



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**AĞIR VASITA HAVA KOMPRESÖRÜ**  
**ARIZALARININ MAKİNE ÖĞRENMESİ**  
**YÖNTEMLERİ KULLANILARAK ANALİZİ**

**Emre GÜL**

**YÜKSEK LİSANS TEZİ**

**Makina Mühendisliği Anabilim Dalı**

**Aralık-2020**  
**KONYA**  
**Her Hakkı Saklıdır**

**TEZ KABUL VE ONAYI**

Emre GÜL tarafından hazırlanan “Ağır Vasıta Hava Kompresörü Arızalarının Makine Öğrenmesi Yöntemleri Kullanılarak Analizi” adlı tez çalışması 17/12/2020 tarihin de aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Makina Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Jüri Üyeleri****İmza****Başkan**

Dr. Öğr. Üyesi Ümit ÖNEN

.....

**Danışman**

Prof. Dr. Mete KALYONCU

.....

**Üye**

Dr. Öğr. Üyesi Muhammed Arif ŞEN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN

Enstitü Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Emre GÜL

17.12.2020

## ÖZET

### YÜKSEK LİSANS TEZİ

## AĞIR VASITA HAVA KOMPRESÖRÜ ARIZALARININ MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK ANALİZİ

Emre GÜL

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Makina Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Mete KALYONCU**

**2020, 113 Sayfa**

**Jüri**

**Danışman Prof. Dr. Mete KALYONCU  
Dr. Öğr. Üyesi Ümit ÖNEN  
Dr. Öğr. Üyesi Muhammed Arif ŞEN**

Küçük bir bileşen olmasına rağmen hava kompresörleri, ağır vasıta aracın uzun yol sürüşlerinde emniyetli bir şekilde hareketini devam ettirmesine yardımcı olmaktadır. Çalışmada literatür ve teknik servis görüşmeleri neticesinde en sık rastlanan hava kompresörü arıza durumları belirlenmiştir. Belirlenen arıza türleri kendi içerisinde değerlendirilmiş ve arıza derecelerine göre deney hazırlıkları yapılmıştır. Deneyler için test düzeneği oluşturularak yazılım ve sensör donanımları ile 19 farklı çalışma durumuna ait veriler kayıt altına alınmıştır. Kayıt altına alınan 23.987 verinin %80'i ile PYTHON programında Destek Vektör Makineleri (DVM), K-En Yakın Komşu (K- $nn$ ), Naive Bayes Sınıflandırıcısı, Rastgele Orman Algoritması ve Yapay Sinir Ağları algoritma modelleri oluşturulmuş ve bu modeller kalan %20'lik veri ile test edilmiştir. Modeller 10 kat çapraz doğrulama işlemine tabi tutulmuştur. Ardından modellerin test verilerine göre doğruluk oranları belirlenmiştir. Destek Vektör Makineleri Radyal Tabanlı Fonksiyon Kerneli %100, K-En Yakın Komşu algoritması Manhattan Uzaklık Ölçütü %99.50, Gaussian Naive Bayes Sınıflandırıcısı %94.60, Rastgele Orman Algoritması %99.30, Yapay Sinir Ağları %99.80 doğruluk oranı sonuçlarını vermiştir. Modellerin Kappa ve  $F_1$  skor değerleri incelenmiş, eğitim ve test verileri için karmaşıklık matrisleri oluşturulmuştur. Modellerin hiç karşılaşmadığı verilerde tahmini sınıfı yüzdelik oranla belirlenmiş ve elde edilen sonuçlar değerlendirilmiştir. Bu çalışma makine öğrenmesi algoritma modellerinin, ağır vasıta hava kompresörü arızalarının tahmin edilmesinde etkili olabildiklerini göstermektedir.

**Anahtar Kelimeler:** Ağır Vasıta Hava Kompresörü, Makine Öğrenmesi, Yapay Sinir Ağları, Kestirimci Bakım, Arıza Analizi, Destek Vektör Makineleri, K-En Yakın Komşu Algoritması, Naive Bayes Algoritması, Rastgele Orman Algoritması.

**ABSTRACT****MS THESIS****ANALYSIS OF HEAVY VEHICLE AIR COMPRESSOR FAILURES USING  
MACHINE LEARNING METHODS****Emre GÜL****Konya Technical University  
Institute of Graduate Studies  
Department of Mechanical Engineering****Advisor: Prof. Dr. Mete KALYONCU****2020, 113 Pages****Jury****Advisor Prof. Dr. Mete KALYONCU****Asst. Prof. Dr. Ümit ÖNEN****Asst. Prof. Dr. Muhammed Arif ŞEN**

In spite of being a small component, air compressors help the heavy vehicle to keep its motion safely on long journeys. In the study, as a result of the literature and technical service interviews, the most common air compressor failure cases were determined. The determined failure types were evaluated within themselves and test preparations were made according to the failure degrees. For the experiments, the test setup was created, software and sensor hardware, and 19 different operating conditions data were recorded. With 80% of the recorded 23,987 data, Support Vector Machines (DVM), K-Nearest Neighbor (K-nn), Naive Bayes Classifier, Random Forest Algorithm and Artificial Neural Networks algorithm models were created in the PYTHON program and these models were tested with the remaining 20% of data. Models were subjected to 10-fold cross validation. Then, the accuracy rates of the models were determined according to the test data. Support Vector Machines Radial Based Function Kernel 100%, K-Nearest Neighbor algorithm Manhattan Distance Criteria 99.50%, Gaussian Naive Bayes Classifier 94.60%, Random Forest Algorithm 99.30%, Artificial Neural Networks gave 99.80% accuracy. Kappa and F1 score values of the models were examined, and complexity matrices were created for training and test data. In the data that the models never encountered, the estimated class was determined by percentage and the results obtained were evaluated. This study shows that machine learning algorithm models can be effective in predicting heavy vehicle air compressor failures.

**Keywords:** Heavy Duty Vehicle Air Compressor, Machine Learning, Artificial Neural Networks, Predictive Maintenance, Fault Analysis, Support Vector Machines, K-Nearest Neighbor Algorithm, Naive Bayes Algorithm, Random Forest Algorithm.

## ÖNSÖZ

Tez çalışmamın planlanmasında, araştırılmasında ve yürütülmesinde bana rehberlik eden, bilgi ve tecrübelerinden fazlasıyla faydalandığım, yönlendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren danışman hocam Prof. Dr. Mete KALYONCU'ya sonsuz teşekkürlerimi sunuyorum.

İlk iş deneyimimi aynı ekipte yaşadığımız, çalışmalarında testlerin gerçekleştirilmesi için verdikleri emeklerden dolayı İbrahim TOY, M. Şükrü AYDINER, Gökselhan KULA'ya ve verdikleri destek, sağladıkları imkanlardan dolayı Yıldız Pul Otomotiv Motor Parçaları Sanayi A.Ş. yönetici ve çalışanlarına teşekkür ederim.

En değerlilerim annem, babam ve ablama; her konuda yanımda oldukları ve desteklerini her zaman hissettirdikleri için sevgi, saygı ve sonsuz teşekkürlerimi sunuyorum.

Emre GÜL

KONYA-2020

## İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iii</b>
<b>ABSTRACT.....</b>	<b>iv</b>
<b>ÖNSÖZ .....</b>	<b>v</b>
<b>İÇİNDEKİLER.....</b>	<b>vi</b>
<b>SİMGELER VE KISALTMALAR.....</b>	<b>viii</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>2. HAVALI FREN SİSTEMLERİ.....</b>	<b>2</b>
2.1. Ağır Vasıta Hava Kompresörleri .....	4
2.1.1. Ağır vasıta hava kompresörü arızaları .....	9
2.2. Hava Kurutucu Tahliye Valfleri .....	14
2.3. Hava Tankları ve Boşaltma Subabı .....	16
<b>3. MAKİNE ÖĞRENMESİ.....</b>	<b>17</b>
3.1. Destek Vektör Makineleri.....	18
3.2. K-En Yakın Komşu Algoritması .....	20
3.3. Naive Bayes Sınıflandırıcısı .....	22
3.4. Rastgele Orman Algoritmaları.....	23
3.5. Yapay Sinir Ağları .....	24
<b>4. KAYNAK ARAŞTIRMASI.....</b>	<b>29</b>
<b>5. MATERYAL VE YÖNTEM.....</b>	<b>37</b>
5.1. Test Sisteminin Oluşturulması.....	37
5.2. Arıza Durumlarının Etiketlenmesi.....	41
5.3. Test Düzeninde Kullanılan Sensörler ve Üniteler.....	43
5.3.1. Basınç sensörleri .....	43
5.3.2. Sıcaklık sensörleri.....	45
5.3.3. Debimetreler .....	46
5.3.4. Oda sıcaklık sensörü .....	46
5.3.5. Yağlama Ünitesi .....	47
5.3.6. Soğutma Suyu Ünitesi .....	48
5.4. Veri Toplama Sistemi .....	49
5.4.1. DEWESOFT ve DEWESOFT x2 yazılımı.....	50
5.4.2. Sirius .....	50
5.4.3. Krypton .....	51
5.5. Test Grafikleri.....	51

5.6. Verilere Uygulanacak İşlemler ve Modelin Değerlendirme Yöntemleri.....	56
5.6.1. K katlı çapraz doğrulama .....	57
5.6.2. Performans ve Sınıflandırma metrikleri .....	57
<b>6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>60</b>
6.1. Sınıflandırma .....	61
<b>7. SONUÇLAR VE ÖNERİLER.....</b>	<b>103</b>
7.1. Sonuçlar .....	103
7.2. Öneriler .....	107
<b>KAYNAKLAR.....</b>	<b>108</b>
<b>ÖZGEÇMİŞ .....</b>	<b>112</b>





## SİMGELER VE KISALTMALAR

### Simgeler

$cm^3$	: Santimetreküp
$m^3$	: Metreküp
%	: Yüzde
kW	: Kilowatt
mm	: Milimetre
$\emptyset$	: Çap
$^\circ$	: Derece
C	: Santigrat
L/d	: Litre / dakika
b	: Bias (Eğilim) Değeri
C	: Düzenleme (Ceza) Parametresi
d	: Polinom Derecesi
w	: Ağırlık Vektörü (Hiper-Düzlemin Normali)
$\gamma$	: Gamma Parametresi
$K(x_i, x_j)$	: Kernel fonksiyonu
$\xi_i$	: Yapay Değişken
$y_i$	: Sınıf Etiketleri
$x_i$	: Hiperdüzlem Üzerindeki Nokta
k	: Komşu Sayısı
p	: Uzayda Bir Nokta
$p_i$	: Uzaydaki Bir Noktanın Koordinat Ekseninde Konumları
q	: Uzayda Bir Nokta
$q_i$	: Uzaydaki Bir Noktanın Koordinat Ekseninde Konumları
$p(x C_j)$	: Sınıf j'den Bir Örneğin x Olma Olasılığı
$P(C_j)$	: Sınıf j'nin İlk Olasılığı
$p(x)$	: Herhangi Bir Örneğin x Olma Olasılığı
$P(C_j x)$	: x Olan Bir Örneğin Sınıf j'den Olma Olasılığı (Son Olasılık)
n	: Eğitim Verisindeki Elemanların Toplamı
y	: İstenilen Çıktı Değeri
Kg/h	: Kilogram / Saat
Rpm	: Devir / Dakika
V	: Volt
mV	: Milivolt
$m^3/s$	: Metreküp / Saniye

**Kısaltmalar**

Adam	: Adaptive Moment Estimation
ALB	: Otomatik Fren Sistemi Valfi
ANN	: Artificial Neural Networks
cc	: Silindir Hacmi
DBN	: Deep Belief Network
DN	: Doğru Negatif
DP	: Doğru Pozitif
DVM	: Destek Vektör Makineleri
EEG	: Elektroensefalografi
K-nn	: K En Yakın Komşu
KNN	: K-Nearest Neighbor Algorithm
KNNR	: K-en Yakın Komşu Regresyonu
LVD	: Logged Vehicle Data
RBF	: Radyal Tabanlı Fonksiyon
RBM	: Restricted Boltzmann Machines
ReLU	: Rectified Linear Unit
RUL	: Kalan Faydalı Ömür
SVM	: Support Vector Machines
TBA	: Temel Bileşen Analizi
TPR	: True Positive Rate
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

## 1. GİRİŞ

Teknolojik gelişmeler son yıllarda ülkeler arasında rekabetin artmasına sebep olmuştur. Ağır vasıta bileşenlerinin üretim maliyetlerinin artmasıyla birlikte, üreticilerin piyasada rekabet edebilmesi için ürünlerinin dayanım sürelerini artırma yoluna sevk etmiştir. Aktif çalışan sistemlerde sürekli durum izleme ile ürünlerin dayanım süreleri kontrol altına alınabilmektedir. Arıza durumlarının sistemin tamamına zarar vermeden kontrol altına alınması sağlanmakta, cüzi ücretlerle sistemin bakımı yapılabilmektedir.


Yapılan araştırmalarda Türkiye’de trafik kazalarının her geçen gün artmasının temel sebepleri, sorunun çözümüne yönelik araştırmaların, disiplinler arası yaklaşımlarda saptanması gereken hedeflerin belirlenememesi, problemin çözümünde mühendislik çalışması gerekliliğinin kavranmamış olmasıdır. Trafik kazalarında birçok faktörün tek ya da çoğul kombinasyonlarının birleşimi şeklinde etki etmektedir. Karakteristik özelliklere bakıldığında Türkiye’de meydana gelen kazaların büyük bir bölümünde ağır vasıtaların önemli bir payı olduğu görülmektedir (Kaplan, 2014).

Ağır vasıtalar uzun yol sürüşlerinde yük, eşya ve insan taşımacılığında kullanılmaktadır. Aracın fren, debriyaj, süspansiyon ve diğer bileşenlerinin birçoğunun çalışması için basınçlı hava gerekmektedir. Basınçlı hava aracın seyir halindeyken güvenli hareketi için önem arz etmektedir. Aracın emniyeti büyük ölçüde fren sistemlerinin performansına bağlıdır. Fren sistemleri tankta bulunan basınçlı hava ile çalışmaktadır. Havayı basınçlandırarak tankta depo edilmesini sağlayan makinalara kompresör adı verilir. Aracın güvenilirliği kompresörün istenen verimde çalışmasına bağlı olmakla birlikte, hava kompresörü aracın yolda güvenli ve emniyetli bir şekilde seyir halinde olmasında en büyük katkıyı sunmaktadır.

Kompresörden alınacak sensör verilerinin anlamlandırılması, yeni verilerle kıyaslama yapılırken kompresörün çalışma anında durumunun izlenmesi, kompresör verilerinde en başarılı algoritma yapısının belirlenmesi gibi konular sonuçlandırıldığında ağır vasıtalar için daha güvenilir bir sürüş imkânı sağlanacaktır. Uzun yol sürüşlerinde konforlu sürüşün sağlanması, özellikle hava sisteminde oluşabilecek arızaların erken fark edilmesi kaza ve sorunların önceden öngörülerek önlenmesi açısından büyük önem taşımaktadır.

## 2. HAVALI FREN SİSTEMLERİ

Vasıtaların ağırlık ve hızlarındaki artış hidrolik fren sisteminin yetersizliğini ortaya çıkarmıştır. Ağır vasıtalarda hidrolik fren sistemleri havalı fren sistemlerine göre sade bir yapıdadır. Sürücünün fren pedalına uyguladığı kuvvet, fren kuvvetinin uygulanmasında eksik kalmaktadır. Büyük hacimli vasıtalarda havalı fren sistemleri yaygın olarak kullanılmaktadır. Havalı fren sistemleri içerisinde hava üreten mekanizmalar yardımıyla fren pedalına uygulanan kuvvetle, havanın mekanik güce dönüştürülerek gerekli yavaşlama ve durdurma işlemini sağlayan fren sistemidir. Havalı fren sisteminin bileşenleri daha fazla olduğu için her bir bileşenin üstlendiği görev iyi bilinmelidir. Aksi halde arıza durumunda bileşenlerin testlerini yapmak ve doğru arıza teşhisi koyabilmek mümkün olmamaktadır (Kaplan, 2014). Şekil 2.1’de havalı fren sistemi görüntüsü verilmiştir.




Şekil 2.1. Havalı Fren Sistemi (Megep, 2013)

Motor hareketi ile kompresör hava üretir. Üretilen hava tankta basınçlandırılarak depo edilir. Havalı fren sistemlerinde genellikle pistonlu tip kompresör kullanılır. Balatalara tanktaki basınç kuvveti iletilerek frenleme sağlanır. Havalı fren sistemi kompresör, fren pedal valfi, fren körükleri, hava kurutucu tahliye valfi, el fren valfi, su tahliye valfi, hava tankı ve emniyet valflerinden oluşmaktadır. Şekil 2.2’de havalı fren sistemi şematik görüntüsü ve Çizelge 2.1’de ise şematik görüntüdeki bileşenlerin isimleri verilmiştir (Megep, 2013).

**Çizelge 2.1.** Hava Kurutuculu ve ALB'li Fren Sisteminin Bileşenleri

1. Kompresör	11. Otomatik Fren Sistemi Valfi (ALB)
2. Hava Kurutucu	12. Depolama Hava Başlığı
3. Basınç Regülatörü	13. El Freni Valfi
4. Dört Devreli Emniyet Supabı	14. Römork Kumanda Supabı
5. Hava Tankları	15. Röle Supabı
6. Basınç Emniyet Valfi	16. Hava Basınç Göstergesi
7. Su Boşaltma Valfi	17. Kontrol Lambası
8. Fren Pedalı Supabı	19. Geri Tepme Supabı
9. Diyaframlı Fren Silindiri	25. Frenleme Havası Bağlantı Başlığı
10. Kombi Fren Silindiri (Körüğü)	

**Şekil 2.2.** Ağır vasıtalarda, hava kurutuculu ve ALB'li fren sisteminin kesit alınmış örneği (Megep, 2013)

Kompresörün ürettiği hava tankta istenilen basınca ulaştığında, kompresör çıkışından alınan hava, kurutucu tahliye valfi sayesinde tekrardan kompresör girişine gönderilir ve böylece kompresör boşta çalışır. Sistemdeki basınç değeri sistem basıncı

altında bir basıncı gösterdiği zaman kompresörün çıkışının sisteme açılması sağlanır (Günyeli, 2019).


## 2.1. Ağır Vasıta Hava Kompresörleri

Hava kompresörleri, ortamdan emdiği havayı, barındırdığı mekanizma ve valf sistemleri ile basınçlandıran sistemlerdir. Hava kompresörleri modellerine göre farklılık gösteren, ağır vasıta araçlarda ihtiyaç yüklemelerine göre tek ya da çift silindirli olarak tasarlanır ve üretilirler. Ağır vasıtalarda  $159 \text{ cm}^3$  ile  $800 \text{ cm}^3$  aralığında  $1.5 \text{ m}^3/\text{d}$  hava seviyelerine yaklaşabilmektedir (Ünüvar ve ark., 2019). Şekil 2.3’de ağır vasıta hava kompresörü resimleri gösterilmiştir.




Şekil 2.3. Ağır Vasıta Hava Kompresörü Resimleri  
(Yıldız Pul Otomotiv Motor Parçaları Sanayi A.Ş.)

Tır, traktör, otobüs ve kamyonlarda kullanılan pistonlu kompresörler 8-12,5 bar aralığında basınçlı hava üretmektedir. Ağır vasıtalarda soğutma işlemi aracın soğutma suyu ile sağlanabilmektedir ve motor yağı ile kompresörün yağlanması sağlanmaktadır. Şekil 2.4’de çift silindirli ve su soğutmalı hava kompresörü patlatılmış görünümü gösterilmiştir.



Şekil 2.4. Çift Silindirli ve Su Soğutmalı Hava Kompresörü Patlatılmış Görünümü




Şekil 2.5. a) Havanın Silindir İçerisindeki Hacime Vakumlanması  
 b) Havanın Sıkıştırılarak Basınçlandırılması (Bendix, 2010).

Pistonun ařađı ynde hareketi ile piston zerindeki silindir hacminde oluřan vakum hava giriř valfinin (emme valfi) aılmasını sađlar. Atmosferik hava, hava giriř valfinden giriř yaparak piston zerinde oluřan silindir hacmini doldurur. Őekil 2.5 a. grselinde rneđi grlmektedir. Piston alt l noktaya ulařtıđında hava giriř valfi kapanır. Piston zerinde kalan hava, hava ıkıř valfi (egzoz valfi) tarafından tutulmaktadır ve pistonun yukarı ynde harekete bařlaması ile hava sıkıřtırılır. Silindir ierisindeki hava sistem basıncından daha yksek bir basınca ulařtıđında, hava ıkıř valfi (egzoz valfi) aılır ve havanın kurutucu tahliye valfine ve ardından tanka depolanması sađlanmaktadır. Őekil 2.5 b. grselinde rneđi grlmektedir (Bendix, 2010).

Atmosferik hava sıkıřtırıldıđıa, hava ierisinde bulunan su buharı ve kompresrdeki yađ tařınımı basınlı hava ile birlikte kurutucu tahliyeden geerken ayrıřarak tahliye ile atmosfere bırakılır. Yađ miktarının ařırı olması kurutucu tahliye valfinin bozulmasına ve sistemde yađ tařınımına sebep olabilmektedir. Grev dngs, kompresrn ykte alıřtıđı srenin toplam sreye oranı olarak tanımlanmaktadır. Hava kompresrleri %25 ykte alıřacak Őekilde tasarlanmaktadırlar. Fren sistemlerinin srekli kullanımı, hava kaađı durumları ve arıza durumlarında yksek grev dngs oluřabilmektedir. Hava kurutucu tahliye valfine giren basınlı havanın sıcaklıđı normal aralıklarda olduđunda, hava kurutucu tahliye valfi kompresrden gelen basınlı havadan yađ ve su buharını ayırabilmektedir. Basınlı havanın sıcaklıđı yksek ise su ve yađ buharı kurutucu tahliye valfini geerek hava ile fren sistemine geebilmektedir. Byk aplı hava ıkıř hattı ya da ıkıř hattı uzunluđunun artırılması sıcaklıđın dřrlmesinde etkilidir. Yađ damlacıkları ve toplanan su, kurutucu tahliye valfi aracılıđıyla devreden ıkma ayarına ulařtıđında otomatik olarak temizlenir (Bendix, 2010).


Kompresrn yk altında alıřması esnasında harcanan enerji artar. Basın reglatrnde ayarlanan basınca ulařıncaya kadar kompresr ykte alıřmaya devam eder. Őekil 2.6 incelendiđinde tank istenilen basınca ulařıncaya kadar bir yay kumanda pistonlarını (17) bađlı bulunan itme yaprak levhaları (8) ile birlikte dıř son noktada tutmaktadır. Bu sayede itme yaprak levhaları (8) her iki silindir arasındaki bir bađlantı kanalına aılan delikleri kapatır. Őekil 2.6' da kompresrn ykte alıřtıđı durumdaki montajlı valf pleyt grnts verilmiřtir.





**Şekil 2.6.** Enerji Tasarrufu Olan Bir kompresörün Valf Plakasındaki By-Pass Mekanizmasının Kapalı Olduğu Durumdaki Görüntüsünün Örneği


Kompresörün rölanti yani enerji tasarrufu aşamasında, tankın istenilen basınca ulaştığı durumda basınç regülatörü ve kompresör rölanti işlemine alınmaktadır. Şekil 2.7 incelendiğinde, basınç regülatörü ayarlanılan basınca ulaştığında regülatörden dönen basınçlı hava, basınç regülatörü ve kompresör arasındaki bir kumanda pistonlarına (17) uygulanır. Kumanda pistonları böylece yayın gücüne karşı aksel olarak dayanma noktasına bastırılır ve bu esnada kendisine bağlı itme yaprak levhalarını (8) beraberinde hareket ettirir. İtme yaprak levhaları her iki silindir arasındaki bir bağlantı kanalına açılan delikleri (18) açar. Hava böylece her iki silindir arasında gidip-gelir. Bu işlem sonucunda piston hareketi esnasında sıkıştırma basıncı düşer ve kompresörün tüketeceği güç azalır. Böylelikle yakıt ve enerji tasarrufu yapılmış olmaktadır. Şekil 2.7’de kompresörün yüksüz çalıştığı durumdaki montajlı valf pleyt görünümü verilmiştir.



Şekil 2.7. Enerji Tasarrufu Olan Bir kompresörün Valf Plakasındaki By-Pass Mekanizmasının Açık Olduğu Durumdaki Görüntüsünün Örneği

Emisyon standartlarının otomotiv sektöründe artması ile birlikte kompresörlerin daha az güç tüketerek daha fazla hava debisi üretmesi istenmektedir. Aracın debi üretiminin artırılırken, güç tüketiminin azaltılmasına yönelik çalışmalar OEM üreticileri tarafından yapılmaktadır. Bilindiği üzere geleneksel kompresörler yükte çalıştığı süreçte 12 kW seviyelerine yaklaşan güç tüketirken, yüksüz çalıştığı durumlarda 2–2.5 kW seviyelerine yaklaşan güç tüketmektedir. Kompresörün yüksüzken güç tüketmemesi ve kompresör bileşenlerinin dayanım ömürlerini artırmak üzere OEM üreticileri tarafından manyetik kavramalı, pnömatik kavramalı ve elektrikli kompresörler üretilmeye başlanmıştır.

Ağır vasıtalarda hava kompresörleri bağlantı yönünden çeşitlilik gösterse de barındırdığı valf sistemleri benzerdir. Kasnaklı ve manyetik kavramalı kompresörler daha çok traktör ve iş makinelerinde tercih edilirken, kayış ile kullanıldıkları için yüksek devirler ve aşırı yükte kayış kaçırma problemi olacağından küçük hacimli kompresörlerde tercih edilmektedir. Dişli bağlantılı ve pnömatik kavramalı kompresörler kamyon- tır gibi vasıtalarda, elektrikli ve vidalı tip kompresörler ise şehir içi otobüs gibi vasıtalarda tercih edilmektedir. Şekil 2.8’de tek silindirli kompresör ve pnömatik devresi verilmiştir.



Şekil 2.8. Tek Silindirli Kompresör ve Pnömatik Devresi (Kaplan, 2014)

### 2.1.1. Ağır vasıta hava kompresörü arızaları

Hava kompresörleri arıza durumlarında verimsiz çalışarak daha fazla güç tüketimine karşılık daha az debi üretebilmektedir. Debide ki azalma tank doldurma süresinde artışa, kompresör bileşenlerinin yorulma dayanımlarında düşüşe sebep olabilmektedir. Bazı arıza durumlarının ise kompresörün kullanılamaz hale gelmesinde etkisinin büyük olduğu bilinmektedir.

Literatür ve teknik servis araştırmaları sonucu ortaya çıkan kompresör arızaları aşağıdaki gibidir;

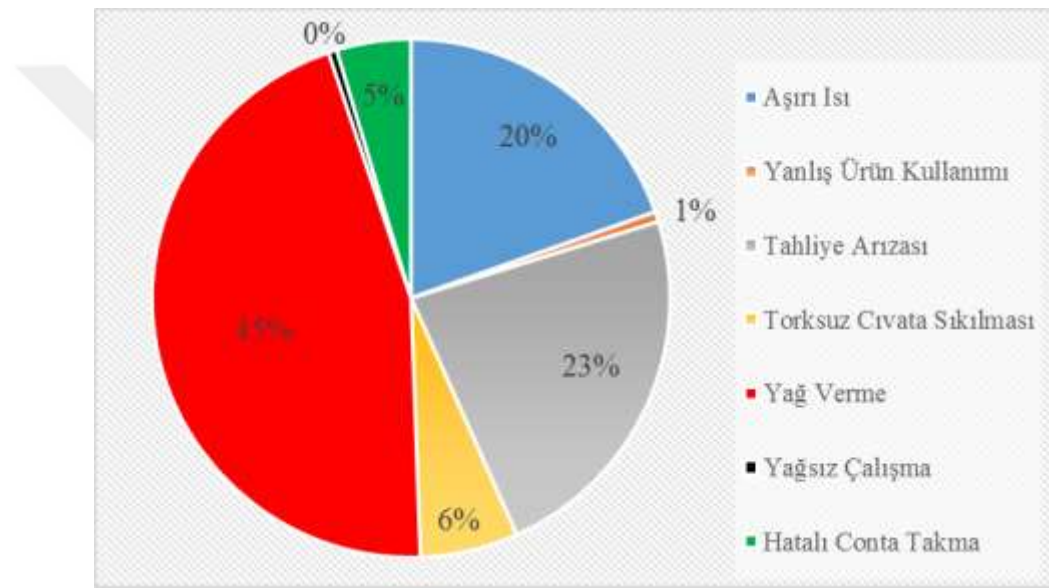
- Hava çıkış hattı basıncının düşük olması,
- Hava çıkış hattı basıncının yüksek olması,
- Hava çıkış sıcaklığının düşük olması,
- Hava çıkış sıcaklığının yüksek olması,
- Biyel kolu kırılması,
- Burç dönmesi,
- Contaların sızdırmazlık özelliklerini kayıp etmesi,
- Cıvata soketlerinde çatlak oluşumu,
- Torksuz sıkma sebebiyle cıvata kırılması,

- Dişli takılamaması,
- Döküm hatası,
- Hava emmiş hattı basıncının düşük olması,
- Hava emmiş hattı basıncının yüksek olması,
- Hava emmiş hattı sıcaklığının düşük olması,
- Hava emmiş hattı sıcaklığının yüksek olması,
- Fanın çalışmaması (dönmemesi),
- Genleşme valfi ayar elemanları arızaları,
- Gömlek-segmanda aşınma,
- Gövde kırılması,
- Gözetleme camında kabarcık görünmesi,
- Hasarlı kompresör valfleri veya pistonları.
- Hava çıkışının tıkalı olması,
- Hava doldurmama,
- Hava girişinin tıkalı olması,
- Hava kısmına su kaçırma,
- Kablolarda yanma,
- Karter ve gövde çok soğuk, terli veya karlı,
- Kompresör durduğunda su akışının devam etmesi,
- Kompresör emme hattı borularında çatlakların olması,
- Kompresör filtrelerinin özelliklerini kayıp etmesi,
- Kompresörün gürültülü çalışması,
- Kompresör hava kurutucu tahliye valfinin bozuk olması,
- Kompresör kayışlarının kayması veya kopması,
- Kompresörün kısa aralıklı çalışması (sürekli yükte çalışması),
- Kompresörün sarsıntı yapması,
- Kompresör soğutma suyu kanallarının tıkalı olması,
- Kompresör ve boru bağlantılarında yağ sızıntıları görülmesi,
- Kompresörde yağ verme (taşınımı),
- Kompresörden boşalan gaz basıncının yükselmesi,
- Kompresöre parça gelmesi,
- Kompresörün çalışmaması (dönmemesi),

- Kompresörde kurum oluşumu,
- Kondensördeki normal basınçta soğutucu maddenin yoğunlaşmaması,
- Kondensördeki soğutucu sıvının kondenser borularında düzenli akması,
- Montaj yapılamaması,
- Parçaların bozulması,
- Pim kırılması,
- Piston sarması,
- Pompanın çalışmaması (dönmemesi),
- Radyatöre hava basması,
- Sıkıştırma arızası,
- Sıvı vuruntusu,
- Sıvı yürümesi,
- Sızdırmazlık (körük) arızası,
- Silindir kapağının aşırı ısınması,
- Silindir kapak contalarının hava kaçırması,
- Sistemde aşırı düzeyde soğutucu akışkan olması (aşırı yükleme),
- Sistemde yetersiz düzeyde soğutucu akışkan olması (az yükleme),
- Soğutucu akışkanın; yağ nem hava ve diğer gazlarla kirlenmesi,
- Su regülatör valfinin gıcırdaması,
- Taşmalı kalkış,
- Valf kırılması,
- Yağ ayırıcısının anormal sesler çıkarması,
- Yağ ayırıcısında yağın tam olarak ayrılmaması,
- Yağ basıncının düşük olması,
- Yağ basıncının yüksek olması,
- Yağ sıcaklığının yüksek olması.
- Yağın kirli olması,
- Yay kırılması,
- Yüksek basınç ile düşük basınç arasındaki farkın azalması,
- Yüksek basma hattı sıcaklıkları,
- Yanlış montaj yapılması,
- Yanlış conta kullanımı,

- Yanlış cıvata kullanımı.

Bu çalışmada kompresör ve bağlantılı olduğu mekanizmaların bakımlarının zamanında yapılmaması sebebiyle kompresörde oluşabilecek arızalar üzerinde durulmuştur. Çeşitli firmaların üretmiş olduğu ağır vasıta hava kompresörü teknik servisleri ile yapılan görüşmeler sonucunda 2018 ve 2019 yıllarında en çok rastlanılan kullanıcı kaynaklı arıza kaydı verileri incelenmiş ve arızaların dağılım grafikleri Şekil 2.9'da verilmiştir. 2018 ve 2019 yıllarına ait toplam 949 adet arıza değerlendirmeye alınmıştır.



Şekil 2.9. Çeşitli Markalara Ait Teknik Servis 2018-2019 Yılı Toplam Verileri


Kompresörün hava girişinden toz partiküllerini alması sonucu silindir gömleği ile piston segmanları arasında aşınma oluşur. Bu aşınma gömlek yüzeyinde üst ölü noktada 0.1 mm iken, alt ölü noktada 0.05 mm aralığında değişmektedir. Piston segmanlarında ise segman kalınlığı 3 mm'den 2.30 mm ölçülere kadar inebilmektedir. Piston segmanları ile silindir gömleği arasında oluşan boşluk, kompresörün kartere hava kaçırmasına ve karterdeki yağın hava çıkışından tanka doğru ilerlemesine yani yağ vermeye (taşınma) sebep olmaktadır. Fazla yağ, hava kurutucu tahliye valfinin arıza göstermesine sebep olabilir. Hava kurutucu tahliye valfinde oluşan arıza tanka yağ kaçmasına ve sistemin yağlanmasına sebep olabilirken, bozulan tahliye hava kompresörünün sürekli yüke girip çıkmasına sebep olabilmektedir.

Tahliye arızasının alt başlıkları; hava girişinin tıkalı olması, hava çıkışının tıkalı olması, hava giriş ve çıkışının tıkalı olması, sürekli yükte çalışma arızaları olarak sıralanabilmektedir.

Motor hava filtresinden filtrelenerek geçen havanın bir bölümü motora gönderilirken, kalan kısmı kompresöre gönderilmektedir. Hava filtresinin tıkalı olması ya da borulardaki tıkanıklık motor girişinde vakuma sebep olabilmekte, kompresörde tank dolum süresini artırmakta ve hava çıkış hattına yağ vermesinde potansiyel bir artışa sebep olabilmektedir. Kompresör hava çıkışının tıkalı olması hava sisteminin yavaş doldurulmasına, kompresörün sürekli yükte çalışmasına, hava kompresörünün aşırı ısınması ve daha fazla yağ vermesine sebep olabilmektedir. Bununla birlikte araçtaki yağın kirli olması içerisinde toz partiküllerini bulundurması hava kompresöründe erken aşınmalara yol açarak yağ vermeye sebep olabilmektedir (Bremse, 2008).

Sürekli yükte çalışma durumu sonucunda kompresör sürekli yüke girip çıkarken sıcaklığın artışına sebep olarak, kompresör içerisinde yağ buharının segmanları geçerek kompresör çıkışında kurum oluşumuna sebep olabilmektedir. Kompresör çıkışında oluşan kurum çıkış hattını tıkayarak tankın dolum süresini artırabilmektedir. Ayrıca basınçların düzensiz olması kompresör pleytine bağlı by-pass mekanizmasının sürekli devreye girip çıkmasıyla aşınmasına buna bağlı olarak mekanizmanın açık kalması ve kompresörün tankta hava doldurmaması gibi sorunlara yol açtığı gözlemlenebilmektedir.

Aşırı ısı arızasının birçok sebebi olabilmektedir. Kompresörler %25 oranında yükte çalışacak şekilde tasarlanırlar. Bu çalışma performansı kompresörlerin ömür ve dayanım sürelerinin maksimumda olması açısından önem arz etmektedir. Kompresörün sürekli yükte olması veya sürekli yüke girip çıkması, soğutma suyu sıcaklığının uzun süreli çalışma anında 120 °C sıcaklık ve üzerinde olması, soğutma suyu debisinde düşüş, hatalı soğutma suyu kullanımı gibi sebeplerden dolayı kompresör kapağında aşırı ısı oluşumu beklenir. Kompresör kapağı ile pleyti arasındaki NBR contaların fiziksel özelliklerini kaybetmesine ve bunun sonucunda suya hava kaçırma, tankta hava doldurmama, atmosfere hava salınımı gibi problemlerin oluşmasında etkilidirler. Şekil 2.10'da NBR conta örneği paylaşılmıştır.



Şekil 2.10. NBR Conta

## 2.2. Hava Kurutucu Tahliye Valfleri

Hava kurutucu tahliye valfleri ağır vasıta araçlarda kompresör ile tank arasına yerleştirilir. Amaçları su buharı, yağ buharı ve diğer kirleticileri hava tankına ulaşmadan önce filtrelemektir. Kuru hava, dağıtıcı vasıtasıyla araçtaki çeşitli bileşenlere dağıtılır.

Hava kurutma olayı, emilimin moleküler bir süzgeç vasıtasıyla gerçekleşmesidir. Basıncı havanın çok sıkı yerleştirilmiş granüllerden oluşan kurutucudan geçmesiyle, hava içerisine sıkışmış su buharı kurutucunun üst yüzeyine bağlanır. Kurutulmuş havanın bir kısmı kurutucunun rejenera edilebilmesi için atmosfer basıncına genişletilirken ters yönde gönderilir. Basınç düşmesi rejenerasyon havası içerisinde bulunan su buharı kısmi basıncının düşmesine sebep olur. Bundan dolayı rejenerasyon havası, kurutucu mekanizmasında biriken nemi alabilecek hale gelmektedir. Kompresörün emdiği havanın içerisinde bulunan su buharı miktarı, emilimin olduğu andaki havadaki bağıl nem ve sıcaklığa bağlıdır. Hava tahliye valfleri, frenleme sona erdikten sonra tekerleklerin veya fren odalarındaki havanın en kısa sürede ve kısa yoldan atmosfere atılmasını sağlarlar (Kaplan, 2014). Şekil 2.11’de hava kurutucu tahliye valfi görüntüsü verilmiştir.






Şekil 2.11. Hava Kurutucu Tahliye Valfi (Anonymous, 2020a)

Şekil 2.12’de, kompresörden gelen hava 11 numaralı porttan giriş yapmaktadır. 31 numaralı port emniyet için kullanılmaktadır. Sistemde herhangi bir tıkanıklık ya da bozulma durumunda hava porttan atmosfere tahliye olmaktadır. Filtrede kurutulup temizlenen hava 21 numaralı port vasıtasıyla dağıtıcılara çıkış yapmaktadır.

Kısılmış basınçlı hava 22 numaralı port aracılığıyla çıkış yapabilmektedir. 23 numaralı port ise lastik şişirme amacıyla kullanılan porttur. Ayrıca 24 numaralı porttan hava çıkışı yapılabilmektedir. Şekil 2.12’de hava kurutucu tahliye valfi pnömatrik şeması verilmiştir.



Şekil 2.12. Hava Kurutucu Tahliye Valfi Pnömatrik Şeması (Anonymous, 2020a)

4/25 numaralı port, by-pass hattıdır. Kompresörden gelen hava, kurutucudan geçtikten sonra set basıncına (8-12.5 bar seviyesi) ulaştığı anda valf yayını yenip valfin yön değiştirmesini sağlamaktadır. Basınç ayarı valfte bulunan setskurdan yapılmaktadır. 3 nolu porta bağlı valfe by-pass yolundan gelen 12 bar seviyelerinde basınçlı hava, bu valfi tetiklemektedir. Valf tetiklenmesi sonucunda kompresörden gelen hava, kurutucuya girmek yerine yön değiştirme valfi vasıtasıyla, atmosfere açılan 3 nolu portu tercih etmektedir. Bu geçiş ile tahliye işlemi gerçekleşmiş olmaktadır. Bir diğer geçiş portu olan by-pass hattında valf tetiklenerek kompresöre bağlı valf mekanizmasının devreye girmesini sağlamaktadır.

### 2.3. Hava Tankları ve Boşaltma Subabı

Kompresör yardımıyla basınçlandırılan hava tanklarda depolanır. Kurutucudan kaçan su buharı yoğunlaşarak tankta su haline dönüşebilir. Suyun boşaltılması tanklarda bulunan boşaltma subabının manuel olarak çekilmesiyle sağlanır (Kaplan, 2014). Şekil 2.13’de tank ve boşaltma subabı görüntüsü verilmiştir.



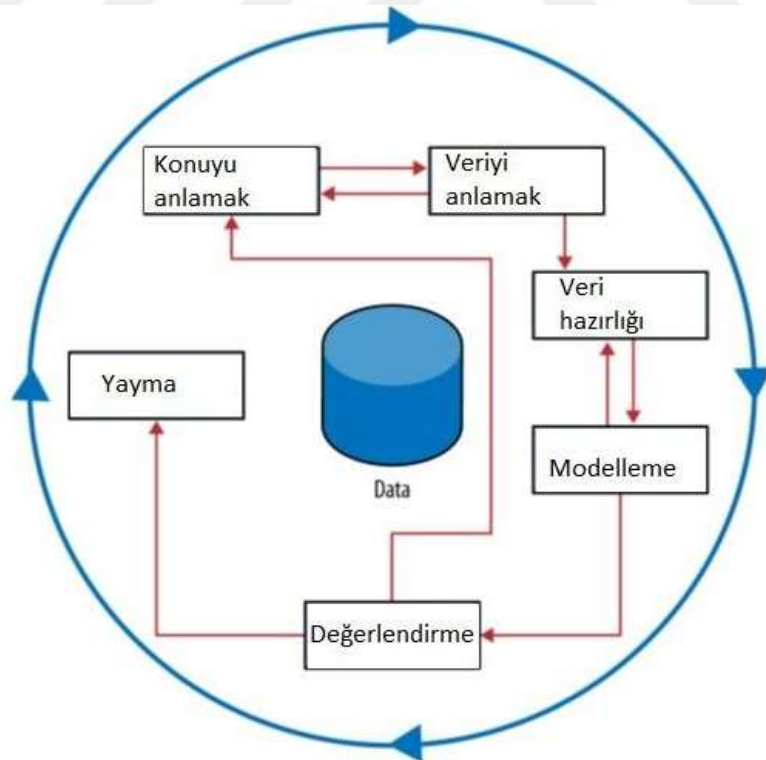
Şekil 2.13. a) Soldaki Tank b) Sağdaki Boşaltma Subabı (Kaplan, 2014)

### 3. MAKİNE ÖĞRENMESİ

Aktif çalışan sistemlerden, sensör teknolojisi ile veriler elde edilmekte ve bu veriler algoritma oluşturulmasında aktif rol almaktadırlar. Büyük veriler, oluşturulan makina öğrenmesi algoritmalarının eğitilmesinde kullanılarak, eğitilen modeller test verileri ile test edilerek modelin doğruluk oranı saptanmaktadır. Modelin doğruluğu saptandıktan sonra, model belirli fonksiyon algoritmalarından geçirilerek optimizasyonu sağlanmakta ve algoritmanın otonom karar verme yapısı oluşturulmaktadır.

Bir probleme ait veriler yardımıyla modelleme işlemi yapılarak algoritmalar oluşturmanın genel adına makine öğrenmesi denilmektedir. Makine öğrenmesi yöntemleri 3 ana başlıkta, Danışmanlı (Supervised), Danışmansız (Unsupervised) ve Yarı Danışmanlı (Semi-Supervised) öğrenme olarak incelenmektedir (Şahin, 2018).


Veriye dayalı tahmini veri toplama, veri işleme ve bakım kararı verme olarak 3 adımdan oluşur. Algoritmalar ise eldeki veri seti yapısına göre incelenir (Öztanır, 2018). Şekil 3.1’de makine öğrenmesi süreci gösterilmiştir.



Şekil 3.1. Makine Öğrenmesi Süreci (Acungil, 2020)

### 3.1. Destek Vektör Makineleri

Verileri optimum seviyede ikiye ayıran n-boyutlu bir hiperdüzlem oluşturan destek vektör makinaları modelleri yapay sinir ağları ile ilişkilidir. Sigmoid kernel fonksiyonu kullanan destek vektör makineleri iki katmanlı, ileri beslemeli bir yapay sinir ağına sahiptir. DVM' ye göre eğitim sınıfındaki tüm veriler bağımsız ve benzer olarak dağılmıştır. Verilerin doğrusal veya doğrusal olmayan bir yapıda ayrılabilirlik karşılaşılabilecek iki durumdur (Aydın, 2016). Şekil 3.2'de doğrusal ayrılabilir durumda hiper düzlem görüntüsü verilmiştir.



Şekil 3.2. Doğrusal Ayrılabilir Durumunda Hiper - Düzlem Görünümü (Kavzoğlu ve Çölkesen, 2010)

Doğrusal ayırıcı düzlemde amaç iki ayrı sınıfa ait verilerin düzleme eşit uzaklıkta olmasını sağlamaktır (Aydın, 2016).

Verileri doğrusal olarak ayıramama durumunda doğrusal olmayan sınıflandırıcılar kullanılır. Gözlem vektörünü uzayda yüksek dereceden bir z vektörüne dönüştürür ve uzayda doğrusal sınıflandırıcıları elde etmek hedeflenir. Çekirdek fonksiyonları değerin yerine koyularak nitelik uzayının değerinin doğrudan bulunmasını sağlamaktadır. Diğer faydası ise eğitim sırasında oluşturduğu fonksiyonda kalıp değerlerinin diğer örnekler için hazır olması sebebiyle gösterdiği kolaylıktır. Bu sayede işlemlerin kolaylaştırılması sağlanır. Bütün değerlerin çarpılarak değerinin hesaplanması yerine, çekirdek fonksiyonu üzerinde doğrudan değerin yerine konularak


nitelik uzayındaki değerinin bulunması sağlanabilir ve yüksek boyutlu nitelik uzayı ile uğraşma olasılığı ortadan kalkar. Polinomial fonksiyon, linear fonksiyon, radyal tabanlı fonksiyon, sigmoid fonksiyon yaygın olarak kullanılan 4 çekirdek fonksiyondur (Aydın, 2016).

**Çizelge 3.1.** Kernel Türleri ve Matematiksel İfadelerinin Gösterimi (Üstüner, 2013)

Kernel Türü	Matematiksel Formülü
Linear Kernel	$K(x_i, x_j) = (x_i \cdot x_j)$
Polinomial Kernel	$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + b)^d, \gamma > 0, \delta > 0$
Radyal Tabanlı Fonksiyon	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
Sigmoid Kernel	$K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) - b), \gamma > 0, \delta > 0$

Çizelge 3.1’de kernel fonksiyonlarının matematiksel formülleri gösterilmiştir. Çeşitli yöntemler aracılığı ile çok sınıflı verilerin sınıflandırılması işleminde kullanılan destek vektör makineleri, başlangıçta iki sınıflı verilerin sınıflandırılması amacıyla tasarlanmıştır (Üstüner, 2013).

Şekil 3.3’de doğrusal olarak ayrılamayan veri setleri için hiper düzlemin gösterimi verilmiştir.



**Şekil 3.3.** (a) Doğrusal olarak ayrılamayan veri seti, (b) Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi. (Kavzoğlu ve Çölkesen, 2010)

Düzenleme parametresi ve yapay değişken kullanılarak doğrusal ayırım yapılamayan veriler için optimizasyon problemi Eşitlik 3.1’de gösterilmiştir;

$$\min\left[\frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^r \xi_i\right] \quad 3.1$$

şeklini alır.

Buna bağlı sınırlamalar ise Eşitlik 3.2’deki gibi ifade edilir (Kavzoğlu ve Çölkesen, 2010).

$$\begin{aligned} y_i(w \cdot \varphi(x_i) + b) - 1 &\geq 1 - \xi_i \\ \xi_i &\geq 0 \text{ ve } i = 1, \dots, N \end{aligned} \quad 3.2$$

Kullanılacak fonksiyona özgü parametrelerin yanında destek vektör makineleri için düzenleme parametresi  $C$ ’nin kullanıcı tarafından belirlenmesi gerekmektedir. Optimum değer belirlenememesi durumunda hiper düzlem doğru belirlenemeyeceği için sınıflandırma doğruluğunda düşüş beklenmektedir.  $C$  parametresinin sonsuz olması ( $C = \infty$ ) durumunda DVM modeli sadece doğrusal olarak ayrılabilen veri setleri için uygun hale gelebilmektedir. Uygun parametre değerlerinin seçimi DVM sınıflandırıcısının performansını direkt etkilemektedir. Ayrıca çapraz doğrulama yaklaşımı ile başarılı sonuçlara ulaşılabilmesinde olanak sağlanabilmektedir (Kavzoğlu ve Çölkesen, 2010).

### 3.2. K-En Yakın Komşu Algoritması

Bir probleme ait verilerde, veriler arasında matematiksel bir ifadeyle mesafe ölçümüne dayalı yakınlık kavramına göre sınıflandırmayı yapan algoritmalarlardır. Bu sınıflandırmanın mantığı aynı sınıftan veya farklı sınıftan örneklerin benzerliklerine göre arasındaki uzaklığı ölçmeye dayalı bir metoda dayanmasıdır (Cömert, 2016).


Sınıf etiketlerinin rastgele dağılması, çoğunluk oylamasına bağlı olarak belirlenmesi temel K-nn algoritmasında yeni verilerin sınıf etiketlerinin belirlenmesinde baskın bir role sahip olmalarına neden olmaktadır. Bununla birlikte Öklid, Manhattan, Minkowski, Chebyshev ve Dilca uzaklığı olmak üzere 5 farklı uzaklık ölçütü kullanılmaktadır (Taşcı ve Onan, 2016).

Kompresör arıza verilerinde Öklid, Manhattan ve Chebyshev uzaklık bağıntısı kullanılacaktır. Şekil 3.4’de K-nn algoritmaları için uzaklık bağıntıları verilmiştir.

$d_{\text{Öklid}}(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}$
$d_{\text{Manhattan}}(p, q) = \sum_{i=1}^n  p_i - q_i $
$d_{\text{Chebyshev}}(p, q) = \max_i ( p_i - q_i )$
$d_{\text{Minkowski}}(p, q) = \sqrt[m]{\sum_{i=1}^n  p_i - q_i ^m}$


Şekil 3.4. Uzaklık Bağlılıkları (Kaya ve ark., 2018)

Yakınlığın ölçülmesi için sınıflandırma ve kümeleme algoritmalarında kullanılan temel uzaklık ölçütü Öklid uzaklık bağlantısıdır (Taşcı ve Onan, 2016). Şekil 3.5’de uzaklık ölçümüne dayanan sınıflandırma görüntüsü verilmiştir.



Şekil 3.5. Uzaklık Ölçümüne Dayanan Sınıflandırma Görüntüsü (Cömert, 2016)

Ağ modelinde k değerinin yüksek olması, sınıflaşmanın azalarak genelleştiğini gösterirken düşük olması modelin etkilenmesinde önemli rol almaktadır (Aydın, 2016). K-en yakın komşu algoritmasının işlem adımları Şekil 3.6’da gösterilmiştir.



Şekil 3.6. K-en Yakın Komşu Algoritması İşlem Adımları

K-en yakın komşu algoritması genel işleyişi;

Eğitim Algoritması: Eğitim seti içerisinde bulunan her bir veri  $(x, f(x))$  eğitim örnekleri listesine eklenir.

Sınıflandırma Algoritması ;  $x_q$  verisini aşağıdaki kurala göre sınıflandırır. Eğitim verileri arasında bulunan  $x_1, \dots, x_k, x_q$  en yakın k tane veriyi temsil etmek üzere,  $x_q$  verisinin sınıf etiketi değerinin belirlenmesi Eşitlik 3.3’de gösterilmiştir (Taşcı ve Onan, 2016).

$$f(x_q) \leftarrow \operatorname{argmax}_{v \in V} \sum_{i=1}^k \delta(v, f(x_i)) \quad 3.3$$

Eşitlik 3.3’de a ve b’nin eşit olduğu durumda  $\delta(a,b) = 1$  alınmalı, aksi durumda  $\delta(a,b) = 0$  alınmalıdır (Taşcı ve Onan, 2016).

### 3.3. Naive Bayes Sınıflandırıcısı

Koşullu olasılık temeline dayanarak özniteliklerinin tümünün sınıflandırılmasında, birbiri arasında eşit ve bağımsız olduğu varsayılan koşullu olasılık temellerine dayanan basit yapılı bir sınıflandırma algoritmasıdır. Sınıflandırma işlemi farklı özniteliklerin sonuca olan etkisinin birleşmesiyle yapılır (Cömert, 2016).

Naive Bayes istatistiksel yöntemler kullanarak sınıflandırma yapmaktadır ve performans açısından önemli bir algoritmadır. Niteliklerin öneminin hepsinde aynı derecede olduğu kabul edilir (Aydın, 2016). Eşitlik 3.4’de Naive Bayes Algoritmasının matematiksel formülü verilmiştir.



- $p(x|C_j)$ : Sınıf j'den bir örneğin x olma olasılığı
- $P(C_j)$ : Sınıf j'nin ilk olasılığı
- $p(x)$ : Herhangi bir örneğin x olma olasılığı
- $P(C_j|x)$ : x olan bir örneğin sınıf j'den olma olasılığı (son olasılık)

$$P(C_j|x) = \frac{p(x|C_j)P(C_j)}{p(x)} = \frac{p(x|C_j)P(C_j)}{\sum_k p(x|C_k)P(C_k)} \quad 3.4$$

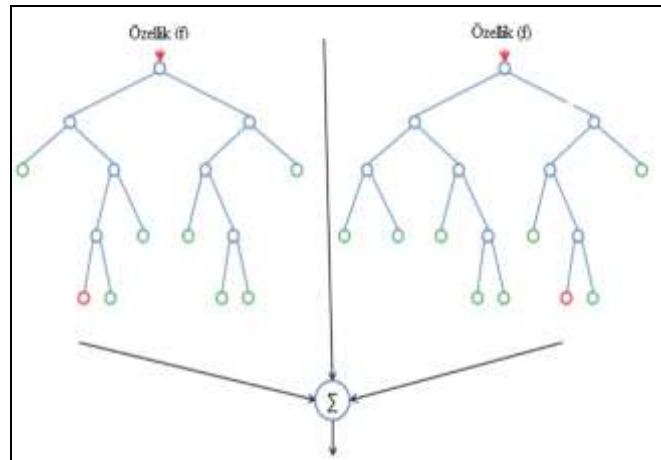
Naive Bayes sınıflandırıcısı Bernoulli Naive Bayes, Multinomial Naive Bayes ve Gaussian Naive Bayes olarak 3 ana başlıkta incelenebilmektedir.

### 3.4. Rastgele Orman Algoritmaları

Rastgele orman algoritması, çok farklı disiplinlere hitap etmesi sebebiyle farklı alanlarda çalışan araştırmacıların dikkatini üzerine çekmektedir ve en başarılı sınıflandırma yöntemlerinden biri olarak bilinmektedir. Ağaç tipi sınıflandırıcılar topluluğu olarak adlandırılabilirler (Akar ve Güngör, 2012).

Rastgele orman algoritmasını genel anlamıyla açıklamak gerekirse; algoritma birden fazla karar ağacını oluşturur. Onları daha doğru ve istikrarlı bir tahmin elde etmek için birleştirir. Algoritma ağaçları büyütürken, modele ek rastgelelik katıyor.


Bir düğümü parçalara ayırırken rastgele bir özellik alt kümesinden en iyi özelliği aramaktadır. Rastgele bir ormanın iki ağaç gibi görülmesi Şekil 3.7'de verilmiştir (Anonim, 2020).



Şekil 3.7. Rastgele Ormanın İki Ağaç Gibi Görülmesi (Anonim, 2020)

Her bir veri seti orijinal veri setinden yer deęiřtirmeli olarak üretilirken, rastgele özellik seçimi kullanılarak ağaçların geliştirilmesi sağlanır ve yeni geliştirilen ağaçlar budanmaz (Akar ve Güngör, 2012).


Çok hızlı olması, aşırı uyuma karşı dayanıklı olması ve istenilen ağaç adedi ile çalışması rastgele orman algoritmasının özelliklerindedir (Akar ve Güngör, 2012). Şekil 3.8’de rastgele orman algoritmasının akış şeması verilmiştir.



Şekil 3.8. Algoritmanın akış şeması (Peker ve ark., 2017)

### 3.5. Yapay Sinir Ağları

İlk yapay sinir ağı modelinin 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirildiği bilinmektedir. Yapay sinir ağları, insan beynine benzetilerek geliştirilmiş, düğüm ve sinir hücrelerinden oluşan, biyolojik sinir ağlarını taklit eden bilgisayar algoritmalarıdır (Elmas, 2018). Şekil 3.9’da yapay sinir ağlarının gelişimine ait zaman çizelgesi gösterilmektedir.



Şekil 3.9. YSA Gelişiminin Zaman Tarihçesi (Bayır, 2006)

İnsanlarda biyolojik sinir sistemini açıklamak gerekirse; merkezinde bilgiyi alan, yorumlayan ve uygun karar üreten beynin bulunduğu 3 katmanlı sistem olarak tanımlanır. Alıcı sinirler aldıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri ise, beynin ürettiği elektriksel darbeleri uygun tepkilere dönüştürmekle görevlidir (Fırat ve Güngör, 2004). Şekil 3.10'da biyolojik sinir sisteminin blok görüntüsü gösterilmektedir.

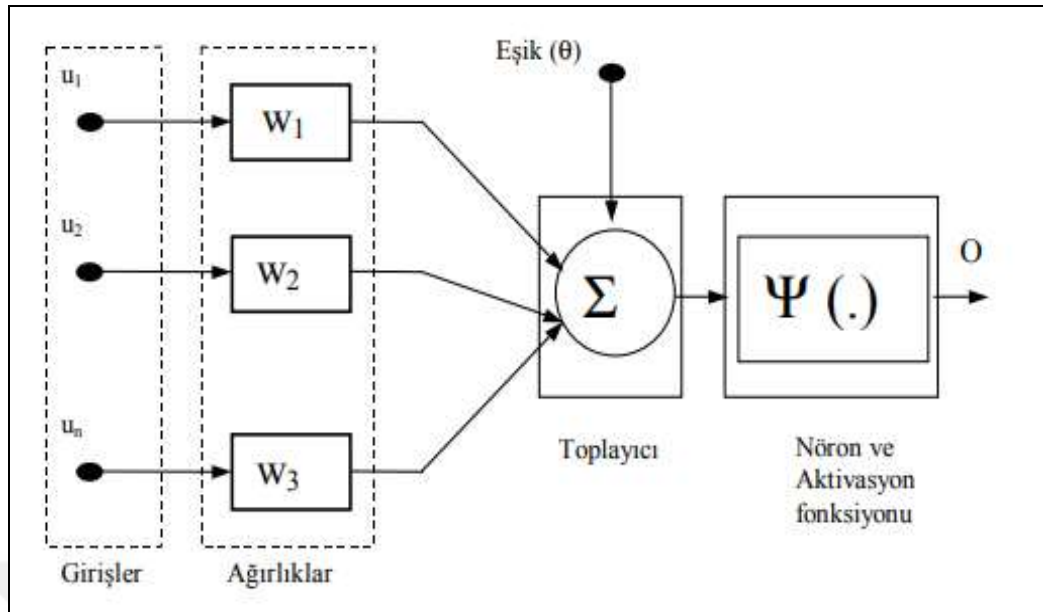


Şekil 3.10. Biyolojik Sinir Sisteminin Blok Görüntüsü (Fırat ve Güngör, 2004)

Sinir hücresi (nöron), merkezi sinir sisteminin temel işlem elemanıdır. Nöronlar sinir ağlarının oluşmasında görev alan, tek başlarına ele alındıklarında çok basit işleve sahip işlemciler olarak bilinirler. Nöron yapısı incelendiğinde sinapslar, toplayıcı ve aktivasyon fonksiyonu olarak 3 ana bölümde incelenir. Şekil 3.11'de bir nörona ait matematiksel model gösterilmektedir (Fırat ve Güngör, 2004).


Nöron girdileri sinaptik bağlantılar üzerindeki ağırlıklarla çarpılarak bir toplayıcıya uygulanmaktadır. Elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır (Fırat ve Güngör, 2004).

Aktivasyon fonksiyonu olarak ReLU ve Softmax fonksiyonları kullanılmıştır. ReLU (Rectified Linear Unit) aktivasyon fonksiyonu giriş değeri sıfırın altındaysa çıktı olarak sıfır, üzerinde ise çıktı değeri giriş değerine eşit olmakla birlikte bağımlı değişken ile doğrusal bir ilişki oluşmaktadır (Ser ve Bati, 2019).



Şekil 3.11. Nöronun matematiksel modeli (Fırat ve Güngör, 2004)

ReLU aktivasyon fonksiyonunun grafiği Şekil 3.12’de, denklemi ise Eşitlik 3.5’de verilmiştir.



Şekil 3.12. ReLU Aktivasyon Fonksiyonu Grafiği (Şahin, 2017)

$$f(x) = \max(0, x)$$

3.5

Çalışmada kullanılacak diğer aktivasyon fonksiyonu ise softmax fonksiyonudur. Fonksiyon dağılım üzerinde kategori bazında olasılığı hesaplama işleminde kullanılmaktadır. İkili değişken üzerindeki olasılığın hesaplanması için kullanılan

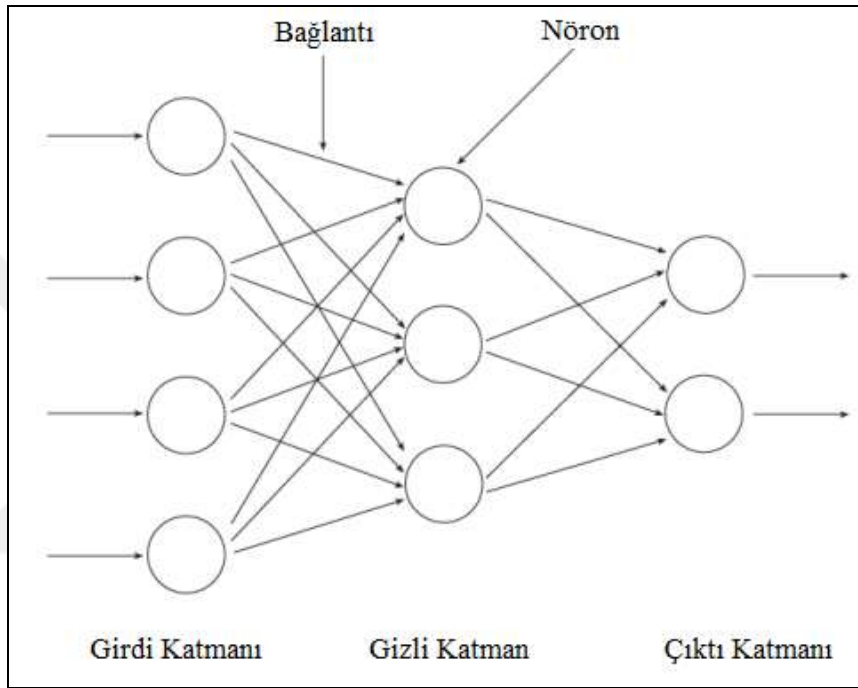
sigmoid fonksiyonunun genelleştirilmiş halidir. Sınıflandırma işlemi yapan yapay sinir ağları algoritmalarında genellikle çıkış birimi olarak kullanılmaktadır. Nöronların bireysel olarak nasıl çalışması gerektiğini aktivasyon fonksiyonları belirlemektedir. En iyi ağırlıkların belirlenmesi için öğrenme sürecinde tüm ağırlıklar denenmekte ve bu yöntem uzun zaman almaktadır. Maliyet fonksiyonları en iyi ağırlıkların tahmin edilmesi için kullanılmaktadır. Maliyet fonksiyonlarına kayıp (loss) fonksiyonları da denmektedir. Yapay sinir ağının eğitiminde sıklıkla çapraz – entropi (cross-entropy) fonksiyonları kullanılmaktadır. İstenen çıktı  $y$ , eğitim verisi elamanlarının toplamı  $n$ , tüm eğitim verisi girdilerinin toplamı  $x$  ile gösterilebilmektedir. Fonksiyonun sonucu hep pozitif olmaktadır. Çapraz – entropi, tüm nöron  $x$  girdileri için hedeflenen  $y$  değerlerini hesaplamaya yaklaştıkça sifıra yaklaşmaktadır. Çapraz- entropi fonksiyonu Eşitlik 3.6’da tanımlanmıştır (Şahin, 2017).

$$C = -1/n \sum x[y \ln a + (1 - y) \ln(1 - a)] \quad 3.6$$

Maliyet fonksiyonları ile hesaplanan maliyeti en aza indirmek için optimizasyon fonksiyonları kullanılmaktadır. Optimizasyon fonksiyonları ağırlık ( $w$ ) ve bias ( $b$ ) değerlerini yapay sinir ağının eğitim sürecindeyken güncelleyerek optimum çözüme doğru ilerleme (maliyeti düşürme) mantığıyla çalışırlar. Adam (adaptive moment estimation) algoritması momentum terimini de dinamik bir şekilde ayarlamak için geliştirilmiştir (Şahin, 2017). Çalışmada optimizasyon olarak Adam algoritması kullanılmıştır.

Girdideki her bir değişim, nöron çıkışında belirli bir değişime sebep olmaktadır. Bu değişimin genliği, girdinin etki derecesini belirleyen bağlantı kazançlarına, toplayıcının eşik değerine ve nöron aktivasyon tipine bağlı olmakla birlikte eşik değerinin kullanımı, pratikte (-1) veya (+1) değerine sahip sabit bir girdinin ( $\theta$ ) ağırlığına sahip bir bağlantı ile toplayıcıya girdiği şeklinde ele alınmaktadır. Gelen sinyalin seviyesine göre her bir nöron açık veya kapalı duruma geçerek basit bir tetikleyici görev üstlenmektedir. Bu işlemler sırasında nöronlar giriş bilgilerini ağırlandırarak bunları toplar ve eşik, lineer ya da non-lineer bir fonksiyonda işleyerek çıktısını vermekte ve çıktıyı hücre bağlantısı olan diğer nöronlar giriş bilgileri olarak almaktadırlar (Fırat ve Güngör, 2004).

Yapay sinir hücrelerinin diğer isimleri ise düğüm (node), birim (unit) ya da işlemci eleman (processing unit)' dir. Katmanlar, nöronların aynı doğrultuda bir araya gelmesiyle oluşmaktadır. Bir yapay sinir ağında Girdi Katmanı, Ara/Gizli Katman ve Çıkış katmanı olarak 3 tür katman bulunmaktadır. Ağlar (Networks), katmanların belirli düzende dizilmesiyle oluşmaktadır. Katman sayısı, dizilişleri ve öğrenme algoritmalarına göre isimlendirilirler. 3 katmanlı bir ağ örneği Şekil 3.13'de gösterilmiştir (Bayır, 2006).



Şekil 3.13. 3 Katmanlı Yapay Sinir Ağı Örneği (Bayır, 2006)

Girdi ve çıktı katmanı tek katmandan oluşabilirken gizli katman sayısı birden fazla sayıda olabilmektedir (Bayır, 2006).

#### 4. KAYNAK ARAŞTIRMASI

Bu çalışma konusuyla ilgili literatürde bulunan çalışmalar aşağıda özetlenmiştir:

Bendix (2004) firmasının yayınladığı havalı fren kompresörleri için geliştirilmiş sorun giderme kılavuzunda, fren sistemine giriş ve hava doldurma sistemi problemlerini teşhis etmek için testler içeren sorun giderme belirtileri anlatılmıştır.

Yıldırım (2006) tez çalışmasında asenkron motordan alınan verilerle, sağlıklı motor ile kırık rotor çubuğu arızası olan motorun sınıflandırması destek vektör makineleri ile yapılmıştır. Toplam 300 veri kullanılmıştır. Lineer, RBF, Polinomial kernel kullanılarak, gerekli parametre ayarları yapılmıştır. Çalışmada bire-karşı-biri metodu kullanılmıştır. Kernel fonksiyonu olarak RBF kerneli seçilmiş, parametresi 5 olarak ayarlanırken C yaptırım parametresi 10.000 alınmıştır.

Knorr-Bremse (2007) firması yayınladığı ticari araç sistemleri servis haberleri dokümanında ağır vasıta hava kompresörlerinde yağ verme sorununun sebep ve sonuçları incelenmiştir.

Widodo ve Yang (2007) çalışmalarında makina durumu izleme ve teşhisinde destek vektör makinesi (SVM) kullanılarak literatür incelemesine dayanan bir anket sunulmaktadır. 1996'dan 2006'ya kadar olan makaleleri, SVM anahtar kelime dizininde SVM kullanarak makina durumu izleme ve makina arıza teşhisini araştırır. SVM, makina öğreniminde popülerlik kazandığından, makina durumu izleme ve teşhisinde SVM'yi uygulayan araştırmacılar nispeten nadirdir. 2006 yılına kadar, makina durumu izleme ve teşhisinde SVM' nin uzmanlık yönelimi ve problem odaklı alana doğru gelişme eğilimi gösterdiği sonucuna varılabilir.

Elhaj ve ark. (2008) çalışmalarında çift silindri endüstriyel kompresör üzerinde matlab ortamında beş farklı fiziksel işleminin (endüksiyon motoru hız - tork karakteristikleri, silindir basıncı değişimi, krank mili dönme hareketi, valfler boyunca akış karakteristikleri ve valf plakalarının titreşimi) matematiksel modelini geliştirmiş ve simülasyonunu oluşturmuşlardır. Valf plakalarındaki kaçaklar ve valf yayının bozulmasının modellenmiştir.

Almasi (2009) çalışmasında pistonlu kompresörlerin bileşen tasarımı ve üretimi, ticari noktalar, yardımcı ve aksesuarlar, performans ve güvenilirlik ile ilgili optimum konfigürasyonunu makalesinde ele almıştır.

Rittal servis (2010) internet sitesinde, kompresörlerde arıza bulma başlığı altında pistonlu kompresör arızaları ve sebeplerinden bahsedilmiştir.

Becerra ve ark. (2011) çalışmalarında otobüs klimalarında kullanılan dört silindirli bir pistonlu kompresör krankında meydana gelen erken arızaların analizine görsel inceleme, krank mili kimyasal analizi, sertlik ve sistemin modellenmesi ile başladılar. Kompresörde oluşan gaz kuvvetlerinin krank mili gerilmesi üzerindeki etkisini için çıkarımlarda bulundular.

Ahmed ve ark. (2012) çalışmalarında temeli titreşim sinyallerine dayanan PCA modeline dayalı yaklaşımla, endüstriyel alanda kullanılan pistonlu hava kompresörlerinde yaşanan arızaların nasıl tespit edildiğini incelediler.

Ünalın Kompresör (2012) internet sitesinde, endüstride kullanılan pistonlu kompresör arızaları ve sebeplerinden bahsedilmiştir.

Elmas (2012) tez çalışmasında destek vektör makineleri, çoklu regresyon ve yapay sinir ağları ile altın fiyatları gümüş, paladyum, platin, dow jones endeksi ve dolar fiyatları ile tahmin edilmiştir. Düzeltilmiş kolerasyon katsayısı, ortalama mutlak hata, hata kareleri ortalamasının karekökü, hata karelerinin ortalamasının yüzdesi ve ortalama mutlak yüzde hata gibi performans kriterleri kullanarak en iyi modeli belirlemeye çalışmıştır. Destek vektör makineleri ile yapılan tahminin yapay sinir ağları ve çoklu regresyona göre daha iyi sonuç verdiği deneyimine sahip olmuştur.

Nowaczyk ve ark. (2012) çalışmalarında, arıza tespiti ve tahmini bakım için kullanılacak araç sinyal verilerinin zaman serileri arasındaki ilginç ilişkileri keşfetmek için denetimsiz bir algoritma geliştirdikleri bir projeyi sunuyorlar. Bir arıza aşılama deneyi sırasında, bir Volvo kamyonundan toplanan veriler üzerinde denetimli öğrenmeyi kullanarak yaklaşımlarını sunuyorlar. Bu gerçek araçlardaki verileri analiz edebilecek ve anormallikleri otonom bir şekilde tespit edebilecek sisteme doğru bir adımdır. Denetlenen sınıflandırmanın keşfedilen ilişkilerin yararlılığını değerlendirmenin en iyi yolu olup olmadığı net değildir. Diğer olasılıkları, özellikle de erişebildikleri servis kayıtları veri tabanına bağlı olanları keşfetmeyi amaçlıyorlar.

Nowaczyk ve ark. (2013) kullanmış oldukları RPM algoritmaları ile ağır vasıta hava kompresörünün kestrimci bakımı için çalışmışlardır. Ana amaçları hava kompresörünün kalan faydalı ömrü üzerinde etkisi olan, ayırık olayları yakalamak ve gereksiz maliyetlerin önüne geçmektir.

Prytz ve ark. (2013) Volvo kamyonunda kayıtlı verileri kullanarak kompresör arızalarını tahmin etme konusundaki deneyimlerini açıkladılar. VOLVO veri toplama



işlemi için LVD isimli bir kayıtlı araç veri tabanı oluşturmuştur ve elde edilen veriler elektronik kontrol ünitelerinde saklanmaktadır ve tüm yerlerden gelen veriler bir merkezde toplanır. Veriler yetkili bir servise kablosuz olarak telematik bir ağ üzerinden gönderilir veya alınır. Verileri alırken sisteme düşen kamyonlardan 3 sınıfı baz aldılar; 1. kompresörü arıza vermemiş olanlar 2. kompresörü yeni arıza vermiş olanlar ve 3. olarak kompresör arızası verebilecek olanlar. Kompresör arızası olan 80 kamyon bunlara bağlı 10 LVD değeri seçtiler ve kompresörü arıza yapmamış 1440 kamyonu da sete eklediler. Bu çalışmanın en önemli sonucu olarak, Logged Vehicle Data (LVD) tabanlı veri madenciliğinin otomotiv endüstrisinde öngörücü bakım çözümü olarak kullanılmasının daha uygun bir yaklaşım olduğunu anlamak ve kestirimci bakımın mümkün olduğunu ve göreceli olarak düşük miktarda veri olmasına rağmen önemli maliyet tasarrufları ile sonuçlanabileceğini göstermeye çalıştılar.

AlThobiani ve ark. (2014) çalışmalarında endüstriyel kompresör valf arızalarının; titreşim, basınç ve akım sinyallerini kullanarak teşhisi için yaklaşım sunmuşlardır. Titreşimin kompresör çalışmasında hep etkili olduğu, oluşan gürültünün diğer verileri etkilediği için hataları tahmin etmede verimsizliğe yol açmaktadır. Titreşim sinyaline bağlı hata modellerini ortaya çıkarmak için Teager-Kaiser enerji yöntemini önermişlerdir. Kompresör valf arızalarını sınıflandırmak için derin sinir ağları (DBNs) mimari modeli uygulanmıştır. Çalışmalarında Bernoulli gizli birimleri ve Gauss görünür birimleri ile RBM' yi ele aldılar. Önerdikleri yaklaşımı, farklı valf koşullarına ait çift silindirli kompresörden elde edilen sinyallerle doğruladılar. DBN'nin arıza sınıflandırmasında üstünlüğünü doğrulamak için, performansını vektör makinası ve geri yayılım nöron ağları ile kıyaslayarak elde edilen önerilen yaklaşımın endüstriyel pistonlu kompresörlerin arıza teşhisinde güvenilebilir ve uygulanabilir olduğunu gösterdiler.

Prytz (2014) lisans tezinde, araç bakımını öngörmeye denetimli ve denetimsiz yöntemleri incelemektedir. Yöntemler veri yönlendirilir ve akışa alınmış, yerleşik veriler veya yerleşik veri tabanlarındaki geçmiş ve toparlanmış verilerden oluşan geniş miktarda veri kullanır. Yöntemler, araçların bir arka ofis sistemiyle iletişim kurmasını sağlayan telematik bir ağ geçidine dayanır. Veri toplamları, toplamalar ya da modeller, kablosuz olarak saptamalara ilişkin verileri analiz eden yerleşik bir sisteme gönderilir. Bunlar daha sonra tamir geçmişi ile ilişkilendirilir ve aynı saptamaları gösteren diğer araçlarda yaklaşan arızaları tahmin etmede tahmin etmek için kullanılacak bir bilgi tabanı oluşturulur. Tez ayrıca veri gösterimleri ve saptama tespiti yapmanın farklı

yollarını araştırıyor. Birincisi COSMO, şehir içi otobüs filosunda gösterilen denetimsiz ve kendi kendini organize eden bir yaklaşımdır. Otomatik olarak en ilginç dahili veri temsilleri ile ortaya çıkar ve sapan aracı izole etmek için fikir birliğine dayalı bir yaklaşım kullanır. Belirtilen ikinci yaklaşım, tamir geçmişinin kullanım istatistiklerini etiketlemek için kullanıldığı, daha önce toplanmış ve birleştirilmiş araç istatistiklerine dayanan görselleştirilmiş bir sınıflandırmadır. Bir sınıflandırıcı, belirli onarımlardan önce gelen kullanım verilerindeki kalıpları öğrenmek için eğitilir ve böylece araç bakımını tahmin etmek için kullanılabilir. Bu yöntem, araç hava kompresörünün arızalarında AB Volvo'nun araç kullanım istatistikleri veri tabanına dayanarak gösterilmiştir.

Fan ve ark. (2015) çalışmalarında şehir otobüslerinde hava kompresörü arızalarına odaklanmışlardır. Hava kompresörünün arızasının teşhisine ilişkin kullandıkları yaklaşım ise Fogelstrom'un ağır bir kamyondaki hava basıncı sistemiyle ilgili sorunları tespit etmek için bir hava tankından gelen basınç sinyalini izlediği yaklaşım olmuştur. Yöntem, tank içindeki hava basıncının dönüş noktasını belirlemeye dayanır. Bu belirleme bazı parametreleri gerektirir (örneğin; maksimum ve minimum basınçları /tahliye hızı /dolum süresi). Veri seti, üç yıl boyunca Haziran 2011'den Eylül 2014'e kadar İsveç'te faaliyet gösteren 19 Volvo otobüs filosundan toplanan verilere dayanmaktadır. Sadece mevcut sinyali izlemeye ve filodaki diğer araçlarla karşılaştırmaya dayanan genel denetimsiz bir sapma-saptama yönteminin (COSMO)'nun, kompresör arızalarını uzman bilgi odaklı bir yaklaşımla daha doğru tespit edebileceğini gösterdiler. COSMO yöntemi histogramları kullanır ve uzman yöntemi ortalamaları kullanmaktadır. Makalenin amacı COSMO yöntemlerinin farklı varyasyonları ile uzman bilgisine dayanan bir yaklaşım arasındaki karşılaştırmaktır. Nihai sonuç olarak, COSMO yönteminin klasik-geleneksel yöntemi geride bıraktığını gördüler.

Verma ve ark. (2015) çalışmasında, pistonlu hava kompresörleri için arıza teşhis modelleri geliştirmek için bir yaklaşım sunulmuştur. Bir arızasız çalışma, 7 arıza çeşidi için toplamda 8 durum için hava kompresöründe gerçek zamanlı arıza teşhis sistemi geliştirildi. Tüm deneysel prosedür ile birlikte veri toplama, hassas konum analizi, sinyal ön işleme, özellik çıkarma, özellik seçimi ve sınıflandırma tüm model geliştirme adımları sunulmuştur. Sunulan yaklaşım, hava kompresörü üzerinde başarıyla uygulanmış ve arızalar tespit edilebilmektedir. Arıza tanıma en hassas yere yerleştirilen sensörden gelen akustik sinyalleri analiz ederek yapıldı. Deney sırasında yapılan analiz,

önerilen modelin birkaç eğitim örneğiyle iyi bir performans gösterebileceğini göstermektedir.

Wang ve ark. (2015) çalışmalarında simüle edilmiş valf hareketlerine bağlı akustik emisyon sinyali kullanarak pistonlu kompresör valf arızalarının teşhisi için yöntem önermişlerdir. Bir valfin fiili çalışma koşulu, krank açısı ekseninde akustik emisyon sinyalinin analiz edilmesiyle elde edilebilir ve valf açılması, valf hareketini simüle ederek tahmin edilebilir. Simüle edilmiş valf hareketi ile sağlanan normal bir valfin tam olarak açılma ve kapanma yerleri, valf arızası teşhisi için referans olarak kullanılabilir. Deney sonuçları, bu yöntemin normal valfle, valf dalgalanmasını ve gecikmeli valf kapanma koşullarını kolayca ayırt edebileceğini gösterir. Emiş ve tahliye valflerinin açılıp kapanmasının karakteristik konumları, akustik emisyon sinyalinin dalga formunda ve simüle edilmiş valf hareketinde açıkça tanımlanabilir.

Farzaneh-Gord ve Khoshnazar (2016) çalışmalarında, pistonlu doğal gaz kompresörünün valf arızaları ile araştırılması için krank açısına dayanan sıfır boyutlu sayısal bir yöntem geliştirilmiştir. Bu model, piston ve valf dinamik ve kütle akış hızını vana ve orifis denklemleri üzerinden hesaba katmayı amaçlamaktadır. Bu amaçla, eşdeğer kütle ve enerji denklemleri ile kompresör silindir, emiş ve deşarj odaları dahil olmak üzere üç kontrol hacmi incelenmiştir. Valf plaka arızasını, plaka ve oturma yüzeyini aşınmasını ve yayların bozulmasını içeren valf arızaları, valf sızıntısına neden olur. Valf sızıntısı simülasyonu için, valf plakasında bir delik dikkate alınır. Simüle edilmiş sonuçlar, sağlıklı valflerle çalışan kompresör için önceki deney sonuçlarını doğrulamaktadır. Tahmin edilen sonuçlar, emme ve tahliye valfi arızalarının kompresör kütle akış hızını düşürdüğünü ve deşarj gazı sıcaklığını artırdığını göstermektedir. Ayrıca, emme valfi arızasının etkisi deşarj valfi arızasından daha ciddidir. Ek olarak, valf arızası emme ve boşaltma odalarının gaz sıcaklığının izlenmesi ile tespit edilebilir.

Pichler ve ark. (2016) çalışmalarında değişen yük altında çatlak ve kırık pistonlu kompresör valflerinin tahmin etmek için yeni bir yaklaşım sunmuşlardır. Ana fikir, titreşim ölçüm verilerinin zaman frekansı temsilinin, hata durumuna bağlı olarak tipik şekilleri göstermesidir. Sorun bu modelleri doğru şekilde tespit etmektir. Algılama görevi için, iki boyutlu oto kolerasyon yoluyla bir sapma yapılır. Otomatik korelasyon kalıpları vurgular ve gürültü etkilerini azaltır. Bu, uygun özellikleri tanımlamayı kolaylaştırır. Özellik tespitinden sonra, sınıflandırma işlemi lojistik regresyon ve destek vektör makinaları kullanılarak yapılır. Yöntemin performansı gerçek ölçüm verilerini analiz ederek doğrulanır. Sonuçlar, farklı kompresör yükleri için yanlış alarm oranlarını

çok düşük bir seviyede tutarken çok yüksek bir algılama doğruluğunu gösterecek ve böylece yükten-bağımsız bir yöntem elde edecektir.

Tuhovcak ve ark. (2016) çalışmalarında ısı transferinin, farklı kompresör ayarları ve sıvılar için çeşitli kolerasyonları karşılaştırarak kompresör verimliliği üzerindeki etkisini incelemiştir.

Loukopoulos ve ark. (2017) çalışmalarında bir endüstriyel kompresörden gelen valf arızası verileri kullanılarak çeşitli prognostik yöntemleri (çoklu doğrusal regresyon, polinom regresyonu, k-en yakın komşu regresyonu (KNNR)) karşılaştırıldı. Ayrıca, K-nn'e dayalı kalan faydalı ömür (RUL) tahmin süreci ile ilgili bir varyasyon, yukarıda belirtilen tüm algoritmaların çıktısını birleştiren bir topluluk yöntemi ile birlikte önerilmiştir. Sonuç olarak, anlık başarısızlık modu göz önüne alındığında kural nispeten kısa olsa bile, önerilen yöntemler kullanılarak iyi tahminlerin mümkün olduğu gösterilmiştir.

Zhao ve ark. (2017) çalışmalarında farklı çaplarda iki termokupul probu kompresörün çalışma odasına montajını yaparak, hava akışının kompresör silindiri içerisinde geçici sıcaklığını ölçmek için kullandılar. İki termokupul tarafından tespit edilen sıcaklıklar gerçek sıcaklıkların oluşturulmasında kullanıldı.

Kaya ve ark. (2018) çalışmalarında EEG (elektroensefalografi) verilerine en yakın komşu algoritmasını matlab programında uygulayarak algoritmanın performans sonucunu incelemiştir. Bu çalışma için temel bileşen analizinin (TBA) kullanıldığı ve kullanılmadığı durumlar için iki aşamalı değerlendirme yapılmıştır. Temel bileşen analizi önemli sayılabilecek özellikleri korurken, verilerin boyutunun azaltılmasını sağlamış bu bağlı olarak sınıflandırma yüzdesini artırmıştır.

Sztyber ve ark. (2018) çalışmalarında, endüstriyel döner kompresörlerin teşhisi amacıyla derin öğrenme tekniklerinin uygulanabilirliği üzerine yapılan çalışmaların sonuçlarını sunmaktadır. Sadece seçilen örnek arızalar, güç kaynağı voltajı ve dalgalanmasının düşmesi verileri kullanıldı. Çalışmanın ana kısmı, sınıflandırıcıların uygulanmasının bir tanımını ve gerçek ölçüm verileri üzerinde yapılan testlerinin sonuçlarını içerir. Deneyler sırasında kaydedilen veriler hem hatasız durumu hem de seçilen arızaları olan durumu temsil etti. Testleri, bir tensorflow kütüphanesinin kompresör teşhisine uygulanmasının haklı olabileceğini, ancak yaklaşımlarının standart derin öğrenme teknikleriyle sınırlı olamayacağını göstermektedirler.

Townsend ve Badar (2018) çalışmalarında pistonlu kompresörlerin çalışmasına ilişkin arıza verileri, sürekli basınç izleme sistemlerinin güvenilirliği, etkinliği ve

ekonomik analizini gerçekleştirmek için toplandı. Amaçları sürekli basınç izlemenin güvenilirliğini, verimliliğini ve mühendislik ekonomisini incelemektir. Sonuç olarak sürekli basınç izleme teknolojisinin kompresör filosunun verimliliği üzerinde güçlü bir etkiye sahip olduğunu gösterdiler.

Aydiner ve ark. (2019a) çalışmalarında ağır vasıta hava kompresörünün termodinamik davranışı deneysel olarak incelenmiştir. Soğutma suyu parametresinin kompresör güç ve debi değerleri üzerindeki etkisi olduğunu yapılan deney sonucunda gösterdiler. Soğutma suyu sıcaklığının artmasının debi ve güç değerlerinde azalmaya yol açtığını gözlemlediler.

Aydiner ve ark. (2019b) çalışmalarında test sisteminin güvenilirliği ve doğruluğunu belirlemek için seçilen bir OEM hava kompresörünü test ederek, elde edilen test grafiklerini, OEM üreticilerinin paylaştıkları test grafikleri ile kıyaslamışlardır. Sonuçları incelediklerinde çevresel faktörlere bağlı olarak %2 seviyelerinde sapmanın olduğunu gözlemlediler.

Cabrera ve arkadaşları (2019) çalışmalarında, pistonlu kompresör arıza teşhisini ele aldılar. Yüksek dengesiz verilerle pistonlu makinelerin arıza teşhisi için Gan modellerini seçmenin yeni bir yöntemi önerilmiştir. Yaklaşımlarında titreşim sinyallerini dalgacık paket dönüşüm tabanlı özellik çıkarma aşamasını kullanacak işler. Daha sonra, veri kümesini yapay olarak dengelemek için farklı bir model seçimi ile geliştirilmiş üretken modeller elde edilir. Son olarak, rastgele orman sınıflandırıcısı tanıma görevi için oluşturulur. Bu yaklaşım literatürde bildirilen diğer yaklaşımlara göre veri dengesizliğinin %99'u ile önemli bir iyileşme sağlayacağı ve dengeli bir veri kümesi ile elde edilene benzer performans gösterir.

Loukopoulos ve ark. (2019) çalışmalarında endüstriyel bir kompresör üzerinden sadece anlık bir arıza modu olan gerçek sıcaklıkta valf arıza verilerini kullanarak çeşitli tahmin yöntemlerinin (çoklu doğrusal regresyon, polinom regresyon, k-en yakın komşu) doğruluk ve değişkenlik ile ilgili olarak tahmin performansını incelemişlerdir. Ayrıca k-en yakın komşu regresyonuna dayanan kalan faydalı ömür (RUL) tahmini için bir varyasyon önerilmiştir.

Ünüvar ve ark. (2019) çalışmalarında ağır vasıta hava kompresöründe farklı valf açıklıklarının kompresör ölü hacmine etkisini debi ve güç grafikleri kıyaslanarak incelemişlerdir. Farklı denemeler sonucunda kompresör için valf seçimi yapılmıştır.

Gül ve Kalyoncu (2020) çalışmalarında ağır vasıta hava kompresörü yağ verme arızasına ait verilerle K-en yakın komşu algoritması modelini oluşturmuş, farklı uzaklık

ölçütlerine göre algoritma modelinin test verilerindeki sınıflandırma tahminine yönelik performansını incelemişlerdir. Komşu sayısının azalması, tüm uzaklık ölçütlerinde model performansını artırmıştır.

Gül, Kalyoncu ve Kula (2020) çalışmalarında ağır vasıta hava kompresörü yağ verme arızasına ait veriler rastgele orman algoritması modelinin oluşturulmasında kullanılmış, oluşturulan modelin test verilerindeki tahmin başarısı karmaşıklık matrisi ile verilmiştir. Modelin hiç tanımadığı veriler ile model test edilerek bilinmeyen verinin hangi sınıfa yüzde kaç oranla dahil edilebileceği sonucu ortaya çıkarılmıştır.

Kula ve Ciniviz (2020) yaptıkları deneysel çalışmada geliştirmiş oldukları ara bağlantı ile turbolandırılmış hava ile çift silindirli bir pistonlu kompresörü beslemişlerdir. CAN modülünden aldıkları veriler ile sensörler vasıtasıyla alınan verileri her iki durum için karşılaştırmışlardır. Kompresör performans kriterleri olarak hava tankları dolma süresi, giriş hava basıncı, hacimsel verim; motor tarafında ise anlık yakıt tüketimi, indike tork değerlerinin yanı sıra opasimetre ile emisyon ölçümü gerçekleştirmişlerdir. Bu çalışma turbolandırılmış hava ile besleme durumunda kompresör hava tankları dolma sürelerinde önemli derecede azalma ve hacimsel verimde artış gerçekleştiğini göstermiştir.

## 5. MATERYAL VE YÖNTEM

Bu bölümde oluşturulan test düzeneği, verilerin etiketlenmesi, etiketli verilerin performans grafikleri ve bu verilerle oluşturulan makine öğrenmesi algoritmalarının sınıflandırma başarıları anlatılacaktır.

### 5.1. Test Sisteminin Oluşturulması


Test verileri, Yıldız Pul Otomotiv Motor Parçaları Sanayi A.Ş. mekanik test merkezinde oluşturulan hava kompresörü uzun ömür test düzeneği (Şekil 5.2) ile elde edilmiştir. Geliştirilen test düzeneği sayesinde ağır vasıta araçlar için hava kompresörünün tam otomatik testlerinin yapılması mümkün olmaktadır.

Test için 636 cc hacme sahip, çift silindirli ve su soğutmalı hava kompresörü seçilmiştir. Kompresör dişli tahrikli olmakla birlikte motor yağı ile yağlanmakta, radyatörden gelen soğutma suyunun kompresör silindir kapağında dolaşımı ile soğutma işlemi yapılmaktadır. Şekil 5.1’ de örnek kompresörün görüntüsü verilmiştir.



Şekil 5.1. Örnek Hava Kompresörü (Wabco, 2020)


Yapılan bir çalışmada OEM hava kompresörü, Yıldız Pul Otomotiv Motor Parçaları Sanayi A.Ş. test cihazında test edilerek, sonuçları OEM üreticilerinin yayınladıkları kompresör debi miktarı - güç tüketimi grafikleri ile kıyaslanması yapılmış ve test sistemi doğrulanmıştır (Aydiner ve ark., 2019b).



**Şekil 5.2.** Hava Kompresörü Uzun Ömür Test Düzenegi  
(Yıldız Pul Otomotiv Motor Parçaları Sanayi A.Ş.)

Hava kompresörü test düzeninde sistemsel olarak yaklaşık 40 kanaldan aynı anda senkron bir şekilde veri alınması mümkün olabilmektedir. Şekil 5.3’de kompresör sensör bağlantı konumları ve Çizelge 5.1’de ise konumlara göre kullanılan sensörler ve birimleri verilmiştir.



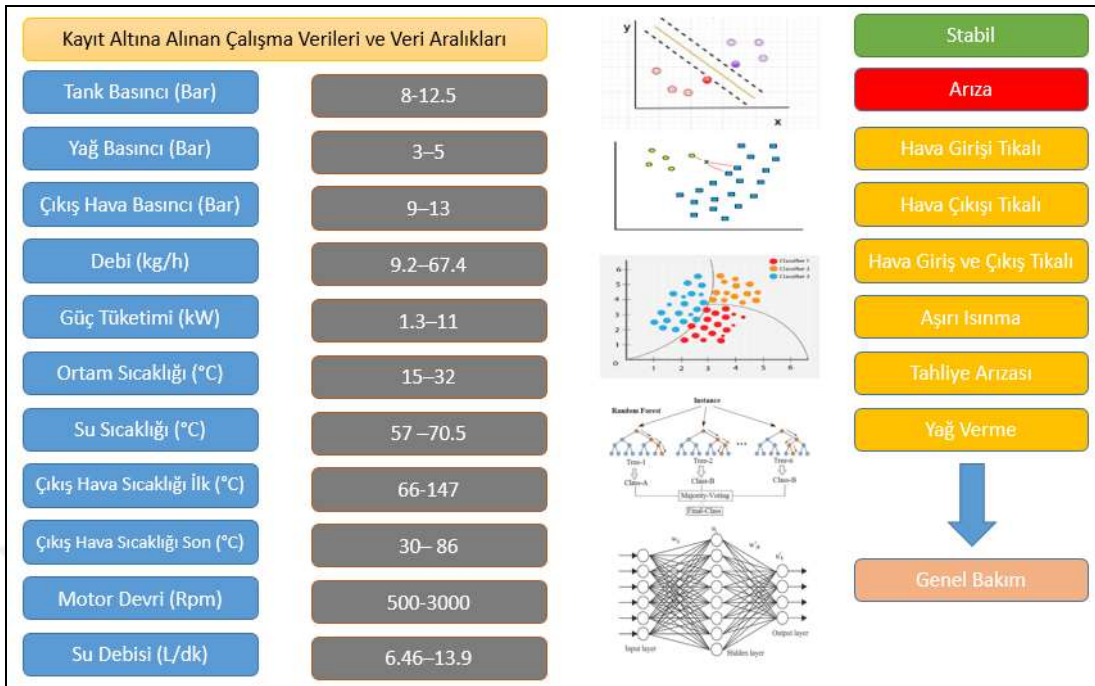


Şekil 5.3. Kompresör Sensör Bağlantı Konumları

Çizelge 5.1. Bağlantı Konumlarına Göre Kullanılan Sensörler

No	Ölçüm Tipi	Ölçüm Metodu	Birimi
1	Tank Basıncı	Basınç Sensörü	bar
2	Yağ Basıncı	Basınç Sensörü	bar
3	Çıkış Hava Basıncı	Basınç Sensörü	bar
4	Hava Debisi	Debimetre	Kg/h
5	Güç Tüketimi	Motor Sürücüsü	kW
6	Ortam Sıcaklığı	Sıcaklık Sensörü	°C
7	Giriş Su Sıcaklığı	Sıcaklık Sensörü	°C
8	Çıkış Hava Sıcaklığı (İlk)	Sıcaklık Sensörü	°C
9	Çıkış Hava Sıcaklığı (Son)	Sıcaklık Sensörü	°C
10	Motor Devri	Motor Sürücüsü	rpm
11	Giriş Su Debisi	Debimetre	l/d

Yapılacak deneylerde belirlenen kompresör çalışma durumları için değişken giriş ve bu girişlere bağlı çıkışların ölçümlerinin yapılması sonrası bir deney sonuç havuzu oluşturulmuştur. Çıkış değerleri olarak normal koşullarda gerçekleştirilen testlerde hava kompresörlerinde en önemli iki parametre olan debi miktarı ve güç tüketimi verileri alınmaktadır ancak testlerde arıza durumları incelendiği için çalışma durum numaraları çıktı olarak etiketlenmiştir. Şekil 5.4'de tahmini bakım alt yapısı ve okunan sensör değer aralıkları gösterilmiştir.



Şekil 5.4. Oluşturulan Tahmini Bakım Alt Yapısı

Giriş verilerine karşın, çıkış verisi olarak kompresör çalışma durumları etiketlenmiştir. 18 farklı durumun her biri için, Şekil 5.4'de gösterilen 11 farklı sensörden veriler kompresör çalışma anında kayıt altına alınmıştır. Tank basıncının 8 bar' dan 12.5 bar seviyelerine gelene kadar saniyede 2 veri kayıt altına alınmış ve toplamda 23.987 veri algoritmaların eğitimi ve test edilmesi için kullanılmıştır.

Çizelge 5.2'de normal çalışma ve arızalı çalışma durumlarının etiketlendiği değerler gösterilmiştir.

Çizelge 5.2. Arıza Durumlarına Bağlı Etiketli Verilerin Gösterimi

Giriş Parametrelerine Etiketlenmiş Çıkış Parametreleri	
Normal Koşullarda Çalışma Durumu	0
Hava Girişinin Tıkalı Olması Durumu	1: 2: 3: 4
Hava Çıkışının Tıkalı Olması Durumu	5: 6: 7
Hava Girişi ve Çıkışının Tıkalı Olması Durumu	8: 9: 10: 11
Aşırı Isı Durumu	12: 13: 14
Tahliye Arızası Durumu (%40 Sürekli Yükte Çalışma)	15
Yağ Verme (Taşınım) Durumu	16: 17: 18

Test cihazına bağlantısı yapılan sensörler yardımı ile elde edilen veriler, veri toplama sistemi (Data Acquisition System) DEWESOFT firmasına ait yazılım ve donanımlar ile anlık alınarak kayıt edilmiştir. Testlerde kullanılacak sensörler yüksek hız ve hassasiyete sahiptir. Burada önemli olan nokta sadece yüksek hızda okuma özelliğine sahip olması değil, yüksek doğruluk ve tekrarlılığına sahip olmasıdır.

Kompresör çalışma anında veriler video kayıta alınmaktadır. Kompresörün çalışması durdurulduktan sonra video kayıtlı veriler DEWESOFT yazılımından Excel uzantılı olarak export edilmiştir. Excel ortamında kayıtlı verilerin arıza durumlarına ilişkin 0-18 arasında belirlenen etiket değerleri (Çizelge 5.2., 5.3., 5.4., 5.5.) de belirlendiği gibi etiketlenmiştir.

Excel’ de çalışma durumlarına göre etiketleme işlemi tamamlandıktan sonra veri dosyası .csv formatında farklı kaydedilerek PYTHON programında okunabilecek biçime dönüştürülmüştür. Etiketli verilerin %80’ i rastgele veri dağılımı yapılarak makina öğrenmesi algoritmalarının eğitimi için kullanılacak, kalan %20’ lik veri ise eğitilen algoritmaların test edilmesi için kullanılarak algoritma başarı oranlarının belirlenmesinde önemli rol alacaklardır.

Yapılan testlerde önemli olan parametrelerin varlığıdır. Hava kompresörlerinde giriş parametrelerine karşın 2 çıkış parametresi (Debi miktarı-Güç tüketimi) vardır. OEM üreticileri tarafından paylaştıkları teknik resimlerde kompresörlerinin çalışma performansını gösterebilmek için debi miktarı-güç tüketimi grafiklerini, her çalışma hızına (600–3000 d/d) göre test ederek kullanıcılarına sunmaktadır. Arıza durumlarında giriş ve çıkış parametrelerinde küçükte olsa bir değişim söz konusu olacaktır. Bu değişimler sensörler vasıtasıyla ölçülerek sayısal büyüklüklere dönüştürülür.

Bir çalışmada hava kompresörlerinde görülen bazı arıza durumları deneysel olarak incelenmiş ve debi miktarı-güç tüketimi grafiklerinde değişim olduğu gözlemlenmiştir (Gül ve ark., 2019). Veri değişimlerine bağlı olası arıza durumları makine öğrenmesi yöntemleri ile incelenebilmektedir.

## 5.2. Arıza Durumlarının Etiketlenmesi

Çizelge 5.3’de kompresör silindir kapağı rakor çaplarında  $\pi.r^2$  ile alan hesaplaması yapılmış ve havanın geçeceği rakor kesit alanları ( $\text{mm}^2$ ) hesaplanmıştır.

**Çizelge 5.3.** Kompresör Çalışma Durumlarının Rakor Çaplarına Bağlı Olarak Düzenlenmesi

Çalışma Durumu	Durum Numarası	Hava Giriş Rakoru Kesit Alanı	Hava Çıkış Rakoru Kesit Alanı
Normal Koşullarda Çalışma	0	415.48	153.94
Hava Girişinin Tıkalı Olması Durumu	1	314.16	153.94
	2	203.58	153.94
	3	113.1	153.94
	4	78.54	153.94
Hava Çıkışının Tıkalı Olması Durumu	5	415.48	113.1
	6	415.48	95.03
	7	415.48	63.62
Hava Giriş ve Çıkışının Tıkalı Olması Durumu	8	314.16	113.1
	9	113.1	113.1
	10	314.16	63.62
	11	113.1	63.62

Çizelge 5.4'de soğutma suyu debisine bağlı çalışma durumlarının belirlenmesinde su pompasının motor devri DEWESOFT yazılımı ile kontrol edilerek çizelgedeki değerlerde çalışması sağlanmıştır.

**Çizelge 5.4.** Soğutma Suyu Debisine Bağlı Çalışma Durumunun Düzenlenmesi

Aşırı Isı Durumu						
Kompresör Devri Normal (d/d)	500	1000	1500	2000	2500	3000
Soğutma Suyu Debisi Normal (l/d)	6.46	8.32	10.2	12.04	13.9	13.9
12. Durum (l/d)	4.6	6.46	8.32	10.18	12.04	12.04
13. Durum (l/d)	4.6	5.53	6.46	8.32	10.18	10.18
14. Durum (l/d)	4.6	4.97	6.08	7.39	8.32	8.32

Tahliye arızası durumu; hava kompresörünün normal koşullarda çalışma testleri yapılırken tank dolum süreleri ölçülerek, kompresörün %25 yükte çalışacağı şekilde DEWESOFT yazılımında algoritmalar oluşturulmuş ve bu döngüde çalışması sağlanmıştır. Tahliye arızası durumu için kompresörün yükte çalışacağı süre toplam sürenin %40 ile %50 arasında olacak şekilde, DEWESOFT yazılımında oluşturulan algoritmalarla düzenlemeler yapılarak bu döngüde çalıştırılması sağlanmıştır. 15. Durum = Tahliye arızası (%40 yükte çalışma) olarak etiketlenmiştir. Çizelge 5.5'de silindir gömleği ile segmanlar arasındaki boşluğa bağlı çalışma durumlarından bahsedilmiştir.

**Çizelge 5.5.** Silindir Gömleği ile Segmanlar Arasındaki Boşluğa Dayalı Çalışma Durumunun Düzenlenmesi

Çalışma Durumu	Durum Numarası	Silindir Gömleği Çapı	Piston Çapı	Piston Segmanı Çapı
Yağ Verme (Taşınımı) Arıza Durumu	16. Durum	Ø85.05 mm	Ø 85 mm	Ø 85 mm
	17. Durum	Ø85.25 mm	Ø85.25 mm	Ø 85 mm
	18. Durum	Ø85.50 mm	Ø85.50 mm	Ø 85 mm

Yağ vermenin önde gelen sebebi hava giriş hattında oluşan yırtık, çatlak vb. durumlardan dolayı hava giriş portundan içeriye toz partiküllerinin gelmesidir. Toz partikülleri zımpara görevi görerek silindir gömleği ile piston segmanlarının aşınmasına sebep olarak segman ağızlarının açılmasına ve arada boşluk oluşumuna sebep olmaktadır. Oluşan boşluk yağ vermenin gerçekleşmesine sebep olmaktadır. 16, 17 ve 18 numaralı çalışma durumlarında silindir gömleği çapı 0.5 – 0.25 – 0.50 mm genişletilerek honlama işlemi yapılmıştır. Piston çapları da aynı oranda olacak şekilde bir büyük piston kullanılmıştır. Segmanlar Ø 85 mm kullanılarak segman aralarının açık kalması ve buna bağlı boşluk oluşturulması amaçlanmıştır.

### 5.3. Test Düzeneginde Kullanılan Sensörler ve Üniteler

#### 5.3.1. Basınç sensörleri

Basınç sensörlerini basitçe tanımlamak gerekirse uygulanan fiziksel şiddeti algılayarak analog sinyale dönüştüren algılayıcılardır. Basınç sensörleri hayatımızda elektronik cihazlarda, otomasyon sistemlerinde ve üretim sektöründe birçok noktada kullanılmaktadır. Bu tez çalışmasında kompresör test sistemi üzerinde çıkış hava basıncını, yağ basıncı ve tank basıncı kontrol ölçebilmek için farklı özellik ve markalarda basınç sensörleri kullanılmıştır. Kullanılan basınç sensörlerine yönelik gerçekleştirilen araştırmalar aşağıda sunulmaktadır.

Kullanılan basınç sensörlerinden biri olan Trafag marka sensör Şekil 5.5'de görülmektedir. -25°C ila 125°C arasında basınç ölçümü gerçekleştirebilmektedir. Sensörün 0-400 bar ölçüm aralığında farklı türleri bulunmaktadır. Test çalışmamızda kullandığımız sensör 0-16 ölçüm aralığına sahip 0-10V analog çıkış verebilen bir çeşittir (Kula, 2020). Bu sensör test sisteminde yağ basıncını ölçmek için kullanılmıştır.



Şekil 5.5. Yağ Basıncını Ölçmek İçin Kullanılan Basınç Sensörü (Kula, 2020)

Test sistemi üzerinde kullanılan sensörlerden biri de çıkış hattını ve tank basıncını ölçen Keller markalı basınç sensörleridir. Bu sensörler piezorezistif ölçüm yeteneğine sahiptir. 0-16 bar ölçüm aralığında 0-10V analog sinyal verebilmektedirler. 40°C - 100°C aralığında basınç ölçümü gerçekleştirebilirler.  $\pm 1$  %FS ölçüm hataları bulunmaktadır (Druck, 2019). Şekil 5.6'da hava çıkış hattı ile tank basıncının ölçülmesinde kullanılan basınç sensörü gösterilmiştir.



Şekil 5.6. Hava Çıkış Hattı ile Tank Basıncının Ölçülmesinde Kullanılan Basınç Sensörü (Druck, 2019)


### 5.3.2. Sıcaklık sensörleri

Test sistemi üzerinde kompresör kapak sıcaklığı ve su tankının sıcaklığı sürekli ölçülmektedir. Özellikle tank su sıcaklığının aşırı yükseldiği durumlarda fan devreye girmektedir. Bu sayede test sisteminin optimum koşullarda çalışması sağlanmaktadır. Fakat bazı durumlarda fanın devreye girmediği arızanın simüle edilebileceği test koşulları da oluşturulabilmektedir.

“Termokupl iki farklı alaşımın ucunun kaynaklanması ile oluşturan basit bir sıcaklık ölçü elemanıdır. Kaynak noktası sıcak nokta, diğer açık iki uç soğuk nokta (veya referans noktası) olarak anılır. Termokupl olayı sıcak nokta ile soğuk nokta arasındaki sıcaklık farkından doğar. Bu sıcaklık farkına orantılı, soğuk nokta uçlarında mV mertebesinde gerilim üretilir. Termokuplun sıcak noktası ve soğuk noktası arasındaki sıcaklık dağılımı nasıl olursa olsun üretilen gerilim, sıcak ile soğuk nokta arasındaki sıcaklık farkına orantılıdır” (Elimko, 2019).

Test sisteminde K tipi termokupllar kullanılmıştır. “K tipi termokupllar Nikel (-) ve Nikelkrom (+) bacadan oluşan bu termokupl oksitleyici ortamlarda tercih edilir. 1300°C’ye kadar mV değeri üretmesine rağmen yaygın olarak 1200°C’ye kadar kullanılır” (Elimko, 2019).

Şekil 5.7’de bir termokupl, tüm parçaları ile bir set halinde verilmiştir.



Şekil 5.7. Komple Termokupl Seti (Elimko, 2019)

### 5.3.3. Debimetreler

Test sistemimizde hava debisini ölçebilmek için ABB markalı 70 kg/h ölçüm aralığına sahip debimetre kullanılmıştır. Şekil 5.8’de sistemde kullanılan debimetrenin görüntüsü verilmiştir.



Şekil 5.8. Debimetre

### 5.3.4. Oda sıcaklık sensörü

Test merkezindeki ortamın bağıl sıcaklık ve nemi sürekli olarak SIEMENS QFA3160D oda sensörü ile ölçülmüştür. Oda sensörü sıcaklık ve nem bilgilerini 0-10V analog çıkış sinyali olarak vermektedir. Analog giriş kanalı yardımıyla okunan sıcaklık ve nem bilgileri kullanıcı ara yüzüne aktarılarak kontrol altında tutulmuştur. Şekil 5.9’da oda sıcaklık sensörü görüntüsü verilmiştir.



a)

b)

Şekil 5.9. Oda Sıcaklık Sensörü a) Nem Ölçerken Görünüm b) Sıcaklık Ölçerken Görünüm



Sensör, kapasitansı ortam havasının bağıl neminin bir fonksiyonu olarak değişen kapasitif algılama elemanı yoluyla sırasıyla odadaki veya dış havadaki bağıl nemi alır. Elektronik devre, sensörün sinyalini % 0-100 bağıl neme karşılık gelen sürekli bir DC 0-10 V sinyaline dönüştürür. Sensör, odadaki veya dış havadaki sıcaklığı, elektriksel direnci sıcaklığın bir fonksiyonu olarak değişen algılama elemanı yoluyla alır. Bu varyasyon, sensörün tipine bağlı olarak aktif bir DC 0-10V çıkış sinyaline dönüştürülür. Çıkış sinyali 0-50 °C,  $\pm 35$  °C veya 40 - 70 °C arasında seçilebilir bir sıcaklık aralığına karşılık gelir (Anonymous, 2016).

### 5.3.5. Yağlama Ünitesi

Yağlama ünitesi; 1 adet 0.25 kW yağ motoru, yağ tankı, manometre, rezistans, hidrolik hortum, soğutma fanı, seviye şalteri ve pnömatik bağlantı elemanlarından oluşmaktadır. Yağlama ünitesi üzerindeki motor sabit hızda kullanılmaktadır. İstenilen yağ basıncı, basınç regülatörü ile ayarlanabilmektedir. Genel olarak testlerde normal kompresör çalışma durumunda yağ basıncı 4-5 bar seviyelerindedir.

Test sisteminin çalışması normal şartlar altında yağ basıncıyla yazılımsal olarak kontrol altındadır. Yağ sisteminde herhangi bir arıza olduğunda (basınç düşerse) veya yağ seviyesi çok azalır (seviye şalteri aktif), kompresör test motoru başta olmak üzere bütün sistemin çalışması DEWESOFT yazılımı üzerinden durdurulabilmektedir. Şekil 5.10' da yağlama ünitesi gösterilmiştir.



Şekil 5.10. Yağlama Ünitesi

Kompresör arıza durumlarının ve ekstrem durumların test edildiği bu çalışmada çoğu testlerde bu yazılımsal güvenlik kontrolü kasıtlı olarak devre dışı bırakılmıştır.


### 5.3.6. Soğutma Suyu Ünitesi

Test sisteminin soğutma suyu besleme ünitesi (Şekil 5.11) 50 litre su tankı, rezistans, termostat ve su pompasından oluşmaktadır.



Şekil 5.11. Soğutma Suyu Besleme Ünitesi

Şekil 5.12’de verilen su tankı rezistans ile ısıtılmaktadır. Rezistansın kontrolü yazılım üzerinden gerçekleştirilebilmektedir. Ayrıca sistemde ki su sıcaklığı set edebilmek için termostat kullanılmaktadır.



Şekil 5.12. Soğutma Suyu Tankı

Test sistemimizde kullanılan Grundfos marka su pompası Şekil 5.13’de verilmektedir. MAGNA3 modeli sirkülasyon pompası analog kontrol (0-10 Volt) ile istenen debide su akışını sağlayabilmektedir.



Şekil 5.13. Su Pompası Görseli

Kullanılan su pompasının özellikleri Çizelge 5.6’da verilmiştir.

Çizelge 5.6. Su Pompası Özellikleri (Anonymous, 2020b)

Volt analog kontrol	0-10 Volt
Anma gerilimi	1 x 230 V
Nominal akış	5,43 m <sup>3</sup> /s
Pompalanan sıvı	Su
Sıvı sıcaklık aralığı	-10 .. 110 °C
Ortam sıcaklığı aralığı	0 .. 40 °C
Maksimum çalışma basıncı	10 bar
Boru bağlantısı	G 1 1/2 "
Basınç derecesi	PN10

#### 5.4. Veri Toplama Sistemi

Veri toplama sistemi olarak DEWESOFT firmasına ait kontrolcü ve x2 yazılımı kullanılmıştır. Dijital (motor, tahliye start/stop gibi) ve analog (motor hızı gibi) kontrollerin yanı sıra analog ölçümler için Sirius modülü kullanılmaktadır. Sıcaklık ölçümlerinin gerçekleştirilmesi için ise 8 kanallı K tipi termokupl ölçüm yeteneğine sahip Krypton modülü kullanılmaktadır.

#### 5.4.1. DEWESOFT ve DEWESOFT x2 yazılımı

Kullanılan Sirius ve Krypton modülleri birbirleriyle senkron çalışabilmektedir. Bu modüllerin yazılımsal kullanımları için DEWESOFT X2 ve X3 yazılımı kullanılabilir. Şekil 5.14’de DEWESOFT yazılım ekranı gösterilmiştir.



Şekil 5.14. DEWESOFT Yazılım Ekranı

#### 5.4.2. Sirius


Test sisteminde analog sensör ölçümlerinin (basınç değerleri, güç değeri, debi değeri gibi) gerçekleştirilmesi amacıyla kullanılmıştır. Evrensel analog amplifikatörler, DSI adaptörleri kullanılarak voltaj ve tam / yarım / çeyrek köprü sinyallerinin yanı sıra IEPE, şarj, termokupllar, RTD, akım, direnç ve LVDT sinyallerini kabul edebilir (Dewesoft, 2019). Şekil 5.15’de sirius görüntüsü verilmiştir.



Şekil 5.15. Sirius Görüntüsü (Dewesoft, 2019)

### 5.4.3. Krypton

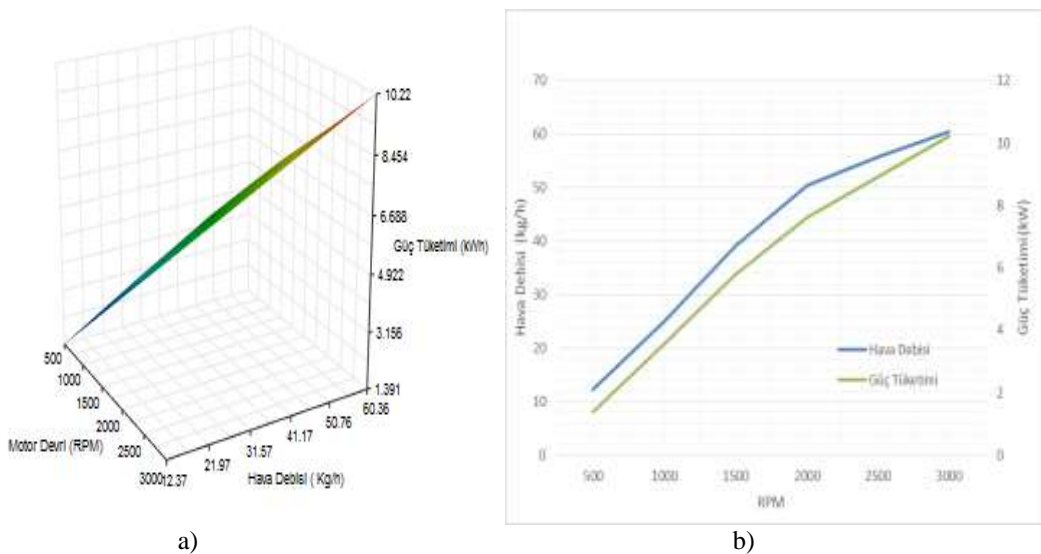
Test sisteminde 8 kanallı sıcaklık ölçüm modeli kullanılmaktadır. Krypton modülü, yüksek ve düşük sıcaklıkta, tozlu, çamurlu karlı ortamlar gibi zorlu koşullar altında kusursuz bir şekilde çalışması için tasarlanmıştır. Krypton modülleri IP67 standardına sahiptir ve  $-40^{\circ}\text{C} \dots 85^{\circ}\text{C}$  ortam sıcaklıklarında çalışabilir. Alüminyum boşaltma kasaya sahip Krypton modülleri titreşim ve şoka karşı dayanıklıdır. Sirius modülü  $\pm 10\text{V}$  çıkış voltajı sinyali ile kontrol cihazı olarak da işlev görebilen 8 analog çıkışla yapılandırılabilir (Mühendislik, 2019). Şekil 5.16'da krypton görüntüsü verilmiştir.



Şekil 5.16. Krypton Görüntüsü (Mühendislik, 2019)


### 5.5. Test Grafikleri

Normal çalışma durumunda (0) motor devrine bağlı hava debisi – güç tüketimi grafiği Şekil 5.17'de verilmiştir.




Şekil 5.17. Normal Çalışma Durumunda Motor Devrine Bağlı  
a) Hava Debisi – Güç Tüketimi Alan Grafiği b) Hava Debisi – Güç Tüketimi Çizgi Grafiği

Tüm çalışma durumlarını kapsayan motor devrine bağlı ortam sıcaklığı - soğutma suyu sıcaklığı alan grafiği Şekil 5.18’de gösterilmiştir.




**Şekil 5.18.** Tüm Çalışma Durumlarını Kapsayan Motor Devrine Bağlı Ortam Sıcaklığı – Soğutma Suyu Sıcaklığı Alan Grafiği

Tüm çalışma durumlarını kapsayan motor devrine bağlı ortam sıcaklığı – çıkış hava sıcaklığı (ilk) alan grafiği Şekil 5.19’da gösterilmiştir.




**Şekil 5.19.** Tüm Çalışma Durumlarını Kapsayan Motor Devrine Bağlı Ortam Sıcaklığı – Çıkış Hava Sıcaklığı (İlk) Alan Grafiği

Tüm çalışma durumlarını kapsayan motor devrine bağlı çıkış hava sıcaklığı (ilk)- çıkış hava sıcaklığı (son) alan grafiği Şekil 5.20’de gösterilmiştir.




Şekil 5.20. Tüm Çalışma Durumlarını Kapsayan Motor Devrine Bağlı Çıkış Hava Sıcaklığı İlk – Çıkış Hava Sıcaklığı (Son) Alan Grafiği

Tüm çalışma durumlarını kapsayan motor devrine bağlı soğutma suyu debisi – soğutma suyu sıcaklığı alan grafiği Şekil 5.21’de gösterilmiştir.




Şekil 5.21. Tüm Çalışma Durumlarını Kapsayan Motor Devrine Bağlı Soğutma Suyu Debisi – Soğutma Suyu Sıcaklığı Alan Grafiği


Tüm çalışma durumlarını kapsayan motor devrine bağlı hava debisi – güç tüketimi alan grafiği Şekil 5.22’de gösterilmiştir.




Şekil 5.22. Tüm Çalışma Durumlarını Kapsayan Motor Devrine Bağlı Hava Debisi – Güç Tüketimi Alan Grafiği









Şekil 5.23. Kompresör Çalışma Durumlarına Göre Kıyaslamalı Grafiklerin Görünümü

Şekil 5.23’de 19 farklı çalışma durumuna ait farklı parametrelerle kıyaslamalı grafikler oluşturulmuştur. Grafikler incelendiğinde verilerin kompresör çalışma durumlarına göre değişim gösterdiği görülmektedir. Bu durum algoritma sınıflandırma başarı oranını olumlu yönde etkileyecektir.

## 5.6. Verilere Uygulanacak İşlemler ve Modelin Değerlendirme Yöntemleri

19 farklı çalışma durumu için toplamda 23.987 adet veri kayıt altına alınmış, veriler %80 eğitim ve %20 test verisi olarak rastgele biçimde iki gruba ayrılmıştır. Tüm algoritmalarda 10 kat çapraz doğrulama işlemi uygulanarak modellerin başarı oranlarının artırılması hedeflenmiştir.

### 5.6.1. K katlı çapraz doğrulama

Modelin değerlendirilme aşamasında başarısı öngörülen algoritmanın kendi içinde genelleşip genelleşmeyeceğine dair değerlendirme yapmak gerekmektedir. Bu değerlendirme işlemi bu çalışmada k-kat çapraz doğrulamadır. Eğitim verilerinin rastgele olarak k eşit parçaya ayrılması sağlanır. k parçadan her defasında bir tanesi test için ayrılarak diğer (k-1) parçalar modelin eğitilmesinde kullanılır. Sistemin genel başarısı veya hatası elde edilen sonuçların ortalaması alınarak bulunmaktadır (Şanlıtürk, 2018). Bu çalışmada k çapraz doğrulama değeri 10 alınmıştır.

### 5.6.2. Performans ve Sınıflandırma metrikleri

Sınıflandırma problemine yönelik model oluşturulduğunda ya da geçmişte oluşturulan modeller kullanıldığında, modelin başarısı, gerçekleştirilen tüm doğru tahminlerin sayısı gibi düşünülebilir. Ancak bu bilgi sınıflandırma doğruluğunu göstermektedir. Bir modelin doğruluğu kararını vermek için sadece sınıflandırma doğruluğu genellikle yeterli olmamaktadır (Şahin, 2018).

Karmaşıklık matrisi (Confusion matrix): Sınıflandırıcıya ait tahmin sonuçlarını sunmanın yolu bir karmaşıklık matrisi kullanmaktır. Gerçek değerleri bilinen bir dizi test verisi ile sınıflandırma modelinin performansını tanımlamak için sıklıkla karmaşıklık matrisi tablosu kullanılmaktadır (Şahin, 2018). Çizelge 5.7’de karmaşıklık matrisi gösterilmiştir.

Çizelge 5.7. Karmaşıklık Matrisi

		Tahmin Edilen Sınıfı	
		+	-
Gerçek Sınıf	+	DP Doğru Pozitif	YN Yanlış Negatif
	-	YP Yanlış Pozitif	DN Doğru Negatif

- Doğru Pozitif (DP): Doğru tahmin edilen pozitif değerleri içerir. Bu sonuç tahmin değeri ile gerçek değer aynı olduğunu gösterir.
- Yanlış Pozitif (YP): Yanlış tahmin edilen pozitif değeri içerir. Bu sonuç gerçek değer ile tahmin değerinin aynı olmadığını gösterir.

- Doğru Negatif (DN): Doğru tahmin edilen negatif değerleri içerir. Bu sonuç tahmin değeri ile gerçek değer aynı olduğunu gösterir.
- Yanlış Negatif (YN): Yanlış tahmin edilen negatif değeri içerir. Bu sonuç gerçek değer ile tahmin değerinin aynı olmadığını gösterir.

Karmaşıklık matrisinde doğru pozitif ile doğru negatif alanlarının artması istenirken buna bağlı olarak yanlış pozitif ve yanlış negatif alanlarının azalması sınıflandırma performansının iyileşmesine sebep olmaktadır (Şahin, 2018).

Doğruluk (Accuracy): Doğru tahmin edilen verilerin toplam veriye oranı olmakla birlikte sezgisel performans ölçüsüdür. Modelde yüksek doğruluk olduğu durumda modelin en iyi olduğu düşünülebilir. Yanlış negatif ve yanlış pozitif değerlerinin birbirinden oldukça farklı ve sayı olarak fazla olduğu durumda modelin performansını değerlendirmek için diğer parametrelere bakılması gerekmektedir. Doğruluk denklemi Eşitlik 5.1’de gösterilmiştir (Şahin, 2018).

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad 5.1$$

Kesinlik (Precision): Doğru tahmin edilen pozitif verilerin, tahmin edilen toplam pozitif verilere oranıdır. Düşük kesinlik oranı çok sayıda yanlış pozitif verileri de belirtebilir. Kesinlik denklemi Eşitlik 5.2’ de gösterilmiştir (Şahin, 2018).

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad 5.2$$

Duyarlılık (Recall): Doğru tahmin edilen pozitif verilerin, pozitif doğru verileri ile yanlış negatif verilerin toplamına oranı olarak verilebilmektedir. Sınıflandırıcının bütünlüğünün ölçüsü duyarlılık olarak düşünülebilir. Düşük duyarlılık yanlış negatif veri sayısının çok olduğunun göstergesidir. Duyarlılık denklemi Eşitlik 5.3’de gösterilmiştir (Şahin, 2018).

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad 5.3$$

F<sub>1</sub> skoru: Kesinlik ile duyarlılık sonucunun harmonik ortalaması olarak bilinmektedir. Yanlış negatif ile yanlış pozitifler hesaba katılmaktadır. Düzensiz bir veri sınıfları olduğu durumda F<sub>1</sub> skoruna bakmak, doğruluk değerine bakılmasından daha yararlı olabilmektedir. Yanlış pozitif ile yanlış negatif sayıları benzer sayıda ise

doğruluk değeri sınıflandırma için en iyi sonuçtur. Benzer sayıda değilse hassasiyet ve duyarlılığa bakmak gerekmektedir.  $F_1$  skoru Eşitlik 5.4' de gösterilmiştir (Şahin, 2018).

$$F_1 \text{ Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad 5.4$$

Kappa değeri: Veri datası içerisindeki tahmin edilebilen sınıflandırmalar arasındaki bir uyum ölçütüdür. Makine öğrenmesi alanında bir sınıflandırıcının doğruluk oranını artırmaya yönelik bir ölçüt olarak kullanılır. Kappa değeri -1 ile 1 arasında değer almaktadır. -1 en kötü durumu yani uyumsuzluğu, +1 ise en mükemmel uyumu göstermekte ve Kappa değerinin 0.4 veya üzeri bir değere sahip olması kabul edilebilir bir uyum göstergesi olabilir (Cömert, 2016). Çizelge 5.8'de Kappa Skorları ve yorumlarından bahsedilmiştir.

**Çizelge 5.8.** Kappa Skorları ve yorumları (Kabil, 2019)

Kappa Skoru	Yorum
0.81-1.00	Mükemmel Uyum
0.61-0.80	Önemli Derecede Uyum
0.41-0.60	İyi Derecede Uyum
0.21-0.40	Orta Derecede Uyum
0-0.20	Kötü Uyum
0	Şansa Bağlı Uyum

Verilerin tahmin edilmesinde iki önemli adım vardır. Birincisi verinin tahmin edilebilmesi için hazırlıklarının yapılması, ikincisi farklı tahmin edici modellerin karşılaştırılmasıdır. Modelleri karşılaştırılması yapılırken; doğruluk, sağlamlık, hız, yorumlanabilirlik gibi ölçütlere dikkat edilmektedir (Gültepe, 2019).

## 6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Test düzeneği ile elde edilen veriler .csv uzantılı veri datası haline getirilmiştir. Ardından PYTHON yazılımında veri datası okunarak, görüntüsü Şekil 6.1’de gösterilmiştir.

Index	tank_pressure	oil_pressure	outlet_pressure	flow_meter	pow
0	8.01976	3.5338	8.62523	62.4105	7.89322
1	8.07659	3.54152	8.63859	61.5891	7.51764
2	8.13158	3.55102	8.66449	59.5456	7.13926
3	8.18344	3.55796	8.691	57.3222	6.90308
4	8.23519	3.56157	8.72053	56.0101	6.70442
5	8.28412	3.56943	8.74045	55.2249	6.45744
6	8.32939	3.58059	8.74717	53.5025	6.12424
7	8.37005	3.59312	8.75808	51.2281	5.78105
8	8.40802	3.60409	8.773	47.6262	5.35808
9	8.44431	3.61261	8.77704	44.8372	4.9622
10	8.47738	3.62493	8.76296	42.1964	4.49827
11	8.50712	3.64062	8.76032	38.8477	4.0194
12	8.53481	3.65559	8.75697	36.0286	3.65092
13	8.55989	3.66802	8.7507	32.8998	3.24625

Şekil 6.1. Veri Datasının PYTHON Yazılımı Görüntüsü

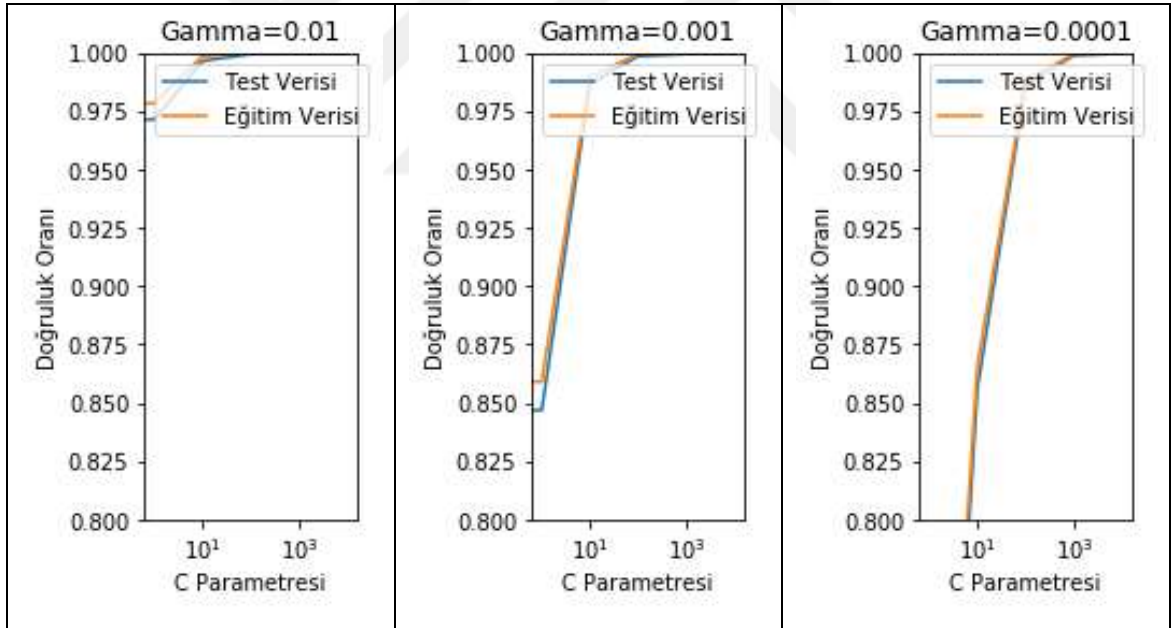
Çizelge 6.1’de veri kümesinin kaç farklı değer barındırdığının görüntüsü verilmiştir.

Çizelge 6.1. Parametreler İçerisindeki Farklı Veri Sayıları

Tank Basıncı	23909
Yağ Basıncı	23835
Çıkış Basıncı	23910
Debimetre	23956
Güç Tüketimi	23901
Ortam Sıcaklığı	23828
Soğutma Suyu Sıcaklığı	23847
Çıkış Hava Sıcaklığı (İlk)	23930
Çıkış Hava Sıcaklığı (Son)	23945
Devir Sayısı	6
Soğutma Suyu Hızı	10

## 6.1. Sınıflandırma

Destek vektör makineleri modellerinin sınıflandırma başarıları için uygulamalar gerçekleştirilecektir. Çekirdek fonksiyonlarının Optimal Hiper parametre değerlerini bulunurken Grid Search arama yöntemi kullanılmıştır. Parametrelerin her bir değeri için algoritmaya ilişkin sınıflandırma başarıları gözlenmektedir. En iyi sınıflandırma başarısını gösteren parametre değerleri Optimal Hiper düzlem parametreleri olarak değerlendirilir. Çekirdek fonksiyonları; lineer (C) ve radyal tabanlı fonksiyon (C,  $\gamma$ ), polinomial fonksiyon (C,  $\gamma$ ,  $\alpha$ , d) ve sigmoid fonksiyon (C,  $\gamma$ ,  $\alpha$ ) olmak üzere dört sınıfa ayrılmaktadır. Ayhan ve Erdoğan'ın çalışmalarında, benzer birçok çalışmada destek vektör makineleri algoritması için Radyal Tabanlı Kernel fonksiyonu kullanıldığından söz edilmiştir (Ayhan ve Erdoğan, 2014). Bu çalışmada Radyal Tabanlı Kernel fonksiyonu kullanılmıştır.




Şekil 6.2. Destek Vektör Makinası Radyal Tabanlı Fonksiyon Kerneline Göre Çözümü

Çekirdek fonksiyonlarına ilişkin C düzenleme parametresinin alt sınırı  $10^{-1}$  ve üst sınırı  $10^4$  olarak belirlenmiştir. Parametrelere ilişkin artış aralıkları  $10^1$  olarak alınmıştır. Diğer parametre değerleri aşağıdakine benzer şekilde yorumlanabilir.

Düzenleme parametresi ( C ) :  $10^{-1}$ ,  $10^0$ ,  $10^1$ ,  $10^2$ ,  $10^3$ ,  $10^4$

Gamma parametresi (  $\gamma$  ) :  $10^{-4}$ ,  $10^{-3}$ ,  $10^{-2}$




**Şekil 6.3.** K-En Yakın Komşu Algoritması Komşu Sayısına Bağlı Model Doğruluk Oranlarının Belirlenmesi

Destek vektör makineleri algoritmasının amaç fonksiyonundaki (C) düzenleme parametresinin farklı değerleri için optimal (C) düzenleme parametresinin bulunabilmesi için Grid Search kullanılmıştır. Farklı gamma değerleri ile farklı



düzenleme parametreleri için model çalıştırılmıştır. Gamma ve düzenleme parametrelerinin en yüksek doğruluk oranını verdiği optimum değerleri Şekil 6.2’de değerlendirilmiştir. Radyal tabanlı Fonksiyon optimum C düzenleme parametresi değeri 10000, Gamma parametresi 0.0001 bulunmuştur.



Şekil 6.4. Rastgele Orman Algoritması Optimizasyonu

K-En Yakın Komşu Algoritması için Öklid Ölçütü, Manhattan Ölçütü, Chebyshev Ölçütü ve Minkowski Ölçütü olmak üzere dört farklı tipte eğitim gerçekleştirilmiştir. Öklid ile Minkowski uzaklık ölçütleri aynı sonuçları verdiği için Minkowski uzaklık ölçütü sonuçları ayrıca paylaşılmamıştır.

K-En Yakın komşu algoritması uzaklık bağıntılarına göre model doğruluk oranları incelenmiş ve Şekil 6.3’de verilmiştir. Tüm uzaklık bağıntılarında komşu sayısı arttıkça test verilerinde model doğruluk oranının azaldığı görülmektedir. En yakın bir komşuya bakılması tüm uzaklık ölçütleri için maksimum doğruluk oranını vermiştir. Ayrıca eğitim ve test verilerinde modelin doğruluk oranlarına da şekilde değinilmiştir.

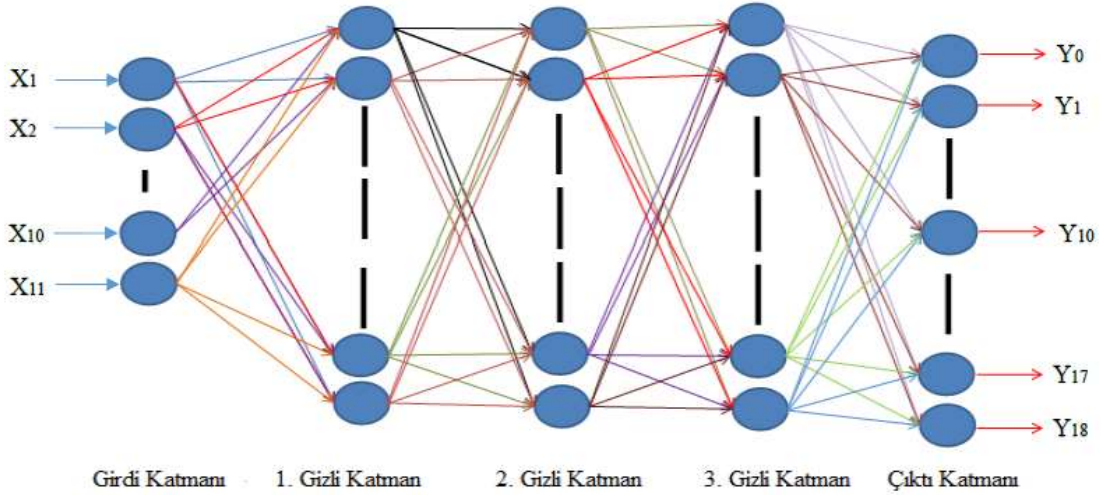
Naive Bayes Sınıflandırıcısı için Bernoulli Naive Bayes Sınıflandırıcısı, Multinomial Naive Bayes Sınıflandırıcısı, Gaussian Naive Bayes Sınıflandırıcısı olmak üzere üç farklı tipte eğitim gerçekleştirilmiştir.

**Çizelge 6.2.** Makine Öğrenmesi Yöntemlerinin Sınıflandırma Performansları (Eğitim Veri Seti)

Makine Öğrenmesi Algoritmaları	Tip	Doğruluk (%)	Kesinlik	Duyarlılık	F <sub>1</sub> Skoru	Kappa değeri	Hatalı Tahmin Edilen Veri Sayısı
Destek Vektör Makineleri	Radyal Tabanlı Fonksiyon Kerneli	%100	1.00	1.00	1.00	1.00	0
K-En Yakın Komşu Algoritması	Öklid Ölçütü	%100	1.00	1.00	1.00	1.00	0
	Manhattan Ölçütü	%100	1.00	1.00	1.00	1.00	0
	Chebyshev Ölçütü	%100	1.00	1.00	1.00	1.00	0
Naive Bayes Sınıflandırıcıları	Bernoulli Naive Bayes Sınıflandırıcısı	%5.90	0.00	0.06	0.01	0.00	18062
	Multinomial Naive Bayes Sınıflandırıcısı	%13.20	0.23	0.13	0.12	0.08	16654
	Gaussian Naive Bayes Sınıflandırıcısı	%95	0.96	0.95	0.95	0.95	961
Rastgele Orman Algoritmaları	Rastgele Orman Algoritmaları	%99.20	0.99	0.99	0.99	0.99	149
Yapay Sinir Ağları	Yapay Sinir Ağları	%99.80	1.00	1.00	1.00	1.00	38


Rastgele orman algoritması için optimize etme işlemi yapılmış ve optimum parametre değerleri Şekil 6.4’de gösterilmiştir. Yapay sinir ağında girdi katmanında 11 adet, ilk gizli katmanda 64, ikinci gizli katmanda 64, üçüncü gizli katmanda 64 ve çıktı

katmanında 19 adet nöron bulunmaktadır. Girdi ve gizli katmanlarda relu aktivasyon fonksiyonu, çıktı katmanında ise Softmax Aktivasyon Fonksiyonu kullanılmıştır. Optimizer olarak adam, Loss olarak Sparse\_Categorical\_Crossentropy seçilmiştir. Ağın eğitimi için 2000 iterasyon gerçekleştirilmiştir. Şekil 6.5’de yapay sinir ağları belirlenen ağ modeli gösterilmiştir. Çizelge 6.2’de belirlenen makine öğrenmesi yöntemlerinin eğitim verileri üzerindeki sınıflandırma performansları gösterilmiştir.




Şekil 6.5. Yapay Sinir Ağları Belirlenen Ağ Modelinin Gösterimi


Şekil 6.6 - Şekil 6.14 arasında eğitim verileri ile oluşturulan sınıflandırma Doğru Pozitif Oranı matrisi (True Positive Rate matrix) (TPR matrisi) verilmiştir. Karmaşıklık matrisinde sol üst köşeden sağ alt köşeye inen köşegen üzerinde gerçek veri ile tahmin edilen veri sonucunun birbirine eşit olması beklenmektedir. Köşegen üzerindeki noktaların %100 iken köşegen dışındaki tüm noktaların 0 olması hedeflenmektedir. Köşegen üzerindeki %100' ün anlamı tüm verilerin doğru tahmin edildiği şeklinde yorumlanabilir.




Şekil 6.6. DVM Radyal Tabanlı Fonksiyon Kerneli Sınıflandırma TPR Matrisi




Şekil 6.7. K-En Yakın Komşu Algoritması Öklid Uzaklık Ölçütü Sınıflandırma TPR Matrisi



Şekil 6.8. K-En Yakın Komşu Algoritması Manhattan Uzaklık Ölçütü Sınıflandırma TPR Matrisi




Şekil 6.9. K-En Yakın Komşu Algoritması Chebyshev Uzaklık Ölçütü Sınıflandırma TPR Matrisi




Şekil 6.10. Bernoulli Naive Bayes Sınıflandırma TPR Matrisi







Şekil 6.11. Multinomial Naive Bayes Sınıflandırma TPR Matrisi



Şekil 6.12. Gaussian Naive Bayes Sınıflandırma TPR Matrisi



Şekil 6.13. Rastgele Orman Algoritması Sınıflandırma TPR Matrisi



Şekil 6.14. Yapay Sinir Ağları Sınıflandırma TPR Matrisi

Şekil 6.6 - Şekil 6.14 arasında eğitim verileri ile oluşturulan sınıflandırma Doğru Pozitif Oranı matrisi (True Positive Rate matrix) (TPR matrisi) şekilleri için açıklamalar aşağıda verilmiştir;

- Şekil 6.6'da DVM Radyal Tabanlı Fonksiyon kerneli sınıflandırma TPR matrisi incelendiğinde tüm eğitim veri setinin doğru tahmin edildiği görülmektedir.
- Şekil 6.7'de K-En Yakın Komşu algoritması Öklid Uzaklık Ölçütü sınıflandırma TPR matrisi incelendiğinde tüm eğitim veri setinin doğru tahmin edildiği görülmektedir.
- Şekil 6.8'de K-En Yakın Komşu algoritması Manhattan Uzaklık Ölçütü sınıflandırma TPR matrisi incelendiğinde tüm eğitim veri setinin doğru tahmin edildiği görülmektedir.
- Şekil 6.9'da K-En Yakın Komşu algoritması Chebyshev Uzaklık Ölçütü sınıflandırma TPR matrisi incelendiğinde tüm eğitim veri setinin doğru tahmin edildiği görülmektedir.
- Şekil 6.10'da Bernoulli Naive Bayes sınıflandırma TPR matrisi incelendiğinde tüm eğitim veri setinin 18 numaralı çalışma durumu olarak tahmin edildiği görülmektedir. Algoritma eğitim esnasında son gelen veriyi hafızada daha baskın tutmaya çalıştığı için tahminde bulunurken de hafızada bulunan son verinin etiket değerini, tahminde bulunacağı yeni eklenen veriye etiketlemektedir. Bu sebepten dolayı sınıflandırma TPR matrisinde tüm eğitim verilerinin tahmin karşılığı 18 numaralı çalışma durumu olarak görülmektedir.
- Şekil 6.11'de Multinomial Naive Bayes sınıflandırma TPR matrisi incelendiğinde doğru tahmin edilen veriler bulunmaktadır. Ancak genel olarak düşünüldüğünde algoritma bu verilerde başarı gösterememiştir.
- Şekil 6.12'de Gaussian Naive Bayes sınıflandırma TPR matrisi incelendiğinde diğer Naive Bayes sınıflandırıcılarına göre bu verilerde doğru tahminde bulunma olasılığının çok daha yüksek olduğu görülmektedir.
- Şekil 6.13'de Rastgele Orman Algoritması sınıflandırma TPR matrisi incelendiğinde 9 sınıfa ait verilerin maksimum %7'lik kısımlarında hatalı tahminde bulunulduğu görülmektedir.


- Şekil 6.14’de Yapay Sinir Ağları sınıflandırma TPR matrisi incelendiğinde 4 sınıfa ait verilerin maksimum %3’lük kısımlarında hatalı tahminde bulunduğu görülmektedir.

**Çizelge 6.3.** Makine Öğrenmesi Yöntemleri Sınıflandırma Performansları (Test Veri Seti)


Makine Öğrenmesi Algoritmaları	Tip	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru	Kappa değeri	Hatalı Tahmin Edilen Veri Sayısı
Destek Vektör Makineleri	Radyal Tabanlı Fonksiyon Kerneli	%99.99	1.00	1.00	1.00	1.00	2
K-En Yakın Komşu Algoritması	Öklid Uzaklık Ölçütü	%99.20	0.99	0.99	0.99	0.91	40
	Manhattan Uzaklık Ölçütü	%99.50	1.00	1.00	1.00	0.99	22
	Chebyshev Uzaklık Ölçütü	%98.60	0.99	0.99	0.99	0.99	66
Naive Bayes Sınıflandırıcıları	Bernoulli Naive Bayes Sınıflandırıcısı	%5.20	0.00	0.05	0.01	0.00	4550
	Multinomial Naive Bayes Sınıflandırıcısı	%12.30	0.23	0.12	0.11	0.07	4210
	Gaussian Naive Bayes Sınıflandırıcısı	%94.60	0.96	0.95	0.95	0.94	258
Rastgele Orman Algoritmaları	Rastgele Orman Algoritmaları	%99.30	0.99	0.99	0.99	0.99	35
Yapay Sinir Ağları	Yapay Sinir Ağları	%99.80	1.00	1.00	1.00	1.00	9

Çizelge 6.3’de belirlenen makine öğrenmesi yöntemlerinin test verileri üzerindeki sınıflandırma performansları gösterilmiştir.

Şekil 6.15 ile Şekil 6.23 arasındaki görseller test verilerine ait sınıflandırma karmaşıklık matrislerini göstermektedir. TPR matrislerinde olduğu gibi sol üst köşegenden başlayan ve sağ alt köşegene giden noktalarda sonucun %100 olması beklenmektedir.




Şekil 6.15. DVM Radyal Tabanlı Fonksiyon Kerneli ile Sınıflandırma Karmaşıklık Matrisi




Şekil 6.16. K-En Yakın Komşu Algoritması Öklid Uzaklık Ölçütü ile Sınıflandırma Karmaşıklık Matrisi






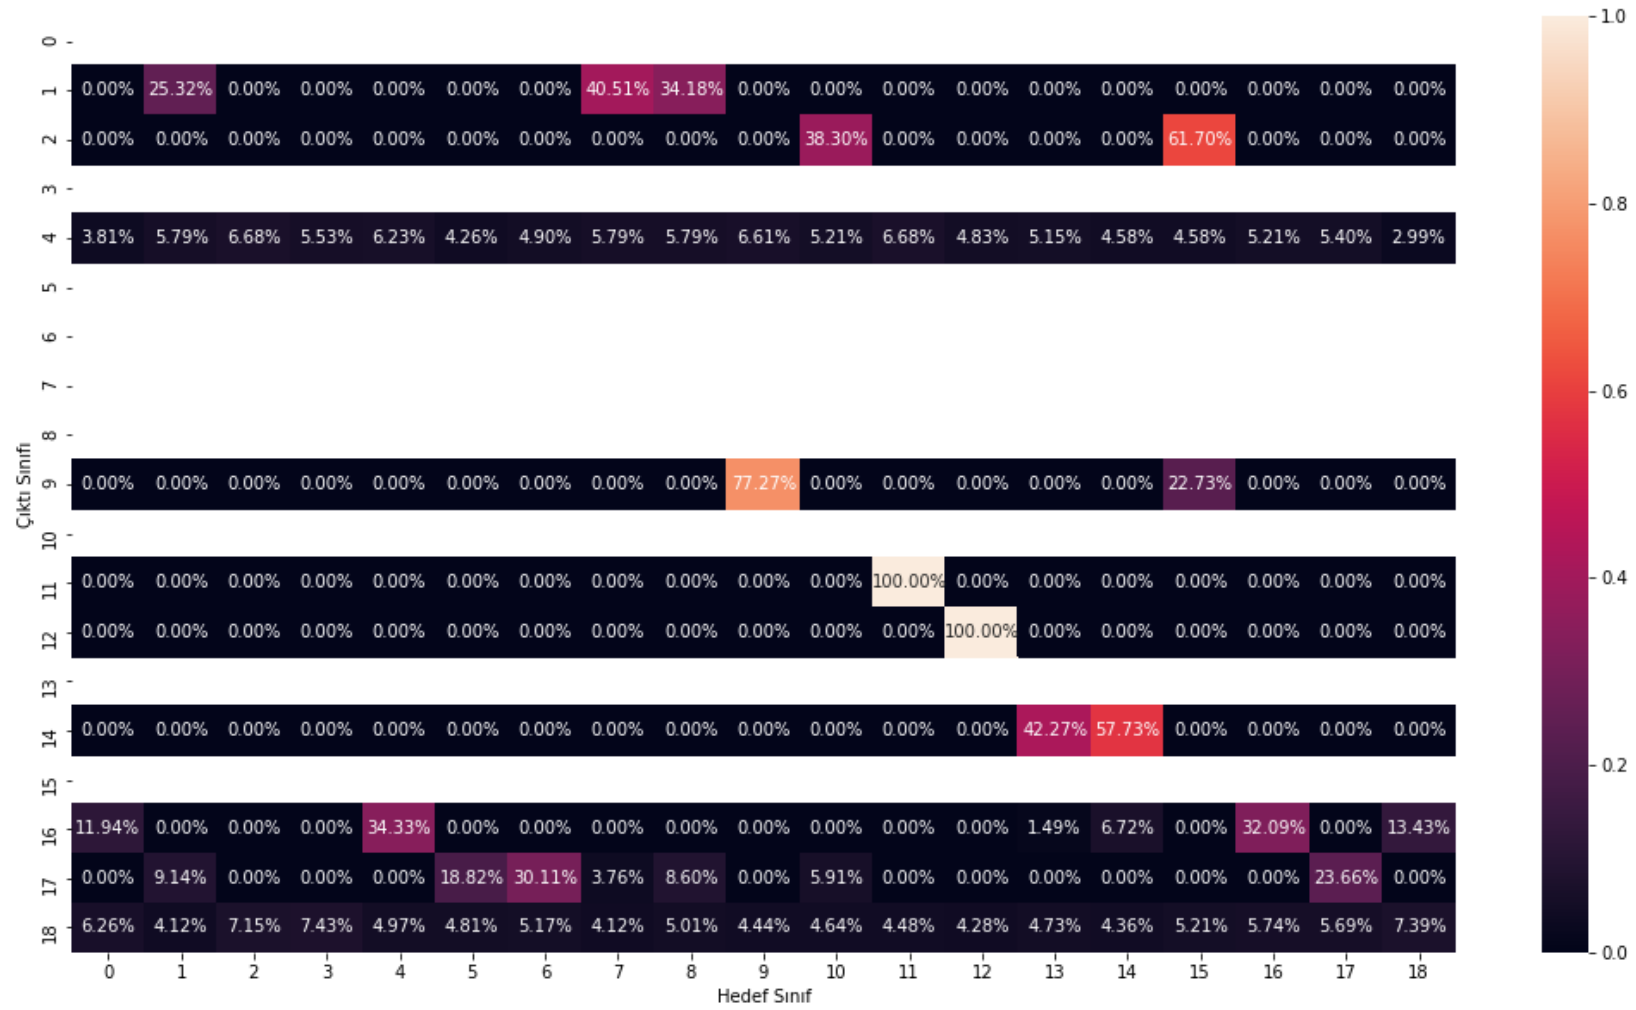
Şekil 6.17. K-En Yakın Komşu Algoritması Manhattan Uzaklık Ölçütü ile Sınıflandırma Karmaşıklık Matrisi




Şekil 6.18. K-En Yakın Komşu Algoritması Chebyshev Uzaklık Ölçütü ile Sınıflandırma Karmaşıklık Matrisi




Şekil 6.19. Bernoulli Naive Bayes ile Sınıflandırma Karmaşıklık Matrisi




Şekil 6.20. Multinomial Naive Bayes ile Sınıflandırma Karmaşıklık Matrisi



Şekil 6.21. Gaussian Naive Bayes ile Sınıflandırma Karmaşıklık Matrisi



Şekil 6.22. Rastgele Orman Algoritması ile Sınıflandırma Karmaşıklık Matrisi



Şekil 6.23. Yapay Sinir Ağları ile Sınıflandırma Karmaşıklık Matrisi

Şekil 6.15 ile Şekil 6.23 arasındaki test verilerine ait sınıflandırma karmaşıklık matrisleri şekilleri için açıklamalar aşağıda verilmiştir;

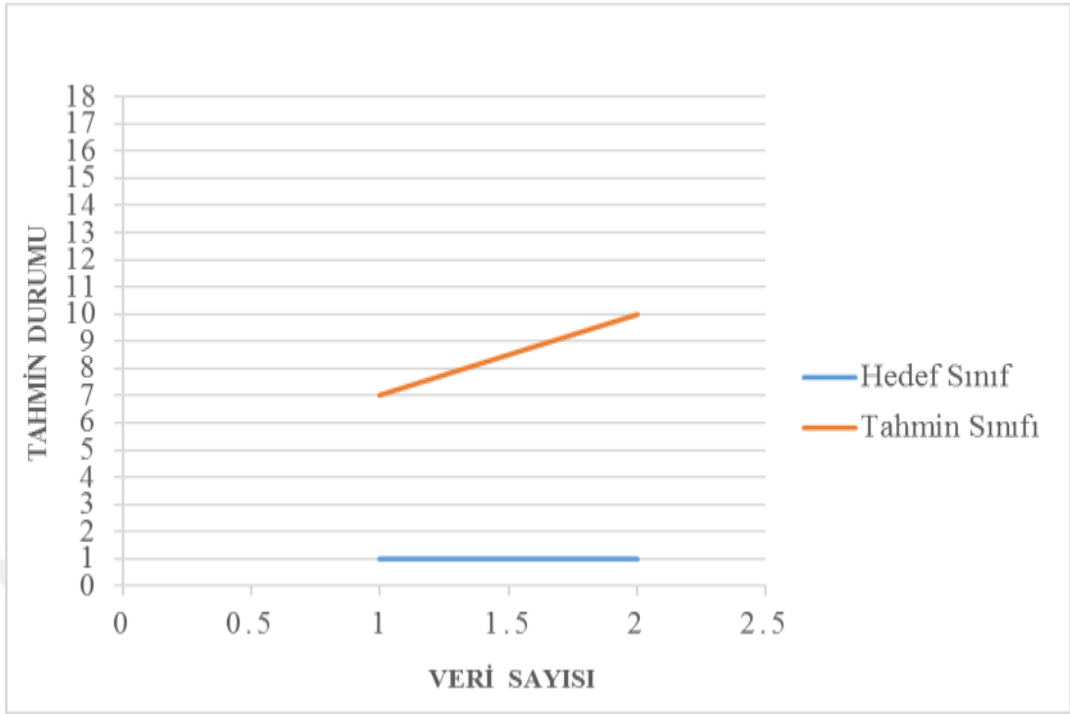
- Şekil 6.15’de DVM Radyal Tabanlı Fonksiyon kerneli ile sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 7 ve 10 numaralı çalışma durumlarına ait sınıflarda %1’den düşük bir oranda hatalı tahminde bulunduğu görülmektedir.
- Şekil 6.16’da K-En Yakın Komşu algoritması Öklid uzaklık ölçütü ile sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 9 sınıfta maksimum %8’lik verilerinde hatalı tahminde bulunduğu görülmektedir.
- Şekil 6.17’de K-En Yakın Komşu algoritması Manhattan uzaklık ölçütü ile sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 6 sınıfta maksimum %5’lik verilerinde hatalı tahminde bulunduğu görülmektedir.
- Şekil 6.18’de K-En Yakın Komşu algoritması Chebyshev uzaklık ölçütü ile sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 9 sınıfta maksimum %10’luk verilerinde hatalı tahminde bulunduğu görülmektedir.
- Şekil 6.19’da Bernoulli Naive Bayes sınıflandırıcısı Karmaşıklık matrisi incelendiğinde algoritma test veri setinde tüm sınıflara ait verileri 18 numaralı çalışma durumu olarak yanlış tahminde bulunmuştur. Şekil 6.10’da eğitim verilerine ait TPR matrisinde de aynı durum söz konusu olmuştur. Algoritma eğitim esnasında son gelen veriyi hafızada daha baskın tutmaya çalıştığı için tahminde bulunurken de hafızada bulunan son verinin etiket değerini, tahminde bulunacağı yeni eklenen veriye etiketlemektedir. Bu sebepten dolayı sınıflandırma Karmaşıklık matrisinde tüm test verilerinin tahmin karşılığı 18 numaralı çalışma durumu olarak verilmiştir. Diğer alanların algoritma yazılım çıktısı olarak boş olduğu görülmektedir.
- Şekil 6.20’de Multinomial Naive Bayes sınıflandırma Karmaşıklık matrisi incelendiğinde test verileri içerisindeki tüm sınıfların ayrımının tam anlamıyla yapılamadığı görülmektedir. Algoritma 0, 3, 5, 6, 7, 8, 10, 13, 15 numaralı çalışma durumlarına ait verileri diğer sınıf verileri olarak etiketlemiştir. Bu durum diğer sınıflara ait verilerin doğru tahmin oranını




etkilemektedir. Şekil 6.11’de eğitim verilerine ait TPR matrisi incelenmiş ve algoritmanın eğitim verileri tahmininde başarı gösteremediği belirtilmiştir.

- Şekil 6.21’de Gaussian Naive Bayes sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 9 sınıfta yanlış tahminde bulunduğu veriler bulunmaktadır. En düşük doğru tahmin % 67.55 gibi bir oranla 6 numaralı çalışma durumuna aittir. Bu verilerde diğer Naive Bayes Sınıflandırıcılarına göre daha güvenilir sonuçlar vermektedir.
- Şekil 6.22’de Rastgele Orman Algoritması sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 6 sınıfta yanlış tahminde bulunduğu veriler bulunmaktadır. En düşük doğru tahmin %93.50 gibi bir oranla 1 numaralı çalışma durumuna aittir.
- Şekil 6.23’de Yapay Sinir Ağları sınıflandırma Karmaşıklık matrisi incelendiğinde test veri setine ait 4 sınıfta yanlış tahminde bulunduğu veriler bulunmaktadır. En düşük doğru tahmin %97.84 gibi bir oranla 1 numaralı çalışma durumuna aittir.


Şekil 6.24 ile Şekil 6.32 arasında verilen cevap grafiklerinde, yanlış tahmin edilen test verilerinin gösterimi yapılmıştır. Hedef sınıf sonuçlarından ne kadar bağımsız tahminlemelerin yapıldığı, hangi sınıfın daha çok tekrarlandığı grafiklerden okunabilmektedir.




Şekil 6.24. DVM Radyal Tabanlı Fonsiyon Kerneli Sınıflandırma Cevap Grafiği



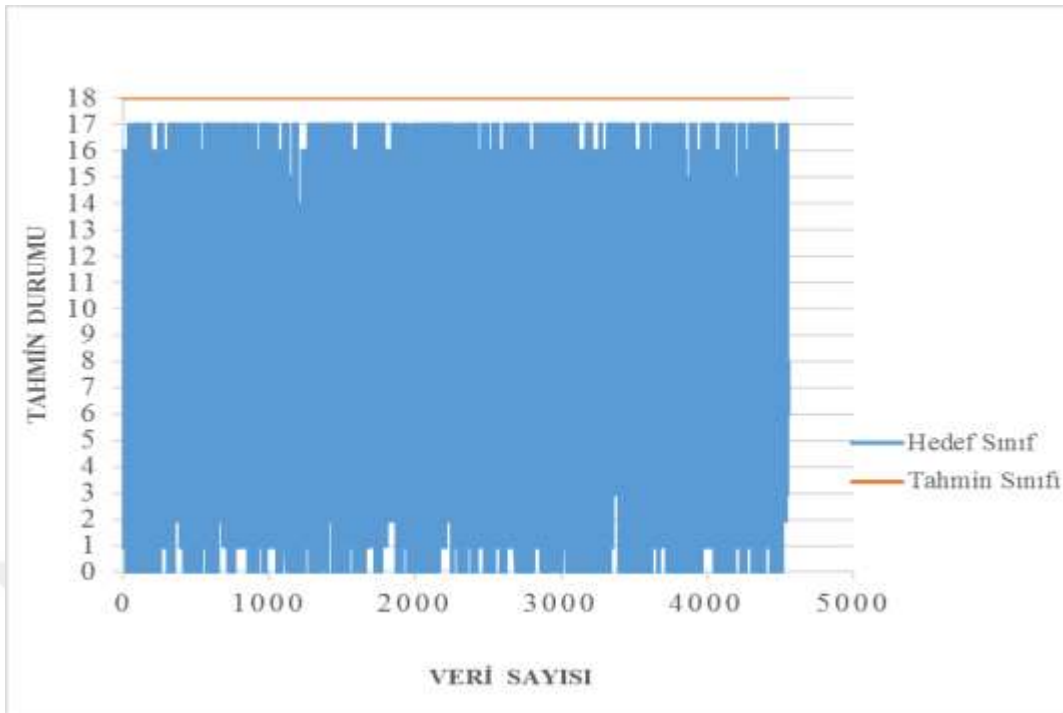
Şekil 6.25. K-En Yakın Komşu Algoritması Öklid Uzaklık Ölçütü Sınıflandırma Cevap Grafiği




Şekil 6.26. K-En Yakın Komşu Algoritması Manhattan Uzaklık Ölçütü Sınıflandırma Cevap Grafiği




Şekil 6.27. K-En Yakın Komşu Algoritması Chebyshev Uzaklık Ölçütü Sınıflandırma Cevap Grafiği




Şekil 6.28. Bernoulli Naive Bayes Sınıflandırıcısı Cevap Grafiği



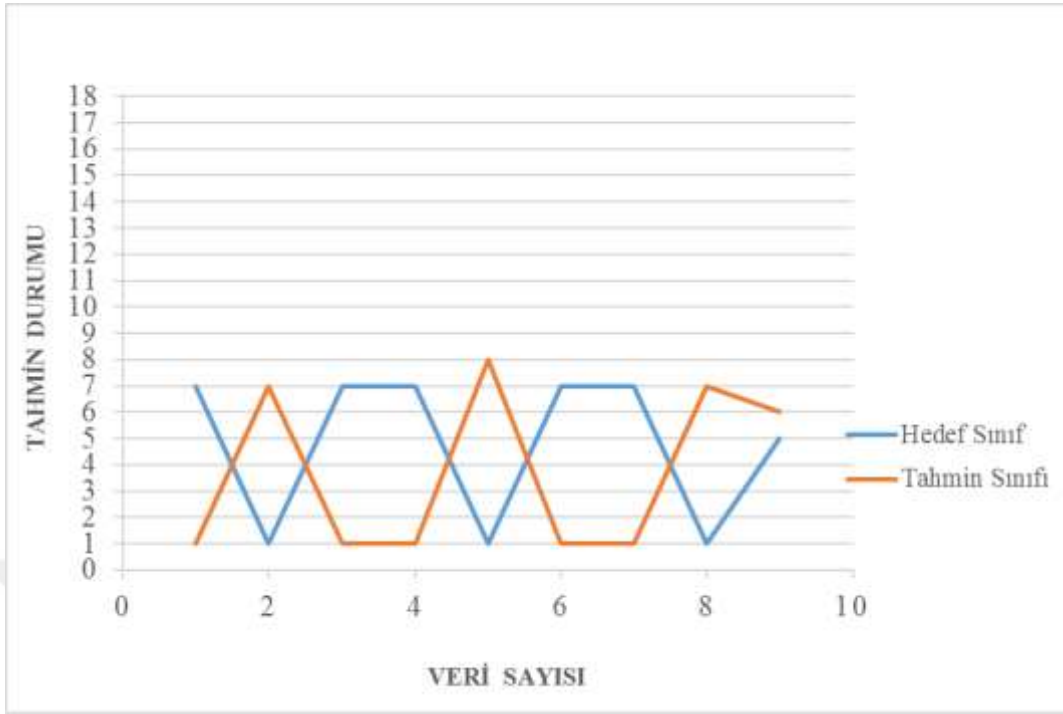
Şekil 6.29. Multinomial Naive Bayes Sınıflandırıcısı Cevap Grafiği



Şekil 6.30. Gaussian Naive Bayes Sınıflandırıcısı Cevap Grafiği



Şekil 6.31. Rastgele Orman Algoritması Sınıflandırma Cevap Grafiği



Şekil 6.32. Yapay Sinir Ağları Sınıflandırma Cevap Grafiği

Ağır vasıta hava kompresörü çalışma verileri, o anki çalışma şartlarına göre sıralı gerçekleşen verilerdir. Çalışma anında gerçekleşen değişim sonraki gelen veriyi de aynı koşullarda etkilemektedir. Rastgele bir günde gerçekleştirilen bir teste benzer bir kompresörden veriler kayıt altına alınmıştır. Oluşturulan makine öğrenmesi algoritma modellerinin sınıflandırma başarılarının görülebilmesi için etiket değeri bilinen veriler, algoritmalarca tahminler yaptırılarak yüzde kaç oranla hangi sınıfa ait olduğu belirlenmeye çalışılmıştır. Buna yönelik algoritma hiç tanımadığı bir veride yüzdelik oranda hangi sınıfa daha yakın olunabileceğini Şekil 6.33 ile Şekil 6.41 arasındaki tahmin matrislerinde göstermektedir.

Hedef Sınıf	0	%98.9	%0.2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	1	%0.2	%85.2	%0.1	%0.1	0	%0.3	0	%2.5	%0.7	0	%9.8	%0.1	%0.3	%0.3	%0.2	%0.2	0	0	0
	2	0	0	%99.7	%0.1	0	0	0	0	0	0	0	0	0	0	%0.1	0	0	0	%0.1
	3	%0.1	0	%0.1	%99.6	0	0	0	%0.1	0	0	%0.1	0	0	0	0	0	0	0	0
	4	%0.3	%4.7	%0.4	%2	%38.9	%2.7	%0.6	%2	%3.7	%3	%2.5	%35.4	%0.7	%0.5	%0.3	%0.5	%0.9	%0.8	%0.1
	5	0	%0.1	0	0	0	%99.8	0	0	0	0	0	0	%0.1	0	0	0	0	0	0
	6	0	0	0	0	0	%0.1	%99.8	0	0	0	0	0	0	0	0	%0.1	0	0	0
	7	0	0	0	0	0	%0.6	0	%95.4	%1.2	0	%1.9	0	0	0	0	%0.9	0	0	0
	8	0	%1.2	0	0	0	0	0	%1.2	%97	0	%0.6	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	%2.4	%0.6	0	0	%96.6	0	0	%0.2	0	0	0	0	%0.2	0
	10	0	0	0	0	0	%0.3	0	0	%0.1	0	%99.4	0	0	%0.2	0	0	0	0	0
	11	%0.7	%35.4	%0.5	%1.2	%0.3	%0.5	%0.9	%4.2	%9	%0.3	%3.2	%37.4	%2.4	%1.1	%0.7	%0.8	%0.3	%0.4	%0.7
	12	%0.2	%0.6	%0.2	%0.1	%0.2	%25.6	%1.7	%0.5	%1.1	%3.1	%0.4	%0.4	%20.3	%0.4	%0.3	%0.2	%18.6	%25.9	%0.2
	13	%0.2	%0.1	0	0	0	0	0	0	0	0	%0.2	0	%0.4	%98.8	%0.1	0	0	%0.2	0
	14	%0.1	%0.2	%0.1	0	%0.2	%0.2	0	0	0	0	0	%0.2	%0.7	%0.3	0	0	%0.2	%97.5	%0.3
	15	%0.4	0	%1.1	%0.1	0	0	%0.1	%0.3	%0.1	0	%0.1	0	0	0	%0.5	%97.3	0	0	0
	16	0	%0.2	0	0	0	0	0	0	0	0	0	0	0	0	%0.1	%0.1	%99.5	%0.1	0
	17	0	0	0	0	%0.1	0	0	0	0	0	0	0	0	0	0	0	0	%99.9	0
	18	0	0	%0.2	%0.1	0	0	0	0	0	0	%0.1	%0.1	0	0	0	0	0	0	%99.5
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	
	Çıktı Sınıfı																			

Şekil 6.33. DVM Radyal Tabanlı Fonksiyon Kerneli Tahmin Matrisi

Hedef Sınıf	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	5	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0
	13	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100
	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	
	Çıktı Sınıfı																			

Şekil 6.34. K-En Yakın Komşu Öklid Uzaklık Ölçütü Tahmin Matrisi



Hedef Sınıf	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0
	5	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0
	13	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100
	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
	Çıktı Sınıfı																		

Şekil 6.35. K-En Yakın Komşu Manhattan Uzaklık Ölçütü Tahmin Matrisi

Hedef Sınıf	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0
	5	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	13	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100
	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100
	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
	Çıktı Sınıfı																		

Şekil 6.36. K-En Yakın Komşu Chebyshev Uzaklık Ölçütü Tahmin Matrisi

Hedef Sınıf	0	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	1	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	2	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	3	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	4	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	5	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	6	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	7	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	8	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	9	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	10	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	11	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	12	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	13	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	14	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	15	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	16	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	17	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	18	%5.13	%5.17	%5.12	%5.42	%5.79	%5.05	%4.99	%5.10	%4.94	%5.43	%5.08	%5.46	%5.18	%5.07	%5.04	%4.95	%5.46	%5.73	%5.89
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	
	Çıktı Sınıfı																			

Şekil 6.37. Bernoulli Naive Bayes Sınıflandırıcısı Tahmin Matrisi

Hedef Sınıf	0	0	0	0	%99	0	0	0	0	0	%1	0	0	0	0	0	0	0	0	
	1	0	0	0	%99	0	0	0	0	%1	0	0	0	0	0	0	0	0	0	
	2	%7.8	%5.8	%19.3	%2.2	0	%0.6	%0.5	%5.6	%3.8	0	%4.1	%4.5	%2.2	%2.3	%3.8	%2.9	%0.1	%4.4	%30.1
	3	0	0	%6.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%93.5
	4	0	0	0	0	%88.7	%0.5	0	0	0	%4.5	0	0	0	0	0	0	%6.3	0	0
	5	0	0	%4.2	0	0	0	0	0	0	0	0	0	0	0	%0.3	0	0	0	%95.5
	6	%0.3	0	%15.2	0	0	0	0	%0.1	0	0	0	0	0	0	%0.2	0	0	0	%84.2
	7	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	%96.9	0	0	0	0	%1.6	0	0	0	0	0	0	%1.5	0	0
	9	%2.2	%7.2	%1.7	%3.3	%0.7	%9	%6.5	%6.2	%7.5	%9.5	%6	%9	%7.5	%2.7	%1.3	%5.6	%5.3	%8.2	%0.6
	10	%8.3	%7.5	%8.1	%10.1	0	%3.9	%3.5	%6.7	%6.6	%0.5	%7.6	%6.3	%3.4	%3.6	%2.9	%5.7	%0.5	%9.2	%5.6
	11	%7.2	%8.3	%10	%5.5	0	%3	%2.6	%7.4	%7	%0.5	%6.8	%7.9	%4.6	%3.4	%3.2	%5.4	%0.6	%8.5	%8.1
	12	0	0	0	0	%66.8	%0.6	%0.2	0	0	%8.5	0	0	0	0	0	0	%23.9	0	0
	13	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	14	%5.7	%6.7	%5.9	%4.9	%0.5	%2.6	%1.5	%5.5	%5.3	%0.6	%5.4	%7.6	%7.4	%7.8	%9.5	%2.6	%5.5	%7.8	%7.2
	15	%7.8	%8.5	%12.5	%2.4	0	%2	%2.4	%9	%6.8	%0.2	%6.7	%5.7	%4.8	%3.9	%4.6	%7.1	0	%6.1	%9.5
	16	%0.6	%0.3	%11.1	0	0	0	0	%0.4	%0.1	0	0	%0.3	0	0	%0.2	0	0	%0.1	%86.9
	17	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	18	%0.1	0	%3.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%96.4
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	
	Çıktı Sınıfı																			

Şekil 6.38. Multinomial Naive Bayes Sınıflandırıcısı Tahmin Matrisi

Hedef Sınıf	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0
	2	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	0	%26.2	0	0	0	0	%64.9	0	0	0	%8.9	0	0	0
	5	0	0	0	0	0	%34.2	0	0	0	0	0	%65.6	0	0	0	%0.2	0	0
	6	0	0	0	0	0	0	0	0	0	0	0	%99	0	0	0	%1	0	0
	7	0	%33.7	0	0	0	0	%66.3	0	0	0	0	0	0	0	0	0	0	0
	8	0	%92	0	0	0	0	%2	%6	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	%86.2	0	0	%12.7	0	0	0	%1.1	0
	11	0	%98.7	0	0	0	0	%1	0	0	0	%0.3	0	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	%1.7	0	0	0	%98.3	0	0
	13	0	%3	0	0	0	0	0	0	0	%42	0	0	%55	0	0	0	0	0
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0
	15	0	%3	0	0	0	0	0	%97	0	0	0	0	0	0	0	0	0	0
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0
	17	0	0	0	0	0	0	0	0	0	0	0	0	%98.9	0	0	0	%1.1	0
	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
		Çıktı Sınıfı																	

Şekil 6.39. Gaussian Naive Bayes Sınıflandırıcısı Tahmin Matrisi

0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	%99.4	0	0	0	0	0	0	0	%0.4	0
2	0	0	%72.9	%27.1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	%0.2	0	%9.5	0	%1.1	0	0	%11.5	%3.1	0	0	%74.6	0	0	0
5	0	0	0	0	%6.5	%5.1	%0.9	0	0	0	0	0	%31.9	0	0	0	%55.6	0	0
6	0	0	0	0	%0.6	%3.5	%5.2	0	0	0	0	0	%90.7	0	0	0	0	0	0
7	0	0	0	0	0	0	0	%99.9	%0.1	0	0	0	0	0	0	0	0	0	0
8	0	%8.1	0	0	0	0	0	%78.2	13.7	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	0	%96.4	0	0	%1.2	0	0	0	%2.4	0
11	0	%99.8	0	0	0	0	0	%0.2	0	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	%61.2	0	0	0	0	0	0	0	%1.1	0	0	0	%37.7	0	0
13	0	%24.4	0	0	0	0	0	%1.1	0	0	%48.9	0	0	%0.9	0	0	0	%24.7	0
14	0	0	0	0	%10	0	0	0	0	0	0	0	0	0	%90	0	0	0	0
15	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0
17	0	0	0	0	0	0	0	0	0	0	%1.9	0	0	%95.2	%0.7	0	0	%2.2	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18

Şekil 6.40. Rastgele Orman Algoritması Tahmin Matrisi

Hedef Sınıf	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	%5	%0.1	0	0	0	0	%0.7	0	0	%94.2	0	0	0	0	0	0	0
	2	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	%0.5	0	0	0	0	0	0	%99.5	0	0	0	0	0	0
	5	0	0	0	0	0	%98.3	0	0	%1.7	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0	0	0	0
	7	0	%68.9	0	0	0	0	0	0	%19	%0.1	%12	0	0	0	0	0	0	0
	8	0	%1.7	0	0	0	0	0	%21.8	%76.5	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0
	11	0	%38.4	0	0	0	0	0	0	0	%61.6	0	0	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	%100	0	0	0	0	0	0	0
	13	0	0	0	0	0	0	0	0	0	0	0	0	0	%71.4	0	0	0	%28.6
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0	0
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	%100	0
	17	0	0	0	0	0	0	0	0	0	0	0	0	0	%8.8	0	0	0	%91.2
	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
		Çıktı Sınıfı																	

Şekil 6.41. Yapay Sinir Ağları Tahmin Matrisi

Şekil 6.33 ile Şekil 6.41 arasındaki tahmin matrislerinde 19 farklı çalışma durumunun her biri için 11 parametrelilik bir veri verilerek sonuçları gösterilmektedir.

Şekil 6.33'de DVM Radyal Tabanlı Fonksiyon Kerneli Tahmin Matrisi incelendiğinde 12 ve 14 numaralı çalışma durumlarına ait veriler 17 numaralı çalışma durumu olarak yanlış tahmin edilmiştir. Diğer veriler ortalama olarak %90 oranla doğru tahmin edilmiştir.

Şekil 6.34'de K-En Yakın Komşu Öklid Uzaklık Ölçütü Tahmin Matrisi incelendiğinde 14 numaralı çalışma durumuna ait veri 17 numaralı çalışma durumu olarak yanlış tahmin edilmiştir. Diğer veriler %100 oranla doğru tahmin edilmiştir.

Şekil 6.35'de K-En Yakın Komşu Manhattan Uzaklık Ölçütü Tahmin Matrisi incelendiğinde 14 numaralı çalışma durumuna ait veri 17 numaralı çalışma durumu olarak yanlış tahmin edilmiştir. Diğer veriler %100 oranla doğru tahmin edilmiştir.

Şekil 6.36'da K-En Yakın Komşu Chebyshev Uzaklık Ölçütü Tahmin Matrisi incelendiğinde 7, 12 ve 14 numaralı çalışma durumlarına ait veriler yanlış tahmin edilmiştir. Diğer veriler %100 oranla doğru tahmin edilmiştir.

Şekil 6.37'de Bernoulli Naive Bayes Sınıflandırıcısı Tahmin Matrisi incelendiğinde tüm çalışma durumlarına ait veriler %5.89 oranla 18 numaralı çalışma durumu sınıfına dahil edilmiştir. Algoritmanın başarılı bir sonuç vermediği gözlemlenmiştir.

Şekil 6.38'de Multinomial Naive Bayes Sınıflandırıcısı Tahmin Matrisi incelendiğinde 4, 9, 14, 18 numaralı çalışma durumları doğru tahmin edilmiştir. Ancak oran olarak bakıldığında çok düşük oranlarla doğru tahmin söz konusudur. Algoritmanın başarılı bir sonuç vermediği gözlemlenmiştir.

Şekil 6.39'da Gaussian Naive Bayes Sınıflandırıcısı Tahmin Matrisi incelendiğinde 1, 4, 5, 6, 8, 11, 12, 15, 17 numaralı çalışma durumlarının yanlış tahmin edildiği görülmüştür. Diğer sınıflara ait verilerin yüksek oranla doğru tahmin edildiği gözlemlenmiştir.

Şekil 6.40'da Rastgele Orman Algoritması Tahmin Matrisi incelendiğinde 0, 2, 3, 7, 9, 10, 14, 16, 18 numaralı çalışma durumlarının doğru tahmin edildiği gözlemlenmiştir. Diğer sınıflara ait veriler yanlış tahmin edilmiştir.

Şekil 6.41'de Yapay Sinir Ağları Tahmin Matrisi incelendiğinde 0, 2, 3, 5, 6, 8, 9, 10, 13, 15, 16, 17, 18 numaralı çalışma durumlarının doğru tahmin edildiği gözlemlenmiştir. Diğer sınıflara ait veriler yanlış tahmin edilmiştir.



## 7. SONUÇLAR VE ÖNERİLER

### 7.1. Sonuçlar

Çalışmada ağır vasıta hava kompresörü arızaları sınıflandırılarak test düzeneği vasıtasıyla belirlenen arızalar manuel olarak meydana getirilmiş ve verileri kayıt altına alınmıştır. Kayıt altına alınan veriler belirlenen makine öğrenmesi algoritma modellerinin oluşturulmasında kullanılmış ve 10 kat çapraz doğrulama yöntemi ile modellerin genelleştirilmesi sağlanmış, başarı oranlarının artırılması hedeflenmiştir. Elde edilen algoritma modellerinin performans değerlendirme sonuçlarına ulaşabilmek için doğruluk (accuracy), Kappa değeri, kesinlik (precision), duyarlılık (recall), F<sub>1</sub> skoru gibi metriklere bakılmıştır.

Dengeli yapıya sahip veri setlerinde sınıflandırma yapılırken performans kriteri olarak genellikle doğruluk oranı kriterine bakılmaktadır. Dengesiz yapıya sahip veri setinde sadece doğruluk oranına bakmak yanlış fikir sahibi olunmasına sebep olabilmektedir. Bir çalışmada performans kriterleri belirlenirken Duyarlılık, Kesinlik ya da F<sub>1</sub> skoruna bakılmasının uygun olacağından bahsedilmiştir. F<sub>1</sub> skorunun değeri ne kadar yüksekse model doğruluğunun o kadar başarılı olabileceği belirtilmiştir (Işık, 2019).

Algoritmalarda yapılan işlemler ve incelemeler sonucunda elde edilen bulgular;

- Destek vektör makineleri için Radyal Tabanlı Fonksiyon Kerneli kullanılmış, ağır vasıta hava kompresörü verilerine göre optimizasyonu yapılmıştır.
- K-en yakın komşu algoritması için dört farklı uzaklık ölçütü kullanılmış, Öklid ile Minkowski uzaklık ölçütleri aynı sonuçları verdiği için Minkowski uzaklık ölçütü sonuçları ayrıca verilmemiştir. Tüm uzaklık ölçütlerine göre komşu sayısı arttıkça algoritmanın doğru tahminde bulunma olasılığı azalmaktadır.
- Naive Bayes sınıflandırıcısı için Bernoulli, Multinomial, Gaussian olmak üzere üç farklı çözüm yaptırılmıştır. Test veri setinde Gaussian Naive Bayes sınıflandırıcısının %94.60, Multinomial Naive Bayes Sınıflandırıcısının

%12.30, Bernoulli Naive Bayes Sınıflandırıcısının %5.20 doğruluk oranına sahip olduğu gözlemlenmiştir.

- Rasgele Orman Algoritması bu veriler için optimize edilmiş ve parametre değerleri paylaşılmıştır. Test veri setinde Rastgele Orman Algoritmaları %99.30, DVM Radyal Tabanlı Fonksiyon kerneli %100 doğruluk oranına sahip olmuştur.
- Yapay sinir Ağları için denemeler yapılmış ve yapılan denemelerde en iyi sonucu veren fonksiyon, gizli katman sayıları, optimizasyon seçimi ve maliyet fonksiyonu seçilmiştir. 2000 iterasyon sonucunda test verilerinde %99.80 başarı oranına sahip tahmin mekanizması oluşturulmuştur.

Çizelge 6.2’de makine öğrenmesi algoritmalarının eğitim verileri için sınıflandırma performansları (doğruluk, kesinlik, duyarlılık,  $F_1$  skoru, Kappa değeri) incelenmiştir. Hatalı tahmin edilen veri sayıları incelendiğinde, DVM Radyal Tabanlı Fonksiyon Kerneli ile K-en yakın komşu algoritması tüm uzaklık ölçütlerinin, başarılı olarak hatalı tahminde bulunmadığı gözlemlenmiştir. Buna karşın belirtilen makine öğrenmesi algoritmalarının TPR matrisleri paylaşılmıştır.

Çizelge 6.3’de makine öğrenmesi algoritmalarının test verileri için sınıflandırma performansları (doğruluk, kesinlik, duyarlılık,  $F_1$  skoru, Kappa değeri) incelenmiştir. Hatalı tahmin edilen veri sayıları incelendiğinde, DVM Radyal Tabanlı Fonksiyon Kerneli algoritmasının en başarılı tahminlemeyi yaptığı görülmektedir. Hatalı tahmin edilen veri sayısı 2’dir. Belirtilen algoritmaların hepsi için karmaşıklık matrisleri paylaşılmıştır. Hangi verilerin hatalı tahmin edildiği cevap grafiklerinde gösterilmektedir.

K-nn algoritmasında eğitim olayı olmamakla birlikte analitik olarak izlenebilmektedir. Avantajlarına rağmen, veri sayısının artmasıyla yüksek bellek alanına ihtiyaç duymakta, işlem yükü ve maliyetin önemli oranda artması algoritma performansının k komşu sayısı gibi parametreye ve özelliklere bağlı olarak etkilenmesi beraberinde dezavantajları getirmektedir (Taşcı ve Onan, 2016).

Yapay sinir ağları kullanılacak aktivasyon fonksiyonları, optimizasyon ve loss fonksiyonları göz önüne alındığında başarı oranları artmaktadır. 2000 iterasyon sonucunda 5 katmanlı yapay sinir ağı yüksek performans göstermiştir. Toplam test verisi sayısı 4798’dir. Eğitim verisi için 19189 veri kullanılmıştır. Farklı bir zamanda aynı kompresör ile gerçekleştirilen testlerde etiket değeri bilinen veriler kayıt altına

alınmış, makine öğrenmesi yöntemleri ile hangi sınıfa dahil olabileceklerinin yüzdesel oranları tahmin matrisleri vasıtasıyla paylaşılmıştır.

**Çizelge 7.1.** Makine Öğrenmesi Yöntemleri Sınıflandırma ve Tahmin Başarıları

Makine Öğrenmesi Algoritmaları	Tip	Eğitim Veri Seti Doğruluk (%)	Eğitim Veri Seti Hatalı Tahmin Edilen Veri Sayısı	Test Veri Seti Doğruluk (%)	Test Veri Seti Hatalı Tahmin Edilen Veri Sayısı	Bilinmeyen Veri setinde Yanlış Tahmin Durumu
Destek Vektör Makineleri	Radyal Tabanlı Fonksiyon Kerneli	%100	0	%99.99	2	2
K-En Yakın Komşu Algoritması	Öklid Ölçütü	%100	0	%99.20	40	1
	Manhattan Ölçütü	%100	0	%99.50	22	1
	Chebyshev Ölçütü	%100	0	%98.60	66	3
Naive Bayes Sınıflandırıcıları	Bernoulli Naive Bayes Sınıflandırıcısı	%5.90	18062	%5.20	4550	17
	Multinomial Naive Bayes Sınıflandırıcısı	%13.20	16654	%12.30	4210	15
	Gaussian Naive Bayes Sınıflandırıcısı	%95	961	%94.60	258	9
Rastgele Orman Algoritmaları	Rastgele Orman Algoritmaları	%99.20	149	%99.30	35	10
Yapay Sinir Ağları	Yapay Sinir Ağları	%99.80	38	%99.80	9	6

Eğitim ve test verileri için algoritma doğruluk oranları incelendiğinde en başarılı tahmin sonucunu Destek Vektör Makineleri Radyal Tabanlı Fonksiyon Kerneli ile verdiği görülmüştür. Algoritmalar Çizelge 7.1’de detaylı incelenip sınıflandırma başarılarına yönelik sıralandığı durumda;

1. Destek Vektör Makineleri Radyal Tabanlı Fonksiyon Kerneli
2. K-En Yakın Komşu Algoritması Manhattan Ölçüsü
3. K-En Yakın Komşu Algoritması Öklid Ölçüsü

4. K-En Yakın Komşu Algoritması Chebyshev Ölçüsü
5. Yapay Sinir Ağları
6. Rastgele Orman Algoritmaları
7. Gaussian Naive Bayes Sınıflandırıcısı
8. Multinomial Naive Bayes Sınıflandırıcısı
9. Bernoulli Naive Bayes Sınıflandırıcısı

gibi bir sonuçla karşılaşılacaktır. Şekil 6.19 ile Şekil 6.20' de Bernoulli Naive Bayes ile Multinomial Naive Bayes Sınıflandırıcısına ait sınıflandırma karmaşıklık matrisleri algoritmaların başarılı bir tahminleme yapamadığını göstermektedir. Tüm algoritmalarda aynı veri seti kullanılmıştır.

Karmaşıklık matrisleri detaylı incelendiğinde;

- Bernoulli Naive Bayes Sınıflandırıcısı test veri setinin tamamının 18 numaralı çalışma durumu olduğu tahmininde bulunmuştur.
- Multinomial Naive Bayes Sınıflandırıcısı ise sınıflandırma karmaşıklık matrisinde 0, 3, 5, 6, 7, 8, 10, 13, 15 numaralı çalışma durumlarını tahmin edememiştir. Algoritma test veri seti içerisinde bulunan bu çalışma durumlarına ait verileri diğer çalışma durumları olarak görmüş ve tahminleme işlemini o şekilde tamamlamıştır.

Şekil 6.19 ile Şekil 6.20' de bulunan karmaşıklık matrislerinde boş görülen bölümlere ait çalışma durumlarının karşılıklarının olmaması, algoritmaların o çalışma durumlarına ait verilerin hiç birini doğru tahmin edememesi gibi sebepler karmaşıklık matrisinin tamamlanamamasına sebep olmuştur.

Veri sayısının artırılması ile algoritma sınıflandırma başarılarının değişme durumları söz konusu olacak ve yukarıda yapılan sıralama da buna bağlı olarak değişebilecektir. Verilerin sürekli okunarak hava kompresörünün çalışma anındaki durumunun incelenmesi istendiği durum ile kayıtlı veriye göre çalışma durumu tahmini gibi durumlar için kullanılacak algoritma seçimi her zaman değişebilecektir. Bu çalışma ile ağır vasıta hava kompresörü çalışma durumuna ait kayıt edilmiş veriler için algoritmaların sınıflandırma başarıları incelenmiş ve kullanılacak algoritmalar listelenmiştir.

## 7.2. Öneriler

Aktif çalışan sistemlerin zamanla bakımsız bırakılması ya da plansız bakım periyotları maddi ve iş gücü zamanında kayıplara yol açmaktadır. Sistemlerde arıza göstergesi olabilecek durumların yaşanmaması bakımların ileri tarihlere ertelenmesine sebep olurken sistemin hangi bölgesinde arızanın gerçekleşebileceğini bilmek zaman ve maddi açıdan kullanıcıları memnun etmektedir.

Bakım zamanının bilinebilmesi ya da o durumun yaşanabileceğinin öncesinden bilinmesi, kullanıcıların planlı davranış sergilemesi ve işlerin zamanında çözülmesi bakımından önem arz etmektedir.

Teknolojinin ilerlemesiyle birlikte aktif çalışan sistemlerin düzeninin bozulmaması, beklenmedik arıza maliyetlerinin ve sürelerinin oluşmaması adına veriler ile tahminler yapılması ve gerçek çalışma şartlarının doğrulanması gibi konularda araştırmalar yapılmaktadır. Sistemden alınan verinin anlamlı hale getirilmesi, anlamlı verinin algoritma alt yapısının oluşturulmasında kullanılması ve gerçek yaşam şartlarına algoritmaların alıştıırılması ve daha doğru sonuçları verecek algoritma arayışları bu konuda yapılacak çalışmaların desteklenmesine katkı sağlamaktadır.

Mevcut veri havuzu için kullanılabilir çoğu algoritma farklı parametrelerle başarılı sonuçlar verebilecektir. Ancak tanınmayan yeni veri girişlerinde tüm algoritmaların aynı başarı oranlarına sadık kalamayabileceği, işlem ve hesaplama süresinin uzun olabileceği ve yüksek bellek gerektirebileceği bilinmelidir. Aktif çalışan sistemler için anlık veri girişi ile anlık cevap alınabilecek modeller kullanılmalı ki maliyet, süre, bellek sorunları ile karşılaşılmasın.

Ağır vasıta hava kompresörü verileri için sürekli veri alma yöntemi ile yeni verilerde yapay sinir ağlarının kullanımının optimum katman sayısı ile nöron sayılarının belirlenmesi sonucunda başarı oranını artıracak yapılan araştırmalar sonucunda görülmektedir. Bu çalışma mekanik makinelerin çalışma anındaki durumlarının incelenmesi için örnek teşkil etmekte ve hava kompresörü arızalarının tahmin edilmesinde makine öğrenmesi algoritmalarının etkili sonuçlar verebildiğini göstermektedir.

## KAYNAKLAR

- Acungil, M., 2020, Nörobilimde makine öğrenmesi ve geleceği, Yüksek Lisans Tezi, Üsküdar Üniversitesi, Sağlık Bilimleri Enstitüsü.
- Ahmed, M., Baqqar, M., Gu, F. ve Ball, A., 2012, Fault detection and diagnosis using Principal Component Analysis of vibration data from a reciprocating compressor, *UKACC International Conference on Control*, 461-466.
- Akar, Ö. ve Güngör, O., 2012, Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması, *Jeodezi ve Jeoinformasyon Dergisi*, (106), 139-146.
- Almasi, A., 2009, Reciprocating compressor optimum design and manufacturing with respect to performance, reliability and cost, *World Academy of Science, Engineering Technology*, 52, 48-53.
- AlThobiani, F. ve Ball, A., 2014, An approach to fault diagnosis of reciprocating compressor valves using Teager–Kaiser energy operator and deep belief networks, *Expert Systems with Applications*, 41 (9), 4113-4122.
- Anonim,2020, Rastgele Orman (Random Forest) algoritması, <https://devhuntery.wordpress.com/2018/09/20/rastgele-ormanrandom-forest-algoritmasi/>, [Ziyaret Tarihi : 14.06.2020].
- Anonymous, 2016, Room sensors for relative humidity (high accuracy) and temperature QFA31.. Building Technologies. SIEMENS, Siemens Switzerland Ltd. Building Technologies Division International Headquarters: 1-8.
- Anonymous, 2020a, Single chamber air dryer+unloader, <https://www.wabco-customercentre.com/catalog/en/9324000240?cclcl=en>, [Ziyaret Tarihi:05.07.2020].
- Anonymous,2020b,Magna325-100,[https://product-selection.grundfos.com/products/magna/magna3/magna3-25-10097924247?tab=variant-curves & pumpsystemid = 1153047778](https://product-selection.grundfos.com/products/magna/magna3/magna3-25-10097924247?tab=variant-curves&pumpsystemid=1153047778), [Ziyaret Tarihi : 23.06.2020].
- Aydın, D. B., 2016, Yenidoğan yoğun bakım ünitesinde idrar yolu enfeksiyonunu tanımlama için yapay sinir ağı tabanlı bir karar destek sisteminin geliştirilmesi Yüksek Lisans Tezi, Bozok Üniversitesi, Fen Bilimleri Enstitüsü
- Aydiner, M. Ş., Ünüvar, E. ve Kalyoncu, M., 2019a, Bir ağır vasıta hava kompresörünün termodinamik davranışının deneysel incelenmesi, *The International Conference of Materials and Engineering Technology*, 475-486.
- Aydiner, M. Ş., Ünüvar, E. ve Kalyoncu, M., 2019b, Bir ağır vasıta hava kompresörünün performansının deneysel olarak incelenmesi, *International Symposium on Automotive Science and Technology*, 388-397.
- Ayhan, S. ve Erdoğan, Ş. J. E. O. Ü. İ. v. İ. B. D., 2014, Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi, 9 (1), 175-201.
- Bayır, F., 2006, Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü.
- Becerra, J., Jimenez, F., Torres, M., Sanchez, D. ve Carvajal, E., 2011, Failure analysis of reciprocating compressor crankshafts, *Engineering Failure Analysis*, 18 (2), 735-746.
- Bendix, 2004, Advanced troubleshooting guide for air brake compressors: 1-24.
- Bendix, 2010, 720cc twin cylinder compressor for international maxxforce™ big bore engines SD-01-3131, Service Data, 1-38.
- Bremse, K., 2007, Kompresör yağ taşınımı. Servis Haberleri, Knorr-Bremse Ticari Araç Sistemleri, 1-14.

- Bremse, K., 2008, Health for your air compressor, Service Instructions, Knorr-Bremse 1-2.
- Cabrera, D., Sancho, F., Long, J., Sánchez, R.-V., Zhang, S., Cerrada, M. ve Li, C., 2019, Generative adversarial networks selection approach for extremely imbalanced fault diagnosis of reciprocating machinery, *IEEE Access*, 7, 70643-70653.
- Cömert, B., 2016, Alın bölgesinden alınan elektrookülogram (EOG) işaretleri için ölçüm devresi tasarımı ve sınıflandırılması, Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü.
- Dewesoft, 2019, Sirius data acquisition system, <https://dewesoft.com/products/daq-systems/sirius>, [Ziyaret Tarihi : 25.05.2020].
- Druck, K., 2019, Piezoresistive pressure transmitters for industrial applications, Keller AG, 1-2.
- Elhaj, M., Gu, F., Ball, A., Albarbar, A., Al-Qattan, M. ve Naid, A., 2008, Numerical simulation and experimental study of a two-stage reciprocating compressor for condition monitoring, *Mechanical Systems Signal Processing*, 22 (2) , 374-389.
- Elimko, 2019, Termokupllar ile ilgili genel bilgiler, 1-15.
- Elmas, Ç., 2018, Yapay zeka uygulamaları, Seçkin Akademik ve Mesleki Yayınlar, p. 1-479.
- Elmas, M., 2012, Destek vektör makineleri iel fiyat tahminleri ve kuyumculuk sektöründe bir uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü.
- Fan, Y., Nowaczyk, S. ve Rögnvaldsson, T., 2015, Evaluation of self-organized approach for predicting compressor faults in a city bus fleet, *Procedia Computer Science*, 447-456.
- Farzaneh-Gord, M. ve Khoshnazar, H., 2016, Valve fault detection for single-stage reciprocating compressors, *Journal of Natural Gas Science Engineering*, 35 , 1239-1248.
- Fırat, M. ve Güngör, M., 2004, Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi, *Teknik Dergi*, 15 (73).
- Gül, E., Ünüvar, E. ve Kalyoncu, M., 2019, Ağır vasıta hava kompresörü arızaları ve performansa etkilerinin deneysel incelenmesi, *International Symposium on Automotive Science and Technology*, 449-455.
- Gül, E. ve Kalyoncu, M., 2020, Ağır vasıta hava kompresörü piston segmanı aşınması durumlarında K-en yakın komşu algoritmasının sınıflandırma performansının incelenmesi, *Avrupa Bilim ve Teknoloji Dergisi*, 78-90.
- Gül, E., Kalyoncu, M. ve Kula, G., 2020, Ağır vasıta hava kompresörlerinde piston segmanlarından yağ verme problemlerinin rastgele orman algoritması ile tahmini *The International Conference of Materials and Engineering Technology*, Gaziantep, 503-514.
- Gültepe, Y., 2019, Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme, *Avrupa Bilim ve Teknoloji Dergisi* (16), 8-15.
- Günyeli, T., 2019, Ağır ticari araçlarda el freni devresinin elektriksel ve pnömatik sinyal ile birlikte kontrolü, Yüksek Lisans Tezi, İstanbul Üniversitesi, Cerrahpaşa Lisansüstü Eğitim Enstitüsü
- Işık, M., 2019, Müşteri yorumları üzerinde metin analitiği çalışmaları ve yorumların makine öğrenmesi algoritmaları ile modellenmesi, Yüksek Lisans Tezi, İstanbul Medeniyet Üniversitesi, Fen Bilimleri Enstitüsü.
- Kabil, K., 2019, Makine öğrenmesinde ayırık öbekleme ve sınıflandırma algoritmaları Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

- Kaplan, S., 2014, Ağır vasıta havalı fren sistemleri, standart testleri ve güvenlik kriterleri yönünden değerlendirilmesi Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü
- Kavzoğlu, T. ve Çölkesen, İ. J. H. D., 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, 144 (7), 73-82.
- Kaya, D., Türk, M. ve Kaya, T., 2018, En yakın komşu algoritması kullanılarak EEG sinyallerine boyut azaltmanın etkilerinin incelenmesi, *El-Cezerî Journal of Science and Engineering*, 5 (2), 591-595.
- Kompresör,Ü., 2012, Kompresör arızaları, [http://www.unalankompresor.com/kompresor\\_arizalari.html](http://www.unalankompresor.com/kompresor_arizalari.html), [Ziyaret Tarihi : 4 Kasım 2019].
- Kula, G., 2020, Ağır Hizmet Tipi Araçlardaki Hava Fren Kompresörü ve Hava Hattının Yeni Teknolojiye Entegresinin Araştırılması Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Kula, G. ve Ciniviz, M., 2020, Atmospheric and turbocharged experimental investigation of heavy vehicle compressor air inlet line, *International Journal of Automotive Science Technology*, 4 (4), 213-222.
- Loukopoulos, P., Sampath, S., Pilidis, P., Zolkiewski, G., Bennett, I., Duan, F., Sattar, T. ve Mba, D., 2017, Reciprocating compressor prognostics, *International Conference Design and Modeling of Mechanical Systems*, 313-323.
- Loukopoulos, P., Zolkiewski, G., Bennett, I., Sampath, S., Pilidis, P., Duan, F., Sattar, T. ve Mba, D., 2019, Reciprocating compressor prognostics of an instantaneous failure mode utilising temperature only measurements, *Applied Acoustics*, 147, 77-86.
- Megep, 2013, Motorlu Araçlar Teknolojisi Fren sistemleri, Milli Eğitim Bakanlığı, 1-169.
- Mühendislik, R., 2019, Krypton, <https://rnc.com.tr/krypton/>, [Ziyaret Tarihi : 25.05.2020].
- Nowaczyk, S., Byttner, S. ve Prytz, R., 2012, Ideas for fault detection using relation discovery, *The 27th annual workshop of the Swedish Artificial Intelligence Society (SAIS), 14–15 May 2012, Örebro, Sweden*, 1-6.
- Nowaczyk, S., Prytz, R., Rögnvaldsson, T. ve Byttner, S., 2013, Towards a machine learning algorithm for predicting truck compressor failures using logged vehicle data, *12th Scandinavian Conference on Artificial Intelligence, Aalborg, Denmark, November 20–22, 2013*, 205-214.
- Öztanır, O., 2018, Makine öğrenmesi kullanılarak kestirimci bakım, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü.
- Peker, M., Özkaraca, O. ve Kesimal, B., 2017, Enerji tasarruflu bina tasarımı için ısıtma ve soğutma yüklerini regresyon tabanlı makine öğrenmesi algoritmaları ile modelleme, *Bilişim Teknolojileri Dergisi*, 10 (4), 443-449.
- Pichler, K., Lughofer, E., Pichler, M., Buchegger, T., Klement, E. P. ve Huschenbett, M., 2016, Fault detection in reciprocating compressor valves under varying load conditions, *Mechanical Systems Signal Processing*, 70, 104-119.
- Prytz, R., Nowaczyk, S., Rögnvaldsson, T. ve Byttner, S., 2013, Analysis of truck compressor failures based on logged vehicle data, *9th International Conference on Data Mining, Las Vegas, Nevada, USA, July 22–25, 2013*.
- Prytz, R., 2014, Machine learning methods for vehicle predictive maintenance using off-board and on-board data, Doctoral Dissertation, *Halmstad University Press*.



- Ser, G. ve Bati, C. T., 2019, Derin sinir ağıları ile en iyi modelin belirlenmesi: mantar verileri üzerine keram uygulaması, Yüzüncü Yıl Üniversitesi, *Tarım Bilimleri Dergisi*, 29 (3), 406-417.
- Servis, R., 2010, Kompresörlerde arıza bulma, <http://rittalservisi.blogspot.com/2010/11/bolum-2-kompresorlerde-ariza-bulma.html>, [Ziyaret Tarihi : 4 Kasım 2019].
- Szyber, A., Chechliniski, L., Syfert, M., Wnuk, P., Lipnicki, P. ve Lewandowski, D., 2018, Analysis of Applicability of Deep Learning Methods in Compressor Fault Diagnosis, *DX@ Safeprocess*.
- Şahin, E., 2018, Makine öğrenme yöntemleri ve kelime tekniği ile istenmeyen e-posta / e-posta sınıflaması, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü
- Şahin, Ö., 2017, iOS platformunda görme engelliler için tl tanıma uygulaması, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Şanlıtürk, E., 2018, Makine öğrenme algoritmalarıyla hatalı ürün tahmini Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Taşcı, E. ve Onan, A., 2016, K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi, *Akademik Bilişim*.
- Townsend, J. ve Badar, M. A., 2018, Impact of condition monitoring on reciprocating compressor efficiency, *Journal of Quality in Maintenance Engineering*.
- Tuhovcak, J., Hejcik, J. ve Jicha, M., 2016, Comparison of heat transfer models for reciprocating compressor, *Applied Thermal Engineering*, 103, 607-615.
- Ünüvar, E., Gül, E., Aydın, M. Ş. ve Kalyoncu, M., 2019, Investigation of the effect of intake and exhaust valve dimensions on performance for heavy duty vehicle air compressors, *The International Aluminium-Themed Engineering and Natural Sciences Conference "IATENS-2019"* Seydişehir / Konya, 556-559.
- Üstüner, M., 2013, Destek vektör makineleri yöntemi ile arazi kullanımı sınıflandırılmasında kernel fonksiyonlarına ait karşılaştırmalı parametre duyarlılık analizi: Rapideye ve spot örneği, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi*, Fen Bilimleri Enstitüsü.
- Verma, N. K., Sevakula, R. K., Dixit, S. ve Salour, A., 2015, Intelligent condition based monitoring using acoustic signals for air compressors, *IEEE Transactions on Reliability*, 65 (1), 291-309.
- Wabco, 2020, Twin-Cyl.Compressor 636cc, [https://www.wabco-customercentre.com/catalog/tr\\_TR/9125101040?cartID=](https://www.wabco-customercentre.com/catalog/tr_TR/9125101040?cartID=), [Ziyaret Tarihi : 23.06.2020].
- Wang, Y., Xue, C., Jia, X. ve Peng, X., 2015, Fault diagnosis of reciprocating compressor valve with the method integrating acoustic emission signal and simulated valve motion, *Mechanical Systems Signal Processing*, 56, 197-212.
- Widodo, A. ve Yang, B.-S., 2007, Support vector machine in machine condition monitoring and fault diagnosis, *Mechanical systems signal processing*, 21 (6), 2560-2574.
- Yıldırım, S., 2006, Arıza teşhisinde destek vektör makinelerinin kullanımı Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü.
- Zhao, B., Jia, X., Zhang, Y., Feng, J. ve Peng, X., 2017, Investigation on transient temperature of a reciprocating compressor based on a two-thermocouple probe, *International Journal of Thermal Sciences*, 122, 313-325.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Emre GÜL  
**Uyruğu** : Türkiye Cumhuriyeti  
**Doğum Yeri ve Tarihi** : GÜCE/1994  
**Telefon** : +90 539 638 87 30  
**E-Posta** : emregl2816@gmail.com  
**Orcid** : 0000-0003-0348-4904

### EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise	Mimar Sinan : Anadolu Teknik Lisesi	Yıldırım	BURSA	2012
Üniversite	: Selçuk Üniversitesi	Selçuklu	KONYA	2018
Yüksek Lisans :	Konya Teknik Üniversitesi	Selçuklu	KONYA	Devam ediyor

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2018-Halen	Yıldız Pul Otomotiv Motor Parçaları Sanayi A.Ş.	Ar-Ge Mühendisi

### UZMANLIK ALANI

Ağır Vasıta Hava Kompresörleri, Arıza Tespiti, Bilgisayar Destekli Tasarım, Deneysel Tasarım, Makine Öğrenmesi, Veri Toplamaya Yönelik Test Sistemleri, IATF 16949: 2016 Kalite Yönetim Sistemi, Proje Yönetimi, Optimizasyon.

### YABANCI DİLLER

İngilizce

### PROJELER

<b>Destek Programı</b>	TÜBİTAK - 1501 Sanayi Ar-Ge Projeleri Destekleme Programı
<b>Proje No / Görevi</b>	3180981 / Proje Yürütücüsü
<b>Proje Adı</b>	Otomotiv Sektörü İçin Kontrolcü ve Veri Depolamaya Sahip Elektrikli Modüler Hava Tedarik Sistemi Geliştirilmesi

**YAYINLAR**

**GÜL, E., ÜNÜVAR, E., KALYONCU, M.**, 2019, “Ağır Vasıta Hava Kompresörü Arızaları ve Performansa Etkilerinin Deneysel İncelenmesi, The 1st International Symposium on Automotive Science and Technology, “Isastech 2019“, 449-455.

**ÜNÜVAR, E., GÜL, E., AYDINER, M. Ş., KALYONCU, M.**, 2019, “Investigation of the Effect of Intake and Exhaust Valve Dimensions on Performance for Heavy Duty Vehicle Air Compressors”, The International Aluminium-Themed Engineering and Natural Sciences Conference “Iatens-2019“, 556-559.

**GÜL, E., KALYONCU, M.**, 2020, “Ağır Vasıta Hava Kompresörü Piston Segmanı Aşınması Durumlarında K-En Yakın Komşu Algoritmasının Sınıflandırma Performansının İncelenmesi”, Avrupa Bilim ve Teknoloji Dergisi, 78-90, DOI: 10.31590/ejosat.802958.

**GÜL, E., KALYONCU, M., KULA, G.**, 2020, “Ağır vasıta hava kompresörlerinde piston segmanlarından yağ verme problemlerinin rastgele orman algoritması ile tahmini”, The International Conference of Materials and Engineering Technology, 503-514.