



**MARMARA ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**



**SIVI VE GAZ İLETİM HATLARINDA  
BASINÇ KAYIPLARI VE ARIZALARIN  
MAKİNE ÖĞRENMESİ İLE KESTİRİMCİ  
BAKIMININ YAPILMASI**

KORAY ALIN

**YÜKSEK LİSANS TEZİ**  
Mekatronik Anabilim Dalı  
Mekatronik Mühendisliği Programı

**DANIŞMAN**  
Dr. Öğr. Üyesi İsmail TEMİZ

**İSTANBUL, 2024**



**MARMARA UNIVERSITY  
INSTITUTE FOR GRADUATE STUDIES  
IN PURE AND APPLIED SCIENCES**



**PREDICTIVE MAINTENANCE OF  
PRESSURE LOSSES AND FAILURES IN  
LIQUID AND GAS TRANSMISSION LINES  
WITH MACHINE LEARNING**

---

**KORAY ALIN**

**MASTER THESIS**

Department of Mechatronics Engineering  
Mechatronics Engineering Program

**Thesis Supervisor**

Asst. Prof. İsmail TEMİZ

**ISTANBUL, 2024**

---

# İÇİNDEKİLER

<b>TEŞEKKÜR</b> .....	<b>i</b>
<b>ÖZET</b> .....	<b>ii</b>
<b>ABSTRACT</b> .....	<b>iv</b>
<b>SEMBOLLER</b> .....	<b>vi</b>
<b>KISALTMALAR</b> .....	<b>vii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>viii</b>
<b>TABLO LİSTESİ</b> .....	<b>ix</b>
<b>1.GİRİŞ</b> .....	<b>1</b>
1.1. Enerji Verimliliği ve Küresel Isınmanın Önemi .....	2
1.1.1. Boru Hatlarında Kestirimci Bakım .....	3
1.1.2. Literatür Taraması.....	3
<b>2.MATERYAL</b> .....	<b>5</b>
2.1. Deney Seti Pano Üyeleri .....	5
2.1.1. Akım Gerilim Modülü .....	5
2.1.2 Santrifuj Pompa .....	7
2.1.3 Taşınabilir Veri Toplama Modülü .....	7
2.1.4 Basınç Transdüseri .....	8
2.1.5 Hız Kontrol Cihazı, Güç Kaynağı ve Sigorta.....	8
2.1.6 Veri Toplama Yazılımı .....	10
<b>3.DENEYLERİN YAPILIŞI VE UYGULANMASI</b> .....	<b>12</b>
3.1. Veri Hazırlığı .....	12
3.2. Ön İşleme .....	12
3.3 Model Eğitimi ve Değerlendirme .....	12
3.4. Deneylerden Elde Edilen Sonuçlar.....	12
3.5. Senaryo Sonuçlarının Görselleştirilmesi.....	13
3.6 Makine Öğrenmesi Modelleri.....	13
3.6.1.Gözetimli Öğrenme (Supervised Learning) .....	14
3.6.2. Gözetimsiz Öğrenme (Unsupervised Learning) .....	14
3.6.3. Pekiştirmeli Öğrenme (Reinforcement Learning) .....	14
3.7 Destek Vektör Makineleri (SVM): .....	15
3.7.1. Destek Vektör Makineleri Örnekli Açıklaması .....	15
<b>4.METODOLOJİ</b> .....	<b>17</b>
4.1. Veri Ön İşleme.....	17
4.2. Özellik Mühendisliği.....	17
4.2.1 Özellik Çıkarımı (Feature Extraction) .....	18
4.2.2 Özellik Seçimi (Feature Selection) .....	18
4.2.3 Özellik Ölçeklendirme (Feature Scaling) .....	18
4.2.4. Özellik Dönüştürme (Feature Transformation) .....	18
4.3. Model Eğitimi ve Doğrulama .....	19
4.4. Model Değerlendirme .....	19
4.5. Görselleştirme .....	19
4.5.1. Karışıklık Matrisi .....	20
4.5.2. ROC Eğrisi ve AUC Değeri .....	20
4.6 SVM Modeli için Python Analiz Kodu.....	20

4.7 Sızıntı Senaryosu .....	23
4.7.1 Sızıntı Senaryosu Düzenegi ve Açıklaması .....	23
<b>5. SONUÇ .....</b>	<b>29</b>
<b>KAYNAKLAR.....</b>	<b>30</b>
<b>ÖZGEÇMİŞ .....</b>	<b>34</b>



## TEŐEKKÜR

Bu arařtırmada, boru hatlarında kestirimci bakım üzerine ynlendirmeleriyle deęerli rehberlikleri ve mentorlukları iin saygıdeęer danıřmanım Dr. đr. yesi İsmail TEMİZ 'e ve Blm Bařkanımız Profesr Mustafa Caner AKNER 'e itenlikle teőekkr ederim. Arařtırma tutkumu teővikleri ile besleyen eřim Natalya ALIN, oęlum Leon ALIN 'a ve arařtırmada beraber yol aldıęım Ersin ŐAHİN 'e derin minnettarlıęımı sunar, yeteneklerime srekli inanları ve destekleri iin ebeveynlerim Melek ve Zeki ALIN 'a kalpten teőekkrlerimi iletirim.



## ÖZET

# SIVI VE GAZ İLETİM HATLARINDA BASINÇ KAYIPLARI VE ARIZALARIN MAKİNE ÖĞRENMESİ İLE KESTİRİMCİ BAKIMININ YAPILMASI

Bu tez çalışmasında sıvı ve gaz iletim hatlarında basınç düşüşlerine ve arıza durumlarına makine öğrenmesi yöntemiyle kestirimci bakım uygulanacaktır. Literatür incelendiğinde petrol ve gaz hatlarında MFL yönteminin kullanıldığı görülmektedir. MFL (Manyetik Akı Sızıntısı) tekniği yaygın kullanılan tahribatsız muayene yöntemlerinden birisi olup boruların dışındaki (çeperlerindeki) çatlakların, hataların, gözle görülemeyen problemlerin tespitinde çokça kullanılır. Tespiti yapılan arızaların detayları görüntülü analizlerle incelenir.

Bu tez çalışmasında da kestirimci bakım felsefesiyle arıza oluşmadan önce tespit edilecektir. Veriler basınç sensörleri aracılığı ile elde edilecektir. Makine öğrenmesi yöntemi kullanılarak elde edilen veriler işlenecektir. Makine öğrenmesi yöntemlerinden, açık kaynak kodlu olması ve görsel işleme özelliklerinden faydalanabilmek adına Orange yazılımı kullanılacaktır. Orange programı geçerli olan birçok veri madenciliği programlarından bir tanesidir. Filtreleme, skorlama, veri ön işleme, modelleri değerlendirme, modelleme ve farklı keşif tekniklerini kullanıcılarının hizmetine sunar. Microsoft Windows, Linux gibi genel geçerliliği olan işletim sistemlerinde rahatlıkla çalıştırılabilmesi ve her geçen gün yenilenen, güncellenen alt yapısı ile son kullanıcıya yönelik rahat kullanım ortamı sağlar. Sistem farklı noktalardaki sensörlerden aldığı verinin sistemin bütününe etkisini ölçecek ve kendini olası koşullar ve sonuçlar konusunda eğitecektir.

Makine öğrenmesi yöntemi ile sıvı ve gaz iletim hatlarındaki basınç düşüşleri ve arıza durumları için kestirimci bakım uygulanabilir.

Birbiri ile bağlantılı farklı iletim hatları ve dağıtım şebekelerinde oluşabilecek arızaların hatlarda belli düzeylerde etkileri vardır.

Aynı anda birden fazla noktada meydana gelecek arıza ve sızıntı durumlarında, birden fazla arızaya müdahale etmede öncelik sıralaması sorunun çözümü noktasında önemli rol oynamaktadır.

Tez sonucunda elde edeceğimiz veriler doğrultusunda yukarıda belirtmiş olduğumuz hipotezler doğrulanacak ya da reddedilecektir. Su, kıymetli likitler, doğal gazlar, sıvı yakıt, petrol gibi sıvı halinde ve gaz halinde bulunan kaynakların tükenmesine giden yolda ehemmiyetli bir önlem alınması fırsatı doğacaktır. İletim hatlarında yaşanacak olan kesintiler önlenecek, sistemin bütünselliği adına daha uzun süre kullanım fırsatı sunacaktır. Kayıp, kaçak, hırsızlık gibi durumlarda daha hızlı tespit etme gücü ve müdahale kabiliyeti ile zarar maliyeti mümkün olan en düşük seviyeye indirgenmeye çalışılacaktır. Bu durum hattın ilk yatırım, işletme ve genel maliyetinin düşürmek adına çok önemli bir aşama oluşturacaktır.

Anahtar Kelimeler: Makine öğrenmesi, kestirimci bakım, iletim hatları

Koray ALIN

Şubat, 2024

## **ABSTRACT**

# **PREDICTIVE MAINTENANCE OF PRESSURE LOSSES AND FAILURES IN LIQUID AND GAS TRANSMISSION LINES WITH MACHINE LEARNING**

In this thesis, to the pressure drops and fault situations in liquid and gas transmission lines by machine learning method. When the literature is examined, the MFL method used in oil and gas lines is seen. The MFL (Magnetic Flux Leakage) approach is a non-invasive inspection technique extensively employed to identify imperfections within the walls of pipes. Detected fault situations are examined with image analysis. In my thesis, the fault will be detected before it occurs with the philosophy of predictive maintenance. The data will be obtained through pressure sensors. The data obtained using the machine learning method will be processed. Orange software will be used because of machine learning methods, open-source code, and visual processing features. Orange program is one of many valid data-mining programs. It offers filtering, scoring, data preprocessing, evaluating models, modeling, and different discovery techniques to its users. It provides a comfortable usage environment for the end user with its ability to be operated easily in generally valid operating systems such as MS Windows, Linux, and its infrastructure that is renewed and updated every day. The system will measure the effect of the data it receives from the sensors at different points on the whole system and train itself on possible conditions and results.

Predictive maintenance can be applied for pressure drops and fault conditions in liquid and gas transmission lines.

Faults that may occur in different interconnected transmission lines and distribution networks have certain effects on the lines.

In case of malfunctions and leaks that will occur at more than one point at the

during same period, the order of priority to intervene in more than one malfunction plays an critical role in finding solutions to the problem.

In line with the data, we will obtain as a result of the thesis, the hypotheses we have stated above will be confirmed or rejected. There will be an opportunity to take an important measure for the exhaustion of fluid and gaseous resources like water, natural gas, and petroleum. Interruptions in transmission lines will be prevented, and it will provide the opportunity to lengthen its service life for the integrity of the system. In cases such as loss, leakage, and theft, it will be tried to reduce the cost of destruction to the lowest possible level with faster detection power and intervention capability. This will constitute a very important step in reducing the initial investment, operation, and general cost of the line.

Keywords in English: machine learning, predictive maintenance, liquid transmission lines

Koray ALIN

February, 2024

## SEMBOLLER

$\omega$  : Ağırlık vektörü

$x$  : Veri noktaları

$b$  : Sapma

$P$  : Hassasiyet

$R$  : Geri çağırma

$TP$  : TP doğru pozitif,

$FP$  : Yanlış pozitif

$FN$  : Yanlış negatif

## KISALTMALAR

**USB** : Universal Serial Bus, cihazları bilgisayarlara bağlamak için kullanılan bir endüstri standardıdır.

**SVM** : Support Vector Machine, gözetimli öğrenme modellerinden biridir.

**F1** : Performans metriği olarak kullanılan bir terim olabilir, F1 Skoru gibi.

**VSD** : Variable Speed Drive, motor hızını kontrol için kullanılan bir cihazdır.

**MFL** : Magnetic Flux Leakage (Manyetik Akı Sızıntısı)

**R<sup>2</sup>** : İstatistikte, bir regresyon modelinin açıklama gücünü ifade eder.

**ROC** : Receiver Operating Characteristic, bir sınıflandırma modelinin performansını değerlendirme yöntemidir.

**CSV** : Comma-Separated Values (Virgülle Ayrılmış Değerler)

**DAQ** : Data Acquisition (Veri Toplama veya Veri Akışı)

**AUC** : ROC Eğrisi Altında Kalan Alan (Area Under Curve)

**MS** : Microsoft

**PCA** : Prensipl Bileşen Analizi (Principal Component Analysis)

**DQN** : Derin Q Ağı

**RBF** : Radyal Temel Fonksiyon (Radial Basis Function)

## ŞEKİL LİSTESİ

Şekil 1.1. İski verilerine göre içme suyundaki kayıp miktarı .....	1
Şekil 2.1. Deney Seti Genel Görünüm .....	5
Şekil 2.2. Akımdan Gerilime Çevirme Devresi .....	6
Şekil 2.3. Santrifuj Pompa .....	7
Şekil 2.4. Taşınabilir veri toplama modülü .....	8
Şekil 2.5. Basınç Transdüseri.....	8
Şekil 2.6. Hız Kontrol Cihazı .....	9
Şekil 2.7. Güç Kaynağı.....	9
Şekil 2.8. Devre Kesici .....	10
Şekil 2.9. Veri Toplama Yazılımı .....	10
Şekil 2.10. Sistemin Genel Görünümü ve Elektrik Panosu Detaylı Görüntüsü.....	11
Şekil 3.1. Örnek Çalışma Grafiği.....	16
Şekil 4.1. Deney Seti Üzerinde Sızıntı Senaryosu .....	23
Şekil 4.2. ROC Eğrisi. ....	24
Şekil 4.3. SVM Model Doğruluğu.....	25
Şekil 4.4. Karışıklık Matrisi .....	26
Şekil 4.5. SVM Karar Sınırları.....	27

# TABLO LİSTESİ

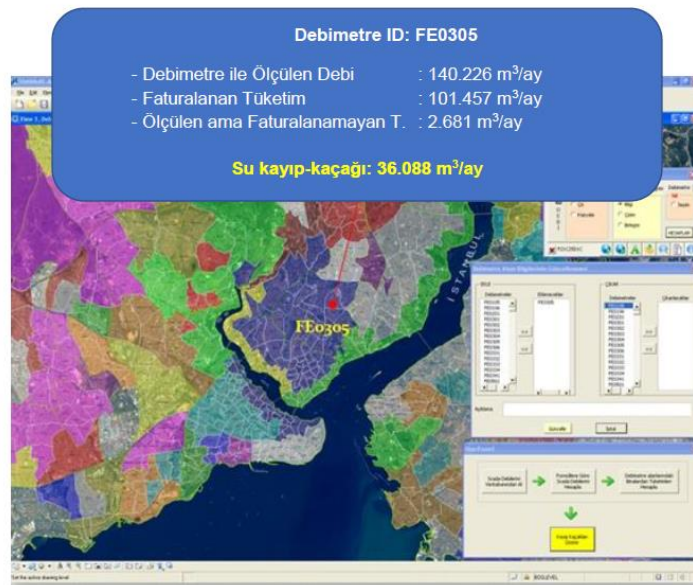
<b>Tablo 1.</b> Sızıntı Senaryosu Data Görseli.....	24
---	----



# 1. GİRİŞ

Son yıllarda, enerji verimliliği ve sürdürülebilirlik kavramları, tüm dünyada önem kazanan temel unsurlar haline gelmiştir. Bu bağlamda, sıvı ve gaz iletim hatlarında yaşanan basınç kayıpları ve arızalar, sadece ekonomik kayıplara yol açmakla kalmayıp, aynı zamanda enerji verimliliği ve sürdürülebilirliğini de olumsuz yönde etkilemektedir. İletim hatlarında yaşanan sorunlar, değerli doğal kaynakların israfına neden olmakta ve küresel enerji tedarikinde önemli aksamalara yol açabilmektedir.

İnsan sağlığı ve ekosistemin korunması açısından da basınç kayıpları ve iletim hatlarındaki arızalar büyük bir risk teşkil etmektedir. Özellikle, petrol ve doğal gaz gibi yanıcı ve tehlikeli maddelerin taşındığı hatlarda meydana gelen sızıntılar, ciddi çevresel felakete ve insan sağlığı üzerinde kalıcı zararlara yol açabilir. Bu durum, ekosistem üzerindeki dengeleri bozarak biyolojik çeşitliliği tehdit eder ve küresel ısınma gibi çevresel sorunlara olumsuz katkıda bulunur. Ekonomik açıdan, iletim hatlarındaki arızalar ve basınç kayıpları, enerji şirketleri ve tüketiciler için önemli maliyetlere neden olmaktadır. Petrol, doğal gaz gibi değerli sıvıların kaybı, enerji sektöründe maliyetleri artırırken, bu durum tüketicilere de yansımakta ve genel ekonomik dengeleri olumsuz yönde etkilemektedir. Dolayısıyla, bu tür kayıpların önlenmesi hem maliyet avantajı sağlamakta hem de enerji kaynaklarının daha verimli kullanılmasını teşvik etmektedir.



Şekil 1.1. İski verilerine göre içme suyundaki kayıp miktarı

Bu tezde ele alınan makine öğrenimi yaklaşımları, sıvı ve gaz iletim hatlarında meydana gelebilecek basınç kayıpları ve arızaların öngörülmesinde kritik bir rol oynamaktadır. Yapay zekâ ve makine öğrenimi teknikleri kullanılarak, iletim hatlarının gerçek zamanlı izlenmesi ve potansiyel sorunların erken tespiti mümkün hale gelmektedir. Bu sayede, olası arızaların önüne geçilerek, enerji verimliliğinin artırılması, ekonomik kayıpların azaltılması, çevre ve insan sağlığının korunması hedeflenmektedir. Makine öğrenimi tabanlı Kestirimci bakım yaklaşımları, sıvı ve gaz iletim hatlarının daha güvenli, verimli ve sürdürülebilir bir şekilde işletilmesine olanak tanıyarak, küresel enerji sistemlerinin geleceğine katkıda bulunmaktadır.

Bu tez Destek Vektör Makineleri (SVM) kullanarak, farklı noktalara yerleştirilmiş sensörlerden alınan verileri sınıflandırıp işleyerek potansiyel arızaları, örneğin sızıntı veya tıkanıklıkları, önceden tahmin etmeyi amaçlamaktadır. Veri seti; normal işletim, sızıntı ve tıkanıklık durumlarını içeren çeşitli senaryolara ait sensör okumalarını zaman serisi içerisinde işlemektedir.

### **1.1.Enerji Verimliliği ve Küresel Isınmanın Önemi**

Boru hatlarındaki kayıp ve kaçakların erken tespiti hem enerji verimliliği hem de küresel ısınma problemleri açısından büyük önem taşımaktadır. Enerji verimliliği, kullanılan enerjinin maksimum fayda sağlaması ve enerji israfının önlenmesi anlamına gelir.[20], [21] Boru hatlarındaki kayıplar, enerjinin üretiminden tüketimine kadar olan süreçte önemli miktarda israfa yol açar. Bu israf hem enerji maliyetlerinin artmasına hem de enerji kaynaklarının sürdürülebilir bir şekilde kullanılamamasına neden olur. Enerji verimliliğinin artırılması, enerji kaynaklarının gereksiz tüketiminin önlenmesine ve dolayısıyla enerji maliyetlerinin düşürülmesine olanak sağlar. Ayrıca enerji üretiminde kullanılan fosil yakıtların azaltılması ile karbon emisyonlarının ve sera gazı salınımının azalmasına katkıda bulunur.

Küresel ısınma, dünya genelinde ortalama sıcaklıkların insan faaliyetleri sonucu artması ve bu durumun çevresel, ekonomik ve sosyal sistemlere olumsuz etkilemesidir. Boru hatlarındaki kayıp ve kaçaklar, fosil yakıtların atmosfere salınan karbon miktarını artırarak küresel ısınma problemini olumsuz etkiler. Sızıntılar yoluyla atmosfere salınan

metan gazı gibi sera gazları, karbondioksitten çok daha olumsuz bir etkiye sahiptir. Bu nedenle, boru hatlarındaki sızıntıların önlenmesi, küresel ısınma ile mücadelede önemli bir adımdır.

Boru hatlarındaki kayıp ve kaçakların önlenmesi, gereksiz enerji tüketiminin önüne geçerek küresel ısınmayla mücadelede kritik bir rol oynar. Enerji üretimi ve tüketimi süreçlerinde verimliliğin artırılması, karbon ayak izinin azaltılmasına ve sürdürülebilir bir gelecek için gerekli olan enerji kaynaklarının korunmasına yardımcı olur. Bu bağlamda, makine öğrenimi ve yapay zekâ gibi teknolojilerin kullanımı, boru hatlarının izlenmesi ve potansiyel sızıntıların erken tespiti için büyük bir potansiyele sahiptir. Bu sistemlerin yaygın kullanımı enerji kaybının önlenmesi ve çevreye olumsuz etkilerin azaltılmasına yönelik büyük olanaklar sağlar. Bu yaklaşım hem enerji verimliliğinin artırılması için hem de küresel ısınma ile mücadelede önemli bir adım olarak görülmektedir.

### **1.1.1. Boru Hatlarında Kestirimci Bakım**

Petrol, su veya gaz gibi kıymetli ürünlerin taşınması, modern ekonomilerin temel direklerinden biridir. Bu ürünlerin taşınmasında kullanılan boru hatlarının verimli ve güvenli işletimi, ekonomik ve çevresel açıdan büyük bir önem taşır. Kestirimci bakım, bir sistemdeki arızaların, sızıntıların veya herhangi bir hasarın önceden tespit edilerek önlenmesi sürecidir. Bu yöntem, arızaların gerçekleşmesi ve sonuçlarının ortaya çıkmasını beklemeden, potansiyel sorunları öngörebilir ve gerekli bakım veya onarımların zamanında yapılmasına imkân sağlar. Kestirimci bakımın boru hatlarında uygulanması, değerli kaynakların kaybını önler, çevresel zararları azaltır, enerji verimliliğini artırır ve işletme maliyetlerini düşürür. Ayrıca, beklenmedik arızalar sonucu oluşabilecek üretim kayıplarını ve operasyonel aksamaları minimize eder. Bu nedenle, kestirimci bakım, boru hatlarının güvenliği, sürdürülebilirliği ve ekonomik verimliliği için vazgeçilmez bir yaklaşımdır.


### **1.1.2. Literatür Taraması**

Bu çalışmada literatürde bu konularda çokça kullanılan yapay zekâ modeli olan SVM

modeli kullanılmıştır.[3] Literatürü incelediğimizde benzer çalışmalar yapıldığını görülür. Genel olarak bakıldığında bu yapay zeka modelinin çoğunlukla rulman, şaft gibi mekanik işler için kullanıldığı görülür.[1] [2] Yine bu yöntem ile kestirimci bakımın yanı sıra kullanım ömrü tahmini yapıldığı da görülmektedir. 4],[5],[9]. Öngörü ile elde edilen kullanım ömrü bilgisi yine bakım zamanı gibi önemli bir veridir. Yerinde ve zamanında değişim gerektiren parçaların önceden tespit edilebilmesi de büyük önem taşır. Karar ağacı ve destek vektör makinesi (SVM) yöntemleri kullanılarak döner mekanik sistemlerdeki çoklu bileşen arızalarının teşhis edilmesi yöntemi geliştirilmiştir. [10]. Akustik ve titreşim verilerinin derin öğrenme tabanlı rastgele orman algoritması ile entegrasyonu sayesinde dişli kutularının arızalarının tespiti için yenilikçi bir yaklaşım geliştirilmiş ve bu metodoloji Mekanik Sistemler ve Sinyal İşleme alanında uygulanmıştır. Ayrıca, rulmanların durum analizi Hilbert-Huang transformasyonu, destek vektör makineleri ve regresyon teknikleri kullanılarak hassas bir şekilde gerçekleştirilmektedir.[11], [12], [13] Laboratuvar ortamından lokomotiflere özgü rulmanlara uyarlanan transfer öğrenme yöntemleriyle donatılmış zeki bir arıza tespit sistemi, rulmanların arıza analizi için karmaşık entropi ölçümleri, çok katmanlı sinyal işleme teknikleri ve geliştirilmiş destek vektör makineleri ile bütünleştirilmiştir. Bu derinlemesine model, uçak motorlarının kalan yararlı ömrünü öngörme ve güvenilirliklerini değerlendirme konusunda da yenilikçi bir perspektif sunmakta, böylece hem demiryolu hem de havacılık endüstrilerindeki bakım stratejilerinin dönüştürülmesine katkı sağlamaktadır. [14], [15], [16] Araçların uzaktan takibi ve onarım zamanlamasını iyileştiren gelişmiş bir sistem, arızaları öngörmek amacıyla veri odaklı metotlar ve ARMA modellemesini entegre eder. Bu yenilikçi yaklaşım, Kestirimci bakım stratejilerini destekleyerek araç bakımını daha etkili ve zamanında müdahale edebilir hale getirir. Ayrıca, endüstriyel makineler için tasarlanmış zeki bir arıza teşhis sistemi, derin öğrenme tekniklerini kullanarak karmaşık arıza modellerini tanımlayabilir ve çözümleyebilir. Bu sistemlerin entegrasyonu, makine bakımını ve arıza yönetimini önemli ölçüde geliştirerek operasyonel verimliliği artırır ve beklenmedik duraklamaları azaltır.[17], [18], [19].

## 2.MATERYAL

Deney setinin altına yerleştirilen haznede bulunan suyun elektrikli pompa vasıtası ile iletim hatlarına gönderilmesi ile sistem üzerinde bulunan sensör çıkışlarından manuel arızalar verdirilerek sistemden sensörler aracılığıyla veriler toplanmıştır. Sistemden aldığımız sensör verileri taşınabilir veri toplama modülü ile anlamlı hale getirilip işlenmiştir. Bu veriler yapay zekâ modelleri de kullanılarak çeşitli senaryoların oluşturulmasında kullanılmıştır.



Şekil 2.1.Deney Seti Genel Görünüm

### 2.1. Deney Seti Pano Üyeleri

#### 2.1.1.Akım Gerilim Modülü

Çeşitli endüstriyel ve otomasyon uygulamalarında sensörler, aktüatörler ve mikrodenetleyiciler arasında sorunsuz bir entegrasyon sağlamak üzere tasarlanmış özelleşmiş bir cihazdır. Bu modül, özellikle 0-20mA veya 4-20mA standart endüstriyel akım sinyallerini, geniş bir cihaz ve sistem yelpazesine uyumluluğu sağlayan 0-3.3V, 0-

5V veya 0-10V gerilim sinyallerine dönüştürmede ustadır. Bu aralık, modülün çeşitli uygulamalara uygun olmasını sağlar.



**Şekil 2.2.** (Ön ve Arka görünüş)  
Akımdan Gerilime Çevirme Devresi

Modülün işlevselliğinin merkezinde, endüstriyel ortamlarda veri iletimi ve kontrol süreçlerinin bütünlüğünün korunması için kritik olan hassas sinyal dönüşümü yer alır. 4-20mA akım sinyali, uzun mesafeler boyunca sinyal kaybını en aza indirme ve elektriksel gürültüye karşı bağışıklık gibi özellikleri sayesinde endüstriyel ortamlarda yaygın olarak kullanılır, bu da cihazlar arasında güvenilir iletişimi sağlar. Bu akım sinyalini bir gerilim sinyaline dönüştürerek, modül, ek karmaşık devreler olmadan gerilim girişlerini kabul eden cihazlarla, örneğin mikrodenetleyicilerdeki analog-dijital dönüştürücülere (ADC) daha kolay bir arayüz sağlar.

Modülün çok yönlülüğü, canlı-sıfır ölçümlerini belirten sistem sağlığını gösteren yaygın kullanılan 4-20mA sinyal aralığını ve daha geniş bir uygulama yelpazesi için ek esneklik sunan 0-20mA aralığını işleyebilme yeteneği ile daha da vurgulanabilir. Bu yetenek, çevresel izleme ve süreç kontrolün çok önemli olduğu sistemlerde bu modülü temel bir araç haline getirir.

Kullanım kolaylığı açısından tasarlanmış olan Akım Gerilim Modülü, mevcut sistemlere sorunsuz bir entegrasyon sağlamak üzere hem akım girişi hem de gerilim çıkışı için basit bağlantılar sunar. Bazı modeller, çıkış gerilimini belirli gereksinimlere göre özelleştirmeye olanak tanıyan ayarlanabilir çıkış aralıkları da sunabilir, bu da modülün farklı senaryolarda da uygulanabilirliğini artırır.

Sonuç olarak, Akım Gerilim Modülü, akım sinyallerini gerilim sinyallerine dönüştürmede güvenilir ve etkili bir araç olarak endüstriyel kontrol sistemlerinin arayüzünde ve entegrasyonunda kritik bir bileşendir. Standart sinyal aralıklarını destekleme ve hassas dönüşüm sağlama yeteneği, çeşitli endüstriyel ortamlarda

otomasyon, kontrol ve çeşitli süreçlerin izlenmesi ve kontrol edilmesinde modülü paha biçilmez bir araç yapar.

### 2.1.2 Santrifuj Pompa

Ebara'nın CDX 70/07 0.6kW modeli, su taşıma işlemleri için tasarlanmış verimli ve güvenilir bir santrifuj pompasıdır. Temiz su veya kimyasal açıdan zararsız sıvıların nakledilmesi amacıyla geliştirilmiş olan bu pompa, endüstriyel ortamlardan tarımsal sulamaya, bina yönetim sistemlerinden genel su transferine kadar geniş bir kullanım alanına sahiptir. 0.6kW'lık güç kapasitesine rağmen enerjiyi etkili bir şekilde kullanır ve küçük boyutları sayesinde sıkışık mekanlarda dahi rahatlıkla kurulum imkânı sunar.



Şekil 2.3. Santrifuj Pompa

### 2.1.3 Taşınabilir Veri Toplama Modülü

Advantech 'in Taşınabilir Veri Toplama Modülü, çok işlevli bir USB aygıtı olarak, veri toplama ve analiz işlemleri için yüksek hızlı bir çözüm sunar. Bu modül, saniyede 200 bin örnek (200kS/s) alma kapasitesi ve 16-bit derinliğinde veri çözünürlüğü ile, çeşitli veri türlerinin doğru şekilde ölçülmesini mümkün kılar. Mühendisler ve araştırmacılar için tasarlanmış olan bu ürün, hızlı ve güvenilir veri toplama ihtiyacını karşılar. USB üzerinden kolayca bilgisayar ve dizüstü bilgisayarlara bağlanabilen modül, saha çalışmalarından laboratuvar deneylerine, endüstriyel takip sistemlerine kadar geniş bir kullanım alanına sahiptir. Çoklu giriş ve çıkış kanalları sayesinde farklı sinyalleri aynı anda toplayabilme özelliğine sahip olan bu cihaz, kompakt yapısı ve dayanıklı tasarımı ile zorlu koşullarda bile üstün performans sergiler. Advantech Taşınabilir Veri Toplama Modülü, karmaşık veri analizi ve izleme gereksinimlerini, kullanım kolaylığı ve yüksek doğrulukla karşılayarak profesyoneller için ideal bir araçtır.



Şekil 2.4. Taşınabilir veri toplama modülü

#### 2.1.4 Basınç Transdüseri

Mesens MPS500 model basınç sensörü, 0 ile 1 bar arası basınç değerlerini hassas bir şekilde ölçmek ve kontrol etmek üzere özel olarak geliştirilmiştir. Bu cihaz, endüstri standartı olan ve uzak mesafelerde dahi sinyal kaybı yaşamadan veri iletimi sağlayan 4~20mA çıkış özelliğine sahiptir. Bu özellikler, MPS500 modelini, süreç kontrolünden otomasyona, akışkan dinamiği üzerine yapılan çalışmalara kadar geniş bir uygulama yelpazesinde tercih edilen bir ürün haline getirir. 420 ölçüm kapasitesiyle, bu basınç sensörü, basınçtaki küçük değişiklikleri bile hassasiyetle algılayabilir, böylelikle analizler ve işletme kararları için güvenilir veriler sunar. MPS500'ün dayanıklı tasarımı, en zorlu endüstriyel şartlarda bile üstün performans ve uzun ömür sunar, bu da onu sürekli basınç takibi gerektiren uygulamalar için mükemmel bir çözüm yapar.



Şekil 2.5. Basınç Transdüseri

#### 2.1.5 Hız Kontrol Cihazı, Güç Kaynağı ve Sigorta

**Hız Kontrol Cihazı** (Değişken Hız Sürücüsü VSD), ya da başka bir adıyla Değişken Frekans Sürücüsü (VFD), elektrik motorlarının çalışmasını, beslenen frekans ve voltajı ayarlayarak kontrol eden bir cihazdır. 0.75kW- 1hp- 200...240V- 1ph versiyonu, özellikle 0.75 kilowatt gücüne ya da yaklaşık 1 beygir gücüne kadar olan motorlar için uygun olup, 200 ile 240 volt aralığındaki tek fazlı elektrikle çalışır. Bu özellikleriyle, motor hızının dikkatle ayarlanması gereken basitten karmaşığa her türlü uygulamada kullanıma uygundur.



Şekil 2.6. Hız Kontrol Cihazı

**Güç Kaynağı** ise, tek veya birden fazla elektrikli cihaza enerji sağlayan bir araçtır. 24 volt olarak belirtilen çalışma voltajı, genellikle endüstriyel alanlarda bulunan düşük voltajlı devrelerde veya kontrol devrelerinde tercih edilir. Kontrol sistemleri, sensörler ve 24 volt gerektiren diğer elektronik cihazlara sürekli ve güvenilir enerji sağlamak için güç kaynakları kritik öneme sahiptir.



Şekil 2.7. Güç Kaynağı

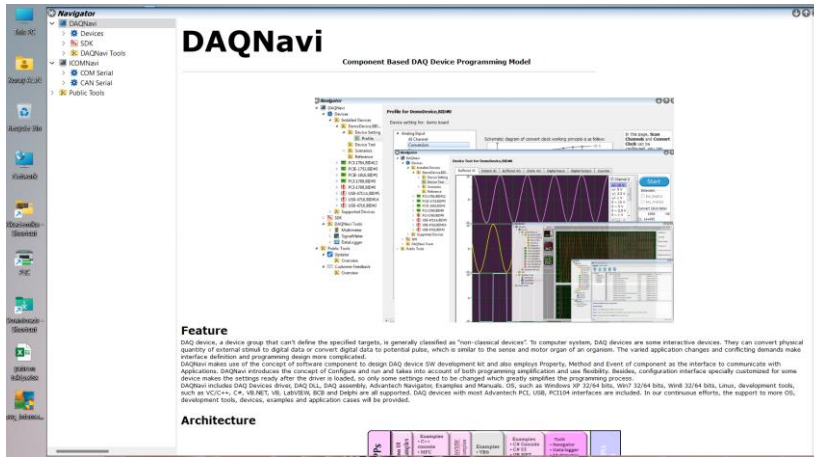
**Sigorta** (devre kesici), aşırı akım, yük aşımı ya da kısa devre gibi durumların elektrik devresine zarar vermesini önlemek üzere tasarlanmış otomatik bir elektrik anahtarıdır. Arıza algılandığında akımı kesme işlevine sahip olan bu cihaz, bir kere kullanılıp atılan sigortalardan farklı olarak, manuel ya da otomatik olarak yeniden ayarlanabilir ve normal çalışmaya geri dönebilir.



Şekil 2.8. Devre Kesici

## 2.1.6 Veri Toplama Yazılımı


DAQNavi yazılımı, DAQ (Veri Toplama) cihazlarının yazılım geliştirme kitini tasarlamak için yazılım bileşeni kavramını benimser. Bu yazılım, uygulamalarla iletişim kurmak için bileşenlerin Özellik, Yöntem ve Olaylarını kullanır ve hem programlama kolaylığı hem de kullanım esnekliği açısından "Yapılandır ve Çalıştır" kavramını tanıtır. DAQNavi, Windows XP, Windows 7, Windows 8 ve Linux işletim sistemlerini destekler; geliştirme araçları olarak VC/C++, C#, VB.NET, LabVIEW ile uyumludur. Yazılım, Advantech'in PCI, USB, PCI104 arabirimlerine sahip cihazları için sürücüler, kütüphaneler ve örnekler sunar.



Şekil 2.9. Veri Toplama Yazılımı

DAQNavi, LabVIEW için özel olarak tasarlanmış sürücülerle, Advantech DAQ cihazlarının LabVIEW ortamında kolayca kullanılmasını sağlar. Ayrıca, .NET ve ActiveX bileşenleri, farklı programlama dilleri ve geliştirme ortamlarında Advantech

DAS kartlarının etkin kullanımını kolaylaştırır. Bu çeşitlilik, DAQ cihazlarının farklı senaryolar ve geliştirme araçları için nasıl optimize edileceğine dair kapsamlı bir rehberlik sunarak, CVS formatında çıktılar alınabilmesini sağlar.



**Şekil 2.10.** Sistemin Genel Görünümü ve Elektrik Panosu Detaylı Görüntüsü

## **3.DENEYLERİN YAPILIŞI VE UYGULANMASI**

### **3.1. Veri Hazırlığı**

Veri seti başlangıçta geniş meta verileri işlemek ve analiz için doğru yapıyı doğru bir şekilde tanımlamak üzere işlenmiştir. Sayısal sensör verilerinin bulunduğu yer tespit edildikten sonra, uygun sütun başlıkları atanarak, "Zaman" sütunu ve on iki sensör kanalı (Sensor\_1'den Sensor\_12'ye) olacak şekilde yapılandırılmış, makine öğrenimi analizi için uygun bir format sağlanmıştır.

### **3.2. Ön İşleme**

Veri ön işleme, sensör okumalarını ölçeklendirmek için veri özelliklerini normalleştirme işlemini içerir, bu da SVM modelinin performansını kolaylaştırır. Açık arıza etiketleri olmadan, sensör okumalarındaki keyfi koşullara dayanarak ikili bir hedef değişken simüle edilerek arızalar (1) ve normal işletim (0) temsil edilir. Bu adım, SVM modelini eğitmek için önemlidir, ancak gerçek uygulamalar için doğru şekilde etiketlenmiş verilere ihtiyaç vardır.

### **3.3 Model Eğitimi ve Değerlendirme**

Radial Basis Function (RBF) çekirdeği kullanılarak bir SVM modeli eğitilmiş, bu çekirdek, doğrusal olmayan verileri işlemede etkili olmuştur. Veri seti, modelin tahmin yeteneklerini doğrulamak için eğitim (%70) ve test (%30) setlerine ayrılmıştır. Modelde genel olarak %98 doğrulukla yüksek hassasiyet ve geri çağırma elde edilmiştir. Bu metrikler, modelin sensör verilerine dayanarak boru hattı sistemi arızalarını güvenilir bir şekilde ayırt edebilme güvenilirliğini göstermiştir.

### **3.4. Deneylerden Elde Edilen Sonuçlar**

Karışıklık matrisi ve sınıflandırma raporu, modelin performansının detaylı bir dökümünü sağlamıştır. Arıza olmayan ve arıza olan durumları tahmin etmede yüksek hassasiyet (%96 arıza olmayanlar için, %100 arıza olanlar için) ve geri çağırma (%100 arıza olmayanlar için, %95 arıza olanlar için) puanları, modelin sensör verilerine dayanarak potansiyel arızaları doğru bir şekilde tanımlama etkinliğini vurgulamıştır.

### 3.5. Senaryo Sonuçlarının Görselleştirilmesi

Karışıklık Matrisi Isı Haritası: Karışıklık matrisini gösteren bir ısı haritası, doğru pozitifleri, doğru negatifleri, yanlış pozitifleri ve yanlış negatifleri etkili bir şekilde gösterir.

Hassasiyet ve Geri Çağırma Metrikleri: Arıza olmayan ve arıza olan durumları tahmin etme hassasiyetini ve geri çağırma karşılaştıran bir çubuk grafik, modelin performansını görsel olarak özetler.

Destek Vektör Makineleri (SVM) ile Analiz

SVM, veri noktalarını ayırtmak için bir hiper-düzlem (karar sınırı) bulmaya çalışır.

Bu süreç, aşağıdaki formülle ifade edilebilir:

$$\omega \cdot x + b = 0 \quad (3.1)$$

Burada  $w$  ağırlık vektörünü,  $x$  veri noktalarını ve  $b$  sapmayı temsil eder. SVM, marjı maksimize ederek en iyi hiper-düzlemi seçer:

Hassasiyet (P) ve geri çağırma (R) metrikleri, modelin performansını değerlendirmede kullanılır ve şu şekilde tanımlanır:

$$\frac{2}{\|w\|} \quad (3.2)$$

$$P = \frac{TP}{TP+FP} \quad (3.3)$$

$$R = \frac{TP}{TP+FN} \quad (3.4)$$

Burada TP doğru pozitif, FP yanlış pozitif ve FN yanlış negatif sayısını temsil eder.

Bu analiz ve görseller, SVM 'nin boru hattı sistemlerinde Kestirimci bakım için potansiyelini vurgulamaktadır.

### 3.6 Makine Öğrenmesi Modelleri

Algoritmaların özelliklerine ve öğrenme türlerine göre çeşitlenir. Bu modeller, verilerden öğrenmek ve tahminler yapmak için kullanılır. Makine öğrenimi modelleri genellikle üç ana kategoride incelenir: Gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme. Özellikle, Destek Vektör Makineleri (SVM) gibi bazı modeller, gözetimli öğrenme kapsamında önemli bir yere sahiptir. İşte en yaygın kullanılan bazı

makine öğrenmesi modelleri ve özellikleri:

### 3.6.1. Gözetimli Öğrenme (Supervised Learning)

Gözetimli öğrenme, modelin, verilen girdilere karşılık gelen çıktıları tahmin etmeyi öğrendiği bir öğrenme türüdür. Bu kategori altındaki önemli modeller:

**Destek Vektör Makineleri (SVM):** SVM, sınıflandırma ve regresyon sorunlarına yönelik kullanılan etkili bir yöntemdir. Veri setindeki örnekleri ayırıştırarak en iyi hiper düzlemi bulmaya çalışır. İki sınıf arasındaki marjı maksimize ederek çalışır ve doğrusal olmayan sınıflandırma için çekirdek (kernel) yöntemlerini kullanabilir.

**Lineer Regresyon:** Sürekli değerlerin tahmin edilmesi için kullanılır.

**Lojistik Regresyon:** İkili sınıflandırma problemleri için kullanılır.

**Karar Ağaçları ve Rastgele Ormanlar:** Hem sınıflandırma hem de regresyon problemleri için kullanılır. Karar ağaçları, veri setini karar noktaları üzerinden bölerek çalışırken, rastgele ormanlar birden fazla karar ağacının tahminlerini birleştirir.

**Yapay Sinir Ağları:** Veriler arasındaki karmaşık ilişkileri modellemek için kullanılır ve genellikle derin öğrenme modelleri olarak adlandırılır.

### 3.6.2. Gözetimsiz Öğrenme (Unsupervised Learning)

Gözetimsiz öğrenme, etiketlenmemiş verileri kullanarak verilerdeki gizli yapıları veya desenleri bulmayı amaçlar. Bu kategori altındaki bazı yöntemler:

**K-Means Kümeleme:** Verileri benzerliklerine göre gruplara ayırır.

**Hiyerarşik Kümeleme:** Verileri ağaç benzeri bir yapıda iç içe geçmiş gruplara ayırır.

**Prensip Bileşen Analizi (PCA):** Veri boyutunu azaltırken, verinin varyansını mümkün olduğunca koruyan bileşenleri bulur.

### 3.6.3. Pekiştirmeli Öğrenme (Reinforcement Learning)

Ajanın, ödülleri maksimize edecek şekilde hareketler seçmeyi öğrendiği bir öğrenme türüdür. Bu kategori altındaki öne çıkan yöntemler:

**Q-Öğrenme (Q-Learning):** Ajanın her durumda hangi eylemin en iyi olduğunu öğrenmesine olanak tanır.

**Derin Q Ağı (DQN):** Q-Öğrenmeyi yapay sinir ağları ile birleştirerek karmaşık problemleri çözmek için kullanılır.

Makine öğrenmesi modelleri, verilerden öğrenme ve tahmin yapma yetenekleri sayesinde, sınıflandırma, regresyon, kümeleme ve daha pek çok alanda etkili çözümler sunar. Özellikle Destek Vektör Makineleri (SVM), karmaşık sınıflandırma problemlerinde yüksek performans sergileyebilen güçlü bir modeldir.

### **3.7 Destek Vektör Makineleri (SVM):**

#### **3.7.1. Destek Vektör Makineleri Örnekli Açıklaması**

Diyelim ki bir otomobil üreticisi, araçların motorlarında oluşabilecek arızaları önceden tahmin edebilmek için bir sınıflandırma modeli oluşturmak istiyor. Veri setinde, motor sensörlerinden alınan çeşitli ölçümler (sıcaklık, basınç, titreşim vb.) ve motorun durumu (normal veya arızalı) bulunmaktadır.

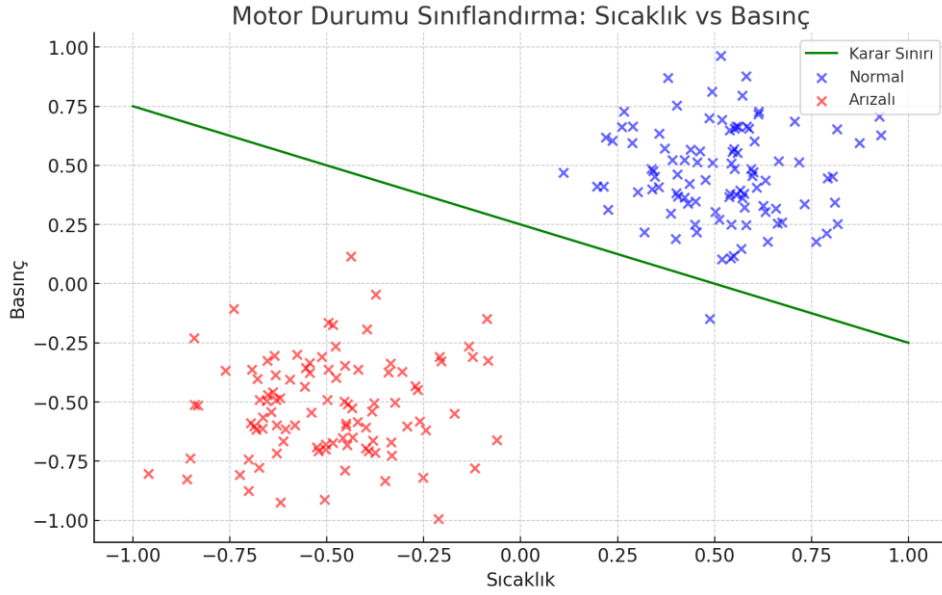
Bu durumda SVM kullanarak bir sınıflandırma modeli oluşturulabilir. Özellikler (sıcaklık, basınç, titreşim) modelin girdisi olarak kullanılırken, motorun durumu (normal veya arızalı) hedef değişken olarak belirlenir.

Model eğitimi sırasında, SVM algoritması öncelikle veri noktalarını iki sınıfa ayıran bir karar sınırı çizer. Eğer veri doğrusal olarak ayrılabilir değilse, çekirdek hile kullanılarak veriler yüksek boyutlu bir uzaya taşınır ve orada doğrusal bir ayırım yapılır. Model, destek vektörleri olarak belirlenen en yakın veri noktalarına olan uzaklığı maksimize edecek şekilde karar sınırını ayarlar.

Bu modelin başarısı, doğru sınıflandırmaların sayısı ve yanlış pozitif (normal bir motorun arızalı olarak sınıflandırılması) ile yanlış negatif (arızalı bir motorun normal olarak sınıflandırılması) durumların minimizasyonu ile ölçülür.

Görsel bir örnek olarak, eğitim veri setindeki her bir motorun durumu (normal veya arızalı) iki boyutlu bir özellik uzayında (sıcaklık ve basınç) gösterilebilir. SVM modeli, bu iki sınıfı en iyi şekilde ayıran bir hiper düzlem oluşturacaktır. Modelin oluşturduğu karar sınırı, yeni gözlemlerin sınıflandırılmasında kullanılır; böylece yeni bir motorun

sensör ölçümleri alındığında, bu motorun durumunu (normal veya arızalı) tahmin edebilir.



**Şekil 3.1.** Örnek Çalışmanın Grafiği

Grafikte, motorun durumunu (normal veya arızalı) temsil eden iki boyutlu bir özellik uzayı (sıcaklık ve basınç) gösterilmektedir. Mavi noktalar normal motorları, kırmızı noktalar ise arızalı motorları temsil etmektedir. Bu hayali veri setinde, normal ve arızalı motorlar için ölçümler farklı ortalama değerlere sahip normal dağılımlar kullanılarak üretilmiştir. Grafikte ayrıca, SVM sınıflandırma modeli tarafından oluşturulabilecek basit bir karar sınırı yeşil çizgi ile gösterilmektedir. Bu karar sınırı, modelin eğitimi sırasında belirlenir ve yeni gözlemlerin sınıflandırılmasında kullanılır. Bu örnekte, karar sınırı doğrusal bir çizgidir; ancak, gerçek SVM modeli, çekirdek hile (kernel trick) kullanarak daha karmaşık sınırlar oluşturabilir. Bu şekilde modelin amacı, sıcaklık ve basınç gibi sensör ölçümlerine dayanarak motorun durumunu (normal veya arızalı) doğru bir şekilde tahmin etmektir. SVM, özellikle marjinal olarak ayrılabilir veri setleri için güçlü ve esnek bir model sunar, böylece karmaşık ve doğrusal olmayan ilişkileri modelleyebilir ve yüksek doğruluk oranları elde edebilir.

SVM, genellikle yüksek doğruluk oranlarına sahip olduğu ve aşırı uyuma (overfitting) karşı dayanıklı olduğu için, bu tür kestirimci bakım görevleri için ideal bir seçimdir. Özellikle, karmaşık ve doğrusal olmayan ilişkilerin mevcut olduğu durumlarda,

çekirdek hile sayesinde başarılı tahminler yapabilir.

## **4.METODOLOJİ**

### **4.1. Veri Ön İşleme**

Normal işletme ve arızaları (tıkanıklıklar veya sızıntılar) temsil eden veri setleri ilk olarak temizlendi ve yapılandırıldı. SVM analizi için uygun olmalarını sağlamak üzere sensör okumaları normalleştirilmelidir. Veri analizine başlamadan önce, veri setindeki eksik değerlerin ve potansiyel aykırı değerlerin ele alınması gerekir. Bu aşamada, veri seti detaylı bir şekilde incelenir, eksik veya hatalı veriler tespit edilir ve düzeltilir. Eksik veri bulunmadığı görülse de, veri setinin özet istatistikleri incelenerek verilerin dağılımı ve potansiyel aykırı değerler hakkında bilgi edinilir. Bu işlem, veri setinin model eğitimi için uygun hale getirilmesini sağlar.

**Yüksek Kaliteli Veri:** Modelin doğru tahminler yapabilmesi için, boru hattı sensörlerinden toplanan verilerin yüksek kalitede olması gerekir. Verilerin doğru, tutarlı ve eksiksiz olması önemlidir.

**Yeterli Veri Miktarı:** Modelin karmaşık desenleri öğrenebilmesi için, hem normal çalışma koşullarını hem de çeşitli sızıntı durumlarını içeren yeterli miktarda veriye ihtiyaç vardır.

### **4.2. Özellik Mühendisliği**

Modelleme öncesi, veri setleri üzerinde önemli bir süreç olan veri ön işleme aşaması gerçekleştirilir. Bu aşamada, normal operasyonlar ve çeşitli arızaları (örneğin tıkanıklıklar veya sızıntılar) içeren veri kümeleri, gereksiz bilgilerden arındırılıp düzenlenir. Sensörlerden alınan ham veriler, modelin daha iyi öğrenmesi ve genelleme yapabilmesi için normalleştirilir. Bu işlem, veriler arasındaki farklı ölçekleri standardize etmek ve SVM algoritmasının analizini kolaylaştırmak için kritik öneme sahiptir. Veri ön işleme, modelin daha doğru tahminlerde bulunmasını sağlayacak sağlam bir temel oluşturur.

#### **4.2.1 Özellik Çıkarımı (Feature Extraction)**

Ham verilerden yeni özellikler çıkarılması sürecidir. Bu, metin verilerinden anahtar kelimelerin çıkarılması, zaman serisi verilerinden eğilimlerin tespiti veya karmaşık veri yapılarından önemli bilgilerin elde edilmesi şeklindedir.

#### **4.2.2 Özellik Seçimi (Feature Selection)**

Modelin eğitimi için kullanılacak en önemli ve etkili özelliklerin belirlenmesidir. Tüm özelliklerin model tarafından kullanılması, modelin karmaşıklığını artırabilir ve overfitting (aşırı uyum) riskini taşır. Özellik seçimi, modelin genelleme yeteneğini artırarak daha iyi performans göstermesini sağlar.

#### **4.2.3 Özellik Ölçeklendirme (Feature Scaling)**

Farklı özelliklerin farklı ölçeklere sahip olması, bazı algoritmaların performansını olumsuz etkileyebilir. Özellik ölçeklendirme, tüm özelliklerin aynı ölçeğe sahip olmasını sağlayarak bu sorunu çözer. Bu, özelliklerin birbiriyle daha uyumlu hale gelmesini ve modelin daha hızlı ve etkili bir şekilde eğitilmesini sağlar.

Özellik mühendisliği, makine öğrenmesi projelerinin başarısında kritik bir rol oynar. İyi tasarlanmış özellikler, modelin eğitim süresini kısaltabilir, daha az veri ile daha iyi sonuçlar elde etmesini sağlayabilir ve genel olarak modelin doğruluğunu ve etkinliğini artırabilir.

#### **4.2.4. Özellik Dönüştürme (Feature Transformation)**

Verilerin model tarafından daha iyi işlenebilmesi için dönüştürülmesidir. Normalizasyon, standartlaştırma, log dönüşümü veya kategorik verilerin sayısal verilere dönüştürülmesi (one-hot encoding gibi) bu sürecin örneklerindedir.

### 4.3. Model Eğitimi ve Doğrulama

Model eğitimi aşamasında, radyal temel işlev (RBF) çekirdeği kullanılarak SVM algoritması tercih edilir. RBF çekirdeği, özellikle doğrusal olmayan ilişkileri modellemekte üstün kabiliyet gösterir, bu yüzden karmaşık veri yapılarını etkili bir şekilde işleyebilir. Model, seçilen özellikler ve eğitim verileri kullanılarak dikkatlice eğitilir. Bu süreçte, modelin arızaları doğru bir şekilde tespit edebilmesi için gerekli parametre ayarlamaları yapılır. SVM modelinin, kullanılan veri setine en iyi şekilde uyum sağlaması için çekirdek (kernel) seçimi ve hiper parametre ayarlarının (örneğin, C ve gamma) optimize edilmesi gerekir.

Model Doğrulama: Modelin genelleştirme yeteneğinin değerlendirilmesi için çapraz doğrulama gibi teknikler kullanılmalıdır. Modelin yeni ve görünmemiş veriler üzerindeki performansı, gerçek dünya koşullarında başarısının bir göstergesidir.

### 4.4. Model Değerlendirme

Modelin performansı, ayrı bir test veri seti kullanılarak değerlendirilir. Bu aşamada, modelin arıza tespitindeki doğruluğu, hassasiyet, geri çağırma ve F1 skoru gibi çeşitli metriklerle ölçülür. Bu değerlendirme, modelin gerçek dünya senaryolarında nasıl performans göstereceğine dair önemli bilgiler sağlar. Performans metrikleri, modelin güçlü ve zayıf yönlerini belirlemede kritik rol oynar.

### 4.5. Görselleştirme

SVM modeli, sensör okumalarına dayanarak arızalı ve arızasız durumlar arasında yüksek doğrulukla ayırım yapma konusunda yüksek bir başarı gösterdi. Karmaşıklık matrisi ve sınıflandırma raporu, modelin performansına dair detaylı içgörüler sağladı ve tahminlerde %98'in üzerinde bir doğruluk gösterdi. Modelin performans metriklerini ve farklı sensörlerin arızaları tahmin etmedeki önemini göstermek için çizelgeler ve grafikler gibi görsel yardımcılar kullanıldı. Bu görseller, modelin karar alma sürecini ve prediktif bakım çerçevesinde her bir sensör okumanın göreceli önemini anlamada yardımcı olur.

Modelin değerlendirilmesi aşamasında, karışıklık matrisi ve ROC eğrisi gibi görsel araçlar kullanılarak modelin performansı görselleştirilir. Karışıklık matrisi, modelin

tahminlerinin doğruluğunu; ROC eğrisi ise modelin sınıflandırma yeteneğini görsel olarak sunar. Bu görselleştirmeler, modelin performansının daha iyi anlaşılmasını sağlar ve model üzerinde yapılacak iyileştirmeler için önemli ipuçları verir.

Yukarıda yazılan adımlar su, gaz kayıp kaçakları üzerinde çalışılan bu deney setinde sızıntı tespiti için bir SVM modelinin nasıl geliştirileceğine dair adım adım bir yol haritası olarak düşünülebilir. Her adım, modelin başarılı bir şekilde geliştirilmesi ve değerlendirilmesi için gerekli detayları içerir.

#### **4.5.1. Karışıklık Matrisi**

Karışıklık matrisi, modelin tahminlerinin gerçek etiketlerle ne kadar uyumlu olduğunu gösterir. Bu özel durumda, modelin hem normal hem de anormal durumları mükemmel bir şekilde tahmin ettiğini görebiliriz. Matristeki değerler, modelin doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif tahminlerinin sayısını temsil eder. Bu durumda da, tüm tahminlerin doğru kategorilere ait olduğunu görüldü, bu da modelin %100 doğruluk oranına sahip olduğunu doğruladı.

#### **4.5.2. ROC Eğrisi ve AUC Değeri**

ROC (Alıcı İşletim Karakteristiği) eğrisi, modelin sınıflandırma eşliğinin farklı değerleri için doğru pozitif oranı ile yanlış pozitif oranı arasındaki ilişkiyi gösterir. AUC (Çizgisinin Altında Bulunan Alan) değeri, ROC eğrisine bakıldığında bunun altında görülen alanın büyüklüğüdür ve modelin rastgele tahminlerden ne kadar iyi performans gösterdiğini ölçer. AUC değeri 1.0, modelin mükemmel sınıflandırma yapabildiğini gösterir. Bu örnekte, AUC değeri %100'dür, bu da modelin mükemmel bir şekilde performans gösterdiği görülür.

#### **4.6 SVM Modeli için Python Analiz Kodu**

Aşağıda, veri seti yolu ('veri\_seti\_yolu.csv') ve hedef sütunu ('hedef\_sütun') olarak yazılan bir kod örneği paylaşılmıştır.

```
# Gerekli kütüphanelerin import yapılması
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler, SimpleImputer
from sklearn.svm import SVC
from sklearn.metrics import accuracy_score, precision_score, recall_score, f1_score,
plot_confusion_matrix, roc_curve, auc
import matplotlib.pyplot as plt

# Veri setinin yüklenmesi
# df = pd.read_csv('veri_seti_yolu.csv') # Veri seti yolu güncellenmeli

# Veri Ön İşleme
# Eksik değerlerin doldurulması
imputer = SimpleImputer(strategy='mean')
df_filled = pd.DataFrame(imputer.fit_transform(df), columns=df.columns)

# Sensör okumalarının standartlaştırılması
scaler = StandardScaler()
features = df_filled.drop('hedef_sütun', axis=1) # 'hedef_sütun' hedef değişkenin adıyla
değiştirilmeli
labels = df_filled['hedef_sütun']
features_scaled = scaler.fit_transform(features)

# Özellik Seçimi
# Tüm kanallar özellik olarak kullanılacak

# Veri Setinin Bölünmesi (Veri setini %70 eğitim ve %30 test olacak şekilde ayrılması)
X_train, X_test, y_train, y_test = train_test_split(features_scaled, labels, test_size=0.3,
random_state=42)
```

### # Linear SVM Modelinin Eğitilmesi

```
svm_model = SVC(kernel='linear')
```

```
svm_model.fit(X_train, y_train)
```

### # Modelin Değerlendirilmesi (kesinlik, geri çağırma ve F1 skoru kullanarak değerlendirme)

```
y_pred = svm_model.predict(X_test)
```

```
accuracy = accuracy_score(y_test, y_pred)
```

```
precision = precision_score(y_test, y_pred, average='binary')
```

```
recall = recall_score(y_test, y_pred, average='binary')
```

```
f1 = f1_score(y_test, y_pred, average='binary')
```

```
print(f'Doğruluk: {accuracy}, Kesinlik: {precision}, Duyarlılık: {recall}, F1-Skoru: {f1}')
```

### # Karışıklık Matrisi ve ROC Eğrisinin Çizdirilmesi

```
# Karışıklık matrisi
```

```
plot_confusion_matrix(svm_model, X_test, y_test)
```

```
plt.title('Karışıklık Matrisi')
```

```
plt.show()
```

### # ROC eğrisi

```
y_score = svm_model.decision_function(X_test)
```

```
fpr, tpr, _ = roc_curve(y_test, y_score)
```

```
roc_auc = auc(fpr, tpr)
```

```
plt.figure()
```

```
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC eğrisi (alan = {roc_auc:.2f})')
```

```
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
```

```
plt.xlim([0.0, 1.0])
```


```
plt.ylim([0.0, 1.05])
```

```
plt.xlabel('Yanlış Pozitif Oranı')
```

```
plt.ylabel('Gerçek Pozitif Oranı')
plt.title('Alıcı İşletim Karakteristiği (ROC)')
plt.legend(loc="lower right")
plt.show()
```

## 4.7 Sızıntı Senaryosu

### 4.7.1 Sızıntı Senaryosu Düzeneği ve Açıklaması



Şekil 4.1. Deney Seti Üzerinde Sızıntı Senaryosu

Modelin değerlendirilmesi sonucunda elde edilen metrikler şu şekildedir:

Doğruluk (Accuracy): %95,83

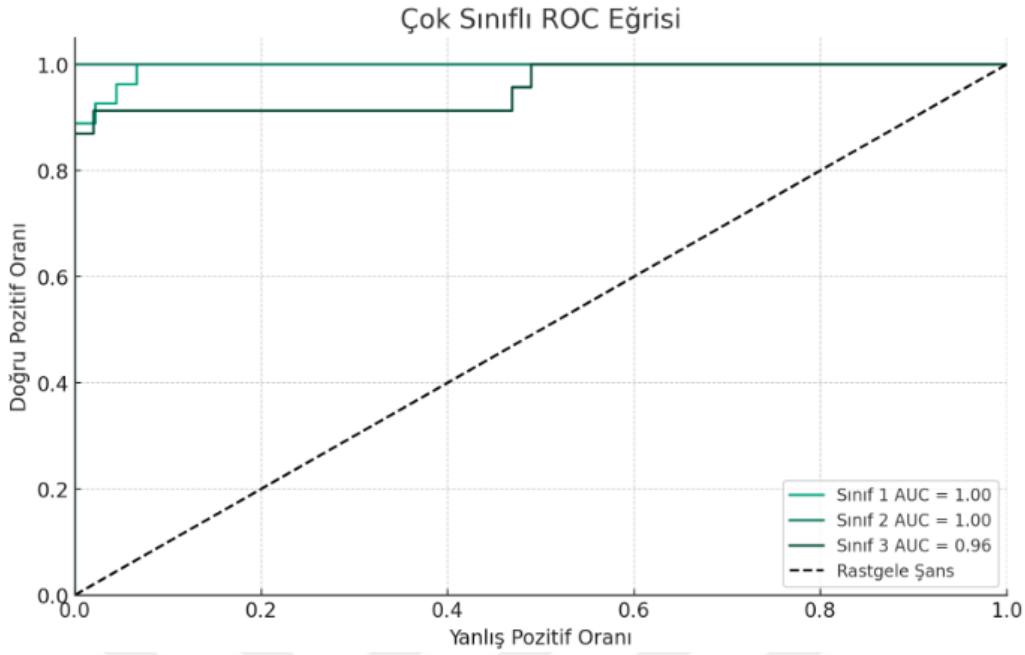
Kesinlik (Precision): %95,87

Hassasiyet (Recall): %95,83

F1-Skoru: %95,82

Bu sonuçlar modelin veri seti üzerinde oldukça yüksek bir performans sergilediğini göstermektedir. Modelin performansını daha detaylı bir şekilde incelemek için karışıklık matrisi ve ROC eğrisi incelenecektir.

Kestirimci bakım ve arıza tespiti bağlamında, bu sonuçlar bu tür senaryoları modellemenin karmaşıklığını ve modeli daha anlaşılır kılmak adına parametre optimizasyonu dahil olmak üzere alternatif modelleme yaklaşımlarını keşfetme ihtiyacını vurgulamaktadır.



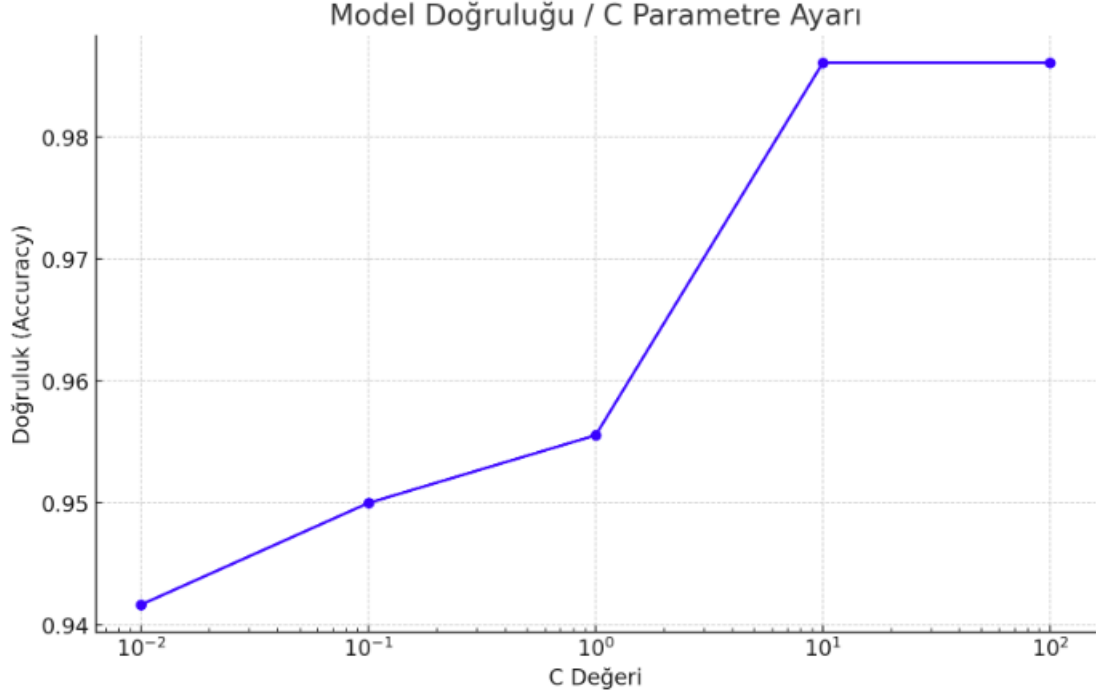
**Şekil 4.2.** ROC Eğrisi

Çok sınıflı ROC eğrisi görülmektedir. Bu grafik, modelin her bir sınıfı ne kadar iyi ayırt edebildiğini gösteren ROC eğrilerini ve ilgili AUC (Eğri Altında Kalan Alan) değerlerini içerir. Her bir eğri, modelin özel bir sınıfa yönelik doğru pozitif oranı (TPR) ile yanlış pozitif oranı (FPR) arasındaki bağlantıyı ifade eder. Eğri ne kadar yükseğe ve sol tarafa doğru ise, modelin o sınıfı ayırt etme performansı o kadar iyidir. "Rastgele Şans" çizgisi, modelin rastgele tahminlerle elde edebileceği performansı temsil eder. AUC değeri 1'e yakın olan sınıflar, modelin o sınıfı ayırt etmede çok iyi performans gösterdiğini gösterir.

Log Name	TÅskanma Senaryosu-2-1_Normal Veri_04.21.2022_02.11.34_PM												
Log Description													
Log Author	Ersin Åzhahin / Koray AlÅtn												
Acquisition Scenario	Analog Input And Digital Input With A SW Timer												
Device Description	USB-4716,81D#1												
AI Channel 0	Unit:Voltage	Data Type:double											
AI Channel 1	Unit:Voltage	Data Type:double											
AI Channel 2	Unit:Voltage	Data Type:double											
AI Channel 3	Unit:Voltage	Data Type:double											
AI Channel 4	Unit:Voltage	Data Type:double											
AI Channel 5	Unit:Voltage	Data Type:double											
AI Channel 6	Unit:Voltage	Data Type:double											
AI Channel 7	Unit:Voltage	Data Type:double											
AI Channel 8	Unit:Voltage	Data Type:double											
AI Channel 9	Unit:Voltage	Data Type:double											
AI Channel 10	Unit:Voltage	Data Type:double											
AI Channel 11	Unit:Voltage	Data Type:double											
DI Port 0	Mask:255	Data Type:byte											
Length(Per Channel)	27067												
Time	2706.7s												
dt	0.1s												
Start Time	21-04-22 14:11												
X_Value	AI Channel 0	AI Channel 1	AI Channel 2	AI Channel 3	AI Channel 4	AI Channel 5	AI Channel 6	AI Channel 7	AI Channel 8	AI Channel 9	AI Channel 10	AI Channel 11	DI Port 0
0	0.16268691	-0.004272461	0.885314941	0.723266602	0.729675293	-0.003967285	0.507202148	2.29309082	1.58996582	2.53112793	-0.532836914	-0.496520996	0xFF
0.1	0.141906738	-0.004272461	0.917053223	0.727233887	0.736083984	-0.005187988	0.566711426	2.287292481	1.605834961	2.502441406	-0.540771484	-0.510559082	0xFF
0.2	0.11505127	-0.003662109	0.913391113	0.706787109	0.748901367	-0.004577637	0.567932129	2.299499512	1.592102051	2.539672852	-0.519714356	-0.506286621	0xFF
0.3	0.104075293	-0.003051758	0.893354688	0.719604492	0.733947254	-0.004577637	0.532265463	2.289733887	1.614074707	2.492675781	-0.528259277	-0.508728027	0xFF
0.4	0.151062012	-0.004577637	0.940551758	0.719299316	0.743713379	-0.004577637	0.551452637	2.305603027	1.599121094	2.487487793	-0.517272949	-0.500793457	0xFF
0.5	0.149841309	-0.003051758	0.91796875	0.706481934	0.725402832	-0.004882813	0.530090332	2.306518555	1.581420898	2.518310547	-0.539245606	-0.514221191	0xFF
0.6	0.159301758	0.010070801	0.877990723	0.698852539	0.736999512	-0.003967285	0.550231934	2.300720215	1.596069336	2.536621094	-0.539245606	-0.512084961	0xFF
0.7	0.195617676	-0.004882813	0.874023438	0.728149414	0.758972168	-0.004577637	0.536804199	2.286376953	1.595458984	2.533405762	-0.521240234	-0.490722656	0xFF
0.8	0.096740723	-0.004577637	0.897216797	0.729675293	0.727233887	-0.004272461	0.563964844	2.294616699	1.593322754	2.530517578	-0.548706055	-0.491638184	0xFF
0.9	0.168457031	-0.004272461	0.933532715	0.69732666	0.731201172	-0.005493164	0.570068359	2.306213379	1.593322754	2.515258789	-0.536804199	-0.510253906	0xFF
1	0.151062012	-0.004577637	0.895690918	0.69152832	0.731811523	-0.004882813	0.57220459	2.284240723	1.589986535	2.51739502	-0.522460938	-0.497741699	0xFF
1.1	0.185852051	-0.003662109	0.903320313	0.714416504	0.729064941	-0.003967285	0.529479981	2.308654785	1.581115723	2.529907227	-0.516662598	-0.501403809	0xFF

**Tablo 1.0.** Sızımtı Senaryosu Data Görseli

Grafikte, sistemden elde ettiğimiz 10 kanal için gerçek ve tahmin edilen sensör okumaları arasındaki karşılaştırma gösterilmektedir, buna göre SVM modeli eğitilmiştir. İdeal senaryoda tahmin edilen değerlerin gerçek değerlerle mükemmel bir şekilde eşleştiğini gösteren diyagonal kesik çizgi, diyagonal çizgiden uzakta dağılmış noktalar; modelin tahminleri ile gerçek veriler arasındaki farklılıkları göstermektedir.



Şekil 4.3. SVM Model Doğruluğu

Modelin doğruluğu ve C parametre ayarlarına bağlı olarak değişimi gösteren yukarıdaki grafiğe göre; C değeri arttıkça modelin doğruluğu genel olarak artmaktadır. Bu, düşük C değerlerinde modelin daha genel bir çözüm üretme eğiliminde olduğunu ve yüksek C değerlerinde ise modelin eğitim verisine daha sıkı bir şekilde uyum sağlamaya çalıştığını gösterir.


C değeri 0.01 iken modelin doğruluğu yaklaşık %94.17, C değeri 100 iken modelin doğruluğu yaklaşık %98.61 olarak gözlemlenmiştir. Bu, modelin belirli bir noktadan sonra, özellikle C=10 ve C=100 için, doğrulukta önemli bir artış gösterdiğini belirtir.

Ancak, C değerinin çok yüksek olması modelin aşırı uyuma (over fitting) eğiliminde olabileceği anlamına gelebilir. Bu durumda, model eğitim verisinde çok iyi performans gösterse de, yeni ve görülmemiş veriler üzerinde beklenen performansı gösteremeyebilir.

Sonuç olarak, modelin doğruluğunu optimize etmek ve genelleme yeteneğini korumak için C değerinin dikkatli bir şekilde seçilmesi gerektiği görülmektedir. Bu grafik, farklı C

değerlerinin modelin performansı üzerindeki etkisini görsel olarak anlamamıza yardımcı olur ve ideal C değerinin seçimi için bir rehber görevi görür.

Kestirimci bakım ve arıza tespiti için yüksek düzeyde bir doğruluk elde etmek kritik öneme sahiptir. Bu nedenle, modelin tahmin performansını iyileştirmek için özellik mühendisliği gibi ek adımlar, alternatif makine öğrenimi modellerini keşfetme veya daha gelişmiş teknikler gibi topluluk yöntemlerini kullanma düşünülebilir.



**Şekil 4.4.** Karışıklık Matrisi


Karışıklık matrisi, bir sınıflandırma modelinin performansını görselleştirmek için kullanılan önemli bir araçtır. Bu matris, modelin her sınıf için ne kadar doğru veya yanlış tahminlerde bulunduğunu gösterir. Matrisin satırları gerçek etiketleri, sütunları ise modelin tahmin ettiği etiketleri temsil eder. Matriste;

**Diyagonal üzerindeki değerler (sol üstten sağ alta)**, modelin her sınıfı doğru olarak ne kadar kez tahmin ettiğini gösterir. Bu değerler ne kadar yüksekse, model o kadar iyi performans göstermiş demektir.

**Diyagonal dışındaki değerler**, modelin yanlış tahminleridir. Bu değerlerin her biri, bir sınıfın başka bir sınıf olarak yanlış sınıflandırılma sayısını gösterir. Bu değerler ne kadar düşükse, modelin o kadar iyi performans gösterdiği anlamına gelir.

Yukarıdaki karışıklık matrisine bakıldığında, modelin yüksek doğrulukta tahminlerde bulunduğu görülür. Diyagonal üzerindeki değerlerin yüksek olması, modelin çoğu sınıfı doğru bir şekilde tanıyabildiğini göstermektedir. Diyagonal dışındaki düşük değerler ise modelin çok az sayıda yanlış sınıflandırma yaptığını işaret eder. Bu da modelin genel olarak yüksek kesinlik ve hassasiyetle çalıştığını gösterir.

Sonuç olarak, bu modelin veri setindeki çeşitli durumları ayırt etmede oldukça başarılı olduğu söylenebilir. Ancak, modelin her sınıfı nasıl sınıflandırdığını ve belirli sınıflar arasında karışıklığın olup olmadığını daha iyi anlaşılması için sınıf bazında detaylı bir analiz yapılması yararlı olabilir.



**Şekil 4.5. SVM Karar Sınırları**

Bu grafikte gösterilen mavi, kırmızı ve gri bölgeler, SVM modelinin karar sınırları ile oluşturulan sınıflandırma alanlarını temsil eder. Her renk, modelin farklı sınıfları nasıl ayırt ettiğini gösterir. Renklerin anlamları şu şekildedir:

**Mavi Bölge:** Modelin birinci sınıfa ait olduğunu tahmin ettiği alanı gösterir. Bu bölgedeki veri noktaları, model tarafından birinci sınıf olarak sınıflandırılır.

**Kırmızı Bölge:** Modelin ikinci sınıfa ait olduğunu tahmin ettiği alanı temsil eder. Bu alandaki noktalar, model tarafından ikinci sınıf olarak değerlendirilir.

**Gri Bölge:** Grafikte gri bölge genellikle karar sınırının kendisini veya modelin sınıflandırma konusunda belirsiz olduğu, yani bir sınıfa net bir şekilde atayamadığı geçiş alanlarını temsil eder. Ancak, bu özel görselleştirmede gri bölge doğrudan görünmeyebilir. Eğer görünüyorsa, bu, belirli bir sınıflandırma kararının veri noktaları arasındaki geçiş veya belirsizlik bölgesini işaret eder. Görselde net bir gri bölge olmaması, modelin her bir veri noktasını belirgin bir şekilde bir sınıfa atadığını ve belirsizlik alanlarının minimal olduğunu gösterir.

Renklerin dağılımı, modelin eğitim veri setindeki özellikler (Basınç ve Akış) temelinde nasıl bir ayırım yaptığını görsel olarak anlaşılmasına yardımcı olur. Noktaların (veri noktalarının) renkli alanlar içinde nasıl yer aldığı, modelin doğruluğu hakkında fikir verir: noktaların kendi renklerine karşılık gelen bölgeler içinde yoğunlaşması, modelin iyi bir sınıflandırma performansı gösterdiğini işaret eder.

## 5. SONUÇ

Bu çalışmada, sıvı ve gaz taşıma hatlarında basınç kayıpları ve arızaların tahmin edilmesi için makine öğrenmesi yöntemlerinin nasıl kullanılabileceği derinlemesine incelenmiştir. Araştırma boyunca, gerçek veriler analiz edilerek ve çeşitli makine öğrenmesi algoritmaları uygulanarak, bu karmaşık sorunun üstesinden gelmekte ne kadar etkili olunabileceği gözlemlenmiştir. Bu süreçte hem teorik bilgileri hem de pratik becerileri birleştirme ihtiyacı doğmuş, bu da araştırma konusunun sadece akademik bir çerçevede kalmayıp, aynı zamanda endüstriyel uygulamalara da önemli katkılar sağlayabileceği görülmüştür. Çalışma, mevcut yöntemlerin sınırlılıklarını aşmak ve daha doğru, etkin tahminler yapabilmek için makine öğrenmesinin potansiyelini ortaya koymuştur. Geliştirilen modeller, basınç kayıpları ve arızaların önceden tespit edilmesinde önemli bir ilerleme sağlayarak, bakım süreçlerini optimize etme ve olası arızaları önleme konusunda önemli fırsatlar sunabileceğini göstermiştir. Bu sayede, işletmelerin bakım maliyetlerini azaltmalarına, operasyonel verimliliği artırmalarına ve çevresel etkileri minimize etmelerine olanak tanıyan stratejik bir araç olarak öne çıkmasını sağlamıştır. Diğer yandan, makine öğrenmesi yöntemlerinin uygulanabilirliğini ve adaptasyonunu farklı senaryolara göre değerlendirme fırsatıdır. Bunun hem algoritma seçiminde hem de model parametrelerinin ayarlanmasında önemli ölçüde esneklik sağlayabileceği gözlenmiştir. Bu tez çalışması ile makine öğrenmesi ve yapay zekâ teknolojilerinin, sıvı ve gaz taşıma hatlarındaki basınç kayıpları ve arızaların tahmin edilmesi gibi karmaşık mühendislik sorunlarının çözümünde nasıl etkili birer araç haline gelebileceği analiz edilmiştir. Elde edilen bulgular, bu teknolojilerin ilgili alanlarda nasıl daha fazla benimsenebileceğine dair önemli ipuçları sunmaktadır. Ancak, araştırmanın sınırlılıklarının da farkında olmak ve bu nedenle, gelecekteki çalışmalarda veri setlerinin çeşitliliğini artırma, model doğruluğunu daha da iyileştirme ve gerçek zamanlı izleme sistemlerinin entegrasyonu gibi konularda daha fazla ilerleme kaydedilmesi gerekmektedir. Bu tez, makine öğrenmesinin mühendislik sorunlarına uygulanması konusunda sadece bir başlangıç noktası olup, bu alanda yapılabilecek daha birçok yenilikçi çalışmayı teşvik etmeyi amaçlamaktadır.

## KAYNAKLAR

- [1.] Saimurugan, M., Ramachandran, K.I., Sugumaran, V., & Sakthivel, N.R. (2011). Multi-component fault diagnosis of rotational mechanical system based on decision tree and support vector machine. *Expert Systems with Applications*, 38(3), 2063-2071.  
<https://www.sciencedirect.com/science/article/pii/S0957417410009991>
- [2.] Soualhi, M., Zerhouni, N., Soualhi, A., Hemsas, K.E. (2015). Detection and Diagnostics of Combined Bearing and Gear Faults Using Electrical Health Indicator. *Proceedings of the Annual Conference of the Prognostics and Health Management Society*. <https://ieeexplore.ieee.org/abstract/document/9804154>
- [3.] Zhang, X., Liang, Y., Zhou, J., & Zang, Y. (2015). A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM. *Measurement*, 70, 79-89.  
<https://www.sciencedirect.com/science/article/pii/S0263224115001633>
- [4.] García Nieto, P.J., García-Gonzalo, E., Sánchez Lasheras, F., & de Cos Juez, F.J. (2015). Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability. *Reliability Engineering & System Safety*, 138, 219-231.  
<https://doi.org/10.1016/j.ress.2015.02.001>
- [5.] Shafi, U., Safi, A., Shahid, A.R., Ziauddin, S., & Saleem, M.Q. (2018). Vehicle Remote Health Monitoring and Prognostic Maintenance System. *Journal of Healthcare Engineering*, 2018, Article 8061514.  
<https://doi.org/10.1155/2018/8061514>
- [6.] Baptista, M., Sankararaman, S., De Medeiros, I.P., Nascimento Jr., C., Prendinger, H., & Henriques, E.M.P. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41-53.

<https://doi.org/10.1016/j.cie.2017.10.033>

- [7.] En-Naaouia, A., Gallab, M., & Kaicer, M. (2020). An Intelligent Model for Improving Risk Assessment in Sterilization Units Using Revised FMEA, Fuzzy Inference, k-Nearest Neighbors and Support Vector Machine. *Journal of Applied Research and Technology*, 18(1), 1-14.  
<https://jart.icat.unam.mx/index.php/jart/article/view/2116>
- [8.] Li, Z., & He, Q. (2015). Prediction of Railcar Remaining Useful Life by Multiple Data Source Fusion. *IEEE Transactions on Industrial Informatics*, 11(6), 1420-1431. <https://ieeexplore.ieee.org/abstract/document/7046427>
- [9.] Saimurugan, M., Ramachandran, K.I., Sugumaran, V., & Sakthivel, N.R. (2011). Multi-component fault diagnosis of rotational mechanical system based on decision tree and support vector machine. *Expert Systems with Applications*, 38(3), 2063-2071.  
<https://www.sciencedirect.com/science/article/pii/S0957417410009991>
- [10.] Li, X., Li, W., Xu, M., Zhou, P., & Wang, H. (2014). A review on the vibration analysis for a damaged gear. *Journal of Vibroengineering*, 16(4), 2158-2178.
- [11.] Soualhi, A., Medjaher, K., & Zerhouni, N. (2015). Bearing health monitoring based on Hilbert–Huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*, 64(1), 52-62. <https://ieeexplore.ieee.org/abstract/document/6852098>
- [12.] Li, Y., Guo, H., Li, X., & Chen, X. (2015). Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals. *Mechanical Systems and Signal Processing*, 60-61, 273-288  
<https://www.sciencedirect.com/science/article/pii/S088832701500148X>

- [13.] Yang, B., Lei, Y., Jia, F., & Xing, S. (2015). An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings. *Mechanical Systems and Signal Processing*, 87, Part A, 274-293.  
<https://www.sciencedirect.com/science/article/pii/S0888327015302566>
- [14.] Zhang, X., Liang, Y., Zhou, J., & Zang, Y. (2015). A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM. *Measurement*, 70, 79-89.  
<https://www.sciencedirect.com/science/article/pii/S0263224115001633>
- [15.] García Nieto, P.J., García-Gonzalo, E., Sánchez Lasheras, F., & de Cos Juez, F.J. (2015). Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability. *Reliability Engineering & System Safety*, 138, 219-231.  
<https://doi.org/10.1016/j.res.2015.02.001>
- [16.] Shafi, U., Safi, A., Shahid, A.R., Ziauddin, S., & Saleem, M.Q. (2018). Vehicle Remote Health Monitoring and Prognostic Maintenance System. *Journal of Healthcare Engineering*, 2018, Article 8061514.  
<https://doi.org/10.1155/2018/8061514>
- [17.] Baptista, M., Sankararaman, S., de Medeiros, I.P., Nascimento Jr., C., Prendinger, H., & Henriques, E.M.P. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41-53.  
<https://doi.org/10.1016/j.cie.2017.10.033>
- [18.] Shamayleh, A., Awad, M., & Farhat, A. (2020). An intelligent fault diagnosis system for industrial machines using a deep learning approach. *Journal of Intelligent Manufacturing*, 31, 759-776.  
<https://doi.org/10.1007/s10845-019-01480-x>

- [19.] Demirel, F. (2010). Su iletim hatları basınç bilgilerinin deneysel bir ortamda kablosuz sensör ağı ile toplanması (Yüksek Lisans Tezi). Elektrik-Elektronik Mühendisliği Bölümü, Tez Yöneticisi: Yrd. Doç. Dr. Radosveta Sokullu, Eylül 2010, 61 sayfa.  
[https://acikbilim.yok.gov.tr/bitstream/handle/20.500.12812/377150/yokAcikBilim\\_382427.pdf?sequence=-1](https://acikbilim.yok.gov.tr/bitstream/handle/20.500.12812/377150/yokAcikBilim_382427.pdf?sequence=-1)
- [20.] Alin, K. (2023). Predictive maintenance application on pipelines using artificial intelligence model. In M. S. Genç, G. Genç, S. T. Azgin, & S. B. Selçuklu (Eds.), Proceedings of the 3rd International World Energy Conference (IWEC 2023), December 4-5, Kayseri, Turkey (pp. 388-393). IKSAD Publishing House.
- [21.] Alin, K. (2023). Boru hatlarında yapay zekâ modeli kullanarak kestirimci bakım uygulaması. In Proceedings of the 6th International Hasankeyf Scientific Research and Innovation Congress (pp. 136-142). Batman, Turkey: ISARC (International Science and Art Research Center).
- [22.] Baykan, O. (2017). Su yönetimi kapsamında içme suyu temin ve dağıtım sistemlerinde su kayıp kaçaklarının kontrolü. İSKİ Genel Müdürlüğü. ISBN: 978-605-9507-24-0. (Kitap yayını)

# ÖZGEÇMİŞ

**Adı Soyadı:** Koray ALIN

**Yabancı Diller:** İngilizce, Rusça

<b>Eğitim Durumu:</b>	<b>Bölümler</b>	<b>Tarih</b>
Dokuz Eylül Üniversitesi	Mühendislik Fakültesi Makine Mühendisliği	18.03.2009 Mezun
Anadolu Üniversitesi	İşletme fakültesi İşletme	27.05.2019 Mezun
Anadolu Üniversitesi	Açıköğretim Fakültesi Web Tasarımı ve Kodlama	26.01.2021 Mezun
Anadolu Üniversitesi	Açıköğretim Fakültesi Bilgisayar Teknolojileri Böl. Bilgisayar Programcılığı	Devam
Marmara Üniversitesi	Fen Bilimleri Enstitüsü Mekatronik Mühendisliği (Tezli Yüksek Lisans)	Devam

## İş Deneyimi:

Alzotech CNC Takım Tezgâhları	Genel Müdür Yrd. / Kıdemli Mühendis	Mart 2010 Kasım 2021
Delphi Technologies (İzmir)	Mekanik Mühendisi	Haziran 2008 Haziran 2009