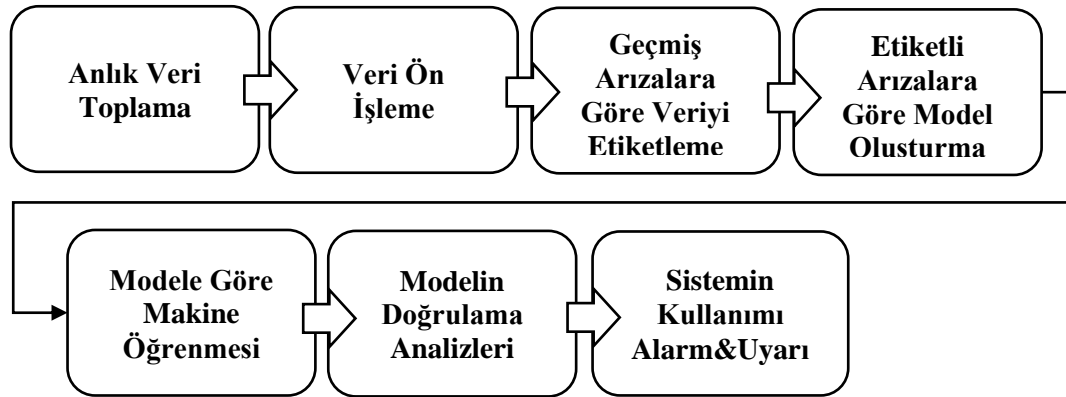


Şekil 3.6. Veri analiz ve kestirimci bakım sistem mimarisi

Sensörlerden gelen bilgilere göre anormal değerler için uyarı veren ve arıza olacağını önceden haber veren sistem mimarisi kurulmuştur.

3.5. Makine Öğrenmesi Modelinin Oluşturulması

Tez çalışmasında son bir yıl içerisinde arıza yaşanan hidrolik pompa motoru ve yağlama motoru verileri kullanılmış ve modelleme yapılmıştır. Python scikit-learn kütüphanesi ile Jupyter Notebook ortamı üzerinde çeşitli denetimli makine öğrenmesi algoritmalarının karşılaştırılması yapılmıştır. Makine öğrenmesi modelinin oluşturulmasında Şekil 3.7' deki ilerleyiş izlenmiştir. Toplanan verilere ön işleme yapılmış, geçmişteki arızalara göre veriler etiketlenmiştir. Etiketli arızalara farklı makine öğrenmesi algoritmalarından en yüksek performansı veren model seçilmiştir. Modelin doğrulama analizleri yapılarak alarm ve uyarı verebilecek sistem oluşturulmuştur.



Şekil 3.7. Makine öğrenmesi model oluşturma akış şeması

Gerçek zamanlı olarak sensörlerden toplanan veriler içerisinde eksik, anormal ve gereksiz bilgiler olabilir. Bu sebeple modelde kullanılacak veri seti için ön hazırlık yapılmıştır. Eksik veriler temizlenmiş ve veri seti üzerinde normalizasyon yapılarak tüm veriler 0 ile 1 arasında ölçeklendirilmiştir. Modelin iyi bir performans göstermesi için boyut azaltılması ve güçlü ilişkilere sahip parametrelerin diğer parametrelerden ayrılması gerekir. Çünkü bu öznelikler model için bilgi taşıyor olabilir. Veri ön işlemenin iyi bir şekilde yapılması model performansını büyük ölçüde etkilemektedir.

Arıza anının 2 hafta öncesinden itibaren toplanan veriler modelleme için kullanılmıştır. Arıza anından önceki 8 saatlik veri “Arızaya Yakın” diğer 2 haftalık veri ise “Arızaya Uzak” olarak etiketlenmiştir. Oluşturulacak modelin sınıflandırma yaparak arızaya yakın ve arızaya uzak olmak üzere 2 kategoride çıkış vermesi beklenmektedir. 3 vardiyalık çalışan bir fabrikada 1 vardiya süresi 8 saattir ve 1 vardiya önceden arıza bildirimini ilk aşamada yeterli olacaktır. Arıza yaşandıkça ve model geliştikçe arızaların daha önceden bildirilmesi hedeflenmektedir.

Modelin doğruluğunu test etmek için sensor verileri ve arıza etiketi arasındaki ilişki veri kümesi iki alt kümeye bölünmektedir. Verilerin % 70 eğitim veri seti ve % 30'u test veri seti için kullanılmıştır. Eğitim veri seti ile model eğitilir ve test veri setiyle de model tahmininin doğruluğunu ölçülür. Test verileri eğitim aşamasına dahil edilmez.

Veri seti etiketleme ve ön işleme aşamalarından sonra gözetimli ML algoritmalarından Naive Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Karar Ağacı, Rastgele Orman ve Lojistik Regresyon algoritmaları ile arıza modelleme çalışmaları yapılmıştır. Model performansı ve karışıklık matrisi verilerine göre en iyi sonuç veren modelin seçimi yapılmıştır.

Modelin performansını değerlendirmek için test kümeleri üzerinde model uygulanarak doğruluk performansı ölçülmektedir. Karışıklık matrisi ile de her sınıfın ayrıntılı sınıflandırma doğruluğu ölçülmektedir. Bu çalışmada kullanılan değerlendirme kriterleri olarak Doğruluk, Kesinlik, Duyarlılık, F1 Skoru ve ROC Eğrisi uygulanmıştır. Karışıklık matrisi, performansın değerlendirilmesine ve sınıflandırıcının etkinliğini doğrulamaya yardımcı olmaktadır.

4. BULGULAR VE TARTIŞMA

Bu kısımda her bir modelin doğruluğunu değerlendirmek için karışıklık matrisinin yanında AUC-ROC eğrileri de oluşturulmuştur. Arızaya Yakın veriler “1” olarak, Arızaya Uzak veriler “0” olarak tanımlanmıştır.

Yapılan modelleme sonucunda arızaya tespitinin başarılı olması için doğru pozitif oranının neredeyse hatasız olması beklenmektedir. Aksi halde, arıza yaşanacağı zaman arıza bildirimini yapılmaması maddi kayba ve üretim kaybına yol açacaktır. Tam zamanlı stoksuz üretim yapılan tesislerde müşteriye gönderilecek parçalarda da sevkiyat sıkıntısı yaşanabilecektir. Endüstriyel pres makinelerinde yaşanan rulman, dişli gibi aktarma organı arızalarının tamiri 1 hafta sürebilmektedir.

4.1. Hidrolik Pompa Motor Makine Öğrenmesi Modeli

Hidrolik pompa motoru veri setinde yaklaşık 476 bin adet arızaya uzak veri, 20 bin adet arızaya yakın veri vardır. Analiz edilecek veriler soldan itibaren sırasıyla: Titreşim X eksen, titreşim Z eksen, titreşim tepe faktörü (crest factor) , titreşim basıklık istatistiksel verisi (kurtosis), titreşim yüksek frekans değeri, sıcaklık değeri ve titreşim ivme değeri verileridir. Veri kümesinde toplam 7 farklı özellik mevcuttur.

-Hidrolik Pompa Motoru Özellikleri: 15kW, 50Hz, 380V, 6 kutuplu, 960d/dk

	vibx	vibz	crest	xkurt	zfreq	temp	zacc	Date	fault
0	1.26	1.71	3.92	2.99	0.07	29.75	0.26	2020-01-16 07:25:31	0
1	1.26	1.71	3.92	2.99	0.07	29.75	0.26	2020-01-16 07:25:33	0
2	0.97	1.09	4.03	2.89	0.07	29.85	0.28	2020-01-16 07:25:35	0
3	0.97	0.86	4.64	2.89	0.07	29.75	0.32	2020-01-16 07:25:37	0
4	0.97	0.86	4.64	2.89	0.07	29.75	0.32	2020-01-16 07:25:39	0

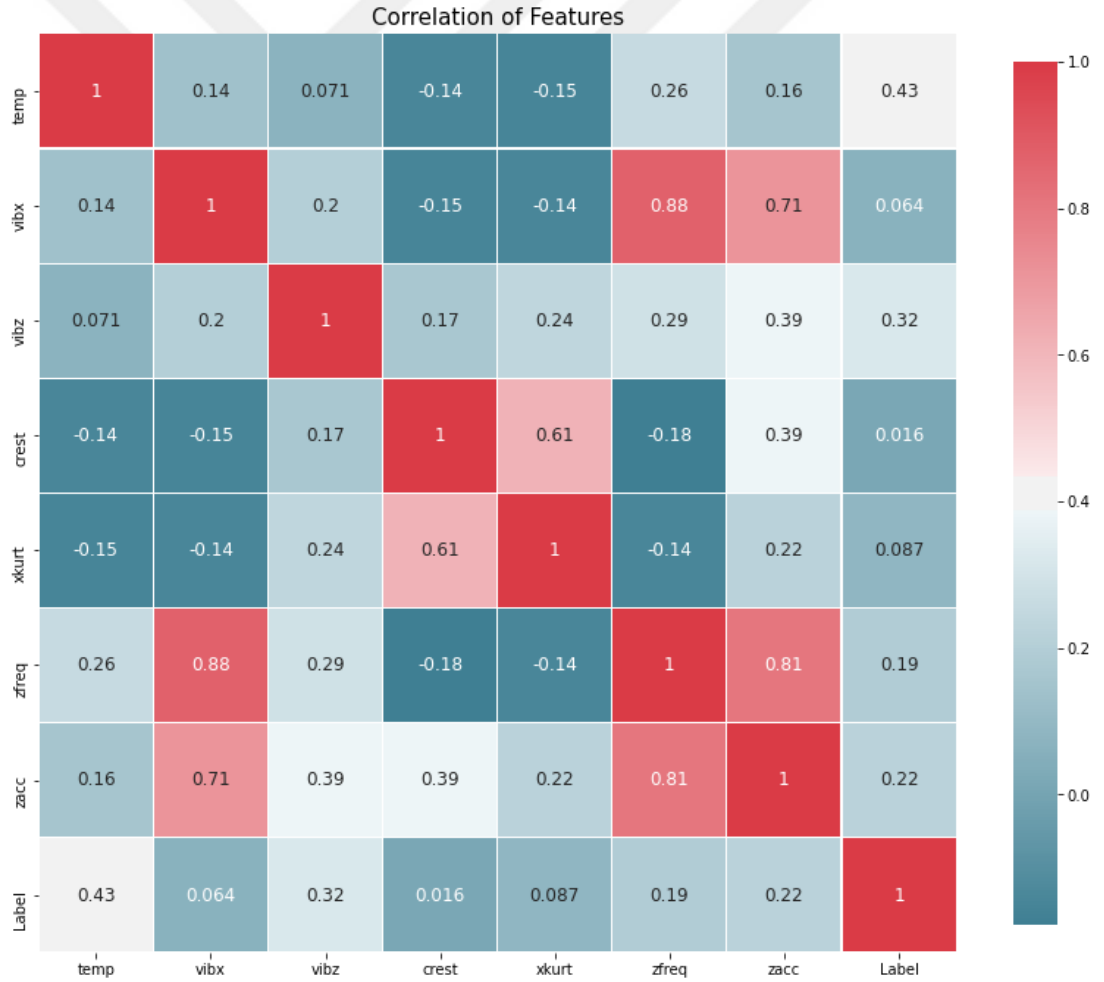
Şekil 4.1. Hidrolik pompa motoru ilk 5 veri örneği

Bu modelde yaklaşık 476 bin adet Arızaya Uzak veri, 20 bin adet Arızaya Yakın veri etiketleme yapılmıştır.

	vibx	vibz	crest	xkurt	zfreq	temp	zacc	Date
fault								
0	476204	476204	476204	476204	476204	476204	476204	476204
1	20874	20874	20874	20874	20874	20874	20874	20874


Şekil 4.2. Hidrolik pompa motoru arıza verisi etiketlenmesi

7 farklı özellik için korelasyon matrisi oluşturulmuştur. Mavi ve kırmızı renk pozitif yönde korelasyonu, koyu mavi renk ise negatif yönde korelasyonu göstermektedir. Örneğin, X eksenı titreşim değeri ile titreşimin yüksek frekans parametresi arasında 0,88 oranında pozitif korelasyon vardır. Biri arttıkça diğeri de artmaktadır. Biri arttıkça diğeri azalan büyük bir negatif korelasyon göze çarpmamaktadır.




Şekil 4.3. Hidrolik pompa motoru korelasyon matrisi

Veri seti içerisinde hangi özelliklerin sonuç üzerinde ne kadar etkili olduğunu belirlemek için ekstra ağaç sınıflandırıcısı yöntemiyle öznelik seçimi yapılmıştır. Bu yöntem bir ağacın dallarına göre sınıflandırma yaparken hangi özelliklerin sonucu bulmada daha etkin olduğunu ortaya koymaktadır. Sıcaklık ve titreşim verilerinin normal ve arıza durumunu yüksek düzeyde temsil ettiği görülmektedir.



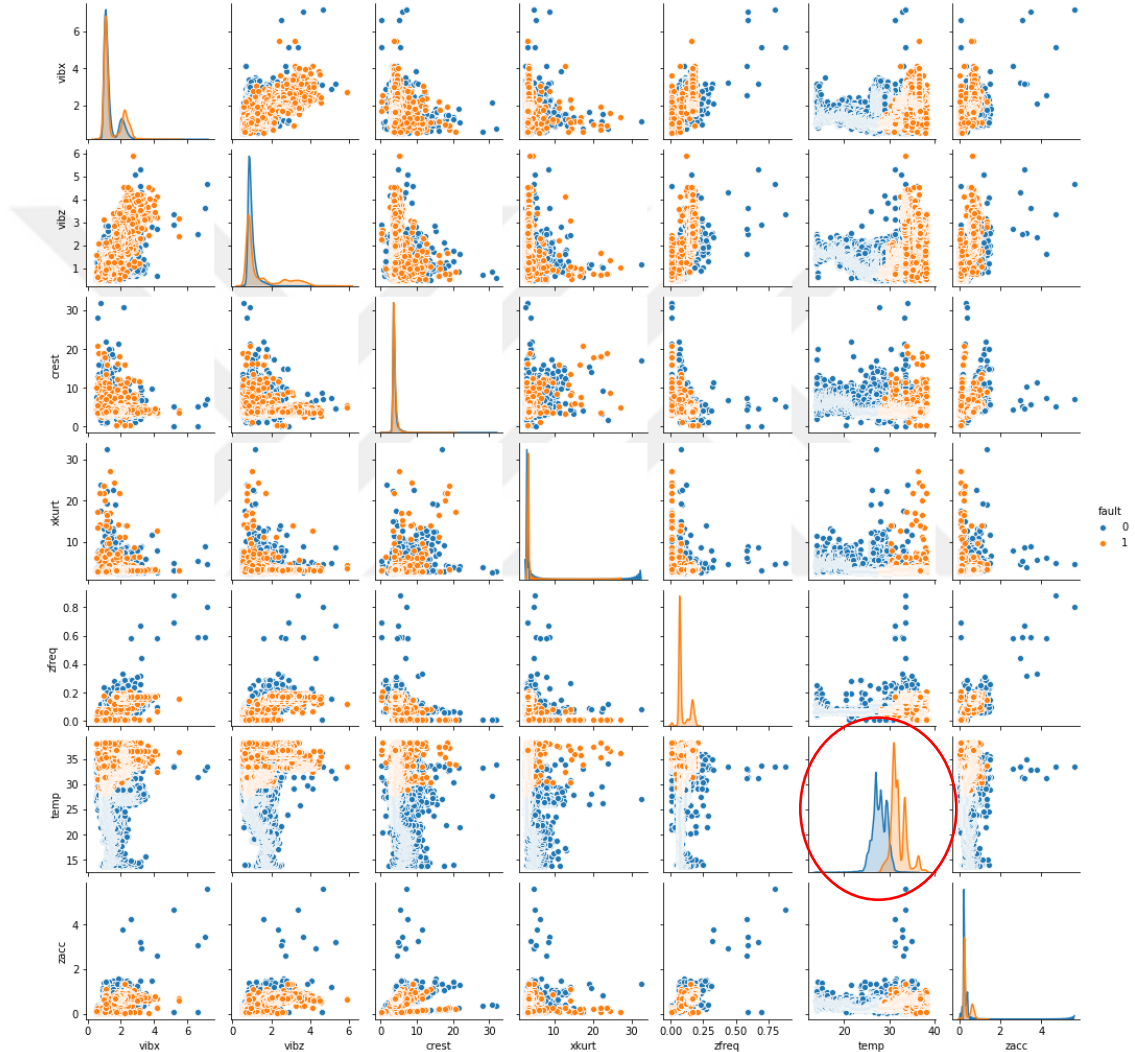
Şekil 4.4. Hidrolik pompa motoru öznelik seçimi

Şekil 4.5’da titreşim ve sıcaklık verilerinin birbirleriyle olan ilişkisi gösterilmiştir. Turuncu renkli arızaya yakın verilerde titreşim ve sıcaklığın arttığı görülmektedir.



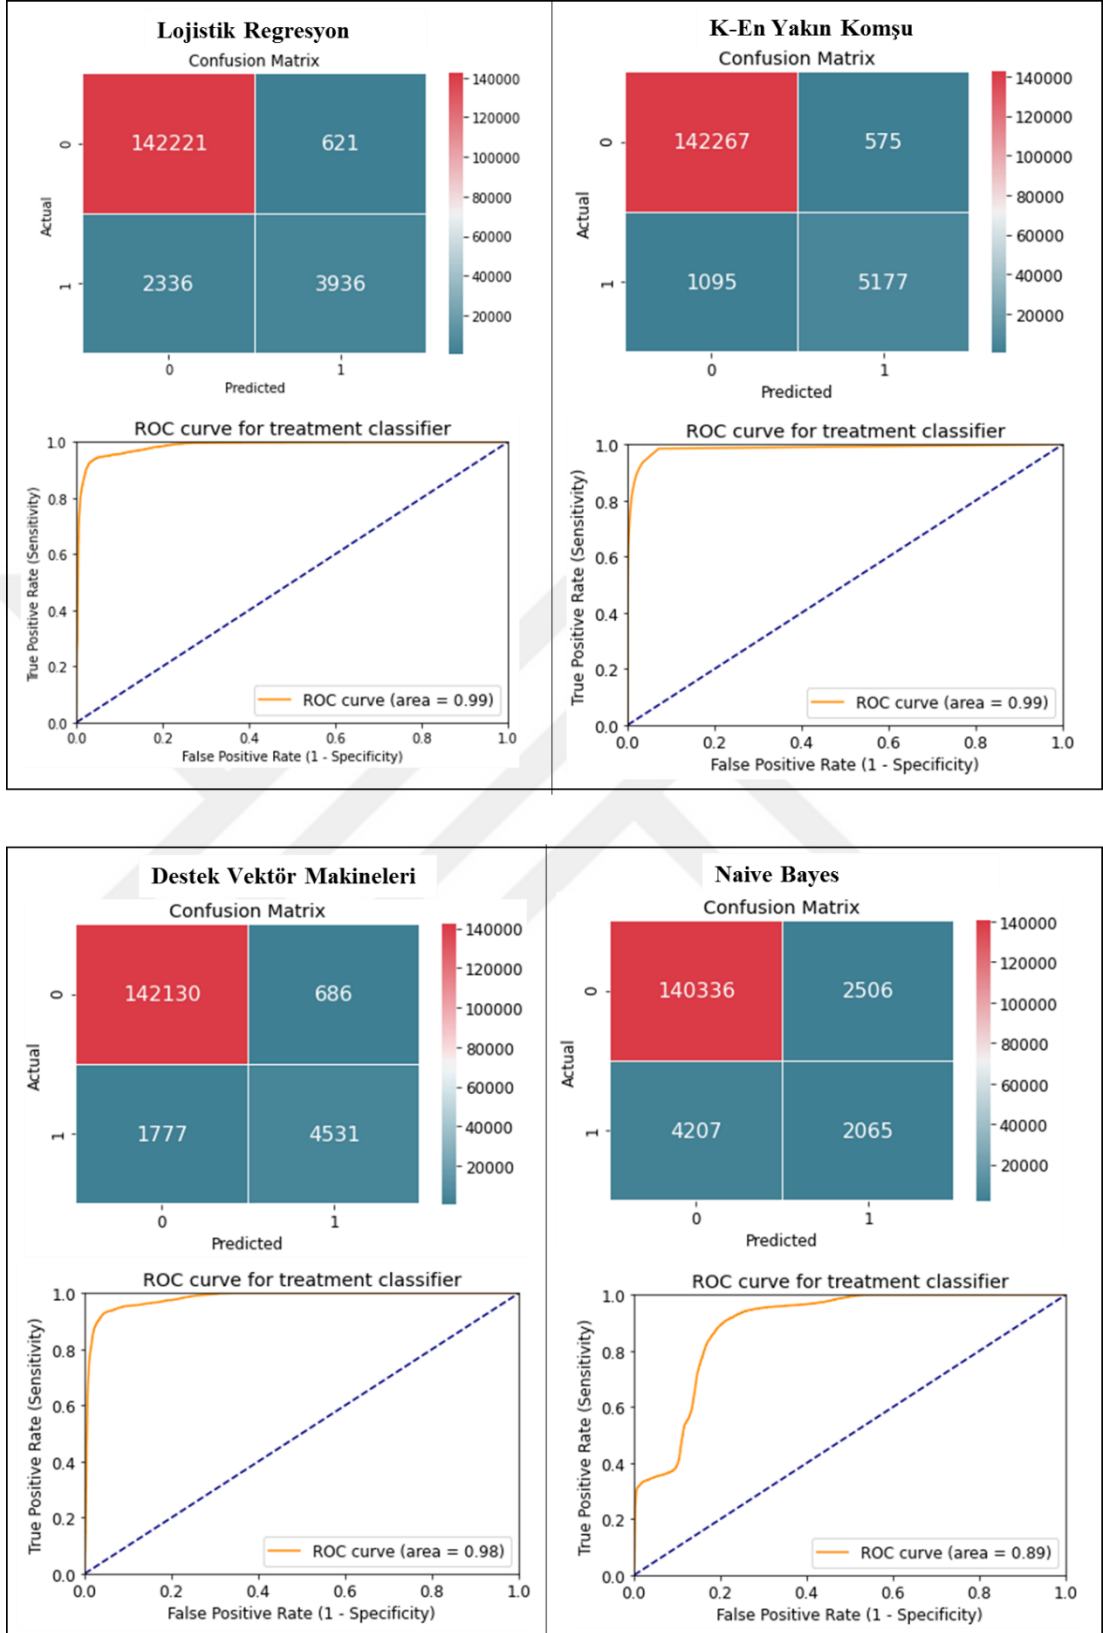
Şekil 4.5. Hidrolik pompa motoru 1.arıza titreşim ve sıcaklık verileri dağılımı

Şekil 4.6’da oluşturulan 7x7’lik korelasyon grafiğinde, veri kümesindeki 7 farklı özelliğin arızaya yakın ve arızaya uzak durumlardaki birbirleriyle olan ilişkileri incelenmiştir. Turuncu renkli noktalar arızaya yakın verileri, mavi renkli noktalar ise arızaya uzak verileri göstermektedir. Kırmızı daire içerisinde alınan sıcaklık verisindeki sınıf ayrımı açıkça görünmektedir. Sıcaklık verileri yaşanan bu arıza için kritik öneme sahiptir.

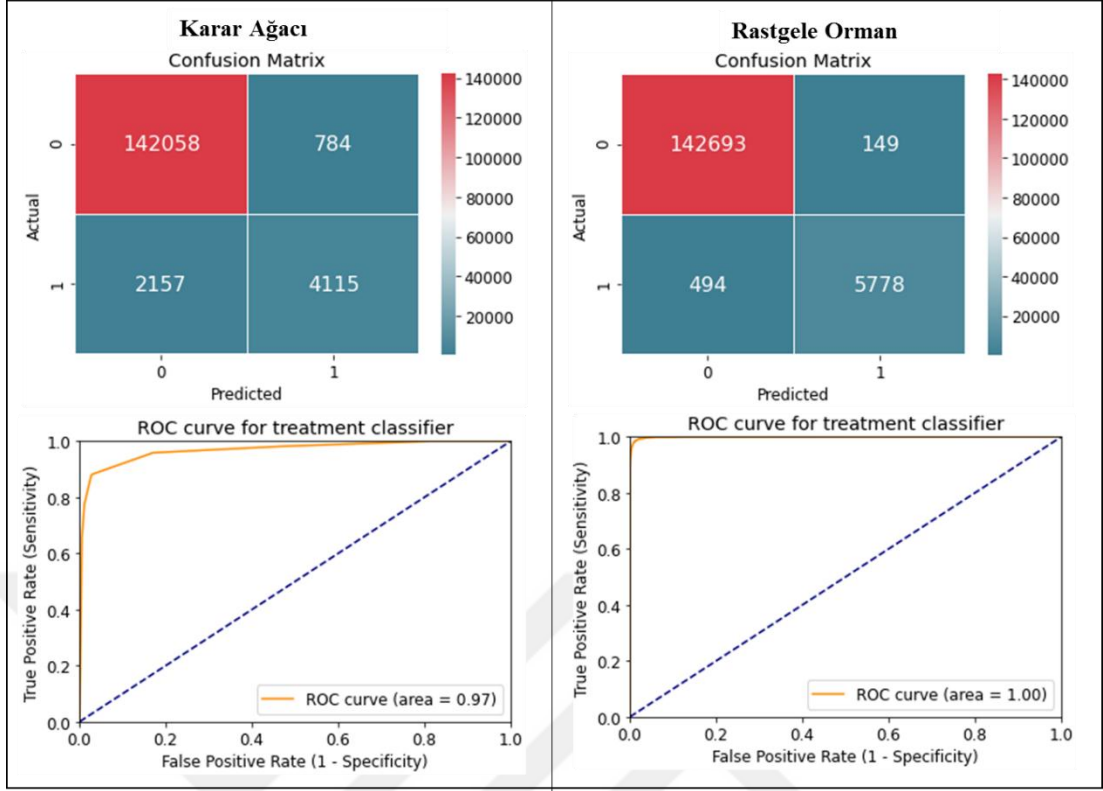


Şekil 4.6. Hidrolik pompa motoru verilerinin dağılım grafileleri

Gözetimli ML algoritmalarından Naive Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Karar Ağacı, Rastgele Orman ve Lojistik Regresyon algoritmaları ile arıza modelleme çalışmaları yapılmıştır. Model performansı ve karışıklık matrisi verilerine göre en iyi sonuç veren modelin seçimi yapılmıştır.



Şekil 4.7. Hidrolik pompa motoru modelleri karışıklık matrisi



Şekil 4.7.(Devam) Hidrolik pompa motoru modelleri karışıklık matrisi

Rastgele Orman modeli %99,5 doğruluk oranıyla en yüksek performansı göstermiştir. Doğruluk Oranının yanında Kesinlik, Duyarlılık ve F1-Skor oranları da yüksek performans sergilemiştir. 142 bin 693 adet arızaya uzak veriyi doğru tahmin etmiştir. 5778 adet arızaya yakın veriyi de doğru tahmin etmiştir. 494 adet veriyi arızaya yakın olduğu halde, arızaya uzak olarak yanlış tahmin etmiştir. 149 adet veriyi de arızaya uzak olduğu halde, arızaya yakın olarak yanlış tahmin etmiştir.


K-en yakın komşu, destek vektör makineleri, karar ağaçları ve lojistik regresyon modelleri de %98 oranında doğruluk sonucu göstermiştir. Destek Vektör Makineleri modeli tüm modeller arasında en yavaş çalışan modeldir. Diğer modellerden 10 kat daha fazla sürede sonuca ulaşmıştır. Veri sayısı arttıkça bu süre daha da uzamaktadır.

Naive Bayes modeli % 95,4 doğruluk oranıyla en düşük performansı göstermiştir. Doğruluk oranı tek başına yeterli bir kriter değildir. Rastgele Orman modeliyle arasında %4'lük Doğruluk Oranı farkı olmasına rağmen karışıklık matrisleri incelendiğinde Kesinlik, Duyarlılık ve F1-Skor oranlarının %30-40 seviyelerinde olduğu görülmektedir. Bu oran ile kıyaslama yapıldığında Naive Bayes modeli çok kötü performans göstermiştir.

Tablo 4.1. 'de tüm yöntemlerin performans sonuçları bir arada gösterilmektedir.

Tablo 4.1. Hidrolik pompa motoru model performans özet tablosu

Metot	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
Lojistik Regresyon	98,00%	86,30%	62,70%	72,60%
K-En Yakın Komşu	98,80%	90,00%	82,50%	86,10%
Destek Vektör Makineleri	98,30%	86,80%	71,80%	78,60%
Naive Bayes	95,40%	45,10%	32,90%	38,00%
Karar Ağaçları	98,00%	83,90%	65,60%	73,60%
Rastgele Orman	99,50%	97,40%	92,10%	94,70%



Şekil 4.8. Hidrolik pompa motoru model performansları

4.1.1. Hidrolik Pompa Motor Arızası

En yüksek performans gösteren Rastgele Orman modeli aynı motorun farklı bir tarihteki diğer arızalı veri seti üzerinde çalıştırılmıştır.

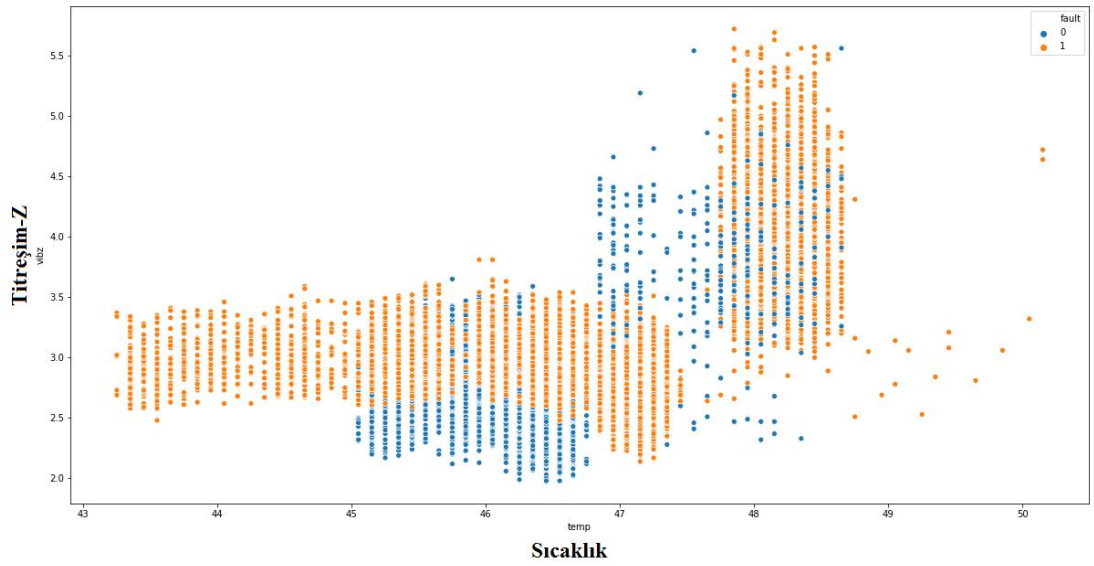
	Time	vibx	vibz	crest	xkurt	zfreq	temp	run	spm	zacc
0	2020-09-10 02:38:33	3.61	2.14	7.49	4.01	0.17	46.25	1.0	21.0	1.28
1	2020-09-10 02:38:42	3.70	2.19	6.22	5.11	0.17	46.25	1.0	20.0	1.05
2	2020-09-10 02:38:45	4.15	2.24	6.00	4.79	0.16	46.25	1.0	20.0	0.98
3	2020-09-10 02:38:47	4.15	2.24	7.48	6.90	0.15	46.25	1.0	20.0	1.12
4	2020-09-10 02:38:50	4.15	2.24	7.48	6.90	0.15	46.25	1.0	21.0	1.12

Şekil 4.9. Hidrolik pompa motoru 2.arıza ilk 5 veri örneği


	vibx	vibz	crest	xkurt	zfreq	temp	run	spm	zacc	Date
fault										
0	6085	6085	6085	6085	6085	6085	6085	6085	6085	6085
1	9198	9198	9198	9198	9198	9198	9198	9198	9198	9198

Şekil 4.10. Hidrolik pompa motoru 2. arıza verisi etiketlenmesi

Arızaya yakın ve arızaya uzak etiketlerine göre titreşim ve sıcaklık verileri arasındaki ilişki Şekil 4.11’de belirtilmiştir. İlk arızadaki grafikte görülen keskin ayrımlar bu grafikte görülememiştir.



Şekil 4.11. Hidrolik pompa motoru 2.arıza titreşim ve sıcaklık verileri dağılımı



Şekil 4.12. Hidrolik pompa motoru 2. arıza model başarıları

Oluşturulan model farklı bir tarihteki arızayı tahminlemesi için çalıştırıldığında %46,6 doğruluk oranıyla başarı göstermiştir. Modellenen önceki arızada motordan anormal sesler gelmesi sonucunda yenisiyle değiştirilmiş ve problem giderilmiştir. Bu arızada ise sistem hidrolik basınç düşük uyarısı vermiştir. Her iki arızanın karakteristiğinin birbirinden farklı oluşu, ikinci arızadaki model performansını düşürmüştür. Arızalar yaşandıkça model geliştirilerek performansın artması hedeflenmektedir.

4.2. Yağlama Motoru Makine Öğrenmesi Modeli

Yağlama motoru veri setinde yaklaşık 645 bin adet arızaya uzak veri, 11 bin adet arızaya yakın veri vardır. Analiz edilecek veriler soldan itibaren sırasıyla: Sıcaklık, titreşim X eksen, titreşim Z eksen, titreşim tepe faktörü (crest factor) , titreşim basıklık istatistiksel verisi (kurtosis), titreşim yüksek frekans değeri, titreşim ivme değeri, pres dakikadaki vuruş sayısı (spm); yağ kirlilik seviyesi 4 mikron-6 mikron-14 mikron partikül sayıları, yağ sıcaklığı ve yağ bağlı nem miktarı verileridir. Toplamda 13 farklı özellik vardır. Titreşim verileri 4 saniyelik olarak, yağ kirlilik verileri 5 dakikalık olarak toplandığından iki ayrı veri dakikalık bazda birbiri ile birleştirilmiştir.

-Yağlama Motoru Özellikleri: 7kW, 50Hz, 380V, 6 kutuplu, 960 d/dk

	temp	vibx	vibz	crest	xkurt	xfreq	xacc	spm	4	6	14	tempf	rh	Time	fault
0	43.15	1.39	1.33	4.38	4.79	0.07	0.32	210.0	40495	11950	207	32.83	23.27	2020-11-01 00:00	0
1	43.15	1.34	1.43	4.56	4.85	0.07	0.33	210.0	40495	11950	207	32.83	23.27	2020-11-01 00:00	0
2	43.15	1.39	1.33	4.25	4.72	0.07	0.31	210.0	40495	11950	207	32.83	23.27	2020-11-01 00:00	0
3	43.15	1.38	1.35	4.22	4.51	0.07	0.31	210.0	40495	11950	207	32.83	23.27	2020-11-01 00:00	0
4	43.15	1.33	1.36	4.30	4.91	0.07	0.31	210.0	40495	11950	207	32.83	23.27	2020-11-01 00:00	0

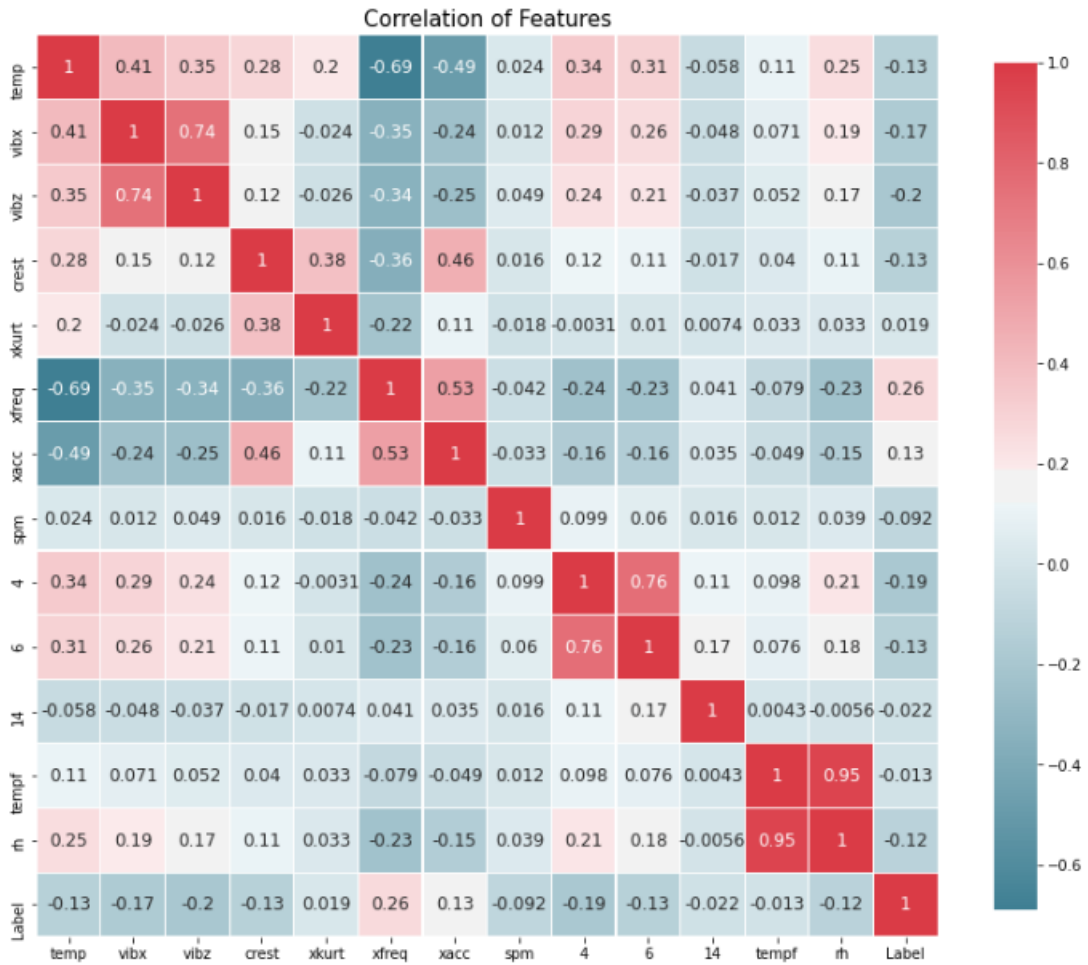
Şekil 4.13. Yağlama motoru ilk 5 veri örneği

Bu modeled yaklaşık 476 bin adet Arızaya Uzak veri, 20 bin adet Arızaya Yakın veri etiketleme yapılmıştır.

	temp	vibx	vibz	crest	xkurt	xfreq	xacc	spm	4	6	14	tempf	rh	Time
fault														
0	645680	645680	645680	645680	645680	645680	645680	645680	645680	645680	645680	645680	645680	645680
1	10957	10957	10957	10957	10957	10957	10957	10957	10957	10957	10957	10957	10957	10957

Şekil 4.14. Yağlama motoru arıza verisi etiketlenmesi


13 farklı özellik için korelasyon matrisi oluşturulmuştur. Mavi ve kırmızı renk pozitif yönde korelasyonu, koyu mavi renk ise negatif yönde korelasyonu göstermektedir. Örneğin, 4 mikron yağ partikül sayısı değeri ile 6 mikron yağ partikül sayısı değeri arasında 0,76 oranında pozitif korelasyon vardır. Biri arttıkça diğeri de artmaktadır. Sıcaklık ile titreşim yüksek frekans değeri arasında da 0,69 oranında negatif korelasyon göze vardır. Biri arttıkça diğeri azalmaktadır.



Şekil 4.15. Yağlama motoru korelasyon matrisi

Sıcaklık ve titreşim verilerinin veri seti üzerinde normal ve arıza durumunu yüksek düzeyde temsil ettiği görülmektedir. Yağın kirlilik derecesiyle motorun arızası arasında yüksek bir ilişki görünmemektedir. Farklı arızalar için yağ kirliliği önemli bir parameter olabilir. Bu sebeple modelin gelişimi için bu parametreler yeni arızalar için göz önünde bulundurulacaktır.

Veri seti içerisinde hangi özelliklerin sonuç üzerinde ne kadar etkili olduğunu belirlemek için ekstra ağaç sınıflandırıcısı yöntemiyle öznelik seçimi yapılmıştır. Sıcaklık ve titreşim verilerinin normal ve arıza durumunu yüksek düzeyde temsil ettiği görülmektedir.

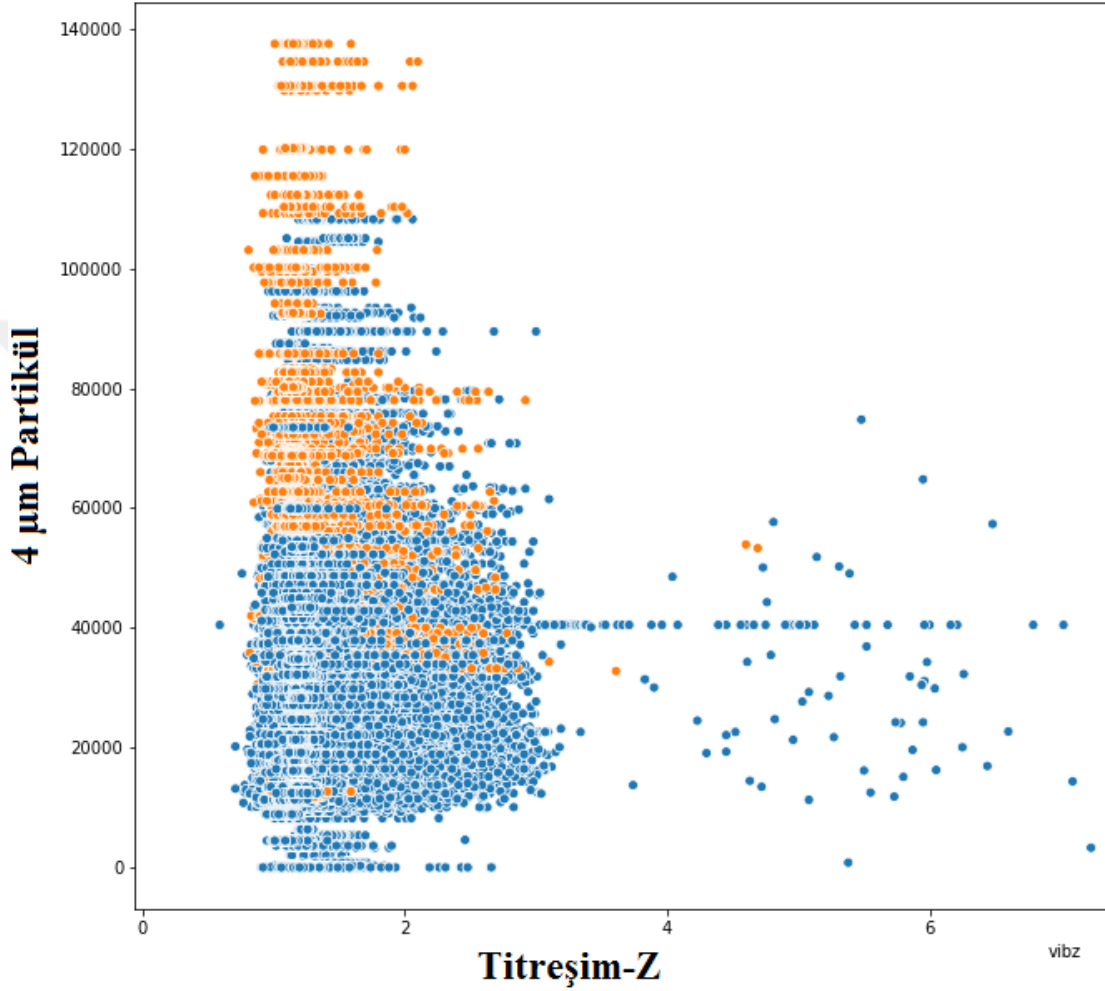


Şekil 4.16. Yağlama motoru öznelik seçimi

Şekil 4.17’de titreşim-Z ve yağ içerisindeki 4 µm partikül verilerinin birbirleriyle olan ilişkisi gösterilmiştir. Turuncu renkli arızaya yakın verilerde 4 µm partikül sayısının arttığı görülmektedir.

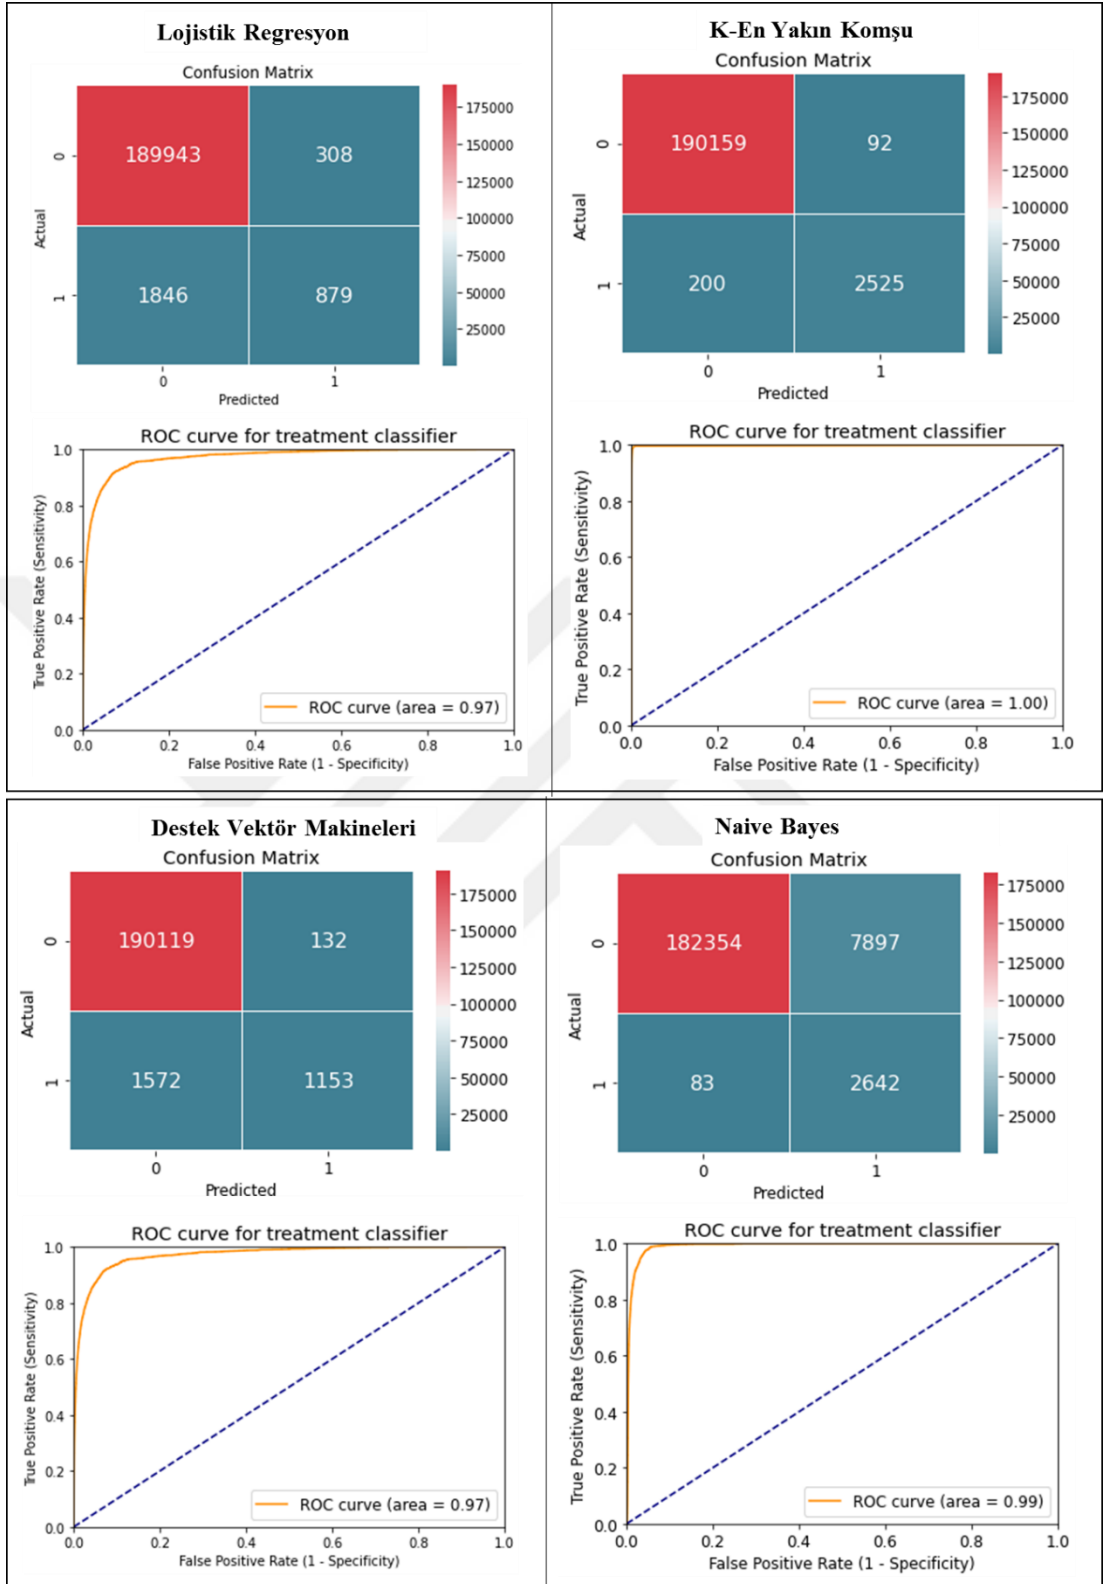
Pratikte yağ kirlilik seviyesinin artışı, yağlama motorunun işlevini yapamamasına ve motorun ısınmasına sebep olmaktadır. Yağ kirlilik seviyesi arttıkça yağ viskozitesi bozulmakta ve motor arızalarına sebep olmaktadır. Yağın kirlilik seviyesini ölçen sistemler sayesinde anormal aşınmalarda erken müdahale ve makine yağının uygun

koşullarda olduğunun tespiti kolaylıkla yapılabilmektedir. Kullanılan ölçüm sistemi ile birlikte yağ filtrasyonu da yapılmakta ve ekipmanların çalışma ömürleri uzamaktadır. Yağın içerisindeki su miktarı ve yağın sıcaklığı da yağ viskozitesi için kritik öneme sahiptir.

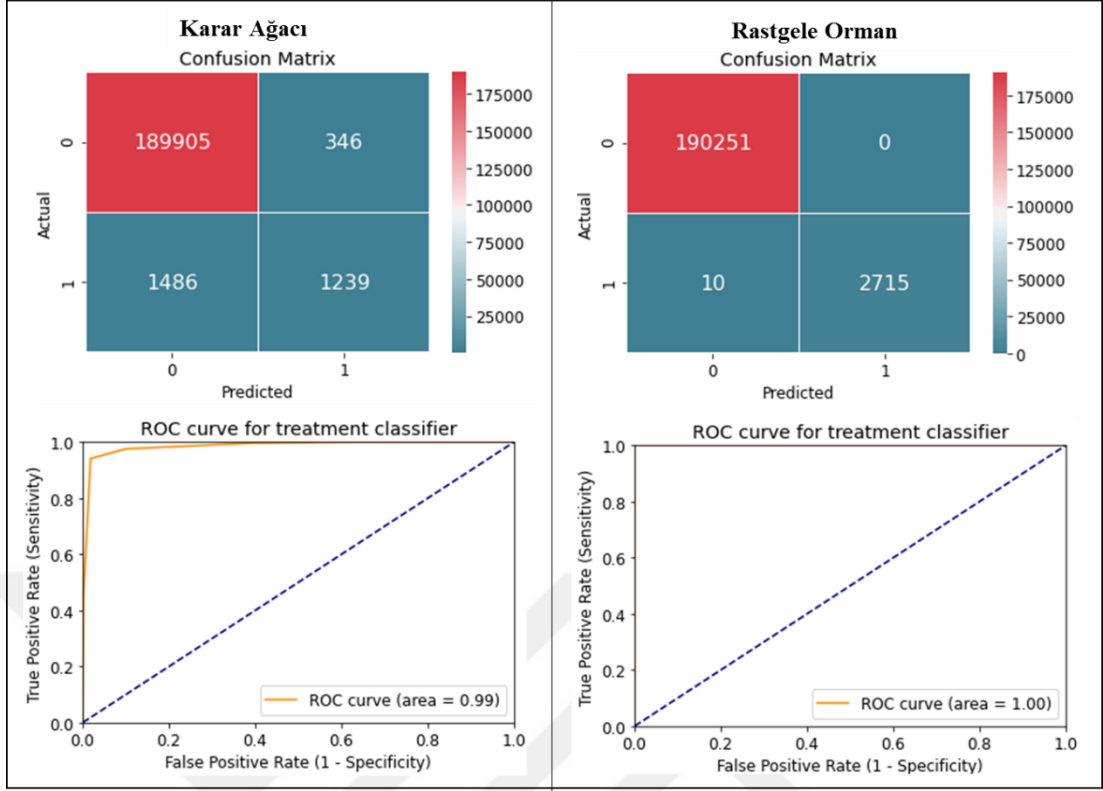


Şekil 4.17. Yağlama motoru titreşim ve 4 µm partikül verileri dağılımı

Yağlama motoru için oluşturulan Rastgele Orman modeli %99,9 Doğruluk oranıyla en yüksek çıkan performansı göstermiştir. Doğruluk oranının yanında Kesinlik, Duyarlılık ve F1-Skor oranları da yüksek performans sergilemiştir. 190 bin 251 adet arızaya uzak veriyi doğru tahmin etmiştir. 2715 adet arızaya yakın veriyi de doğru tahmin etmiştir. 10 adet veriyi arızaya yakın olduğu halde, arızaya uzak olarak yanlış tahmin etmiştir. Arızaya uzak olduğu halde, arızaya yakın olarak yanlış tahmin ettiği veri yoktur. Naive Bayes modeli %95,8 doğruluk oranıyla en düşük performansı göstermiştir.



Şekil 4.18. Yağlama motoru modelleri karışıklık matrisi



Şekil 4.18.(Devam) Yağlama motoru modelleri karışıklık matrisi

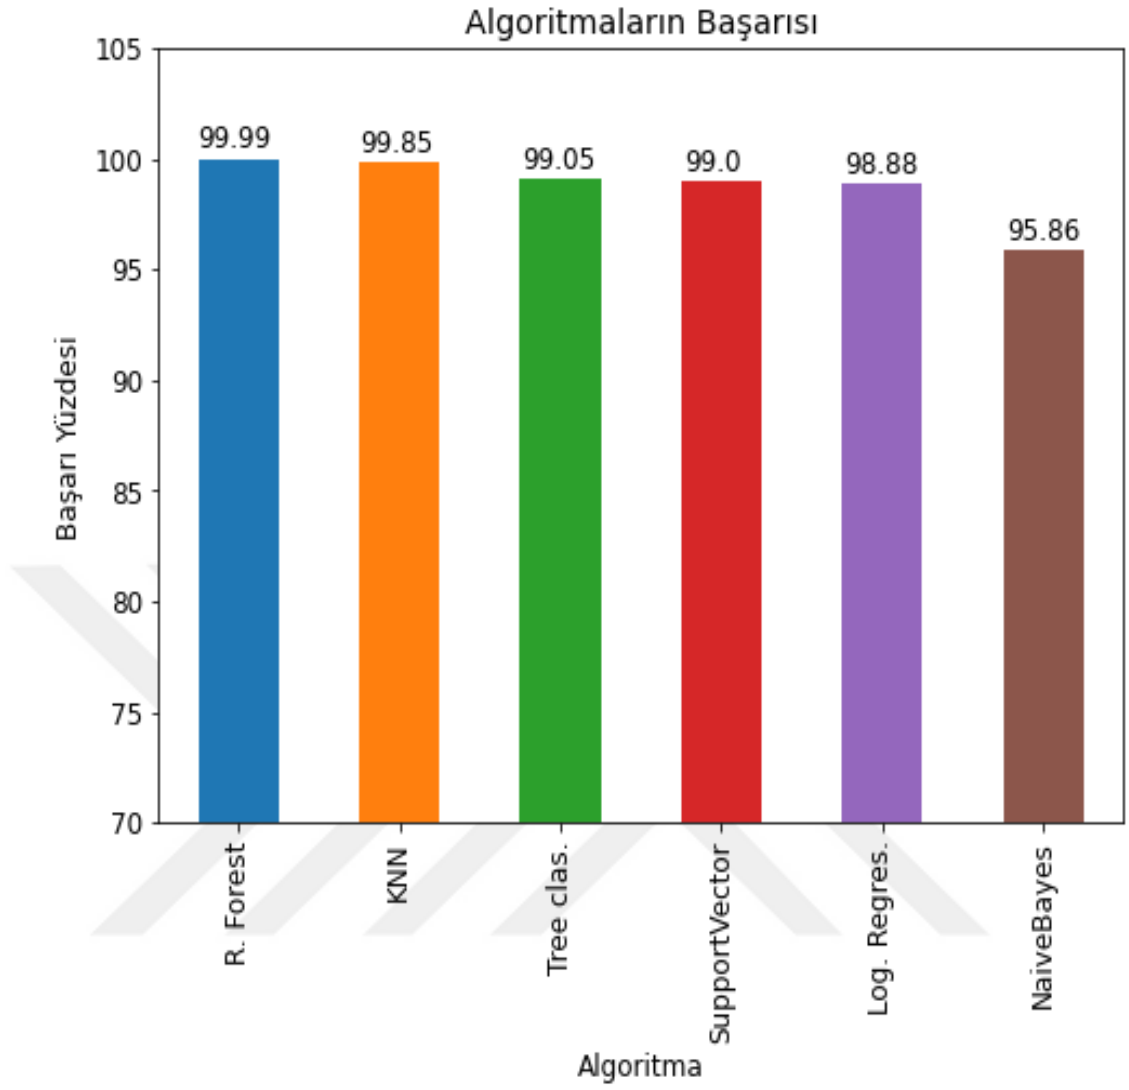
Tablo 4.2’de tüm yöntemlerin performans sonuçları bir arada gösterilmektedir.

Tablo 4.2. Yağlama motoru model performans özet tablosu

Metot	Doğruluk	Kesinlik	Duyarlılık	F1-Skor
Lojistik Regresyon	98,80%	74,00%	32,20%	44,90%
K-En Yakın Komşu	99,80%	96,40%	92,60%	94,50%
Destek Vektör Makineleri	99,00%	89,70%	42,30%	57,50%
Naive Bayes	95,80%	25,00%	96,90%	39,80%
Karar Ağaçları	99,00%	78,10%	45,40%	57,40%
Rastgele Orman	99,90%	100,00%	99,60%	99,80%

Rastgele Orman modelinde Kesinlik oranının %100 çıkması modelin yanlış arıza bilgisi vermediği anlamına gelmektedir. Sadece arızalı verileri bildirmesi sisteme olan güveni de arttıracaktır.

Yağlama motorunda modellenen arıza haricinde herhangi bir arıza yaşanmadığı için modelin ikinci bir arıza performansı test edilememiştir. Oluşturulan bu model de arızalar yaşandıkça geliştirilecektir.



Şekil 4.19. Yağlama motoru model performansları

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışması kapsamında, 2500 ton endüstriyel transfer pres makinesindeki kestirimci bakım çalışmalarından bahsedilmiştir. Pres makine kontrolcüsünden toplanan temel verilerin yanında, makinenin belirlenen noktalarına yerleştirilen algılayıcılar ile sıcaklık, titreşim, yağ kirlilik seviyesi gibi veriler de toplanmıştır. Bu yaklaşım ile gerçek zamanlı olarak toplanan farklı çalışma koşullarına ait ham verilerden arızalar için anlamlı bilgi taşıyan özneliklerin seçimi ve çıkarımı yapılmıştır. Ham girdi verilerinden eksik ve yanlış veriler temizlenmiş, arızalarla ilgili gizli bilgiler ortaya çıkarılmış, daha sonra bu veriler farklı seviyelere bölünerek boyutunun azaltılması sağlanmıştır. Verinin hazır hale getirilmesi için yapılan tüm bu çalışmalar makine öğrenmesi modellerininin büyük bir kısmını oluşturmuştur. Hazır hale getirilen veriler, ekipmanın verdiği arıza ile eşleştirilerek etiketlenmiştir. 2 motor arızası için denetimli makine öğrenmesi algoritmaları ile arıza teşhis modelleri gerçekleştirilmiştir. Arıza modellemesinde sınıflandırmaya dayalı algoritmalar kullanılarak etiketlenmiş veriler ile modeller eğitilmiştir. Bakım çalışmalarında personele bilgi verebilecek çıktılar üretmek hedeflenmiştir. Sistemin 8 saat önceden uyarı vermesi için çalışmalar yapılmıştır.

İki farklı motor için ayrı ayrı veri setleri eğitilerek oluşturulan modeller, test veri kümeleriyle denenmiş ve performansları ayrı ayrı gözlemlenmiştir. Oluşturulan modeller tüm veri seti ile de ayrı ayrı doğrulanmıştır. Naive Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Karar Ağacı, Rastgele Orman ve Lojistik Regresyon olmak üzere 5 farklı model oluşturulmuştur. Rastgele Orman modeli arıza kestiriminde diğer yöntemlere göre önemli farkla başarılı sonuçlar üretmiştir. Geliştirilen Rastgele Orman modeli hidrolik pompa motoru veri seti için %99.5 ve yağlama motoru veri seti için %99.9'luk sınıflandırma oranları ile en yüksek performansı göstermiştir. Naive Bayes algoritması, iki veri seti üzerinde de en düşük performans gösteren algoritma olmuştur. Her ne kadar Naive Bayes modelinin doğruluk değerleri diğer yöntemlerden belirgin biçimde kötü olmasa da, gerçek arızaların tahmin edilememesi, önemli maliyet ve üretim kaybına yol açacağından

kabul edilebilir değildir. Gerçekte arıza olmayacağı halde arıza uyarısının verilmesi gereksiz yere motorlara bakım yapılmasına neden olacaktır. Bazı durumlarda ise sisteme olan güvenilirliği azaltacaktır.

Hidrolik pompa motorunda yaşanan ilk arızaya göre %99.57 başarı performansı ile oluşturulan model, ikinci arızada test edildiğinde %46.6 performans göstermiştir. Yaşanan arızaların karakteristikleri ve arıza anındaki makine koşulları birbirinden farklı olduğundan toplanan veriler arttıkça ve yeni arızalar yaşandıkça ML modeli daha da gelişecektir.

Endüstri 4.0 ve Akıllı Fabrika çalışmaları kapsamında üretim hatlarındaki makinelere yerleştirilecek sensörler ile yapılacak kestirimci bakım çalışmaları için gelecekteki çalışmalara yol gösterebilecek nitelikte sonuçlar elde edilmiştir. Tez çalışmasının devamında, burada elde edilen sonuçlar ışığında önerilen yöntem, fabrikadaki diğer makinelerden toplanan veriler için de uygulanabilir ve üretilen sonuçlara göre bakım planlaması gerçekleştirilebilir.

Bu tez, sanayide kestirimci bakım uygulamaları için arıza teşhisi konusunda ML yöntemlerinden nasıl faydalanılabileceğini göstermiştir. Kestirimci bakım ile arıza teşhisi; daha güvenli, daha etkili ve daha uygun maliyetli bakım faaliyetleri yürütmek için çok önemlidir. Hangi ekipmanın arıza vereceği hakkında bilgi verdiğinden akıllı bakım kararlarının etkinleştirilmesi için gereklidir. Bu bilgiler, yedek parçaların arıza yaşanmadan önce temin edilmesine ve değiştirilmesine olanak sağlamaktadır. Ayrıca problemin temel nedenini keşfederek tekrar yaşanmamasını sağlamak için önlem alınmasına yardımcı olmaktadır.

Sonuç olarak, makine verimliliğini artıran ve bakım maliyetlerinin düşüren kestirimci bakım uygulamaları bakım yönetiminin performansını doğrudan etkilemektedir. Etkin bir şekilde kestirimci bakım uygulayan işletmeler önemli rekabet üstünlükleri elde etmektedir. Bu doğrultuda doğru zamanda doğru bakım yapılmasını sağlayan kestirimci bakım uygulamaları, işletmeler açısından oldukça önemli hale gelmiştir.

KAYNAKLAR

- [1] Kanawaday A., Sane A., Machine learning for predictive maintenance of industrial machines using IoT sensor data, *Software Engineering and Service Science (ICSESS) 2017 8th IEEE International Conference*, 87-90, 2017.
- [2] Lejon E., Kyösti P., Lindström J., Machine learning for detection of anomalies in press-hardening: Selection of efficient methods, *Procedia CIRP*, 2018, **72** 1079–1083.
- [3] Pelt M., Stamoulis K., Apostolidis A., Data analytics case studies in the maintenance, repair and overhaul (MRO) industry, *MATEC Web of Conferences*, 304, 2019.
- [4] Kadioğlu T., Toprak T., Raylı Sistem Araçlarında Rams Verilerini ve Tekniklerini Kullanarak Araç Performansını Bakım ve Arıza Giderlerini İyileştirmek, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 2020, **19**(38), 190-207.
- [5] Carvalho T., Soares F., Vita R., Francisco R., Basto J.P., Alcalá G., A Systematic Literature Review of Machine Learning Methods Applied to Predictive Maintenance, *Computers & Industrial Engineering*, 2019, **10**(137), 1-14.
- [6] Wuest T., Weimer D., Irgens C., Thoben K.D., Machine Learning in Manufacturing: Advantages, Challenges, and Applications, *Production & Manufacturing Research*, 2016, **4**(1), 23–45.
- [7] Ayan Ö.A., Döner Makine Elemanların Titreşim Analizi ile Kestirimci Bakımı, Trakya Üniversitesi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Edirne, 2019, 536493.
- [8] Öztanır Ö., Makine Öğrenmesi Kullanılarak Kestirimci Bakım, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2018, 492302.
- [9] Acar G., Otomotiv Sektöründe Kullanılan Kestirimci Bakım Yöntemleri ve Uygulamaları, Kocaeli Üniversitesi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Kocaeli, 2014, 372696.
- [10] Halil Y., Karadayi M., Titreşim Analizi ile Pompalarda Arıza Tesbiti ve Kestirimci Bakım İçin Örnek Bir Çalışma, *Makina Mühendisleri Odası MMO*, 2014, 36–51.
- [11] Pinto R., Cerquitelli T., Robot fault detection and remaining life estimation for predictive maintenance. *Procedia Computer Science*, 2019, **151**, 709–716.

- [12] Killeen P., Ding B., Kiringa I., Yeap T., IoT-based predictive maintenance for fleet management, *Procedia Computer Science*, 2019, **151**, 607–613.
- [13] Dalzochio J., Kunst R., Pignaton E., Binotto A., Sanyal S., Favilla J., Barbosa J., Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges, *Computers in Industry*, **123**, 2020.
- [14] Göçülü G., İşletmelerde Kestirimci Bakım Uygulamaları, Mustafa Kemal Üniversitesi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Hatay, 2015, 408935.
- [15] Keleşoğlu C., Konik Dişlilerde Yapay Sinir Ağı Yöntemiyle Arıza Teşhisi, Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2015, 413432.
- [16] Kalem S., Yapay Sinir Ağları Kullanarak Dişli Kutusu Arıza Analizi, Yüksek Lisans Tezi, Niğde Üniversitesi, Fen Bilimleri Enstitüsü, Niğde, 2008, 245137.
- [17] Erol S.S., Dinamik Sistemlerin Kestirimci Bakımına Etki Eden Faktörlerin Durum Bazlı İncelenmesi, Pamukkale Üniversitesi, Doktora Tezi, Fen Bilimleri Enstitüsü, Denizli, 2015, 409992.
- [18] Kızrak M.A., Bolat B., Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım, *Bilişim Teknolojileri Dergisi*, 2019, **12** (2), 103-109.
- [19] Malhotra P., Ramakrishnan A., Anand G., Vig L., Agarwal P., Shroff G., LSTM-Based Encoder-Decoder for Multi-sensor Anomaly Detection, *ICML 2016 Anomaly Detection Workshop*, New York, NY, ABD, 11 Temmuz 2016.
- [20] Benedetti M., Leonardi F., Messina F., Santoro C., Vasilakos A., Anomaly Detection and Predictive Maintenance for Photovoltaic Systems, *Neurocomputing*, 2018, **310**, 59-68.
- [21] Xu J., Wang Y., Xu L., PHM-Oriented Integrated Fusion Prognostics for Aircraft Engines Based on Sensor Data, *IEEE Sensors Journal*, 2014, **14** (4), 1124-1132.
- [22] Bayram S., Kaplan K., Kuncan M., Ertunç H.M., Bilyeli Rulmanlarda Zaman Uzayında İstatistiksel Öznitelik Çıkarımı ve Yapay Sinir Ağları Metodu ile Hata Boyutunun Kestirimi, *Otomatik Kontrol Ulusal Toplantısı*, Malatya, Türkiye, 26-28 Eylül 2013.
- [23] Karaçay K., Aktürk N., Bilyalı Rulman Yerel Kusurlarının Neden Olduğu Titreşimlerin Modellenmesi, *Gazi Üniv. Müh. Mim. Fak. Dergisi*, 2009, **24** (2), 191-197.
- [24] Baptista M., Sankararaman S., Medeiros I. P., Nascimento C., Prendigar H., Henriques E.M.P., Forecasting Fault Events for predictive maintenance Using Data-Driven Techniques and ARMA Modeling, *Computers & Industrial Engineering*, 2018, **115**, 41-53.

- [25] Canizo M., Onievey E., Condez A., Charramendietax S., Trujillo S., Real-time Predictive Maintenance for Wind Turbines Using Big Data Frameworks, *IEEE International Conference on Prognostics and Health Management*, Dallas, ABD, 19-21 Haziran 2017.
- [26] Prytz R., Nowaczyk S., Rögnavaldsson T., Byttner S., Predicting The Need for Vehicle Compressor Repairs Using Maintenance Records and Logged Vehicle Data, *Engineering Applications of Artificial Intelligence*, 2015, **41**, 139-150.
- [27] Lasisi A., Attoh-Okine N., Principal Components Analysis and Track Quality Index: A Machine Learning Approach, *Transportation Research Part C*, **91**, 2018, 231-238.
- [28] Lejona E., Kyosti P., Lindstrom J., Machine Learning for Detection of Anomalies in Press-Hardening: Selection of Efficient Methods, *51st CIRP Conference On Manufacturing Systems*, Stockholm, İsviçre, 16-18 Mayıs 2018.
- [29] Susto G.A., Schirru A., Pampuri S., McLoone S., Beghi A., Machine Learning for Predictive Maintenance: A Multiple Classifier Approach, *IEEE Transactions on Industrial Informatics*, 2015, **11** (3), 812-820.
- [30] Praveenkumar T., Saimurugan M., Krishnakumar P., Ramachandran K.I., Fault Diagnosis of Automobile Gearbox Based on Machine Learning Techniques, *12th Global Congress on Manufacturing and Management*, Vellore, Hindistan, 8-10 Aralık, 2014.
- [31] Pan Z., Ge Y., Zhou Y.C., Huang J.C., Zheng Y.L., Zhang N., Liang X.X., Gao P., Zhang G.Q., Cognitive Acoustic Analytics Service for Internet of Things, *IEEE 1st International Conference on Cognitive Computing*, Havaii, ABD, 25-30 Haziran 2017.
- [32] Ceyhan C., İot İle Bulanık Mantık Temelli Kestirimci Bakım Çözümüne Yönelik Sistem Tasarımı ve Uygulaması, Erciyes Üniversitesi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Kayseri, 2019, 534700.
- [33] Strecht P., Cruz L., Soares C., Mendes J., A comparative study of classification and regression algorithms for modelling students' academic performance, *In International Conference on Educational Data Mining (EDM)*, 2015, 392-395.
- [34] Andrew K.S., Daming L., Dragan B., A review on machinery diagnostics and prognostics implementing condition-based maintenance, *Mechanical Systems and Signal Processing*, 2006, **20**(7), 1483-1510.
- [35] Yurtsever M., Makine Öğrenmesi Ve Derin Öğrenme Yöntemleri İle Titreşim Analizi Tabanlı Arıza Teşhis Ve Kestirimci Bakım Sistem Tasarımı, Doktora Tezi, Ege Üniversitesi Sosyal Bilimler Enstitüsü, 2020, 649039.
- [36] Lee J., Shin J., Realff M., Machine learning: Overview of the recent progresses and implications for the process systems engineering field, *Comput. Chem. Eng.*, 2018, **114**(6), 111-121.

- [37] Dimitoglou G., James A. Adams, Carol M. Jim, Comparison of the C4.5 and a Naive Bayes Classifier for the Prediction of Lung Cancer Survivability, *Journal of Computing*, 2012, **4**(8).
- [38] Cao D.S, Huang C., Yan J., Zhang L.X., Hu Q.N, Xu Q.S., Liang Y.Z., Kernel k-nearest neighbor algorithm as a flexible SAR modeling tool, *Chemom. Intell. Lab. Syst.*, 2012, **114**(2), 19-23.
- [39] Wahbeh A., Al-Radaideh Q., Al-Kabiand M., Al-Shawakfa E., A Comparition Study Between Data Mining Tools Over Some Classification Methods, *International Journal of Advanced Computer Science and Applications*, 2011, **35**(1), 18-26.
- [40] Vapnik V. N., A review of process fault detection and diagnosis: Part I: Quantitative model-based methods, *Computers & Chemical Engineering*, 1995, **27**(3), 293-311.
- [41] Susilo D., Widodo A., Prahasto T., Nizam M., Fault diagnosis of roller bearing using parameter evaluation technique and multi-class support vector machine, *AIP Conference Proceedings*, 1788, 2017.
- [42] García P.J., Gonzalo E., Vilán J.A., A new predictive model based on the PSO-optimized support vector machine approach for predicting the milling tool wear from milling runs experimental data, *Int J Adv Manuf Technol.*, 2016, **86**, 769–780.
- [43] Cawley G.C., Talbot N. L., On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation, *Journal of Machine Learning Research*, 2010, **11**, 2079–2107.
- [44] Sun, H., Hu X., Attribute Selection for Decision Tree Learning with Class Constraints, *Chemometrics and Intelligent Lab. Systems*, 2017, **163**, 16-23.
- [45] Breiman L., Random forests, *Mach. Learn.*, 2001, **45**(1), 5-32.
- [46] Biau G., Scornet E., A random forest guided tour, *An Official Journal of the Spanish Society of Statistics and Operations Research*, 2016, **25**, 197–227.
- [47] Diaz P., Salas J.C., Cipriano A., Núñez F., Random forest model predictive control for paste thickening, *Minerals Engineering*, 163, 2021.
- [48] Benali, L., Notton G., Fouilloy A., Voyant C., Dizene R., Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components, *Renewable Energy*, 2019, **132**, 871-884.
- [49] Al-Juaidi A.E.M., Nassar A.M. Al-Juaidi, O.E.M. Evaluation of flood susceptibility mapping using logistic regression and GIS conditioning factors, *Arab J Geosci*, 765, 2018.

- [50] Coates A., Demystifying unsupervised feature learning, Ph.D. dissertation, Stanford Üniversitesi, Eylül 2012.
- [51] Saxena A., Prasad M., Gupta A., Bharill N., Patel O., Tiwari A., A review of clustering techniques and developments, *Neurocomputing*, 2017, **267**, 664-681.
- [52] Jain A.K., Data clustering: 50 years beyond k-means, *Pattern Recognition Letters*, 2010, **31**(8), 651-666.
- [53] Samanta B., Al-Balushi K., Artificial neural network based fault diagnostics of rolling element bearings using time-domain features, *Mechanical Systems and Signal Processing*, 2003, **17**(2), 317-328.
- [54] Yiakopoulos C., Gryllias K., Antoniadis I., Rolling element bearing fault detection in industrial environments based on a k-means clustering approach, *Expert Systems with Applications*, 2011, **38**(3), 2888-2911.
- [55] Shlens J., A tutorial on principal component analysis, *Systems Neurobiology Laboratory*, University of California at San Diego, 1–13, 2005.
- [56] Zhang F., Zhang T., Yu H., A novel rolling bearing fault diagnosis method, *9th International Congress on Image and Signal Processing*, BioMedical Engineering and Informatics, 2016, 1148–1152.
- [57] Bishop C.M., Pattern Recognition and Machine Learning, *Springer*, 2006.
- [58] Domingos P., A few useful things to know about machine learning, *Commun. ACM*, 2012, **55** (10), 78–87.
- [59] Murphy K., Machine Learning: A Probabilistic Perspective, *The MIT Press*, 2012.
- [60] Sammut C., Webb G.I, Encyclopedia of Machine Learning, *Springer*, 2011.
- [61] Duyar, A., Model Bazlı Arıza Analizi ve Kestirimci Bakım, *Mühendis ve Makine*, 2009, **50**(598).
- [62] Kalyoncu M., Titreşim Analizi İle Makine Elemanları Arızalarının Belirlenmesi., *Mühendis ve Makine*, 2006, **47**(552), 28-35.
- [63] Jeffares A., K-means: A Complete Introduction, <https://towardsdatascience.com/k-means-a-complete-introduction-1702af9cd8c/> (Ziyaret tarihi: 15 Şubat 2021).
- [64] Ma Y., Lin H., Wang Y., Huang Y., He X., A multi-stage hierarchical clustering algorithm based on centroid of tree and cut edge constraint, *Information Sciences*, 2021, **557**, 194-219.
- [65] Guy S.H., Hong K., Ronil V. C., Amir H.R., Shiwei H., Mark B., Peering Into the Black Box of Artificial Intelligence: Evaluation Metrics of Machine Learning Methods, *American Journal of Roentgenology* 2019, **212**, 38-43.



Ek-A

Jupyter Notebook ortamında Python yazılımı kullanılarak makine öğrenmesi modeli oluşturulmuştur. Kod satırları aşağıdaki gibidir.

```
# Matematiksel işlemler ve veri işleme kütüphanelerinin yüklenmesi
import pandas as pd
import numpy as np
# Veri görselleştirme kütüphanelerinin yüklenmesi
import seaborn as sns
import matplotlib.pyplot as plt
%matplotlib inline
# Makine öğrenmesi algoritma kütüphanelerinin yüklenmesi
from sklearn.linear_model import LogisticRegression
from sklearn.svm import SVC, LinearSVC
from sklearn.ensemble import RandomForestClassifier
from sklearn.neighbors import KNeighborsClassifier
from sklearn.naive_bayes import GaussianNB
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier, ExtraTreesClassifier
from sklearn.naive_bayes import GaussianNB
from sklearn.model_selection import RandomizedSearchCV
from sklearn.model_selection import GridSearchCV
from sklearn import preprocessing
from sklearn.datasets import make_classification
from sklearn.preprocessing import binarize, LabelEncoder, MinMaxScaler
from sklearn.preprocessing import LabelEncoder
from sklearn.preprocessing import StandardScaler
# Model performansı değerlendirme kütüphanelerinin yüklenmesi
from sklearn import metrics
from sklearn.metrics import accuracy_score, mean_squared_error,
precision_recall_curve
from sklearn.model_selection import cross_val_score
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.metrics import confusion_matrix
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
from sklearn.metrics import classification_report
# CSV formatındaki verinin yazılıma yüklenmesi
d1=pd.read_csv('C:/Users/PC/Desktop/python/31_hidrolik_16012020_29012020.csv
',encoding='utf-8',sep=',')
d1.head()
# Veri ön işleme, eksik ve yanlış verilerin silinmesi
```

```

d1['Time'] = pd.to_datetime(d1['Time'])
d1['Date'] = d1['Time'].dt.strftime('%Y-%m-%d %H:%M:%S')
d1.drop(labels = ["Time"], axis = 1, inplace = True)
d1['Date'] = pd.to_datetime(d1['Date'])
d1.isna().sum()
d1.dropna(inplace=True)
# Arıza yaşanan tarihlerin veri setinde seçilmesi
start_date = "2020-01-27 02:00"
end_date = "2020-01-27 14:00"
after_start_date = d1["Date"] >= start_date
before_end_date = d1["Date"] <= end_date
between_two_dates = after_start_date & before_end_date
filtered_dates = d1.loc[between_two_dates]
print(filtered_dates)
# Arızalı verilerin “1” ve normal verilerin “0” olarak etiketlenmesi
d1['fault']=0
d1['fault'].loc[between_two_dates]=1
len(d1[d1['fault']==1])/len(d1['fault'])
d1=d1[(d1['vibx']>0.5)& (d1['vibz']>0.5)& (d1['crest']>0)& (d1['xkurt']>0)&
(d1['zfreq']>0)]
# Arızalı ve normal verilerin sayısı
d1.groupby(by="fault").count()
# Veriler arasındaki korelasyon matrisinin oluşturulması
list1 = ["temp", "vibx", "vibz", "crest", "xkurt", "zfreq", "zacc", "Label"]
def correlation_heatmap(d1):
    _, ax = plt.subplots(figsize=(14, 12))
    colormap = sns.diverging_palette(220, 10, as_cmap = True)
    _ = sns.heatmap(
        d1[list1].corr(),
        cmap = colormap,
        square=True,
        cbar_kws={'shrink':.9 },
        ax=ax,
        annot=True,
        linewidths=0.1, vmax=1.0, linecolor='white',
        annot_kws={'fontsize':12 }
    )
    plt.title('Correlation of Features', y=1.05, size=15)
correlation_heatmap(d1)
# Giriş verileri
feature_cols = ['temp','vibx','vibz', 'crest', 'xkurt','zfreq','zacc']
X = d1[feature_cols]
# Çıkış verisi

```



```

y = d1.Label
# X ve y olarak eğitim ve test verilerinin %70'e %30 olarak bölünmesi
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.30,
random_state=0)
print('X_train shape : ',X_train.shape)
print('X_test shape : ',X_test.shape)
print('y_train shape : ',y_train.shape)
print('y_test shape : ',y_test.shape)
methodDict = { }
rmseDict = ( )
# Rastgele orman algoritmasının modellenmesi
def randomForest():
    # Calculating the best parameters
    forest = RandomForestClassifier(n_estimators = 20)
    featuresSize = feature_cols.__len__()
    param_dist = {"max_depth": [3, None],
                  "max_features": randint(1, featuresSize),
                  "min_samples_split": randint(2, 9),
                  "min_samples_leaf": randint(1, 9),
                  "criterion": ["gini", "entropy"]}
    forest = RandomForestClassifier(max_depth = None, min_samples_leaf=8,
min_samples_split=2, n_estimators = 20, random_state = 1)
    my_forest = forest.fit(X_train, y_train)
    # make class predictions for the testing set
    y_pred_class = my_forest.predict(X_test)
    accuracy_score = evalClassModel(my_forest, y_test, y_pred_class, True)
    #Data for final graph
    methodDict['R. Forest'] = accuracy_score * 100
# Tüm modellerin başarı performanslarının grafiksel gösterimi
def plotSuccess():
    colors = ['#1f77b4', '#ff7f0e', '#2ca02c', '#d62728', '#9467bd', '#8c564b', '#e377c2']
    s = pd.Series(methodDict)
    s = s.sort_values(ascending=False)
    plt.figure(figsize=(8,6))
    ax = s.plot(kind='bar', color=colors)
    for p in ax.patches:
        ax.annotate(str(round(p.get_height(),2)), (p.get_x() * 1.005, p.get_height() *
1.005))
    plt.ylim([70.0, 105.0])
    plt.xlabel('Algoritma')
    plt.ylabel('Başarı Yüzdesi')
    plt.title('Algoritmaların Başarısı')

```

KİŞİSEL YAYINLAR VE ESERLER

Yiğit E., Bilgin M. Z. , Öner A. E., Makine Öğrenmesi Kullanılarak Endüstriyel Pres Makinesine Uygulanan Kestirimci Bakım Çalışmaları, *Akıllı Sistemler ve Uygulamaları Dergisi*, 2020, **3**(2), 57-63.



ÖZGEÇMİŞ

Erkut YİĞİT lise öğrenimini Zonguldak Anadolu Öğretmen Lisesi'nde tamamladı. 2009 yılında girdiği Kocaeli Üniversitesi Elektrik Mühendisliği Bölümü'nden 2013 yılında mezun oldu. 2014 yılına kadar Robo Otomasyon firmasında çalıştıktan sonra Eskişehir 1. Ana Jet Üssünde Hava Mühendis Asteğmen olarak askerlik görevini tamamladı. 2015 yılında Toyotetsu Otomotiv Parçaları A.Ş. firmasında çalışmaya başladı. Halen Toyotetsu'da Arge ve Otomasyon Uzmanı olarak görevine devam etmektedir.

