

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GEMİ İNŞAATI VE GEMİ MAKİNELERİ MÜHENDİSLİĞİ ANABİLİM DALI

**GEMİ ANA MAKİNE YANMA İŞ ELEMANLARI ARIZALARININ
TAHMİNLENMESİ**

DOKTORA TEZİ

Selim BAŞTÜRK

NİSAN 2025

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GEMİ İNŞAATI VE GEMİ MAKİNELERİ MÜHENDİSLİĞİ ANABİLİM DALI

**GEMİ ANA MAKİNE YANMA İŞ ELEMANLARI ARIZALARININ
TAHMİNLENMESİ**

Selim BAŞTÜRK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (GEMİ İNŞAATI VE GEMİ MAKİNELERİ MÜHENDİSLİĞİ)
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 25 / 03 / 2025

Tezin Savunma Tarihi : 10 / 04 / 2025

Tez Danışmanı : Prof. Dr. Sercan EROL

Trabzon 2025

ÖNSÖZ

“Gemi Ana Makine Yanma İş Elemanları Arızalarının Tahminlenmesi” isimli bu tez çalışması Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Gemi İnşaatı ve Gemi Makineleri Mühendisliği Anabilim Dalı, Doktora Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. Sercan EROL’a teşekkürü bir borç bilirim. Ayrıca, eğitim öğretim hayatımda katkısı olan tüm hocalarıma ve ortak olarak çalışmalar yürüttüğümüz ve tez çalışması süresinde de hiçbir yardımdan kaçınmayan arkadaşlarıma teşekkür ederim.

Tez çalışması sürecinde bana desteklerini esirgemeyen Deniz Ulaştırma İşletme Mühendisliği Bölümü’ndeki tüm değerli hocalarıma ve asistan arkadaşlarıma teşekkürlerimi sunarım.

Son olarak, doğduğum günden beri elimi hiç bırakmayan, hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Neriman BAŞTÜRK ve babam Selahattin BAŞTÜRK, eşim Rabia BAŞTÜRK’e ve kardeşlerime teşekkür eder, minnettarlığımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Selim BAŞTÜRK

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Gemi Ana Makine Yanma İş Elemanları Arızalarının Tahminlenmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Sercan Erol’un sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 10/04/2025

Selim BAŞTÜRK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	X
SEMBOLLER VE KISALTMALAR DİZİNİ	XI
1. GENEL BİLGİLER	1
1.1. Gemi Makinelerinde Bakım Tutum Faaliyetleri ve ISM Kod Gereklilikleri	3
1.2. Gemilerde Planlı Bakım Tutumda ISM Kod Gereklilikleri	4
1.3. Gemi Dizel Makinelerinde Yanma ve Ana Makine Yanma İş Elemanları	5
1.3.1. Gemi Dizel Makinelerinde Yanma	5
1.3.2. Gemi Ana Makine Yanma İş Elemanları	7
1.4. Gemi Ana Makine Yanma İş Elemanlarını Arızaya Sevk Eden Faktörler.....	12
1.4.1. Gemi Yakıtları.....	12
1.4.2. Sülfür.....	13
1.4.3. Mikro Karbon Kalıntısı.....	15
1.4.4. Katalitik İnce Partiküller	15
1.4.5. Vanadyum	17
1.4.6. Yakıt İçerisindeki Diğer İçerikler	18
1.4.7. Arızaya Neden Olan Diğer Faktörler	19
1.5. Literatür Araştırması	19
1.6. Tez Çalışmasının Amacı ve Kapsamı	23
1.6.1. Amaç	23
1.6.2. Kapsam.....	23
2. YAPILAN ÇALIŞMALAR.....	24
2.1. Giriş.....	24
2.2. Veri Setinden Elde Edilen Gemi Ana Makine Yanma İş Elemanları Arızaları.....	26

2.2.1.	Ana Makine Enjektörde Görülen Arızalar	27
2.2.2.	Ana Makine Yakıt Pompasında Görülen Arızalar	30
2.2.3.	Ana Makine Silindir Başlığında Görülen Arızalar	32
2.2.4.	Ana Makine Pistonunda Görülen Arızalar	36
2.3.	Çalışmada Kullanılan Yöntemler	38
2.3.1.	Tek Örneklem Kolmogorov Smirnov (KS) Testi	39
2.3.2.	Mann Whitney U Testi	39
2.3.3.	Tek Örneklem Binom Testi	40
2.3.4.	Yapay Sinir Ağları	40
2.3.5.	WEKA Programı	43
2.3.6.	K En Yakın Komşu Algoritması (KNN)	46
2.3.7.	Çok Katmanlı Algılayıcı	47
2.3.8.	Naive Bayes	49
2.3.9.	Rastgele Orman	50
2.3.10.	Sıralı Minimum Optimizasyon	51
2.4.	Modelleme Çalışması	52
3.	BULGULAR VE TARTIŞMA	54
3.1.	Arızaların İncelenmesi	54
3.2.	Yakıt Değerlerinin Arızalara Etkisinin İstatistikî Bulguları	60
3.3.	Yapay Sinir Ağları ile Çalışma Saati Bazlı Arıza Tahminlemesi	61
3.4.	WEKA Programı ile Durum Bazlı Arıza Tahminlemesi	66
4.	SONUÇLAR	73
5.	ÖNERİLER	75
6.	KAYNAKLAR	78
7.	EKLER	84
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

GEMİ ANA MAKİNE YANMA İŞ ELEMANLARI ARIZALARININ TAHMİNLENMESİ

Selim BAŞTÜRK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Gemi İnşaatı ve Gemi Makineleri Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Sercan EROL
2025, 83 Sayfa, 14 sayfa Ek

Gemi ana makinelerinde yanlış bakım tutum faaliyetleri, yağlama yağı ve yakıt büyük çaptaki arızalara neden olan temel faktörlerdir. Bu arızalar sonucunda ciddi maddi kayıplar ortaya çıkarken, gemilerin arıza esnasında bulunduğu deniz trafiği düşünüldüğünde (manevra esnasında, kanal-boğaz geçişi) bu arızalar seyir güvenliğini de olumsuz etkilemektedir. Bu çalışmada makine arızalarına etki eden ana makine ve yakıt faktörleri istatistiki olarak belirlenip, arızaların zamansal tahminlenmesi amaçlanmıştır. İstatistiki sonuçlara bakıldığında arızalara sebep olan faktörler; yakıt içerisinde bulunan sülfür oranı, vanadyum, katalitik ince partiküller ve mikro karbon kalıntısı olarak belirlenmiştir. Veri setindeki arızaların oluşma saatlerinin normal dağılım göstermemesi sonucunda Yapay Sinir Ağları ile zamansal tahminlemede istenilen korelasyon analiz değeri düşük kalmaktadır ($R=0,67289$). Bundan ötürü durum bazlı (arıza var yok şeklinde) arıza tahminlemesi için WEKA programı vasıtasıyla diğer makine öğrenme algoritmaları kullanılmıştır. Sonuç olarak durum bazlı arıza tahminlemede Rastgele Orman modelin genel doğruluğunda %94,7 oranında başarı sağlamıştır.

Anahtar Kelimeler: Gemi ana makine, Arıza, Makine öğrenme, Tahminleme, Sülfür

PhD. Thesis

SUMMARY

ESTIMATING FAILURE TIMES OF SHIP MAIN ENGINE COMBUSTION PARTS

Selim BAŞTÜRK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Department of Naval Architecture and Marine Engineering
Supervisor: Prof. Sercan EROL
2025, 83 Pages, 14 Pages Appendix

Incorrect maintenance practices in marine main engines, along with lubrication oil and fuel-related issues, are the primary factors leading to major failures. These failures not only result in significant financial losses but also negatively impact navigational safety, especially considering the maritime traffic conditions at the time of failure (e.g., during maneuvering, canal or strait transits). This study aims to statistically identify the main engine and fuel-related factors contributing to engine failures and to forecast the timing of such failures. According to the statistical findings, the factors causing these failures include the sulfur content in the fuel, vanadium, catalytic fine particles, and micro carbon residue. Due to the failure times in the dataset not exhibiting a normal distribution, the desired correlation analysis value could not be achieved in temporal prediction using Artificial Neural Networks ($R = 0.67289$). Therefore, other machine learning algorithms were utilized via the WEKA software for condition-based fault prediction (i.e., presence or absence of failure). As a result, the Random Forest model achieved a high overall accuracy of 94.7% in condition-based fault prediction.

Key Words: Ship main engine, Failure, Machine learning, Prediction, Sulfur

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Bakım çeşitleri	3
Şekil 2. Gemi ana makine yanma iş elemanları	8
Şekil 3. Enjektör nozul ve yuva kısmında deformasyon.....	9
Şekil 4. Aşınmış yakıt pompası pistonu (plencer)	9
Şekil 5. Yanmaya bağlı egzoz valfi deformasyonu	10
Şekil 6. Piston ve kırık segmanlar.....	11
Şekil 7. Silindir gömleği aşınması	12
Şekil 8. Dökme demir silindir gömleği mikroskopik görüntüsü	17
Şekil 9. Arızaların dağılımı.....	26
Şekil 10. Enjektör arızalarının çalışma saatine göre dağılımı.....	29
Şekil 11. Yakıt pompası arızalarının çalışma saatine göre dağılımı.....	32
Şekil 12. Silindir başlığı arızalarının çalışma saatine göre dağılımı.....	35
Şekil 13. Piston arızalarının çalışma saatine göre dağılımı	38
Şekil 14. MLP katman yapısı	48
Şekil 15. Rastgele orman algoritması iş akış şeması	51
Şekil 16. Çalışmada kullanılacak modelin ana hatları	53
Şekil 17. Yapay sinir ağları ile tahminleme sonucu 1	62
Şekil 18. Yapay sinir ağları ile tahminleme sonucu 2	63
Şekil 19. Yapay sinir ağları ile tahminleme sonucu 3	64
Şekil 20. Yapay sinir ağları ile tahminleme sonucu 4	65
Şekil 21. Doğruluk metriği grafiği.....	67
Şekil 22. Kesinlik metriği grafiği.....	67
Şekil 23. Hassasiyet metriği grafiği	68
Şekil 24. F1 skoru metriği grafiği	69
Şekil 25. ROC alanı metriği grafiği	69
Şekil 26. WEKA programında Rastgele Orman algoritması ekran görüntüsü	70

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. 2015-2017 yılları arasında en maliyetli gemi ana makine arızaları.....	1
Tablo 2. 2015-2017 yılları arasında en maliyetli gemi ana makine arızalarının nedenleri	2
Tablo 3. IMO sülfür emisyon sınır değerleri	14
Tablo 4. Genel makine arızalarının tahminlenmesi ile ilgili yapılan çalışmalar	20
Tablo 5. Gemi makine arızalarının tahminlenmesi ile ilgili yapılan çalışmalar	21
Tablo 6. Veri setindeki gemilerin bilgileri.....	24
Tablo 7. Ana makine enjektör arızaları.....	27
Tablo 8. Ana makine yakıt pompası arızaları	30
Tablo 9. Ana makine silindir başlığı arızaları.....	32
Tablo 10. Ana makine piston arızaları	36
Tablo 11. Enjektör arızalarının analizi.....	54
Tablo 12. Yakıt pompası arızalarının analizi	56
Tablo 13. Silindir başlığı arızalarının analizi.....	57
Tablo 14. Piston arızalarının analizi	59
Tablo 15. Yakıt özellikleri ve arıza varlığı arasındaki korelasyon	60
Tablo 16. Yakıt için arıza varlığına bağlı olarak U değerlerinin hesaplanması.....	61
Tablo 17. Makine öğrenme algoritmaları sonuçları.....	66

SEMBOLLER VE KISALTMALAR DİZİNİ

ABS	: Amerikan klas kuruluşu
CBM	: Durum bazlı bakım
CCAI	: Karbon aromatik indeks değeri
EFN	: Makine dostu yakıt standardı
GT	: Gros tonaj
HFO	: Ağır gemi yakıtı
HT	: Yüksek sıcaklıktaki silindir soğutma suyu
IFO	: Orta düzey viskozitede gemi yakıtı
IMO	: Uluslararası Denizcilik Örgütü
ISM	: Emniyetli yönetim sistemi
KNN	: K-En yakın komşu algoritması
KS	: Kolmogorov-Smirnov testi
MLP	: Çok katmanlı algılayıcı algoritması
NKK	: Japon klas kuruluşu
P	: Olasılık
Pmax	: Silindir içerisindeki maksimum basınç değeri
Pcomp	: Sıkıştırma esnasındaki maksimum basınç değeri
PMS	: Planlı bakım tutum
PRC	: Kesinlik hassasiyet alanı
R	: Korelasyon katsayısı
ROC	: Alıcı operatör karakteristiği eğrisi
SMO	: Sıralı minimum optimizasyon algoritması
TBN	: Toplam baziklik değeri
U	: Mann Whitney U testinde gruplar arasındaki fark, eşitlik
ULSFO	: Ultra düşük sülfürlü gemi yakıtı
VLSFO	: Çok düşük sülfürlü gemi yakıtı
WEKA	: Veri madenciliği aracı (Waikato Environment for Knowledge Analysis)
YSA	: Yapay Sinir Ağları

1. GENEL BİLGİLER

Dünya ticaretinde denizyolu taşımacılığı 2024 yılında %2,4 artarak, toplam taşımacılıkta %80'in üzerine çıkmıştır (yaklaşık olarak 11 milyar tonluk kargo) (UNCTAD, 2023). Makine arızaları; gemilerin manevra, kanal-boğaz geçişi ve deniz trafiğinin yoğun olduğu yerlerde olası gemi güvenliği açısından risk teşkil etmektedir. Ayrıca, oluşan arızaların ortalama giderilme süresi 6 saate kadar uzamakta (MAK, 2008) ve beklenmedik makine arızaları daha büyük arızalara ve dolayısıyla gemi işletmecileri için daha büyük maddi ve iş kayıplarına yol açmaktadır. 2021 yılında Ever Given gemisinin Süveyş Kanalı'nda karaya oturmasıyla beraber Asya ile Avrupa arasında tedarik zinciri olumsuz olarak ciddi şekilde etkilenmiş olup günlük yaklaşık 9,6 milyar dolarlık ticaret engellenmiştir (Forti vd., 2021). Ever Given gemisinin kanalda karaya oturmasıyla alakalı kesin neden bilinmemekle beraber makine arızası ciddi ihtimallerden biri olarak değerlendirilmektedir.

Dünyada 2013-2018 yılları arasında ticari gemilerde oluşan kazaların yaklaşık %30'u makine ekipmanlarından meydana gelen arızalardan oluşmaktadır, bununla birlikte ticari gemilerde makine arızaları sonucu oluşan maddi hasarlar toplam maddi kayıpların %12'sini oluşturarak 1 milyar doları aşmaktadır (AGCS, 2019). Tablo 1'de 2015-2017 yılları arasında meydana gelen ve en çok masraf çıkaran gemi ana makine arızaları gösterilmektedir.

Tablo 1. 2015-2017 yılları arasında en maliyetli gemi ana makine arızaları
(The Swedish Club, 2018).

Arızalı parça	Arıza sayısı	Ortalama masraf (USD)
Krank mili/yatak	28	1.192.092
Kam mili	4	880.114
Silindir/silindir gömleği	32	543.623
Yatak	17	588.168
Piston	7	391.419
Yakıt pompası	19	227.940
Silindir başlığı	4	195.699

Tablo 1'e göre en çok makine arızası silindir ve silindir gömleğinde meydana gelmiş olup, en az arıza silindir başlığında oluşmaktadır. Bununla beraber krank mili 28 arıza ile en çok arıza gösteren ikinci makine parçasıdır. Arıza oluşuktan sonra, en çok masraf oluşturan makine parçası ise krank mili ve krank miline bağlı yataklardan oluşmaktadır. Bununla birlikte piston, yakıt pompası ve silindir başlığı gibi silindir yanma iş elemanları da en masraflı ana makine arızaları tablosunda yer almaktadır. Ticari gemilerin büyük bir çoğunluğu halen ağır yakıt (HFO) kullanmaktadır. Bu ağır yakıtın yanması sonucu gemi makinelerinde ciddi hasarlar ve arızalar oluşmaktadır. Özellikle ana makine yanma iş elemanları olarak adlandırılan enjektör, yakıt pompası, silindir başlığı ve piston üzerinde ağır deniz yakıtı kullanımına bağlı olarak ciddi hasarlar ve arızalar meydana gelmektedir.

Tablo 2'de 2015-2017 yılları arasında ortalama olarak en çok masraf oluşturan gemi ana makine arızaları, adetleri ve bu arızalara yol açan sebepler gösterilmektedir.

Tablo 2. 2015-2017 yılları arasında en maliyetli gemi ana makine arızalarının nedenleri (The Swedish Club, 2018).

Arıza nedeni	Arıza sayısı	Ortalama masraf (USD)
Yağlama eksikliği	40	763.320
Yanlış/eksik bakım tutum	19	544.167
Kirli yakıt	11	344.069

Tablo 2'ye göre en fazla karşılaşılan makine arızası nedeni yağlama yağı eksikliği olup, eksik ve yanlış planlı bakım tutum sonucunda ise 19 arıza meydana gelmiştir. Gemi yakıtları kaynaklı arıza adeti 11 olup ortalama 344.069 dolar maddi hasar ortaya çıkmıştır.


Gemilerde olası makine arızalarının önüne geçmek amacıyla planlı bakım tutumlar yapılmaktadır. Planlı bakım tutum zamanları ve prosedürleri ana makine üretici firmaların operasyon manuellere göre gemi personeli tarafından yapılmaktadır. Ancak planlı bakım tutum zamanları daha çok fabrika üretim tesislerinde deneysel olarak uygulandığından geminin seyir koşullarında farklı parametrelerin işin içine girmesiyle her zaman olası arızaların önüne geçilememektedir. Gemi ana makine üretici firmaları da operasyon manuellere göre planlı bakım tutum zamanları belirlemiş olup gemiler belirlenen bu zamanlara bağlı kalıp planlı bakım tutum işlemlerini yapmaktadır. Bu kapsamda ana makine yanma iş elemanlarının farklı birçok parametre ışığında planlı bakım tutum zamanlarının

optimize edilmesi, ayrıca olası yanma iş elemanları arızalarının parametreler yardımıyla tahminlenmesi büyük önem arz etmektedir.

Gemi ana makine yanma iş elemanlarında oluşabilecek arızaların önüne geçebilmek adına planlı bakım tutumların düzenli yapılması gerekmektedir. Planlı bakım tutumlar dışında da farklı bakım türleri de bulunmaktadır. Bu kapsamda öncelikle Bölüm 1.1’de gemi makinelerinde bakım tutum başlığı altında, bakım tutum çeşitleri incelenmektedir.

1.1. Gemi Makinelerinde Bakım Tutum Faaliyetleri ve ISM Kod Gereklilikleri

Genel olarak bakım sözcüğü, makinelerin ve diğer ekipmanların arıza yapmadan verimli bir şekilde çalışmasını sağlamak anlamına gelmektedir. Böylece beklenmedik arızalar karşısında daha yüksek bakım tutum giderlerinin önüne geçilmesi hedeflenmektedir. Bu sayede iş gücü, zaman ve maddi açıdan gemiye avantaj sağlanmaktadır. Şekil 1’de bakım çeşitleri gösterilmektedir.



Şekil 1. Bakım çeşitleri (Gürsoy vd., 2019).

a) Arızı bakım

Bakım çeşitlerinden arızı bakım; herhangi bir arıza meydana geldiğinde yapılan bakım türüdür. Ekipmanın veya makinenin belirgin bir arızası gerçekleştiğinde yapılmaktadır. Bu aşamada arızalanan parçanın onarılması, onarılamama durumunda yenisi ile değişimi söz konusudur. Ayrıca, arızalanan parçanın çalışmasına etki eden bağlantı ve sızdırmazlık elemanları da yenilenmektedir. Arızalanan parçanın değişim yapılıp yapılmayacağı,

parçanın yapısı, malzeme kalitesi ve parçayı oluşturan sistemin manuellereindeki bilgiye göre değişmektedir.

c) Kestirimci bakım

Makine veya ekipmanların parametreleri arıza riskini artırmadan fonksiyonlarını yerine getirip getirmediği ölçülerek gerçekleştirilen bakımdır (Gürsoy vd., 2019). Kestirimci bakımda özellikle sensör teknolojisi kullanılarak durum odaklı bakım (Condition Based Monitoring Maintenance-CBM) yapılmaktadır. Böylece her ekipman veya makinenin operasyon ve kondisyon durumu gözlenmektedir. Bu sayede olası makine arızaları önceden belirlenmektedir (Asuquo, 2017). Gemi makinelerinin bakım tutumunda hâlihazırda planlı bakım tutum en çok kullanılan bakım çeşidi olmakla beraber, son yıllarda CBM'ye dayalı bakım bazı makine elemanlarında uygulanmaktadır.

b) Periyodik bakım (Planlı bakım tutum)

Belirlenen kriterlere veya önceden belirlenen aralıkla yapılan bakım türüdür. Bu bakım türünde ekipmanın veya makinelerin bozulma olasılığını azaltmak hedeflenmektedir. Ticari gemilerde planlı bakım tutumda Uluslararası Denizcilik Örgütü (IMO) tarafından Emniyetli Yönetim Sistemi (ISM) kapsamında belirlenen bakım tutum gereklilikleri uygulanmaktadır.

Çalışmada kullanılan veri setinde; gemi ana makine yanma iş elemanları düzenli olarak planlı bakım tutum yapılmasına rağmen arızalar ortaya çıkmıştır. Meydana gelen arızalar sonrasında arıza bakımları da yapılmıştır. Gemi işletmecileri açısından; gemilerde planlı bakım tutumun düzenli ve verimli bir şekilde gerçekleştirilmesi adına ISM kodun planlı bakım tutum ile ilgili kısımlarının iyice idrak edilmesi gerekmektedir. Bu kapsamda bölüm 1.2'de ISM kod gerekliliklerinden bahsedilmektedir.

1.2. Gemilerde Planlı Bakım Tutumunda ISM Kod Gereklilikleri

Gemilerin emniyetli bir şekilde işletilmesi adına planlı bakım tutumlarla ilgili ISM kod bazı hususlar belirlemiş olup bu noktada gemi işletmelerinin bu hususlara uyması gerekmektedir. Gemilerde planlı bakım tutum ile ilgili ISM kodun ilgili maddeleri şu şekildedir;

ISM Kod 10.1:

Gemiler ilgili kural ve düzenlemelere, ayrıca gemi işletmecisi (şirket) tarafından belirlenmiş olan ek gerekliliklere uygun şekilde bakımının sağlanması için prosedürler oluşturmaktadır (ISM Code, 2018).

ISM Kod 10.2:

Bu gerekliliklerin karşılanmasında, şirket bakım tutum ile ilgili aşağıdaki yükümlülükleri sağlamalıdır:

- Denetimlerin uygun aralıklarla yapılması,
- Herhangi bir uygunsuzluğun (biliniyorsa olası nedeniyle birlikte) raporlanması,
- Uygun düzeltici faaliyetlerin gerçekleştirilmesi,
- Bu faaliyetlere ilişkin kayıtların tutulması (ISM Code, 2018).

ISM Kod 10.3:

Şirket; ani çalışma arızası ve tehlikeli durumlara yol açabilecek ekipman ve teknik sistemleri belirlemelidir. Güvenlik Yönetim Sistemi (SMS), bu tür ekipman veya sistemlerin güvenilirliğini artırmaya yönelik özel önlemleri içermelidir. Bu önlemler, sürekli kullanılmayan yedek ekipman veya teknik sistemlerin düzenli olarak test edilmesini kapsamalıdır (ISM Code, 2018).

ISM Kod 10.4:

10.2 maddesinde belirtilen denetimler ile 10.3 maddesinde atıfta bulunulan önlemler, geminin operasyonla ilgili bakım rutinine entegre edilmelidir (ISM Code, 2018).

Gemi ana makine ve parçalarının arızalanma olasılığını azaltmaya yönelik yapılan planlı bakım tutum faaliyetlerinden sonra Bölüm 1.3'te arızaların oluşumunda etkin bir rol oynayan yakıtın yanma aşamaları ve gemi ana makine yanma iş elemanları anlatılacaktır.

1.3. Gemi Dizel Makinelerinde Yanma ve Ana Makine Yanma İş Elemanları

1.3.1. Gemi Dizel Makinelerinde Yanma

İçten yanmalı motorlarda yanma; oldukça kısa bir zaman diliminde gaz fazında gerçekleşen kimyasal bir süreçtir. Bu kadar kısa sürede yanmanın etkili bir şekilde oluşabilmesi ve gelişebilmesi için, yakıt buharının hava ile yüksek düzeyde karışması; yani karışımın homojen özellik göstermesi gerekmektedir. Homojen karışım; her bir yakıt molekülünün çevresinde, tam oksidasyonun gerçekleşebilmesi için yeterli sayıda oksijen molekülünün bulunması durumunu ifade eder (Stone, 1999; Wang ve Farhan, 2022).

Yanma sürecinde, yakıt parçacıkları bileşenleri olan hidrojen molekülleri ve karbon atomlarına ayrışır; bu elementler oksijenle ayrı ayrı tepkimeye girer. Hidrojenin oksijenle birleşmesi sonucunda su buharı, karbonun oksijenle birleşmesiyle ise karbondioksit oluşur.

Ancak yanma sırasında yeterli miktarda oksijen bulunmaması durumunda karbon monoksit oluşur ve bu durum, yanma sürecinden elde edilmesi beklenen ısı enerjisinin azalmasına neden olur (Küçükşahin, 2008).

İçten yanmalı motorlarda her güç çevriminde silindire alınan hava miktarının, aynı çevrimde püskürtülen yakıt miktarına oranı "hava/yakıt oranı" olarak tanımlanmaktadır. Bu oran, yanmanın verimliliği ve egzoz emisyonları üzerinde doğrudan etkili bir parametredir.

Yanmanın fazları şu şekildedir;

- Tutuşma gecikmesi
- Hızlı yanma
- Yavaş yanma
- Art yanma

a) Tutuşma gecikmesi

Dizel motorlarında sıkıştırma sonucu basıncı ve sıcaklığı artan hava ortamına püskürtülen yakıt ancak bazı fiziksel ve kimyasal proseslerin oluşmasından sonra kendi kendine tutuşur. Yakıtın yanma odasına girmesinden alevli yanmanın oluşmasına kadar geçen süreye tutuşmanın hazırlık evresi veya tutuşma gecikmesi denir (Stone, 1999).

Fiziksel süreçler için gerekli süre fiziksel tutuşma gecikmesi, kimyasal süreçler için gerekli süreye kimyasal tutuşma gecikmesi denir. Tutuşma gecikmesi de bu iki sürenin toplamından oluşur.

Fiziksel süreç şu şekilde gerçekleşmektedir;

- Yakıt spreyinin parçalanması ve damlacık oluşumu
- Sıvı haldeki yakıtın ısınarak buharlaşması
- Buhar haline geçen yakıtın hava ile karışarak yanmaya hazır hale gelmesi
- Damlacık çapları küçüldükçe birim hacim başına düşen yüzey alanı artar ve yakıt damlacığının ısınma ve buharlaşma süresi kısalır (Küçükşahin, 2008).

Kimyasal süreçte ise ağır hidrokarbonlar daha hafif elemanlara bölünerek oksijen ile kimyasal tepkimeler oluşmaktadır.

Tutuşma gecikmesi;

- Yakıt cinsine, sıcaklığına ve viskozitesine
- Hava sıcaklığı ve basıncına
- Yakıt püskürtme zamanlaması,
- Silindirdeki hava girdaplarının oluşumuna
- Hava çokluk kat sayısına bağlıdır (Küçükşahin, 2008).

Dolayısıyla, tutuşma gecikmesi süresinin kısa sürmesi için doğru hava yakıt oranı, yakıtın atomize şekilde püskürtülmesi, yakıtın silindir hacminin tamamına yayılması, püskürtme avansının doğru olması ve sıkıştırma sonunda doğru sıcaklığın elde edilmesi gerekmektedir.

b) Hızlı yanma

Yanmanın oluşup, basıncın ani olarak yükselmeye başladığı noktadan, maksimum basıncın elde edildiği noktaya kadar geçen süreye " hızlı yanma" ya da "gerçek enerjinin elde edildiği yanma" denir. Ağır devirli makinelerde 2-3 bar/krank, yüksek devirli makinelerde 6-8 bar/krank dolaylarındadır (Alagumai, 2014; Küçükşahin, 2008).

c) Yavaş yanma


Yavaş yanma (kontrollü yanma), üst ölü noktaya yakın, giderek artan bir hacim içerisinde. Püskürtülen yakıt damlacıkları yeterli oksijeni bulur bulmaz düşük tutuşma gecikmesi nedeniyle daha hızlı yanar. Bu aşamada çoğu zaman silindire yoğun bir şekilde yakıt verilmesine rağmen önemli bir miktarda ısı açığa çıkmasına rağmen basınç yükselmesi geriler. Bu periyod enjektör iğne valfinin yuvasına oturması ve püskürtmenin sona ermesi ile sonlanır (Alagumai, 2014; Küçükşahin, 2008).

d) Art yanma

Yanma enjeksiyon işleminin tamamlanmasıyla bitmez. Yanma odasında kalmış yanmamış ve kısmi yanmış yakıt partikülleri oksijen ile temas ettikçe yanmaya devam eder. Bu safhaya art yanma safhası denir. Genellikle bu periyot, maksimum çevrim sıcaklığının meydana geldiği noktalarda başlar ve genişleme stroku boyunca devam eder. Çok uzun art yanma silindir gömleği yüzeylerinin silindir başlığı ve piston kafasının aşırı ısınması piston segman ve kanallarında kurum ve yapışkan artık oluşmasına yol açar (Alagumai, 2014; Küçükşahin, 2008).

1.3.2. Gemi Ana Makine Yanma İş Elemanları

Denizyolu taşımacılığında, gemi ana makine yanma iş elemanları arızaları gerek seyir güvenliği gerekse maddi ve iş gücü açısından ciddi olumsuzluklara yol açmaktadır. Gemi ana makinesinde yanma iş elemanları; yakıt pompası, enjektör, silindir başlığı, piston ve silindir gömleğinden oluşmaktadır. Şekil 2’de yanma iş elemanları gösterilmektedir.



Şekil 2. Gemi ana makine yanma iş elemanları (MAK, 2008).

Gemi ana makine yanma iş elemanları ayrı olarak düşünülse de aslında her birinin verimli veya verimsiz çalışması ya da arıza yapması diğer makine parçalarını etkilemektedir. Gemi ana makinesinde silindir içindeki yanma işlemi için öncelikle her bir silindirde ayrı olarak bulunan yakıt pompaları, yakıtı yüksek basınçlı yakıt devresi vasıtasıyla silindir başlığı içerisinde bulunan enjektöre basmaktadır. Enjektörün yakıtı püskürtmesiyle silindir içinde yanma gerçekleşmektedir. Yakıt pompasındaki olası bir arıza enjektöre yakıtın istenilen basınçta ulaşmasını engellemektedir. Bunun sonucunda silindir içerisinde yanma işlemi olmayabilir veya yanma işleminin kalitesi düşük kalabilir, dolayısıyla ana makinenin işleminin durdurmasına veya ana makine performansının düşmesine sebep olmaktadır. Enjektör de yakıt pompası gibi yanma kalitesini belirleyen temel etmenlerden biridir. Öte yandan silindir başlığı ve piston da silindir içindeki yanmadan etkilenen diğer iş elemanlarıdır (Küçükşahin, 2016). Silindir içerisindeki yanma olayının gemi ana makine yanma iş elemanlarına etkisi, yanma iş elemanlarının malzeme yapısı ve yanma sonucu bu elemanlarda oluşan deformasyonlarla ilgili bilgiler şu şekildedir;

a) Yakıt püskürtme valfi (enjektör)

Gemi makinelerinde yakıt püskürtme sistemleri yüksek basıncın etkisinde bulunmaktadır. Bundan ötürü; yakıt pompası çıkış basınç elemanlarında (barıl ve plencer), enjektör iğne valflerinde açıklıkları (klerens) etkileyen, basıncın düşmesine ve aşınmaya neden olan erozyonlar oluşmaktadır.




Şekil 3. Enjektör nozul ve yuva kısmındaki deformasyon (Bejger ve Drzewieniecki, 2020).

Şekil 3'te 2 zamanlı gemi dizel makinesinde enjektör kaçağı ve enjektör yuvasındaki deformasyon görülmektedir. Bunun gibi enjektör kaçaklarında yakıt püskürtme verimi dolayısıyla yanma verimi düşmektedir ve piston segman yuvalarında karbon atıkları oluşmaktadır (Bejger ve Drzewieniecki, 2020).

Enjektör yapımında kullanılan malzemelerin aşınma, paslanma ve yakıt erozyonuna karşı yüksek korumaya sahip olması gerekmektedir. Enjektör iğne valfleri yüzeyleri sertleştirilmiş %3 nikel oranında çeliklerden, nozul kısmı yüksek ısıya dayanımlı çeliklerden, enjektör gövde kısmı ise nitelikli dökme demir veya yumuşak çelikten imal edilmektedir (Küçükşahin, 1999).

b) Yakıt pompası

Yakıt püskürtme sistemlerinde kullanılan malzemelerin aşınmaya, paslanmaya ve yakıt erozyonuna karşı yüksek dirençli olması gerekmektedir.



Şekil 4. Aşınmış yakıt pompası pistonu (plencer) (Bejger ve Drzewieniecki, 2020).

Şekil 4’te kavitasyon erozyonuna uğramış ve aşınmış bir plencer görülmektedir. Yakıt pompalarında da enjektörlerde olduğu gibi aşınma ve erozyona karşı dayanıklılığı sağlamak amacıyla, kullanılan malzemelere ısıtım işlem uygulanmaktadır. Yakıt pompalarının gövdeleri, yüzeyi sertleştirilmiş Siemens-Martin çeliği veya yumuşak çelikten üretilmektedir. Yakıt püskürtme pompası plencerleri, %3 nikel içeren ve yüzeyi sertleştirilmiş çeliklerden imal edilir. Yakıt püskürtme pompalarının valf ve yuvalarında, paslanmaz çelik veya yüksek kaliteli dökme demir tercih edilmektedir. Yakıt pompası kam milleri plencerlerinde kullanılan malzeme ile aynı materyalden üretilmektedir (Küçükşahin, 1999).

c) Silindir başlığı

Çalışmakta olan bir makinede silindir başlığı, gaz basınç kuvveti ve silindir başlığı saplamalarının sıkma kuvveti gibi çeşitli etkilere maruz kalmaktadır. Bunların yanı sıra, silindir başlığının yanma odasına bakan yüzeyi yüksek sıcaklıktaki yanma gazlarıyla, diğer yüzeyi ise daha düşük sıcaklıktaki soğutma suyu ile temas halindedir. Bu durum, yüksek sıcaklık farklarından kaynaklanan ısıtım gerilmelerinin silindir başlığı üzerinde etkili olmasına neden olur. Sonuç olarak, mekanik ve ısıtım gerilmelere karşı dayanıklı bir silindir başlığı malzemesi kullanılması gerekmektedir.



Şekil 5. Yanmaya bağlı egzoz valfi deformasyonu (URL-1, 2025).

Şekil 5’te silindir başlığında bulunan ve sorunlu yanma sonucu oluşan egzoz valfi deformasyonu görülmektedir. Egzoz valfi üzerindeki parçanın kopmasından ötürü silindir egzoz sıcaklığında ciddi artışların meydana gelmesi olasıdır. Dizel makinelerin silindir başlıkları genellikle yüksek kaliteli dökme demirden üretilir. Daha yüksek gerilmelere dayanması gereken silindir başlıkları ise krom, nikel ve molibden gibi alaşımlar içeren

dökme demirden yapılmaktadır. Ağır hizmet motorlarında kullanılan silindir başlıkları ise yüksek sıcaklığa dayanıklı alaşımlı çeliklerden imal edilmektedir (Küçükşahin, 1999).

d) Piston

Dizel makinelerin tümünde, pistonlar emme strokunda çok düşük bir hava basıncı (0,85-6 bar) ile maksimum yanma basıncı (40-250 bar) arasındaki basınç değişimlerinin neden olduğu mekanik ve yanma sırasında oluşan ısıl gerilmelere maruz kalmaktadır. Pistonlar, ısıl ve mekanik gerilmelerin yanı sıra, yetersiz yağlama ve silindir gömleği yüzeyindeki çıkıntılar nedeniyle aşınmalara karşı da dayanıklı olmalıdır. Ağır devirli, yüksek güçlü gemi dizel makinelerinde kullanılan pistonların yapımında; yanma sonucu oluşan gazların yüksek sıcaklık etkisinde kalan üst parçasında molibden çeliği, alt parçada ise dökme demir kullanılmaktadır (Küçükşahin, 1999).




Şekil 6. Piston ve kırık segmanlar (Vukcevic vd., 2019).

Şekil 6’da sol kısımda piston ve segmanları görülmektedir. Sağ taraftaki görselde ise yakıtta bulunan katalitik ince partiküller sonucu deforme olan ve kırılan segmanlar görülmektedir.

e) Silindir gömleği

Silindir gömleği, aşınma direncini artırmak ve ısı transfer oranını iyileştirmek amacıyla silindir bloğunun içine sıkı geçme yöntemiyle yerleştirilen bir parçadır. Motor içerisindeki toplam sürtünmenin yaklaşık %30’u silindir bileşenlerinden kaynaklanmaktadır. Yanma sonucu ortaya çıkan ısıнын yaklaşık %5’i veya potansiyel olarak kullanılabilir gücün %10’u, mekanik sürtünme nedeniyle kaybolmaktadır. Sürtünme performansında tasarım optimizasyonları ve yağlayıcı geliştirmeleri ile iyileştirmeler yapılmış olsa da sürtünme

enerjisinin geri kazanımı için motor tasarımında köklü bir değişiklik yapılmamıştır (Shinde ve Jadhav, 2016). Şekil 7’de silindir içerisinde yanma sonucu oluşan sülfürik asit kaynaklı silindir gömleği aşınması görülmektedir.



Şekil 7. Silindir gömleği aşınması (Kjemtrup vd., 2020).

Silindir bileşenlerinin uzun ömürlü olması, yüksek sıcaklık direncine sahip olması ve üstün mekanik özellikler sunması, motorun verimli bir şekilde çalışması için en önemli gereksinimlerdir. Silindir gömleklerinin yüksek sıcaklığa ve yüksek basınca ve aşınmaya karşı direnç sağlaması gerekmektedir. Bu üç olumsuz duruma karşı koyması adına gemi dizel makineleri silindir gömleklerinde malzeme olarak dökme demir kullanılmaktadır (Küçükşahin, 1999).

Gemi ana makine yanma iş elemanları tanıtıldıktan sonra bu elemanlarda arızaya yol açan faktörlerin açıklanması gerekmektedir. Bu kapsamda, literatürdeki araştırmalar ve çalışmalara dayanan arızalara etki eden faktörler Bölüm 1.4’te anlatılmıştır.

1.4. Gemi Ana Makine Yanma İş Elemanlarını Arızaya Sevk Eden Faktörler

1.4.1. Gemi Yakıtları

Gemi yakıtlarının içeriğinde bulunan maddelerin gemi ana makine silindirleri üzerindeki olumsuz etkileri bilinmektedir. Bu kapsamda öncelikle gemi yakıtları kısmından

bahsedilecektir. Genel olarak günümüzde ticari gemiler fosil yakıtlar kullanmaktadır ve bu yakıtlar iki ana kategoriye ayrılmaktadır:

1. Artık yakıtlar
2. Damıtılmış yakıtlar

Artık yakıtlar; ağır fuel yakıt (HFO) ve hafif fuel yakıt (LFO) olmak üzere ikiye ayrılır. LFO, HFO'ya göre daha düşük viskozite ve yoğunluğa sahiptir. Halihazırda deniz yolu taşımacılığında tonaj olarak yüklerin %92,6'sını taşımak için ağır deniz yakıtı kullanılmaktadır (DNV, 2024). HFO tipi yakıtlar, damıtma kolonunun dibinde biriken ağır yakıtlardır ve yüksek miktarda kükürt içerir. Bu nedenle, IMO (Uluslararası Denizcilik Örgütü) düzenlemelerine uyum sağlamak amacıyla HFO'daki kükürt miktarı düşürülmüş ve düşük kükürtlü ağır yakıt (LSHFO- kütlece %1,5'ten az kükürt içeren) ile ultra düşük kükürtlü yakıt (ULSFO- kütlece %0,1'den az kükürt içeren) üretilmiştir.

Damıtılmış yakıtlar ise deniz dizel yakıtı (MDO) ve deniz gaz yağı yakıtı (MGO) olmak üzere ikiye ayrılmaktadır. MDO, dizel yakıtı olarak adlandırılırken, MGO çok daha düşük kükürt içeriğine sahip hafif gaz yağıdır. Artık yakıt ve deniz gaz yağı yakıtlarının (MGO) karışımına ise ara fuel yakıtı (IFO) denilmektedir. Özellikle yüksek kükürt içeriğine sahip olan HFO, günümüzde uygulanan sıkı çevre gereksinimlerini karşılamaktan uzak olduğundan tercih edilmemeye başlanmıştır (Bilgili, 2014).

Gemilerde kullanılan artık yakıtların gemi makine parçalarında arızalara sebep olduğu bilinmektedir. Yakıt pompası ve enjektörlerde yakıt kaynaklı arızalara rastlandığını belirten çalışmalar mevcuttur (Kowalski, 2014; Kowalski, 2016). Bununla beraber, özellikle gemilerde kullanılan HFO tipi yakıtların silindir başlığı, silindir gömleği ve piston üzerinde aşınmalara yol açarak makine arızalarına sebep olmaktadır (Alkaff vd., 2005; Lars vd., 2020).

Bu kapsamda, gemi yakıtlarının gemi ana makine yanma iş elemanları arızalarına etkisini öğrenmek amacıyla gemi yakıtlarında bulunan içerikler bu bölümde detaylı anlatılacaktır.

1.4.2. Sülfür

IMO, uluslararası deniz taşımacılığının güvenlik ve çevreye duyarlılık doğrultusunda gelişimini yönlendirmekten sorumlu bir kuruluş olarak sorumluluğu bulunmaktadır. Sorumlulukları arasında; gemi tasarımı, deniz taşımacılığının işleyişi, kirletici atıkların

bertaraf edilmesi, gemi güvenliği, sürdürülebilirlik ve verimlilik bulunmaktadır. Deniz taşımacılığı kaynaklı kirliliklerin önlenmesi ve azaltılması da IMO'nun temel görevlerindendir (IMO, 2024).

Son düzenlemeler arasında yakıt standartlarını kontrol etmek ve CO₂, NO_x ve SO_x emisyonlarını azaltmak yer almaktadır. Bu kapsamda, MARPOL Ek VI'da belirlenen en önemli düzenlemelerden biri emisyon kontrol (ECA) alanlarıdır. Bu alanlar genellikle kıyı şeritlerinde yer almakta olup, bu alanlarda etraftaki nüfusun güvenliği için daha katı kirlilik düzenlemeleri uygulanmaktadır. Tablo 3' te IMO SO_x emisyonları ile ilgili limit değerleri göstermektedir.

Tablo 3. IMO sülfür emisyonları sınır değerleri (IMO, 2024).

SO _x ve partikül madde (PM) emisyonları (ECA dışında)	SO _x ve partikül madde (PM) emisyonları (ECA içerisinde)
1 Ocak 2012'den önce %4,50 m/m	1 Temmuz 2010'dan önce %1,50 m/m
1 Ocak 2012'den itibaren %3,50 m/m	1 Temmuz 2010'dan itibaren %1,00 m/m
1 Ocak 2020'den itibaren %0,50 m/m	1 Ocak 2015'ten itibaren 0,10% m/m

Yakıt bileşenlerinden biri olan sülfür gerek çevre kirliliği gerekse gemi dizel makinelerine verdiği zararlar açısından dikkat çekici bir noktada bulunmaktadır. 2020'de yürürlüğe giren en güncel düzenleme, açık denizde yakıtlardaki sülfür içeriğini %0,5'e, ECA bölgelerinde ise %0,1'e düşürmeyi zorunlu kılmaktadır. Denizcilik işletmeleri IMO sülfür düzenlemelerine uymak amacıyla düşük sülfürlü fuel yakıtlar (VLSFO, ULSFO) kullanmak veya yüksek sülfürlü yakıt kullanmaya devam edip bacadan çıkan egzoz gazlarını filtreleme amacıyla temizleyici (scrubber) kullanmak zorundadır.

Ham petrol, sülfür ve ağır hidrokarbonlarla bileşik halde bulunduğu damıtma işlemi sırasında sülfürün büyük bir kısmı ağır fuel (yakıt) içinde kalmaktadır. Yanma işlemi sırasında kükürt önemli bir etki yaratarak, SO₃ (kükürt trioksit) oluşturur. Oluşan SO₃ daha sonra yanma sonucu ortaya çıkan su buharı (H₂O) ile birleşerek sülfürik asit (H₂SO₄) meydana getirir. Sülfürik asidin yanma sürecindeki aşındırıcı etkisi, doğru yağlama yağı kullanımı ve yanma alanındaki sıcaklıkların kontrol edilmesiyle azaltılabilir (Vedachalam vd., 2022).

Kükürt oksitlerin (SO_x) makine dışında da olumsuz etkileri bulunmaktadır. Denizcilik endüstrisinde SO_x, deniz motorlarında yakıtların yanması sonucu havaya salınır. Denizyolu

taşımacılığı, dünya çapındaki insan kaynaklı SO₂ emisyonlarının yaklaşık %13'ünü oluşturmaktadır. Kükürt oksitlerin temel etkilerinden biri asit yağmuru oluşumudur. Asit yağmuru yağış olarak yeryüzüne indiğinde bitki örtüsüne zarar verirken su kütlelerini asidik hale getirerek su ekosistemindeki türleri olumsuz etkilemektedir (Vedachalam vd., 2022).

1.4.3. Mikro Karbon Kalıntısı

Yanlış ve içeriği doğru olmayan yakıt kullanımı doğrudan motor bileşenlerinin verimliliği ve dayanıklılığı üzerinde etkili olmaktadır. Yakıt içeriğinde bulunan kirleticiler, korozif aşınmanın şiddetini artırmakla beraber yanlış biçimde kendiliğinden tutuşma özellikleri ortaya çıkarmaktadır. Bu durumda silindirlerde kronik yanma sorunları veya hiç yanma olmaması gibi durumlara rastlanmaktadır. Silindir içinde biriken yakıt atıkları; emme ve egzoz çıkış valflerine zarar verebilir, valflerin sıkışmasına ve çalışmaz hale gelmesine yol açabilir. Ayrıca, süpürme havası alıcılarında ve egzoz manifoldlarında yangınlara neden olabilir. Bahsedilen sorunlara yol açan düşük kaliteli yakıtlar nedeniyle birçok motor hasarları ve vakalar ortaya çıkmaktadır (Chybowski vd., 2023).

Karbon kalıntısı, belirli koşullar altında ham petrolün buharlaşması ve pirolizi sonrasında geride kalan artıktır. Bir yakıtın karbon kalıntısı, yüksek sıcaklık koşullarında hareketsiz bir atmosferde karbon birikintileri oluşturma eğilimini ifade eder (Hassan vd., 2008). Genellikle Mikro Karbon Kalıntısı (MCR) veya alternatif olarak Conradson Karbon Kalıntısı (CCR) olarak belirtilmektedir. Sayısal olarak MCR değeri ile CCR değeri hemen hemen aynıdır.

Karbon kalıntısı, yakıtın yanması sonucunda oluşacak karbon bazlı tortular hakkında bilgi sağlar. Yüksek karbon-hidrojen oranına sahip yakıtların tamamen yanması daha zor olduğu için yanma ve egzoz alanlarında biriken tortuların artmasına neden olur. Yüksek karbon kalıntısı değerine sahip yakıtlar, özellikle eski motorların kısmi yük koşullarında çalışması sırasında sorunlara yol açabilir. Yakıtın karbon kalıntısı değeri, üretiminde kullanılan rafineri işlemlerine bağlıdır.

1.4.4. Katalitik İnce Partiküller

Katalitik ince partiküller, artık yakıtlarda bulunabilen alüminyum-silika bazlı, çok sert ve küçük parçacıklardır. Son yıllarda ağır fuel yakıtların kalitesi düşmektedir. Bu durum, yakıt kaynaklı motor hasarları üzerinde ciddi bir etki yaratarak gemi sahipleri, kiracılar ve


sigortacılar için kayıpların artmasına neden olmuştur. Özellikle, çevre politikaları ve fosil yakıtların sürekli artan maliyetleri yakıt kalitesindeki düşüşte önemli bir rol oynamıştır. Ham petrol stoklarından daha değerli damıtılmış (distile) yakıtlar ayrıştırıldıkça ve egzoz emisyon yasaları kükürt içeriğini sınırladıkça, gemiler alınan fuel yakıtlarda, tehlikeli derecede yüksek seviyelerde katalitik ince partiküller (cat fines) kalmaktadır (JHC Report, 2025).

Geçmişte, yakıtlar gemi motorlarında verimli bir şekilde yanacak şekilde rafine edilirken temel olarak yoğunluk ve viskozite faktörleri baz alınmaktaydı. Günümüzde ise rafineriler; Emisyon Kontrol Alanlarında (ECA) kullanılmak üzere düşük kükürtlü yakıtlar üretmeye odaklanmaktadır (JHC Report, 2025).

Bu karmaşık süreçte kullanılan katalizörler; alüminyum ve silisyum oksitleri olup düşük sülfürlü yakıt damıtma işleminde, yakıtla reaksiyona girdikçe parçalanarak giderek daha küçük hale gelmektedir. Bahsedilen katalizörler pahalı olmakla beraber çoğunlukla rafineri tarafından geri dönüştürülür ancak cat fines olarak bilinen daha küçük partiküller, işlemin bir yan ürünü olan çökelti yakıtın (slurry oil) içine karışmaktadır.

Çökelti yakıt nispeten yüksek yoğunluk ve viskoziteye sahip, ancak düşük kükürt içeriği olan yüksek aromatik bir sıvıdır. Çökelti yakıt yüksek kükürtlü artık yakıtla karıştırıldığında, düşük kükürtlü ancak potansiyel olarak daha yüksek seviyelerde katalitik ince partikül içeren bir yakıt ortaya çıkmaktadır.

Yakıt enjekte edildiğinde bahsedilen ince partiküller motorun yanma odasına girebilir ve burada silindir gömleği, piston kanalları ve segmanların yüzeyine yapışabilir. Motorun içine girdikten sonra bu çok sert parçacıklar aşındırıcı olarak hareket ederek hareketli parçaların hızla aşınmasına neden olmaktadır (Vedachalam vd., 2022). Aşınma oranları, katalitik ince partikül parçacıklarının miktarına ve boyutuna bağlıdır. Belirli koşullarda, maksimum aşınma sınırlarının ötesine geçilmesi sadece birkaç hafta içinde gerçekleşebilir. Bu sorun ağırlıklı olarak büyük iki zamanlı motorları etkilemekle birlikte, dört zamanlı motorlarda da aşınma vakaları olabilmektedir. Şekil 8'de gemi dizel ana makinesi silindir gömleğinin görüntüsü verilmektedir.



Şekil 8. Dökme demir silindir gömleği mikroskobik görüntüsü (URL-2, 2025).

Şekil 8'deki mikroskop fotoğrafta, katalitik ince parçacıklarının silindir gömleğinin grafit ince katmanlarına gömüldüğü görülmektedir. Gömlek çevresindeki dökme demir yapısı, sürtünme nedeniyle deforme hale gelmiştir.

Norveç Loydu Petrol Servisleri (DNVPS), gemi yakıtlarında katalitik ince partikül (cat fines) seviyelerinin her yıl arttığı konusunda uyarıda bulunarak düşük kükürtlü deniz yakıtlarının ağır fuel yakıtlara (HFO) göre daha yüksek katalitik ince partikül içerdiğini belirtmektedir. Öte yandan ticari gemilerden alınan 400 binden fazla yağlama yağı örnekleri incelendiğinde, yağ numunelerinin %43'ünde kritik seviyelerde katalitik ince partiküllere rastlandığı görülmüştür (JHC Report, 2025).

Katalitik ince partiküllerin olası gemi dizel makinelerine vereceği zararların önüne geçmek için; yakıt ayrıştırıcılarının sıcaklık ve kapasiteleri doğru ayarlanarak verimli bir şekilde çalışmalarının sağlanması, yakıt servis ve dinlenme tanklarında düzenli tank temizliği yapılması, yakıtın gemi ana makinesine girmeden hemen önce 10 mikron çapında yakıt filtresi ile donatılması önerilmektedir (JHC Report, 2025).

1.4.5. Vanadyum

Vanadyum, ağır deniz yakıtlarında bulunan en önemli iz elementlerden biridir. Yakıt içerisinde erimiş olarak bulunmakta olup yakıttan ayrıştırılamaz (Lin, 2000). Yanma sırasında vanadyumun oksidasyonu sonucunda vanadyum oksit (VO), vanadyum dioksit (VO_2) ve ardından vanadyum pentoksit (V_2O_5) oluşur. V_2O_5 'in düşük erime noktasına sahip olduğu bilinmektedir, bu nedenle yoğunlaşan V_2O_5 parçacıkları dış katmanlarda yarı sıvı ve

yapışkan hale gelir. Bu parçacıklar kolayca egzoz valflerine, piston üst noktalarına ve turboşarj gibi makine parçalarına yapışmaktadır. Bunun neticesinde yağlama olan noktalarda yağ filminin mesafesi bozulacağından aşınmalar meydana gelmektedir (Surawski vd., 2017; Lin vd., 2000).

1.4.6. Yakıt İçerisindeki Diğer İçerikler

Yanma kalitesi, gemi yakıtları için önemli bir göstergedir, ancak şu ana kadar yanma kalitesini değerlendiren ortak ve standart bir yöntem bulunmamaktadır. Bu özelliği tanımlayan hesaplanmış indekslerden biri Hesaplanmış Karbon Aromatiklik İndeksidir (CCAI). CCAI yakıtın yoğunluğu ve viskozitesinden deneysel olarak hesaplanan bir indekstir. Bir yakıtın tutuşma gecikmesi, o yakıtın karbon aromatikliği ile ilişkilidir; ayrıca karbon aromatikliği ile viskozite ve yoğunluk arasında bir korelasyon bulunmaktadır (CIMAC, 2025a). Genel olarak, düzenli kullanım sırasında CCAI değerinin 860'ı aşmaması halinde yakıtın kabul edilebilir yanma kalitesine sahip olduğu varsayılmaktadır. CCAI değeri 860-880 arasında olan yakıtlarda makinenin doğru şekilde çalıştırılmasında sorunlar yaşanabilir. CCAI değeri 880'in üzerindeki yakıtlar ise kısa sürede makine parçalarında hasara yol açabilmektedir. CCAI yalnızca yakıtın yanma kalitesinin ilk değerlendirmesi için uygulanabilir çünkü bu indeksler, yakıtın kimyasal bileşiminin yanma süreci üzerindeki etkisini dikkate almamaktadır (Chybowski ve Matuszak, 2007).

Makine Dostu Yakıt Standardı (Engine Friendless Number-EFN); kullanılacak yakıtın makineye ne kadar uygun olup olmadığını belirlemek amacıyla kullanılmaktadır. Bağımsız yakıt analiz laboratuvarının kullandığı bir değerdir. EFN değerinin değerlendirmesi aşağıdaki gibidir.

0-35: Kötü

40-55: Normal

55-70: İyi

75-100: Çok iyi

EFN'nin yakıtın aşınma ve korozyon potansiyelini incelemektedir. Düşük değerdeki bir EFN değerinin makinada aşınma ve korozyon hasarına neden olma potansiyelinin olduğu bilinmektedir (URL-3, 2025).

1.4.7. Arızaya Neden Olan Diğer Faktörler

a) Yağlama yağı

Yağlama yağında bulunan aşındırıcı kalsiyum ve sodyum makine parçalarını olumsuz etkileyerek arızalara yol açmaktadır. Düşük sülfürlü yakıt kullanan gemi ana makinelerinde yüksek Toplam Baz Sayısı (TBN) silindir gömleği ve piston arasında bazik kalıntı oluşturarak, arada bulunan yağ filmini bozmaktadır. Dolayısıyla piston ve silindir gömleği üzerinde aşınmalar meydana gelmektedir (Thomas vd., 2019).

b) İnsan Hatası

Genel olarak makine arızalarında, makinelerin işletilmesinden ve bakım tutumundan sorumlu personelin büyük bir önemi bulunmaktadır. Personelin herhangi bir planlı bakım tutum işleminde veya makine sistemlerinin devreye alınıp devreden çıkarılmasında yapacağı küçük bir hata ileride büyük bir makine arızası olma riskini taşımaktadır. Bu durumda personel, makine arızalarının oluşumunda insan hatasını engelleme noktasında kilit rol üstlenmektedir. Makinelerde oluşan arızalara insan faktörünün etkisi araştırıldığında insan hatasının kaynakları olarak: yetersiz beceri, eksik eğitim, bakım görevlerinin karmaşıklığı, kötü yazılmış kullanım kılavuzları ve bakım prosedürleri, kötü tasarlanmış ekipman, uygunsuz aletlerin kullanımı, yetersiz çalışma düzeni, çalışma alanında sınırlı aydınlatma ve yüksek gürültü seviyeleri belirlenmiştir (Dhillon ve Liu, 2006).

c) Yedek parça

Gemilerin makinelerine ve ekipmanlarına periyodik bakım yapılması, bakım arasındaki dönemde herhangi bir arıza olmayacağı anlamına gelmez. Kullanılan yedek parçaların kalitesi, insan kaynaklı ihmal, yağ/yakıt kalitesi, hava koşulları, geminin rotası, önceki bakım personelinin deneyimi gibi faktörler, herhangi bir arızaya yol açabilmektedir (Lazakis vd., 2010). Özellikle son yıllarda orijinal yedek parça kullanılmaması makinelerde ciddi arızalara yol açmıştır.

1.5. Literatür Araştırması

Literatüre bakıldığında; gemi ana makineleri arızalarının tahminlenmesi ile ilgili çalışmalar sınırlıdır. Ana makine arızalarının tespiti ile ilgili tahminleme yapılan çalışmalarda daha çok eski arızaların olduğu çalışma saatleri kayıtları üzerinden yola çıkılmış olup diğer parametreler (silindir egzoz sıcaklığı, yakıt içeriği, yağlama yağı ve silindir soğutma suyu basınç, sıcaklığı vb.) kullanılmamıştır. Tablo 4'te genel olarak makine

arızaları ile ilgili literatürde yapılan çalışmaların içeriği ve araştırma yöntemleri gösterilmektedir.

Tablo 4. Genel makine arızalarının tahminlenmesi ile ilgili yapılan çalışmalar

Makine elemanı	Yöntem	Yazar
Rulman, freze bıçağı	Tekrarlayan Evrişimsel Yapay Sinir Ağları (RCNNs)	(Wang vd., 2020)
Rulman	Derin öğrenme	(Li vd., 2020)
Rulman	Vibrasyon analizi	(Khadersab ve Shiva Kumar, 2018)
Rulman	İleri makine öğrenimi	(Piltan vd., 2019)
Rulman	Derin öğrenme	(Li vd., 2020)
Rulman	Olasılıkçı Yapay Sinir Ağları (PNN-Probabilistic Neural Network)	(Jiang vd., 2018)
Dönen makineler, rulman	Makine öğrenimi	(Li vd., 2018)
Rulman	İleri makine öğrenimi	(Wang vd., 2017)
Dönen makineler	Grupsal Ampirik Kip Ayrışımı (EEMD) ve Destek Vektör Makineleri (SVM)	(Lobato vd., 2020)
Dönen makineler	Yapay zekâ teknikleri karşılaştırması; -En Yakın Komşu Algortiması (k-NN) -Naive Bayes, Destek Vektör Makineleri (SVM) -Yapay Sinir Ağları (ANN) -Derin Öğrenme (Deep Learning)	(Liu vd., 2018)

Tablo 4’te görüldüğü üzere genel makine arızalarının tahminlenmesi üzerine ağırlıklı olarak rulmanlar ve dönen makineler üzerinde çalışmalar yapılmıştır. Bu çalışmalarda ağırlıklı olarak elektrik motorları gibi dönen makinelerin rulman yatakları üzerinde bulunan vibrasyon değerleri baz alınmıştır. Durum bazlı görüntüleme yani sensör teknolojisi kullanılarak makine öğrenme algoritmaları yardımıyla kestirimci arıza tahminleme sonuçları elde edilmiştir.

Tablo 5'te ise gemi makineleri arızaları üzerine literatürde yapılan çalışmalar belirtilmektedir.

Tablo 5. Gemi makine arızalarının tahminlenmesi ile ilgili yapılan çalışmalar

Makine elemanı	Yöntem	Yazar
Gemi makineleri	Kablosuz Sensör Ağı (WSN)	(Panic vd., 2018)
Silindir elemanlarındaki aşınma, Pompa elektrik motorları, Kompresörler	Yapay zekâ	(Jimenez vd., 2020)
Egzoz gazları sıcaklıklarının tahminlenmesi	Durum Bazlı Bakım (CBM), Yapay Sinir Ağları (YSA)	(Raptodimos ve Lazakis, 2020)
Ana makine hava giriş sistemi ve silindir elemanları	Olasılıksal Makine Elemanları, Güvenilirlik Değerlendirmesi (PMRA) ve Dinamik Bayes Ağı	(Dikis ve Lazakis, 2018)
Ana makine durumu görüntülenmesi	YSA ve Destek Vektör Makineleri (SVM)	(Gkerekos vd., 2017)
Ana makine ve ana makineye bağlı sistemler	YSA	(Göksu ve Erginer, 2020)
Egzoz gazları sıcaklıklarının tahminlenmesi	Hata Ağacı Analizi (FTA), Hata Türü Etki Analizi (FMEA), YSA	(Lazakis vd., 2018)
Balast pompaları	YSA	(Kimera ve Nangolo, 2020)
Gemi sevk sistemlerinde dönen elemanlar	Tahribatsız Test (NDT), Mikro yapısal Analiz ve Sonlu Elemanlar Analizi (FE)	(Vizentin vd., 2020)

Tablo 5'te yer alan bilgiler ışığında; Göksu ve Erginer (2020) çalışmasında genel olarak tüm ana makine sistemlerinin arızalarının zamansal tahminlemesini yapmıştır. Çalışmada arıza tahminlemesinde yapay sinir ağları modelini kullanmışlardır. Çalışmada sadece arızalardaki çalışma saatlerini parametre olarak belirlemiştir.

Panic vd., (2018) çalışmasında; konvansiyonel gemi makine durum bazlı görüntülemeden kablosuz sensör teknolojisine geçişin makine arızalarını tahminlemede önemli olduğu sonucuna varmıştır.

Jimenez vd., (2020) yapay zeka ile gemilerde önleyici bakım çözümleri oluşturmak amacıyla yaptığı çalışmada; yağ numune sonuçları, vibrasyon değerleri ve performans verilerini kullandı. Sismik araştırma gemisine ait 6 ana makine, 2 kompresör ve pompalardaki elektrik motorları veri setine dahil edildi. Yağ numune sonuçlarına göre; silindir elemanlarındaki aşınma değerlerini buldu. Elektrik motorlarındaki sensörlerden alınan vibrasyon değerleri ile hava kompresörlerinin, ana makine performans bilgileri ile ana makinelerin genel durumunun belirlendi.

Raptodimos ve Lazakis (2020) çalışmalarında sensör teknolojisi yardımıyla durum bazlı bakım kapsamında egzoz gazları sıcaklık tahminlemesi yaptı. 2 zamanlı 8 silindirli Panamax konteyner gemisinde kapsamında egzoz gazlarının sıcaklığı YSA ile tahmin edilerek kritik ana makine arızalarının tespiti amaçlandı. Elde edilen tahminleme sonuçlarında Ortalama Mutlak Yüzde Hatası (MAPE) oranının %4,64 ten %1,02'ye düştüğü görüldü.

Dikis ve Lazakis, (2018); konteyner gemisine ait 2 zamanlı ana makinenin sensör bilgilerini (süpürme havası giriş sıcaklık ve basınç değerleri, her silindirin egzoz sıcaklık değerleri vb.) kullanarak ana makine hava giriş sistemi ve silindir elemanları hatalarını Olasılıksal Makine Elemanları Güvenilirlik Değerlendirmesi (PMRA) ve Dinamik Bayes Ağı yöntemleri ile belirlemiştir.

Lazakis vd., (2018), çalışmalarında gemi ana makinesi kritik ekipman ve sistemlerinin durumunu egzoz gazlarının tahminlemesini yaparak öğrenmeyi amaçlamıştır.

Başka bir çalışmada ise, geçmiş arıza kayıtlarına ve gem personelinin görüşlerine bakılarak gemi hava kompresörlerinin bakım tutum zamanlarının düzenlenmesi yapılmıştır (Stazic vd., 2020).

Vorkapic vd., (2017) ise LPG tankerinin sıvılaştırma sistem elemanlarının bakım tutum aralıklarının düzenlenmesi ile ilgili çalışma ortaya koymuşlardır.

Kandemir ve Çelik (2020), çalışmalarında dizel jeneratörün tüm planlı bakım tutum işlemlerini insan güvenilirliği üzerinden analiz etmiştir.

Buksa vd., (2009) çalışmalarında gemi dizel ana makinesi planlı bakım tutum zaman düzenlemesini risk analizi ve bakım tutum maliyetleri açısından analiz etmiştir.

Bir diğer çalışmada ise geminin tüm planlı bakım sistemi, uzman görüşleri alınarak yeniden düzenlenmesi amaçlanmıştır (Stazic vd., 2017).

Görüldüğü üzere literatürde gemi ana makinesi yanma iş elemanlarının (enjektör, yakıt pompası, silindir başlığı ve piston); teknik parametreler (silindir egzoz sıcaklığı, yakıt

içeriği, silindir soğutma suyu ve yağlama yağı basınç sıcaklığı vb.), geçmiş arıza ve bakım tutum operasyon kayıtları ile olası arızaların tahminlenmesi üzerine yapılan çalışmalara rastlanmamıştır.

1.6. Tez Çalışmasının Amacı ve Kapsamı

1.6.1. Amaç

Gemi ana makinesinde oluşan arızalar ciddi maddi kayıplar ve deniz ticaretini aksatan zaman kayıpları ortaya çıkarmaktadır. Bununla beraber, arızalara bağlı oluşan kazalar denizde çevre ve can güvenliğini de tehlikeye atmaktadır. Bu tez çalışmasında gemi ana makine yanma iş elemanları olası arızalarının tahminlenmesi yapılarak, olası arızalara erken müdahaleler ile doğabilecek kayıpların (maddi, zaman, can ve çevre) önüne geçilmesi amaçlanmaktadır.

1.6.2. Kapsam

Gemi ana makine yanma iş elemanları arızalarının tahminlenmesi amacıyla; deniz ticaret filosuna sahip bir denizcilik işletmesinden veriler elde edilmiştir. Bu kapsamda 14 adet iki zamanlı gemi ana makineye sahip gemilerin 2016-2024 yıllarını kapsayan ay sonu evrakları ve yakıt analiz raporları incelenmiştir. Ay sonu evrakları; ana makine performans raporları, ana makine parçaları çalışma saatleri, arıza raporları ve diğer teknik formlardan oluşmaktadır. Veri setinden 220 adet arıza durumuna ait ve 175 adet arıza olmayan durumlara ait net veriler elde edilmiştir. Arızalar gemi ana makine yanma iş elemanlarını içermektedir. Bunlar; enjektör, yakıt pompası, silindir başlığı ve pistondan oluşmaktadır. Silindir gömleği ile ilgili arıza kayıtlarına rastlanmadığından silindir gömleği arızalarına yer verilmemiştir.

2. YAPILAN ÇALIŞMALAR

2.1. Giriş

Çalışmada kullanılan veri seti, Türk ticari gemi filosunda bir denizcilik şirketine ait toplam 14 gemiden elde edilmiştir. Veriler 2016-2024 yılları arasında gemilerin Emniyetli Yönetim Sistemi (ISM) ay sonu evraklarından sağlanmıştır. Bu gemilerin hepsi 2 zamanlı tek ana makineye sahip dökme sınıfında yer alan gemilerdir. Tablo 6’da veri setinde kullanılan gemilerin bilgileri bulunmaktadır.

Tablo 6. Veri setindeki gemilerin bilgileri

	Tam boy (m)	GT	KW	Ana makine	Klas	Bayrak	İnşa yılı	Arıza adeti
Dökme 1	189,99	32983	9480	STX MAN B&W 6S50MC-C7	NKK	Singapur	2010	35
Dökme 2	224,94	39737	10320	HITACHI MAN B&W 6S60MC	NKK	Panama	2009	6
Dökme 3	185,74	25938	7171	MITSUI MAN B&W 6S50MC	NKK	Singapur	2001	10
Dökme 4	199,98	34795	8450	HITACHI MAN B&W 6S50MC-C8	NKK	Singapur	2012	5
Dökme 5	190,00	33226	9480	STX MAN B&W 6S50MC-C7	ABS	Singapur	2010	8
Dökme 6	169,37	17025	5850	MAKITA MITSUI B&W 6S42MC-C7	NKK	Singapur	2013	10
Dökme 7	190,00	33226	9480	STX MAN B&W 6S50MC	ABS	Singapur	2010	10
Dökme 8	169,37	17025	5850	MAKITA MITSUI MAN B&W 6S42MC	NKK	Türk	2010	2
Dökme 9	224,94	39737	10320	MITSUI MAN B&W 6S60MC	NKK	Singapur	2010	9
Dökme 10	189,99	30011	7800	MITSUI MAN B&W 6S50MC	NKK	Türk	2002	32
Dökme 11	189,99	32983	9480	STX MAN B&W 6S50MC-C7	NKK	Türk	2010	43
Dökme 12	189,99	32983	9480	STX MAN B&W 6S50MC-C7	NKK	Türk	2010	26
Dökme 13	185,74	25938	7171	MITSUI MAN B&W 6S50MC	NKK	Singapur	2001	7
Dökme 14	199,98	34773	8260	HITACHI MAN B&W 6S50ME	NKK	Singapur	2016	17


Tablo 6’da görüldüğü üzere dökme sınıfı gemilerin tümü 2 zamanlı tek ana makineye sahip olup, makine güçleri 5850 KW ile 10320 KW arasında değişmektedir. Dökme 1-11-12, Dökme 2-9, Dökme 3-13, Dökme 5-7, Dökme 6-8 gemileri kendi aralarında kardeş (sister ship) gemilerdir. Tüm gemilerde ana makineler; MAN B&W markasında çokça kullanılan 6S42M, 6S50M ve 6S60M tipindedir. Tüm ana makinelerde silindir sayısı 6 olup, silindir çapları 42 cm ile 60 cm arasında değişmektedir. Bununla beraber, strok ve silindir çapı oranlarına göre tüm gemilerin ana makineleri süper uzun strok özelliğindedir. Dökme 14 gemisi haricindeki tüm gemilerin ana makineleri kam mili kontrollü iken, Dökme 14 gemisinde kam mili kontrolü yerine elektronik kontrol bulunmaktadır. Veri setindeki gemilerden 12 tanesi Japon klas kuruluşuna (NKK) bağlı iken kalan 2 adeti Amerikan klas kuruluşuna (ABS) bağlıdır. Gemilerin 9 adeti Singapur bayraklı, 3 adeti Türk bayraklı ve 1 adeti ise Panama bayraklıdır. Gemilerin inşa yılları incelendiğinde; en yaşlı gemi 2001 yılında inşa edilmiş olup en yeni gemi ise 2016 yılında inşa edilmiştir. Veri setindeki 14 gemiden 7’si 2010 yılında inşa edilmiştir. En fazla arıza 2010 yapımı Dökme 11 gemisinde (43 adet) ile gerçekleşirken en az arıza 2 adet ile Dökme 8 gemisinde meydana gelmiştir.

Veri seti olarak ticari gemi filosunun planlı bakım tutum sistemi (PMS) kayıtları, kayıt altında tutulan ana makine performans verileri, arıza rapor kayıtları ve ay sonu evrak kayıtları alınarak incelenmiştir (Ek Şekil 1-2-3). Kayıt altındaki verilerden ana makine yanma iş elemanlarının bakım tutumuna ve arıza yapmasına neden olabilecek veriler kullanılmıştır. Bu veriler; yakıtın özelliklerinden (Ek Şekil 4), ana makine silindir maksimum basınç değeri (P_{max}), silindir sıkıştırma basınç değeri (P_{comp}), makine yükü, egzoz sıcaklığı, yağ, yakıt, silindir soğutma suyu sıcaklık ve basınç değerlerini içeren performans raporlarından (Ek Şekil 2), ana makine yanma iş elemanları değişim zamanlarını içeren çalışma saatleri evraklarından (Ek Şekil 3) oluşmaktadır. Ayrıca gemilerin geçmiş PMS ve arıza kayıt raporları da incelenerek yanma iş elemanlarının değişim dönemleri arasındaki parametrik verilerin değişimi de incelenmiştir.

İki zamanlı ana makinelerde silindir yağlaması yapılan temiz yağ, yağlama yapıldıktan sonra silindir içinde yakılmaktadır. Dolayısıyla silindir yağlama yağının yağ analizine gönderilmesi söz konusu değildir. Veri setindeki gemilerin hepsinin iki zamanlı ana makineye sahip olmasından ötürü ve yağlama yağının laboratuvar analiz içerikleri bilinmediğinden, yağlama yağının arızalara etkisi veri setinde kullanılmamıştır.

2.2. Veri Setinden Elde Edilen Gemi Ana Makine Yanma İş Elemanları Arızaları

Veri setinde; planlı bakım tutum dışında ana makine yanma iş elemanlarına ait toplam 220 adet arızaya rastlanmıştır. Şekil 9’da veri setinden elde edilen gemi ana makine yanma iş elemanları arızalarının dağılımı gösterilmektedir.



Şekil 9. Arızaların dağılımı

Şekil 9’da görüldüğü üzere veri setinden elde edilen bilgiler ışığında en çok arıza 77 adet ile silindir başlığında görülürken, en az arıza 38 adet ile yakıt pompasında oluşmuştur. Gemi ana makinelerinin enjektörlerinde 53 adet arıza bulunurken yakıt pompalarında ise 52 adet arıza ortaya çıkmıştır.

Gemilere ait arızalar belirlenirken arızalara etki eden faktörlerin belirlenmesi amacıyla öncelikli olarak gemi ana makine yanma iş elemanları ile ilgili arıza raporlarının alındığı gemilerin bilgileri verilmiştir. Daha sonra arıza raporları, ay sonu evrakları (başmühendis raporu, aylık çalışma saatleri) irdelenerek arızaların öncesinde arızaya etken faktörler incelenmiştir. Ayrıca arızalarda veri setinde bulunan yakıt analiz raporları da incelenmiştir. Gemilerde bulunan makine jurnallerinin gemi dışında kayıtlarının bulunmamasından ötürü ana makine performans raporlarından faydalanılmıştır.

Öte yandan ay sonu evraklarında ise düzenli olarak tutulması gereken ana makine performans raporları gibi bazı evraklara rastlanmamaktadır. Özellikle haftalık alınması gereken P_{max} ve P_{comp} değerlerine aylık olarak rastlanmıştır. Bu durumda arızaların

tahminlenmesinde hesaba katılması gereken iki parametrenin sadece ay sonu evraklarında bulunan aylık değerleri göz önüne alınmıştır. Dolayısıyla arıza raporlarında belirtilmediği sürece ana makinenin egzoz sıcaklık, soğutma suyu sıcaklık ve basınç, yakıt giriş sıcaklık ve basınç, şarj havası sıcaklık ve basınç değerlerine ulaşamamıştır. Verilerin anlamlı bir şekilde dağılım göstermesi adına arıza raporlarındaki başmühendis ifadeleri esas alınmaktadır.

2.2.1. Ana Makine Enjektörde Görülen Arızalar

Veri setinde incelenen ana makine enjektörlerinde görülen arızalar toplam 53 adettir. Enjektör arızaların gemilere göre dağılımı Tablo 7’de gösterilmektedir.

Tablo 7. Ana makine enjektör arızaları

Gemi adı	Çalışma saati	Tarih	Değişim nedeni	Silindir numarası
Dökme 1	2742	18.12.2019	Aşınma	4 (baş taraf)
Dökme 1	2742	18.12.2019	Aşınma	4 (kıç taraf)
Dökme 1	4335	01.04.2022	Aşınma	1
Dökme 1	4335	01.04.2022	Aşınma	2
Dökme 1	4335	01.04.2022	Aşınma	3
Dökme 1	4335	01.04.2022	Aşınma	4
Dökme 1	4646	05.05.2022	Aşınma	5
Dökme 1	4646	05.05.2022	Aşınma	6
Dökme 1	6056	08.11.2017	Aşınma	6
Dökme 1	4369	28.12.2017	Aşınma	6
Dökme 1	3329	30.03.2020	Aşınma	1
Dökme 4	670	29.11.2020	Yakıt kaçağı	4
Dökme 4	56	29.11.2020	Yakıt kaçağı	5
Dökme 4	317	10.12.2020	Yakıt kaçağı	4
Dökme 5	340	28.06.2021	Aşınma	5
Dökme 5	4441	24.09.2021	Aşınma	4
Dökme 5	70	11.08.2020	Aşınma	4
Dökme 5	3184	27.03.2020	Yakıt kaçağı	2


Tablo 7'nin devamı

Dökme 6	4362	26.01.2018	Egzoz sıcaklığı	5
Dökme 7	421	16.07.2018	Yakıt kaçağı	3
Dökme 7	384	03.02.2021	Yakıt kaçağı	3
Dökme 7	384	03.02.2021	Yakıt kaçağı	5
Dökme 9	542	07.10.2022	Yakıt kaçağı	2
Dökme 9	542	07.10.2022	Yakıt kaçağı	4
Dökme 9	542	07.10.2022	Yakıt kaçağı	5
Dökme 10	491	25.04.2020	Aşınma	1
Dökme 10	2447	31.10.2024	Aşınma	6
Dökme 11	2189	17.06.2021	Yakıt kaçağı	1
Dökme 11	2189	17.06.2021	Yakıt kaçağı	4
Dökme 11	1213	11.01.2023	Yakıt kaçağı	2
Dökme 11	2724	11.01.2023	Yakıt kaçağı	5
Dökme 11	2634	11.01.2023	Yakıt kaçağı	6
Dökme 11	218	27.03.2020	Yakıt kaçağı	1
Dökme 11	1782	27.03.2020	Yakıt kaçağı	2
Dökme 11	1782	27.03.2020	Yakıt kaçağı	5
Dökme 11	1423	08.01.2021	Yakıt kaçağı	2
Dökme 11	1423	08.01.2021	Yakıt kaçağı	3
Dökme 11	1423	08.01.2021	Yakıt kaçağı	5
Dökme 11	1423	08.01.2021	Yakıt kaçağı	6
Dökme 12	378	10.04.2018	Aşınma	4
Dökme 12	1819	18.08.2018	Aşınma	6
Dökme 12	431	28.09.2020	Yakıt kaçağı	1
Dökme 12	431	28.09.2020	Yakıt kaçağı	5
Dökme 12	4705	23.08.2024	Yakıt kaçağı	3 (baş taraf)
Dökme 12	4705	23.08.2024	Yakıt kaçağı	3 (kış taraf)
Dökme 12	335	13.09.2024	Yakıt kaçağı	3
Dökme 14	144	14.06.2020	Yakıt kaçağı	6
Dökme 14	3447	08.05.2020	Yakıt kaçağı	6
Dökme 14	3979	27.08.2020	Aşınma	4

Tablo 7'nin devamı

Dökme 14	2083	15.05.2020	Aşınma	1
Dökme 14	2083	15.05.2020	Aşınma	5
Dökme 14	3579	15.08.2020	Aşınma	2
Dökme 14	301	13.11.2020	Aşınma	3

Tablo 7'ye bakıldığında enjektör arızalarının temel nedenlerinin aşınma ve yıpranma olduğu görülmektedir. Bunun dışında enjektörlerden kaynaklı yakıt kaçakları ve egzoz sıcaklıklarının düşük veya yüksek olması da enjektörlerin temel değişim nedenleri arasında yer almaktadır. Şekil 10'da ise enjektör arızalarının çalışma saatine göre dağılımı gösterilmektedir.



Şekil 10. Enjektör arızalarının çalışma saatine göre dağılımı

Enjektörlerin planlı bakım tutum zamanı 8000 saattir. Şekil 10'da görüldüğü üzere çalışma saatleri 5000 saate gelmeden enjektör arızalarının büyük bir bölümü ortaya çıkmaktadır.

2.2.2. Ana Makine Yakıt Pompasında Görülen Arızalar

Ana makine yakıt pompalarında görülen arızalar toplam 52 adettir. Yakıt pompası arızalarının gemilere göre dağılımı ve arızalara etki eden faktörler Tablo 8’de gösterilmektedir.

Tablo 8. Ana makine yakıt pompası arızaları


Gemi adı	Çalışma saati	Tarih	Değişim nedeni	Numara
Dökme 1	8666	10.01.2018	Aşınma	4
Dökme 1	7183	10.01.2018	Aşınma	6
Dökme 1	5167	03.01.2022	Yakıt kaçağı	3
Dökme 1	5356	11.08.2017	Yakıt kaçağı	1
Dökme 1	5356	11.08.2017	Aşınma	6
Dökme 1	6420	28.12.2017	Aşınma	6
Dökme 1	9249	21.03.2018	Aşınma	3
Dökme 1	7903	08.11.2017	Aşınma	4
Dökme 1	8375	18.12.2017	Aşınma	4
Dökme 3	8360	05.04.2022	Aşınma	3
Dökme 4	2220	10.10.2019	Aşınma	5
Dökme 4	12750	22.09.2018	Yakıt kaçağı	1
Dökme 5	215	24.06.2018	Yakıt kaçağı	6
Dökme 5	11357	26.06.2018	Yakıt kaçağı	3
Dökme 5	11498	17.12.2018	Yakıt kaçağı	2
Dökme 5	11498	17.12.2018	Yakıt kaçağı	5
Dökme 6	11951	11.02.2022	Aşınma	1
Dökme 6	11951	11.02.2022	Aşınma	2
Dökme 6	11951	11.02.2022	Aşınma	3
Dökme 6	11951	11.02.2022	Aşınma	4
Dökme 6	11951	11.02.2022	Aşınma	5
Dökme 6	11951	11.02.2022	Aşınma	6
Dökme 7	4862	22.01.2020	Yakıt kaçağı	2
Dökme 7	7532	13.01.2023	Kazıklama	3
Dökme 7	4948	04.04.2018	Yakıt kaçağı	6

Tablo 8'in devamı

Dökme 8	3816	30.06.2017	Yakıt kaçağı	6
Dökme 8	3118	31.03.2017	Yakıt kaçağı	4
Dökme 10	5302	01.07.2022	Yakıt kaçağı	6
Dökme 10	5302	05.07.2022	Yakıt kaçağı	4
Dökme 10	9260	29.06.2017	Yakıt kaçağı	2
Dökme 10	11241	31.07.2018	Yakıt kaçağı	4
Dökme 10	11659	05.12.2020	Yakıt kaçağı	1
Dökme 10	10241	06.18.2018	Yakıt kaçağı	2
Dökme 10	5282	23.02.2019	Yakıt kaçağı	3
Dökme 10	10194	23.02.2019	Yakıt kaçağı	5
Dökme 10	4867	07.04.2022	Yakıt kaçağı	3
Dökme 10	1283	27.03.2023	Yakıt kaçağı	3
Dökme 11	11548	08.02.2023	Yakıt kaçağı	5
Dökme 11	11548	08.02.2023	Yakıt kaçağı	6
Dökme 11	3946	17.01.2021	Yakıt kaçağı	1
Dökme 11	3946	17.01.2021	Yakıt kaçağı	2
Dökme 11	3946	17.01.2021	Yakıt kaçağı	3
Dökme 11	3946	17.01.2021	Yakıt kaçağı	6
Dökme 12	6393	10.03.2018	Aşınma	5
Dökme 14	12964	08.05.2020	Yakıt kaçağı	4
Dökme 14	12253	14.02.2020	Egzoz sıcaklığı	1
Dökme 14	9103	18.10.2021	Yakıt kaçağı	1
Dökme 14	9103	18.10.2021	Yakıt kaçağı	2
Dökme 14	9103	18.10.2021	Yakıt kaçağı	3
Dökme 14	9103	18.10.2021	Yakıt kaçağı	4
Dökme 14	9103	18.10.2021	Yakıt kaçağı	5
Dökme 14	9103	18.10.2021	Yakıt kaçağı	6

Yakıt pompası ile ilgili arızalar incelendiğinde yakıt kaçaıkları büyük bir oran içermektedir. Öte yandan aşınma ve egzoz sıcaklığı da yakıt pompalarının alınma nedenlerini oluşturmaktadır.

Şekil 11’de yakıt pompası arızalarının çalışma saatine göre dağılımı gösterilmektedir.



Şekil 11. Yakıt pompası arızalarının çalışma saatine göre dağılımı

Yakıt pompalarının planlı bakım tutum zamanı 12000 saattir. Arızaların çoğunluğu planlı bakım saatinden çok önce meydana gelmektedir.

2.2.3. Ana Makine Silindir Başlığında Görülen Arızalar

Bu çalışmada, ana makinede görülen arızaların büyük bir çoğunluğu silindir başlıklarında meydana gelmiştir (toplam 77 arıza). Silindir başlığı arızaları ile ilgili detaylı bilgiler Tablo 9’da gösterilmektedir.

Tablo 9. Ana makine silindir başlığı arızaları

Gemi adı	Çalışma saati	Tarih	Değişim nedeni	Numara
Dökme 1	8120	24.01.2023	Su kaçağı	4
Dökme 1	2484	26.05.2021	Su kaçağı	2
Dökme 1	2484	28.05.2021	Su kaçağı	1
Dökme 1	7583	16.02.2018	Su kaçağı	6
Dökme 1	2484	26.06.2021	Su kaçağı	6

Tablo 9'un devamı

Dökme 1	6169	12.07.2022	Su kaçağı	3
Dökme 1	5191	28.08.2017	Egzoz valfi aşınma	4
Dökme 1	6743	23.09.2022	Su kaçağı	3
Dökme 1	1648	25.10.2021	Su kaçağı	3
Dökme 1	7874	06.12.2022	Egzoz valfi aşınma	1
Dökme 1	7874	07.12.2022	Egzoz valfi aşınma	6
Dökme 1	6892	06.12.2017	Su kaçağı	5
Dökme 2	6080	03.03.2022	Su kaçağı	3
Dökme 2	6080	04.03.2022	Su kaçağı	4
Dökme 2	5699	05.11.2021	Su kaçağı	1
Dökme 2	2463	02.08.2022	Su kaçağı	4
Dökme 2	8550	02.08.2022	Su kaçağı	6
Dökme 2	2853	29.10.2022	Aşınma	2
Dökme 3	10132	24.10.2017	Egzoz valfi aşınma	5
Dökme 3	16601	03.12.2018	Su kaçağı	6
Dökme 3	16601	08.12.2018	Su kaçağı	2
Dökme 3	16289	18.12.2018	Egzoz valfi aşınma	4
Dökme 3	4371	26.03.2020	Egzoz valfi aşınma	3
Dökme 3	4766	28.05.2020	Egzoz valfi aşınma	1
Dökme 3	4766	28.05.2020	Egzoz valfi aşınma	2
Dökme 3	4766	28.05.2020	Egzoz valfi aşınma	4
Dökme 3	4766	28.05.2020	Egzoz valfi aşınma	5
Dökme 6	14206	28.10.2022	Aşınma	5
Dökme 7	5897	29.01.2019	Egzoz valfi aşınma	1
Dökme 7	3555	24.11.2022	Su kaçağı	1
Dökme 7	2963	01.08.2024	Su kaçağı	1
Dökme 9	609	06.05.2019	Su kaçağı	4
Dökme 9	3287	11.01.2020	Su kaçağı	3
Dökme 9	1406	14.01.2019	Su kaçağı	3
Dökme 9	1108	29.04.2020	Egzoz valfi aşınma	3
Dökme 9	5136	01.11.2021	Su kaçağı	4


Tablo 9'un devamı

Dökme 9	6158	04.11.2021	Su kaçağı	6
Dökme 10	3527	13.03.2020	Egzoz valfi aşınma	2
Dökme 10	3527	27.04.2020	Egzoz valfi aşınma	1
Dökme 10	5479	02.05.2020	Su kaçağı	4
Dökme 10	2592	26.07.2018	Su kaçağı	1
Dökme 10	4773	26.07.2018	Su kaçağı	2
Dökme 10	4773	26.07.2018	Su kaçağı	3
Dökme 10	4773	26.07.2018	Su kaçağı	4
Dökme 10	2592	26.07.2018	Su kaçağı	5
Dökme 10	2592	26.07.2018	Su kaçağı	6
Dökme 10	5188	18.09.2018	Su kaçağı	3
Dökme 10	6396	17.01.2019	Su kaçağı	2
Dökme 10	4692	16.02.2019	Su kaçağı	4
Dökme 10	4618	26.02.2019	Su kaçağı	6
Dökme 10	4618	27.02.2019	Su kaçağı	1
Dökme 10	1095	11.03.2019	Su kaçağı	3
Dökme 10	1486	05.05.2021	Su kaçağı	6
Dökme 10	2580	16.09.2021	Su kaçağı	3
Dökme 10	321	08.05.2021	Su kaçağı	4
Dökme 10	1486	29.04.2021	Su kaçağı	1
Dökme 11	2385	20.02.2021	Su kaçağı	4
Dökme 11	4311	11.08.2021	Su kaçağı	2
Dökme 11	7293	04.07.2022	Su kaçağı	1
Dökme 11	569	11.05.2020	Egzoz valfi aşınma	1
Dökme 11	2129	03.01.2021	Su kaçağı	1
Dökme 11	2129	03.01.2021	Su kaçağı	3
Dökme 11	2129	03.01.2021	Su kaçağı	6
Dökme 11	569	03.04.2020	Su kaçağı	1
Dökme 11	569	04.04.2020	Su kaçağı	5
Dökme 12	6196	17.08.2018	Aşınma	3
Dökme 12	3474	18.08.2018	Aşınma	6

Tablo 9'un devamı

Dökme 12	2684	21.02.2019	Su kaçağı	5
Dökme 12	851	11.04.2018	Su kaçağı	1
Dökme 12	2008	02.08.2018	Aşınma	1
Dökme 12	2171	04.11.2017	Su kaçağı	2
Dökme 12	3753	07.04.2017	Egzoz valfi aşınma	1
Dökme 13	1461	10.02.2020	Su kaçağı	6
Dökme 13	5799	23.02.2021	Su kaçağı	5
Dökme 13	2808	04.06.2019	Aşınma	4
Dökme 13	3354	04.11.2022	Su kaçağı	5
Dökme 14	2083	16.05.2020	Enjektör sıkışması	2

İki zamanlı ana makineye sahip gemilerde özellikle su kaçaqları silindir başlığı operasyonlarının temel yapılma sebebini oluşturmaktadır. Silindir başlığı malzeme ömürlerinin azalmasına bağlı olarak ortaya çıkan aşınma ve yıpranma, egzoz valflerinde oluşan aşınmaya bağlı yüksek egzoz sıcaklıkları da temel arıza sebeplerindendir. Şekil 12'de silindir başlığı arızalarının oluşma saatinin dağılımı gösterilmektedir.



Şekil 12. Silindir başlığı arızaları

Silindir başlığında arızaların büyük bölümü 2000 ila 8000 saat arasında gerçekleşmiştir. Bu değerler planlı bakım saati olan 12000 saatin bayağı gerisinde bulunmaktadır.

2.2.4. Ana Makine Pistonunda Görülen Arızalar

Ana makine pistonlarında görülen arızalar toplam 38 adettir. Ana makinelerde görülen piston arızalarının gemilere göre dağılımı ve arızalara etki eden faktörler Tablo 10'da gösterilmektedir.


Tablo 10. Ana makine piston arızaları

Gemi adı	Çalışma saati	Tarih	Değişim nedeni	Silindir numarası
Dökme 1	5837	06.10.2017	Kırık segman	1
Dökme 1	7418	12.03.2018	Aşınma	4
Dökme 1	7583	15.03.2018	Aşınma	5
Dökme 6	14206	28.10.2022	Kırık segman	5
Dökme 6	360	13.06.2024	Kırık segman	2
Dökme 7	5527	12.01.2019	Kırık segman	3
Dökme 10	6185	17.07.2024	Kırık segman	3
Dökme 11	5925	06.10.2022	Piston kafası arıza	5
Dökme 11	6142	06.10.2022	Piston kafası arıza	6
Dökme 11	2133	04.05.2020	Kırık segman	1
Dökme 11	2133	04.05.2020	Kırık segman	6
Dökme 11	2133	05.05.2020	Kırık segman	2
Dökme 11	2133	05.05.2020	Kırık segman	4
Dökme 11	2133	05.05.2020	Kırık segman	5
Dökme 11	2463	20.05.2020	Kırık segman	1
Dökme 11	341	03.06.2020	Kırık segman	1
Dökme 11	306	10.06.2020	Kırık segman	5
Dökme 11	296	18.06.2020	Kırık segman	5
Dökme 11	296	18.06.2020	Kırık segman	6
Dökme 11	306	19.06.2020	Kırık segman	2
Dökme 11	52	22.06.2020	Kırık segman	5

Tablo 10'un devamı

Dökme 11	96	03.06.2020	Kırık segman	5
Dökme 11	96	03.06.2020	Kırık segman	6
Dökme 12	6016	01.08.2018	Aşınma	3
Dökme 12	2684	22.02.2019	Kırık segman	3
Dökme 12	6403	06.03.2018	Kırık segman	1
Dökme 12	1921	25.02.2019	Aşınma	4
Dökme 12	3346	21.02.2019	Kırık segman	5
Dökme 12	8675	27.10.2018	Aşınma	6
Dökme 12	3535	17.11.2022	Kırık segman	2
Dökme 12	4598	02.10.2021	Kırık segman	6
Dökme 12	3872	24.06.2020	Kırık segman	1
Dökme 12	3872	26.06.2020	Kırık segman	6
Dökme 12	4768	04.09.2024	Aşınma	6
Dökme 13	5799	26.02.2021	Aşınma	6
Dökme 13	5786	27.07.2019	Kırık segman	3
Dökme 13	9547	04.06.2019	Kırık segman	4
Dökme 14	6571	01.03.2023	Kırık segman	6

İki zamanlı makinelerde görülen piston arızalarında, pistonların değişim nedenleri arasında kırık segmanlar ilk sırada yer almaktadır. Bununla birlikte aşınma ve piston kafasındaki deformasyonlar da değişim nedenleri arasında yer almaktadır. Şekil 13'te piston arızalarının çalışma saatine göre dağılımı gösterilmektedir.



Şekil 13. Piston arızalarının çalışma saatine göre dağılımı

Piston arızalarında dikkat çeken temel nokta arızaların ilk 3000 saatlik çalışma diliminde ortaya çıkmasıdır. Bu değer aralığı planlı bakım saati olan 12000 saatin çok gerisinde bulunmaktadır.

2.3. Çalışmada Kullanılan Yöntemler

Çalışmada öncelikli olarak gemi ana makine yanma iş elemanları arızalarına yol açabilecek faktörlerin belirlenmesi amacıyla, istatistiki yöntemlere başvurulmuştur. Bu kapsamda, gemi yakıtlarının içeriğinde bulunan bileşikler istatistiki yöntemlerle irdelenmiştir. İki zamanlı makinelerde kullanılan yeni silindir yağının yağlamadan sonra ana makine tarafından silindir içerisinde yakılmasından dolayı, yağlama yağının detaylı laboratuvar analiz değerleri bilinmemektedir. Bu nedenle yağlama yağının arızalara olan etkisi irdelenememiştir. İnsan hatası ve yedek parça ile ilgili veri seti oluşturma aşamasında net bilgilere ulaşamadığından bu faktörler göz ardı edilmiştir. Ayrıca gemi ana makine yanma iş elemanları arızaları tahminleme işleminde, silindir gömleği ile ilgili olarak planlı bakım tutum dışında arızaya bağlı bir değişim olmadığından silindir gömleği arıza tahminlemesi de dikkate alınmamıştır.

2.3.1. Tek Örneklem Kolmogorov Smirnov (KS) Testi

A.N. Kolmogorov (1933) ve N.V. Smirnov (1939) tarafından, oranlama veya eşit aralıklı ölçekteki değişkenler için geliştirilmiş bir uyum testidir. Kolmogorov-Smirnov testi, bir veri setinin belirli bir teorik dağılıma ne kadar uyduğunu değerlendiren parametrik olmayan bir testtir. Bu test, verilerin dağılımını, teorik bir dağılımın kümülatif dağılım fonksiyonu ile karşılaştırarak bir test istatistiği hesaplar. Bu istatistik, gözlemlenen değerlerin teorik dağılımdan ne kadar farklı olduğunu belirler. Yani, veri seti ile teorik dağılım arasındaki farkı ölçmek için kullanılmaktadır. Bu test ile daha çok veri setinin teorik dağılıma uygunluğu test edilmektedir (Yıldırım ve Gökpinar, 2012).

$X_1, X_2, \dots, X_n$ Rastgele seçilen bir örneklem belirlen bir dağılımdan örneğin; düzgün, üstel, normal vb. gelip gelmediğini test etmek amacıyla kullanılan bir uyum iyiliği testidir. Sıfır ve alternatif hipotezleri şu şekilde ifade edilmektedir (Facchinetti, 2009).

$$H_0: F(x) = F_0(x) \quad (1)$$

$$H_1: F(x) \neq F_0(x) \quad (2)$$

F_0 : Belirlenen dağılım fonksiyonu

F : Rastgele örneklem geldiği dağılım fonksiyonu

KS testinin test istatistiği ise şu şekildedir.

$$D = \sup_x |F_n(x) - F_0(x)| \quad (3)$$

2.3.2. Mann Whitney U Testi

Mann-Whitney U testi, bağımsız iki örneklem aynı ana kütleden gelip gelmediğini değerlendirmek için kullanılan parametrik olmayan bir testtir. Eğer iki bağımsız örneklem ortalamalarının birbirinden farklı olup olmadığı t-testi ile belirlenemiyorsa, bu durumda iki bağımsız örneklem için kullanılan parametrik olmayan Mann-Whitney U testi ile analiz yapılabilmektedir (Gamgam ve Altunkaynak, 2008).

Parametrik testlerin varsayımları gerçekleşmediğinde, analizi gerçekleştirmek için en güçlü seçenek Mann-Whitney U testidir. Bu testte; incelenen örneklemelerin ana kütleden rastgele olarak seçilmiş bağımsız örneklem olması ve örneklem içindeki bağımsızlığın

yanı sıra bağımlı değişkenin sıralı (ordinal) olması gerekmektedir. Mann-Whitney U testi, t-testinin uygulanamadığı durumlarda kullanılabilecek bir alternatif testtir.

Ana kütlesi bilinmeyen örneklemelerin medyanları (veri setinde ortada bulunan nokta) M_1 ve M_2 olmak üzere H_0 hipotezi şu şekilde ifade edilmektedir (Tanrıverdi, 2019).

$$H_0: M_1 = M_2 \quad (4)$$

Mann-Whitney U test istatistiği ise aşağıdaki gibi hesaplanır;

$$T = S - \frac{n_1(n_1-1)}{2} \quad (5)$$

n_1 : Bağımsız örnek hacmi

S : X gözlemlerine atanan sıra sayılarının toplamı

2.3.3. Tek Örneklem Binom Testi

Tek örneklem testi, bir popülasyonun seçili bir özelliğinin bilinen bir değeriyle karşılaştırılmasını sağlayan test olarak bilinmektedir. Örneklem içinden alınan bu özellik popülasyonun beklenen değeriyle uyumlu olup olmadığını belirlemek amacıyla kullanılmaktadır.

Belirli bir özelliğin ana kütesindeki oranı tespit etmeye yönelik çalışmalarda, direkt olarak bir oran belirlemek yerine ana kütlede alınan n boyutlu bir örneklem kullanılarak ana kütle hakkında bilgi edinilmeye çalışılan ve bu amaçla uygulanan parametrik olmayan tek örneklem testine, binom testi adı verilmektedir (Gamgam ve Altunkaynak, 2008).

Bu testte yapılan her ölçüm birbirinden bağımsız olup, iki ayrı sonuçtan oluşan varsayımlar kabul edilmektedir. Tek örneklem binom testinin test istatistiği ise şu şekildedir.

$$b = \sum_{i=1}^n \delta_i \quad (6)$$

2.3.4. Yapay Sinir Ağları

Yapay Sinir Ağları, insan beyninin en belirgin özelliği olan öğrenme fonksiyonlarını gerçekleştiren bilgisayar bazlı öğrenme sistemleridir. Öğrenme işlemini gerçekleştirirken örnekler kullanılmaktadır. Yapay sinir ağlarının temelini oluşturan ağlar, birbirlerine sinir hücresi adı verilen ve işlemleri gerçekleştiren elemanlarla bağlıdır. Sinir hücreleri ile birbirine bağlı olan her bir bağlantının bir ağırlık değeri vardır. Yapay sinir ağlarında örnekler vasıtasıyla oluşan bilgi, ağırlık değerleriyle ilişkili olup buradan ağa yayılmaktadır.

Var olan diğer hesaplama yöntemlerine kıyasla yapay sinir ağları farklı bir hesaplama yöntemi sunmaktadır. Ortama uyum sağlayan, net bir durum içinde olmasa bile karar verebilen, eksik bilgilerle de çalışabilen ve sistemdeki hatalara karşı toleranslı olan yapay sinir ağlarının günlük hayatta birçok alanda kullanımı bulunmaktadır.

Bununla beraber yapay sinir ağlarının dezavantajlı olduğu bazı özellikleri de bulunmaktadır. Yapay sinir ağlarının ağ yapısının oluşturulmasında ve ağ değişkenlerinin seçiminde belli bir standardı bulunmamaktadır. Öte yandan problemin sadece nümerik ifadeler ile belirtilmesi, veri setinin eğitiminin nasıl sona erdirileceğinin bilinmemesi ve bu durumlarda ağın davranışlarını açıklayamaması da yapay sinir ağlarının diğer olumsuz denilebilecek özelliklerini oluşturmaktadır.

Bütün özellikleri ele alındığında yapay sinir ağlarının günümüzde özellikle sınıflandırma, optimizasyon alanlarında sıklıkla kullanıldığı bilinmektedir (Öztemel, 2003).

Yapay Sinir Ağlarının Yapısı ve Temel Elemanları:

Yapay sinir ağları insan sinir sisteminden esinlenerek oluşturulmuştur. Sinir hücrelerinin (nöron) birbirleri ile iletişimleri sinapslar (synaps) vasıtasıyla gerçekleşmektedir. Sinir hücreleri işlediği bilgileri diğer hücreler aksonlar (axon) ile iletmektedir. Sinir hücreleri dışarıdan gelen bilgileri bir toplam fonksiyonu ile toplayarak aktivasyon fonksiyonu üzerinden çıktıyı üretmektedir. Daha sonra oluşan çıktıyı ağın bağlantıları üzerinden diğer hücrelere (işlem elemanları) göndermektedir.

Yapay sinir ağlarında farklı aktivasyon ve toplama fonksiyonları bulunmaktadır. Ağları birbirlerine bağlayan bağlantıların değerleri ağırlık değeri olarak ifade edilmektedir. Yapay sinir ağlarında işlem elemanları paralel bir şekilde konumlanarak 3 katman halinde bir ağ oluşturmaktadır. Bunlar;

- Girdi katmanı
- Ara katmanlar
- Çıktı katmanı

Girdi katmanında ilk olarak bilgiler ağa dahil olmaktadır. Bilgiler, daha sonra işlenerek çıktı katmanına iletilmektedir. Başka bir deyişle girdi katmanından giren bilgiler, ağın ağırlık değerleri kullanılarak çıktıya dönüştürülmektedir.

Bu noktada ağın doğru çıktılar üretebilmesi için ağırlık değerlerinin doğru olması gerekmektedir. Ağırlıkların doğru belirlenebilmesi ağın eğitilmesi vasıtasıyla gerçekleşmektedir. Başlangıçta rastgele atanan bu değerler eğitim esnasında örnek her ağa gösterilerek ağın öğrenme kuralına göre değiştirilir. Bu süreç ağ eğitim setindeki bütün

örnekler için doğru sonuçlar ortaya çıkana dek devam etmektedir. Bu süreçten sonra test setindeki örnekler ağı gösterilmektedir. Ağ, test setindeki örneklere doğru cevaplar verdiğinde ağı eğitilmiş olduğu varsayılmaktadır.

Yapay sinir ağlarında, ağı ağırlıkları belirlense dahi her bir ağırlığın ne ifade ettiği bilinmemektedir. Dolayısıyla, ağı girdiler hakkında ki kararını ağırlıkların verecek olmasından ötürü ağı zekasının ağırlıklar içinde saklandığı ifade edilebilmektedir. Yapay sinir ağlarında ağı bir problem esnasında olayı öğrenmesi için en doğru yapay sinir ağı modelini seçmek gerekmektedir. Halihazırda birçok yapay sinir ağı modeli bulunmakta olup doğru modeli seçerken şu kriterlere dikkat etmek gerekmektedir (Öztemel, 2003).

- Ağı topolojisi
- Toplama fonksiyonu
- Aktivasyon fonksiyonu
- Öğrenme stratejisi
- Öğrenme kuralı

Yapay sinir ağlarında giriş fonksiyonu şu şekilde ifade edilmektedir.

$$z_j = \sum_{i=1}^n w_{ij}x_i + b_j \quad (7)$$

z_j : Nöronların ağırlıklı toplam girdisi

b_j : Bias (nöronun aktivasyon eşiği) değeri

n : Girişlerin sayısı

x_i : Giriş değerleri

w_{ij} : Ağırlıklar

Yapay sinir ağlarında ağırlıklı toplam (z_j) daha sonra bir aktivasyon fonksiyonundan geçirilerek çıktı oluşturulmaktadır. Oluşturulan çıktı formülü genel olarak şu şekilde gösterilmektedir (Wu vd., 2023).

$$a_j = f(z_j) \quad (8)$$

Yapay sinir ağlarında aktivasyon fonksiyonları, nöron davranışının belirlenmesinde önemli derecede etki etmektedir. Nöronun çıkış genişliği aranan değerler arasında sınırlanmaktadır. Bu değerler yaygın olarak $[0,1]$ veya $[-1,1]$ arasındadır. Bu aşamada aktivasyon fonksiyonu gelen net girdide işlem yaparak, bu girdi için üreteceği çıktıyı oluşturmaktadır. Doğrusal olmayan fonksiyonlar daha çok tercih edilen aktivasyon

fonksiyonlarındandır. Problemlerde çoğunlukla doğrusal, bipolar sigmoid, hiperbolik tanjant ve sigmoid aktivasyon fonksiyonları kullanılmaktadır (Hamzaçebi, 2011).

Doğrusal aktivasyon fonksiyonu; lineer problemlerin çözümünde kullanılmaktadır. Toplama fonksiyonundan çıkan sonuç sabit bir değerle (a) çarpılarak ortaya çıkmaktadır.

$$f(x) = a \cdot x \quad (9)$$

Sigmoid aktivasyon fonksiyonu; sürekli ve türevlenebilir bir fonksiyondur. Her bir giriş değeri için sonucu 0 ile 1 arasında bir aralıkta verir ve matematiksel olarak şu şekilde ifade edilir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (10)$$

Bipolar Sigmoid aktivasyon fonksiyonu; ağ yapısında hiyerarşik katmanlar oluşturmak için kullanılan bir bipolar aktivasyon fonksiyonudur. Bu fonksiyon, geliştirilmiş bir bipolar sigmoid aktivasyonu sağlar. Ağırlıkların -1 ile +1 arasında sınırlandırarak, hata oranını en aza indirmek amacıyla tasarlanmıştır.

$$f(x) = \frac{1+e^{-2x}}{1+e^{-2x}} \quad (11)$$

Hiperbolik tanjant aktivasyon fonksiyonu, yapısal olarak sigmoid fonksiyonuna benzer. Ancak bu fonksiyonun çıkış değerleri, -1 ile +1 arasında değişir (Öztemel, 2003).

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (12)$$

2.3.5. WEKA Programı

WEKA (Waikato Environment for Knowledge Analysis), farklı mevcut metodolojileri test etmek için tasarlanmış gelişmiş bir makine öğrenimi algoritmaları ve ön işleme tekniklerini barındıran bir programdır. Giriş verilerinin dönüştürülmesi ve ön işleme, özellik seçimi yapma, sınıflandırma, kümeleme, regresyon görevleri ile elde edilen öğrenme yöntemlerinin istatistiksel değerlendirilmesini gerçekleştirme gibi çeşitli araçlar sunmaktadır. WEKA, kullanıcı dostu bir araçtır ve aynı zamanda Java, Python ve R gibi makine öğrenimi görevleri için en yaygın kullanılan bazı dillerle kolayca entegre edilebilmektedir (Lang, 2019).

WEKA, sınıflandırma ve regresyon için tüm önemli öğrenme tekniklerinin uygulanmasını içermektedir, bunlar; karar ağaçları, kural setleri, Bayesçi sınıflandırıcılar, destek vektör makineleri, lojistik ve doğrusal regresyon, çok katmanlı algılayıcılar ve en yakın komşu yöntemlerinden oluşmaktadır (Frank vd.,2004).

WEKA’da seçilen yöntemlerin bir arada kullanılması, veri setinin karmaşıklığına ve çeşitliliğine bağlı olarak daha fazla bilgi ve farklı bakış açıları sunmaktadır. Çalışmada kullanılan öğrenme algoritmaları; Rastgele Orman (Random Forest), Sıralı Minimum Optimizasyon (SMO), Çok Katmanlı Algılayıcı (MLP), Naive Bayes ve K-En Yakın Komşu (KNN) algoritmalarıdır. Her bir algoritmanın kendine özgü avantajları, çalışmada farklı veri özelliklerini daha iyi yakalayabilme olanağı sağlamıştır. Özellikle, farklı algoritmaların bir arada kullanılması, modelin genel performansını artırarak daha güvenilir sonuçlar elde edilmesini sağlamıştır.

Naive Bayes’in hızı ve basitliği, MLP’nin derin öğrenme kapasitesi, SMO’nun yüksek doğruluğu, KNN’nin anlaşılabilirliği ve Rastgele Orman algoritmasının genel izleme yeteneği bu yöntemlerin kombinasyonunu etkili kılmaktadır (Lang vd., 2019). Ayrıca hem klasik hem de modern makine öğrenimi tekniklerini bir arada kullanarak, çalışmada elde edilen sonuçların çeşitliliğini ve güvenilirliğini arttırmak hedeflenmektedir.

WEKA’da kullanılan metrikler;

a) Doğruluk (Accuracy)

Modelin genel doğruluğunu belirtmektedir. Doğru sınıflandırılan örneklerin toplam örneklere oranını ifade ederken, yüksek doğruluk oranı modelin genel başarısını göstermektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+F} \quad (13)$$

TP: Doğru pozitif (true positive), gerçekte pozitif olan örnekleri doğru bir şekilde pozitif olarak tahmin etme durumunu belirtmektedir.

TN: Doğru negatif (true negative), gerçekte negatif olan örnekleri doğru bir şekilde negatif biçimde tahmin etmeyi göstermektedir.

FP: Yanlış pozitif (false positive), gerçekte negatif olan örnekleri yanlış biçimde pozitif olarak tahmin etme durumunu ifade etmektedir.

FN: Yanlış negatif (false negative), gerçekte pozitif olan örnekleri yanlış biçimde pozitif olarak tahminlemeyi göstermektedir.

b) Kesinlik (Precision)

Pozitif olarak sınıflandırılan örneklerin ne kadarının gerçekten pozitif olduğunu göstermektedir. Yüksek kesinlik değeri, modelin yanlış pozitif oranının düşük olduğunu gösterir. Bu, özellikle yanlış pozitiflerin maliyetinin yüksek olduğu koşullarda önem arz etmektedir.

$$Kesinlik = \frac{TP}{TP+FP} \quad (14)$$

c) Hassasiyet (Recall)

Gerçek pozitif örneklerin ne kadarlık kısmının doğru bir şekilde pozitif olarak sınıflandırıldığını belirtmektedir. Yüksek hassasiyet, modelin gerçek pozitif örnekleri doğru tespit ettiğini gösterirken, yanlış negatiflerin kritik olduğu durumlarda daha büyük önem taşımaktadır.

$$Hassasiyet = \frac{TP}{TP+F} \quad (15)$$

d) F1 Skoru (F measure)

F1 skoru (F-measure): Kesinlik ve hassasiyetin harmonik ortalamasıdır. Her iki metriği de göz önünde bulundurur. Modelin genel başarımını tek bir değerle özetler ve özellikle sınıf dağılımının dengesiz olduğu durumlarda etkili bir değerlendirme sağlamaktadır.

$$F1 = 2 \times \frac{Kesinlik \times Hassasiyet}{Kesinlik + Hassasiyet} \quad (16)$$

e) Matthews Korelasyon Katsayısı (MCC)

İki sınıflı sınıflandırma modellerinin doğruluğunu değerlendiren bir ölçüttür. MCC, -1 ile +1 arasında değer alır, +1 mükemmel tahmini, 0 rastgele tahmini ve -1 tamamen yanlış tahmini ifade eder. MCC'nin yüksek olması, modelin güçlü bir performansa sahip olduğunu göstermektedir.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP+F) \times (TP+F) \times (TN+FP) \times (TN+FN)}} \quad (17)$$

f) Alıcı Operatör Karakteristiği Eğrisi (ROC)

ROC eğrisi altında kalan alanı ifade eder ve modelin ayırt etme yeteneğini değerlendirir. ROC eğrisi, yanlış pozitif oranına karşılık doğru pozitif oranını gösterir. ROC

alanı 0.5 ile 1 arasında değişir; 0.5 rastgele tahmini, 1 ise mükemmel sınıflandırmayı temsil etmektedir.

g) Kesinlik Hassasiyet Alanı (PRC)

Kesinlik-Hassasiyet eğrisi altında kalan alanı ifade eder. Özellikle dengesiz veri setlerinde daha etkili bir değerlendirme sunar. PRC alanının yüksek olması, modelin hem kesinlik hem de hassasiyet açısından başarılı performans sergilediğini göstermektedir (Merlini ve Rossini, 2021).

2.3.6. K En Yakın Komşu Algoritması (KNN)

K-En Yakın Komşu (KNN) algoritması, denetimli bir makine öğrenimi algoritması olup ağırlıklı olarak sınıflandırma amaçları için kullanılmaktadır.

Denetimli bir algoritma olan KNN, etiketli eğitim verilerinin özelliklerini ve etiketlerini dikkate alarak, etiketlenmemiş verilerin sınıflandırmasını tahmin etmektedir. Genel olarak, KNN algoritması test sorgusuna benzer bir eğitim modeli kullanarak veri kümelerini sınıflandırabilir. Bu sınıflandırmayı, sorgunun test edildiği veri noktasına en yakın k komşu noktalarını dikkate alarak yapmaktadır.

Son olarak, algoritma çoğunluk oylaması kuralını uygulayarak hangi sınıflandırmanın sonlandırılacağını kontrol eder. Tüm makine öğrenimi algoritmaları arasında, KNN algoritması en basit formlardan biri olup, uyarlanabilir ve anlaşılması kolay tasarımı bulunmaktadır. Bununla beraber farklı boyutlar, etiket sayıları, gürültü seviyeleri, aralıklar ve bağlamlar için veri kümesi üzerinde regresyon ve sınıflandırma problemlerini çözme kabiliyeti nedeniyle sınıflandırma görevlerinde yaygın olarak kullanılmaktadır (Uddin vd., 2022).

KNN eğitim kümesi şu şekildedir;

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (18)$$

x_i : Özellik vektörü

y_i : Sınıf etiketi

q : Test noktası

K : Komşu sayısı

K en yakın komşu (KNN) algoritması, komşularının mesafesine bakarak tahminlemede bulunmaktadır. Eğer K değeri küçükse model aşırı öğrenmeye yatkın olmaktadır. K değeri fazla olduğunda ise model genelleşerek büyümüş anlamına gelmektedir

ancak bu durumda doğrulukta düşme olabilmektedir. Bunun için komşularla arasındaki mesafeye bakmaktadır. Makine öğrenme algoritmalarında farklı mesafe ölçümleri bulunmakta olup temel olarak Öklid Mesafesi kullanılmaktadır.

Öklid mesafesi:

$$d(x_i, q) = \sqrt{\sum_{j=1}^m (x_{ij} - q_j)^2} \quad (19)$$

m : Özellik sayısı

x_{ij} : Eğitim veri noktasının j -inci özelliği

q_j : Test veri noktasının j -inci özelliği

Alternatif olarak kullanılan mesafe fonksiyonları ise şu şekildedir;

Manhattan mesafesi:

$$d(x_i, q) = \sum_{j=1}^m |x_{ij} - q_j| \quad (20)$$

Minkovski mesafesi

$$d(x_i, q) = (\sum_{j=1}^m |x_{ij} - q_j|^p)^{\frac{1}{p}} \quad (21)$$

p : Düzen parametresi

Kullanılacak mesafe yöntemi belirlendikten sonra test noktası q ile eğitim veri kümesi arasındaki mesafeler hesaplanmaktadır. Böylece en az mesafeye sahip K komşu seçilmektedir.

Sınıflandırma problemlerinin çözümünde aşağıda gösterilen fonksiyon kullanılmaktadır.

$$\hat{y} = \underset{c}{\operatorname{argmax}} \sum_{i=1}^K 1(y_i = c) \quad (22)$$

c : Sınıf etiketi

1: Gösterge fonksiyonu (doğru=1, yanlış=0)

2.3.7. Çok Katmanlı Algılayıcı


Çok katmanlı algılayıcı (MLP), yaygın olarak kullanılan bir sinir ağıdır. MLP, bir girdi katmanı, gizli katmanlar ve bir çıktı katmanı dahil olmak üzere birden fazla katmandan oluşmaktadır. Çok Katmanlı Algılayıcı (MLP), yapay sinir ağlarının en temel ve sık görülen kollarından biridir. Yapay sinir ağlarında olduğu gibi insan beynini taklit etme işleviyle

beraber çalışan matematiksel bir yapıdır. Birbirine bağlı nöron adı verilen yapay sinir hücrelerinin oluşup çok katmanlı bir yapıya sahiptir (Chan vd., 2023). Katmanlı yapılar şunlardan oluşmaktadır;

Giriş Katmanı: Model tarafından verilere ulaşılan ilk kademe olarak adlandırılmaktadır.

Gizli Katman(lar): Her birinin ağırlıklar ve her bir katmana eklenen sabit bir değere sahip (bias) bölümlerden oluşmaktadır.

Çıktı Katmanı: Tahminlemenin yani sonuçların üretildiği katmandır.



Şekil 14. MLP katman yapısı (Kaya ve İnce, 2021)

Şekil 14’te görülen MLP yapısında; X1, X2 ve X3 girdi katmanını, Y1, Y2 ve Y3 çıktı katmanını ifade ederken ortadaki kısım gizli katman veya katmanları belirtmektedir.

Giriş katman n tane giriş değişkeninden oluşmaktadır.

$$X = \{x_1, x_2, x_3, \dots, x_n\} \quad (23)$$

Çıktı katmanı ise m adet çıktı değişkenlerinden oluşmaktadır.

$$Y = \{y_1, y_2, y_3, \dots, y_m\} \quad (24)$$

MLP’de bulunan toplam parametre sayısı;

$$n_{h1} + \sum_{k=1}^{N_h-1} h_k \cdot h_{k+1} + h_{N_h} \cdot n \quad (25)$$

ifadesinden bulunmaktadır.

N_h : i (inci) katmandaki gizli düğüm sayısı.

N_h ve h_k değerleri daha yüksek olduğunda, bir MLP’yi optimize etmek için daha uzun hesaplama süreleri gerekmektedir.

2.3.8. Naive Bayes

Bayes teorisi, öznel Bayesyen tümevarım teorisinin önemli bir parçasıdır. Bayesyen karar verme, eksik koşullar altında bazı bilinmeyen durumların öznel olasılığını tahmin etmektedir.

Ω tüm veri setini ifade etmektedir.

$C_1, C_2, C_3, \dots, C_n \in \Omega$ C ise i adet kategoriye belirtmektedir.

$P(C_i) > 0, i = 1, 2, 3, \dots, n$

Birbiriyle uyumsuz iki kategoriye $\bigcup_{i=1}^n C_i = \Omega$ ifade etmektedir.

$P(X) > 0$

$$P(C_i | X) = \frac{P(X|C_i)P(C_i)}{\sum_{i=1}^n P(X|C_i)P(C_i)} \quad (26)$$

Naive Bayes, olasılık teorisini baz alan sınıflandırma algoritmalarından biridir. Temel olarak Bayes teoremini kullanarak verilen özelliklerin şartlı olasılıklarını hesaplamaktadır. Yüksek boyutlu veri setlerinde daha çok metin sınıflandırması işlemlerinde yüksek hız ve etkinlik sağlamaktadır. Sınıflandırma işlemlerinde Naive Bayes'in temel varsayımı veri setinin özelliklerinin birbirinden bağımsız olduğu şeklinde olmaktadır. Ancak bu varsayım gerçek veri setlerinde net olarak geçerli olmasa da çoğu uygulamada yine de olumlu sonuçlar vermektedir. Algoritmanın temel özellikleri arasında hızlı eğitim süresi ve düşük hesaplama maliyeti bulunmaktadır (Chen vd., 2021).

$$P(C_i | X) = \max\{P(C_1 | X), P(C_2 | X), \dots, P(C_n | X)\} \quad (27)$$

$X = (A_1, A_2, \dots, A_k)$ özellik vektörü iken A_j ise her seferinde değişkenlik gösteren x_j 'nin j adet değişimim göstermektedir.

Naive Bayes sınıflandırma işleminde, tüm özellikleri birbirinden bağımsız ele almaktadır.

$$P(X|C_i) = \prod_{j=1}^k P(A_j = x_j | C_i) \quad (28)$$

$$P(C_i|X) = \frac{\prod_{j=1}^k P(A_j = x_j|C_i)P(C_i)}{P(X)} \quad (29)$$

$$\frac{1}{P(X)} = a(> 0)$$

$$P(C_i|X) = a \prod_{j=1}^k P(A_j = x_j|C_i)P(C_i) \quad (30)$$

Numune setinde $N(D)$ Toplam numune sayısını göstermektedir.

$N(C_i)$ ise C_i kümesi içindeki numune sayısını göstermektedir.

A_j özelliği C_i kümesi içerisinde X_j olduğu zaman numune sayısı: $N(C = C_i, A_j = x_j)$

$$P(C_i) = \frac{N(C_i)}{N(D)} \quad (31)$$

$$P(A_j = x_j|C = C_i) = N(C = C_i, A_j = x_j)/N(C_i) \quad (32)$$

Formül (26) ve formül (29) değerleri formül (30) üzerine koyulduğunda; aşağıdaki bağıntı ortaya çıkmaktadır.

$$P(C_i|X) = a \prod_{j=1}^k \frac{N(C=C_i, A_j=x_j)}{N(C_i)} \frac{N(C_i)}{N(D)} \quad (33)$$

2.3.9. Rastgele Orman

Rastgele orman algoritması; makine öğrenmesinde manuel olarak ayarlanan modelin sürecini, sonuçlarını ve genel performansını kontrol eden hiper parametre kestirimi yapmaya gerek olmadan da iyi sonuçlar vermektedir. Hiper parametreler modelin eğitim sürecinden önce belirlenerek eğitim esnasında değiştirilmemektedir.

Rastgele orman algoritması regresyon ve sınıflandırma problemlerine uyumlu olmasından ötürü sıkça kullanılan algoritmalarından biridir. Aşırı öğrenme diğer bir deyişle veri setinin ezberlenmesi (overfitting) makine öğrenme algoritmalarının temel dezavantajlarından biri olarak bilinmektedir. Rastgele orman algoritmasının matematiksel ifadesi aşağıda görülmektedir


$$f(x) = \frac{1}{T} \sum_{t=1}^T h_t(x) \quad (34)$$

T : Toplam karar ağacı sayısı

$ht(x)$: t (inci) karar ağacının tahmini

$f(x)$: En son tahmin

Şekil 15'te ise rastgele orman algoritmasının akış şeması görülmektedir.



Şekil 15. Rastgele orman algoritması akış şeması (Sarker, 2021).

Rastgele orman algoritması, aşırı öğrenmenin önüne geçmek için veri setinden defalarca kez alt kümeler seçerek bu alt kümeleri eğitmektedir. Böylece çok fazla karar ağacı oluşmakta olup her bir karar ağacı bireysel tahmin yapmaktadır (Sarker, 2021).

2.3.10. Sıralı Minimum Optimizasyon

Sıralı Minimum Optimizasyon (SMO) Algoritması destek vektör makinesi tabanlı bir algoritma olup John Platt tarafından geliştirilmiştir. Destek vektör makinelerinin eğitim aşamasında, optimizasyon problemlerinin çözülmesinde kullanılır. İkinci dereceden fonksiyonları içeren matematik optimizasyonlarının çözümünde kullanılan Kuadratik Programlama (QP) algoritmalarına kıyasla Destek Vektör Makineleri (SVM) problemini çözmek için daha verimli bir algoritmadır (Sarker, 2021).

SMO algoritması, birden fazla değişken içeren bir optimizasyon problemini, her biri az sayıda değişkenin (genellikle yalnızca bir değişkenin) hedef fonksiyonunu optimize eden alt problemlere bölen bir ayrıştırma yöntemi (decomposition) olarak düşünülebilir. Diğer tüm değişkenler, alt problemde sabit olarak kabul edilir ve değiştirilmez (Sarker, 2021).

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^n \alpha_i \quad (35)$$

Yukarıda verilen optimizasyon problemini çözmede SMO algoritması kullanılmaktadır. Problemde aşağıdaki koşullar bulunmaktadır;

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C$$

α_i : Lagrange çarpanları

C : Ceza parametresi

y_i : Sınıf etiketleri

$K(x_i, x_j)$: Kernel fonksiyonu

n : Eğitim veri sayısı

SMO, optimizasyonu iki adıma bölerek iki Lagrange çarpanı seçmektedir (α_i, α_j). İki çarpanın seçilmesindeki amaç iki değişkenli optimizasyonun analitik çözümlenebilmesi ve daha kolay olmasıdır. SMO sınır değerler içerisinde (0, C) iki α çarpanı seçer ve sadece bu iki çarpan optimize edilirken diğer çarpanlar sabit tutulmaktadır.

$$\alpha_j^{new} = \alpha_j + y_j \frac{(E_i - E_j)}{\eta} \quad (36)$$


η : Seçilen Lagrange çarpanlarının güncellenmesinde kullanılan parametredir.

E_i ve E_j ise tahmin hatalarını ifade etmektedir.

$$\eta = 2K(x_i, x_j) - K(x_i, x_i) - K(x_j, x_j) \quad (37)$$

2.4. Modelleme Çalışması

Tez çalışmasında ham veri setinin tüm yöntemler ele alınarak tahminlemenin nasıl yapılacağına dair modelleme Şekil 16'da gösterilmektedir.



Şekil 16. Çalışmada kullanılacak modelin ana hatları

Çalışmada ilk olarak gemi ana makine yanma iş elemanları arızaları ile ilgili gemi evrakları incelenecektir. Bu evraklar geminin ay sonu evraklarında yer alan; arıza raporları, ana makine performans raporları, çalışma saatleri evrakları ve yakıt numuneleri analiz raporlarından oluşmaktadır. Ham veri setinden arızalar analiz edilip istatistikî yöntemlerle arızalara etki eden faktörler belirlenecektir. Sonrasında, zaman üzerinden başka bir deyişle arızaların oluşabileceği çalışma saatine bağlı tahminlenmesi için Yapay Sinir Ağları yöntemi kullanılacaktır. Bu yöntem kullanılırken, her bir katmandaki nöron sayısı ve katman sayısı değiştirilerek sonuçlar irdelenecektir. Arıza çalışma saatlerinin düzensiz dağılımından dolayı sonuçlar olumsuz olduğunda diğer makine öğrenme algoritmaları ile durum bazlı (arıza var, arıza yok şeklinde) arıza tahminlemesi yapılacaktır.

Çalışmada tüm işlemler, Intel® Core (TM) i5-13420H CPU 2.10 GHz işlemcili, 16 GB RAM özellikli bir bilgisayar ortamında yapılmıştır. İstatistikî analizlerde IBM SPSS 22, yapay sinir ağları ile zaman bağlı tahminlemede MATLAB® R2022b yazılımı, duruma bağlı arıza tahminlemede WEKA Version 3.8.6 yazılımı kullanılmıştır.

3. BULGULAR VE TARTIŞMA

3.1. Arızaların İncelenmesi

Bu bölümde arızalar tablo haline getirilip, arıza durumundaki yakıt türü ve ana makine basınç sıcaklık değerleri detaylı incelenmiştir (Tablo 11, Tablo 12, Tablo 13, Tablo 14). Silindir egzoz sıcaklık değerleri, yakıt pompalarının yakıt seviyelerini gösteren yakıt indeks değerleri, Pmax-Pcomp değerleri, ana makine yağ sıcaklık ve basınç değerleri, ana makine silindir soğutma suyu (high temperature-HT) basınç ve sıcaklık değerleri incelenmiştir. İlk dikkat çeken kısım yakıt değişikliğine bağlı olarak ortaya çıkan arıza adetindeki artış olmuştur. Gemilerde yanma iş elemanlarında oluşan toplam 220 arızanın 73 adeti ağır yakıt (IFO 380) kullanılan dönemde gerçekleşirken, gemiler Uluslararası Denizcilik Örgütü (IMO) 2020 Sülfür regülasyonları sonrası ortaya çıkan düşük sülfürlü ağır yakıt (VLSFO) kullanırken ortaya çıkan arıza adeti 147’dir.

Arıza olmadan önce ana makine egzoz sıcaklıkları, Pmax ve Pcomp değerleri silindir bazlı ortalama değer (mean value) civarında olduğundan, arıza durumunda normal olarak belirtilmiştir. Öte yandan makine silindir soğutma suyu (HT), yağlama yağı basınç ve sıcaklık değerleri incelendiğinde ise arızalardan önceki süreçte ana makine HT ve yağ değerlerinde herhangi bir anormallik görülmemiştir.

Tablo 11’de enjektör arızalarının analizi görülmektedir.

Tablo 11. Enjektör arızalarının analizi

Enjektör çalışma saati	Tarih	Yakıt tipi	Egzoz sıcaklığı	Yakıt indeks değeri	Yağ sıcaklığı	Yağ basıncı	HT sıcaklık	HT basınç
2742	18.12.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2742	18.12.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4335	01.04.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4335	01.04.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4335	01.04.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4335	01.04.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4646	05.05.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4646	05.05.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6056	08.11.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4369	28.12.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3329	30.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
670	29.11.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal

Tablo 11'in devamı

56	29.11.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
317	10.12.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
340	28.06.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4441	24.09.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
70	11.08.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3184	27.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4362	26.01.2018	HFO	Yüksek	Normal	Normal	Normal	Normal	Normal
421	16.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
384	03.02.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
384	03.02.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
542	07.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
542	07.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
542	07.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
491	25.04.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2447	31.10.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2189	17.06.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2189	17.06.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1213	11.01.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2724	11.01.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2634	11.01.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
218	27.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1782	27.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1782	27.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1423	08.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1423	08.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1423	08.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1423	08.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
378	10.04.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
1819	18.08.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
431	28.09.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
431	28.09.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4705	23.08.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4705	23.08.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
335	13.09.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
144	14.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3447	08.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3979	27.08.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2083	15.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2083	15.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3579	15.08.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
301	13.11.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal

Toplam 53 enjektör arızasının 45'i VLSFO kullanılan dönemde oluşmuştur. Bununla beraber sadece bir enjektör arızasında egzoz sıcaklığı alarm seviyesinde ortalama değerin üstündeyken, diğer tüm enjektör arızalarında egzoz sıcaklığı normal değerlerdedir.

Tablo 12'de ise yakıt pompası arızaları gösterilmektedir.

Tablo 12. Yakıt pompası arızalarının analizi

Yakıt pompası çalışma saati	Tarih	Yakıt tipi	Egzoz sıcaklığı	Yakıt indeks değeri	Yağ sıcaklığı	Yağ basıncı	HT sıcaklık	HT basınç
8666	10.01.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
7183	10.01.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
5167	03.01.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5356	11.08.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
5356	11.08.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6420	28.12.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
9249	21.03.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
7903	08.11.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
8375	18.12.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
8360	05.04.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2220	10.10.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
12750	22.09.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
215	24.06.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
11357	26.06.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
11498	17.12.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
11498	17.12.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
11951	11.02.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11951	11.02.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11951	11.02.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11951	11.02.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11951	11.02.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11951	11.02.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4862	22.01.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
7532	13.01.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4948	04.04.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3816	30.06.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3118	31.03.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
5302	01.07.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5302	05.07.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
9260	29.06.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
11241	31.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
11659	05.12.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
10241	06.18.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
5282	23.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
10194	23.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4867	07.04.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1283	27.03.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11548	08.02.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
11548	08.02.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3946	17.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3946	17.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3946	17.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3946	17.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6393	10.03.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
12964	08.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
12253	14.02.2020	VLSFO	Yüksek	Normal	Normal	Normal	Normal	Normal

Tablo 12'nin devamı

9103	18.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
9103	18.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
9103	18.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
9103	18.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
9103	18.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
9103	18.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal

Toplam 52 arızanın 29 adeti VLSFO kullanırken oluşmuştur. Yüksek egzoz sıcaklığı arızaların sadece bir adetinde görülürken, diğer tüm arızalarda egzoz sıcaklığı normal değerlerdedir. Tablo 13'te silindir başlığı ve Tablo 14'te ise piston arızalarının analizi görülmektedir.

Tablo 13. Silindir başlığı arızalarının analizi

Silindir başlığı çalışma saati	Tarih	Yakıt tipi	Egzoz sıcaklığı	Yakıt indeks değeri	Yağ sıcaklığı	Yağ basıncı	HT sıcaklık	HT basıncı
8120	24.01.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2484	26.05.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2484	28.05.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
7583	16.02.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2484	26.06.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6169	12.07.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5191	28.08.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6743	23.09.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1648	25.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
7874	06.12.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
7874	07.12.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6892	06.12.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6080	03.03.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6080	04.03.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5699	05.11.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2463	02.08.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
8550	02.08.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2853	29.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
10132	24.10.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
16601	03.12.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
16601	08.12.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
16289	18.12.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4371	26.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4766	28.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4766	28.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4766	28.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4766	28.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
14206	28.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5897	29.01.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal

Tablo 13'ün devamı

3555	24.11.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2963	01.08.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
609	06.05.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3287	11.01.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1406	14.01.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
1108	29.04.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5136	01.11.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6158	04.11.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3527	13.03.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3527	27.04.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5479	02.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2592	26.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4773	26.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4773	26.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4773	26.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2592	26.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2592	26.07.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
5188	18.09.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6396	17.01.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4692	16.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4618	26.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
4618	27.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
1095	11.03.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
1486	05.05.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2580	16.09.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
321	08.05.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
1486	29.04.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2385	20.02.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4311	11.08.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
7293	04.07.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
569	11.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2129	03.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2129	03.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2129	03.01.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
569	03.04.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
569	04.04.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6196	17.08.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3474	18.08.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2684	21.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
851	11.04.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2008	02.08.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2171	04.11.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3753	07.04.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
1461	10.02.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5799	23.02.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2808	04.06.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3354	04.11.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2083	16.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal

Tablo 14’te piston arızalarının analizi yapılmıştır.

Tablo 14. Piston arızalarının analizi

Piston çalışma saati	Tarih	Yakıt tipi	Egzoz sıcaklığı	Yakıt indeks değeri	Yağ sıcaklığı	Yağ basıncı	HT sıcaklık	HT basınç
5837	06.10.2017	HFO	Normal	Normal	Normal	Normal	Normal	Normal
7418	12.03.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
7583	15.03.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
14206	28.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
360	13.06.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5527	12.01.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6185	17.07.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5925	06.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6142	06.10.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2133	04.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2133	04.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2133	05.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2133	05.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2133	05.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
2463	20.05.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
341	03.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
306	10.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
296	18.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
296	18.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
306	19.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
52	22.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
96	03.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
96	03.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
6016	01.08.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
2684	22.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6403	06.03.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
1921	25.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3346	21.02.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
8675	27.10.2018	HFO	Normal	Normal	Normal	Normal	Normal	Normal
3535	17.11.2022	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4598	02.10.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3872	24.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
3872	26.06.2020	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
4768	04.09.2024	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5799	26.02.2021	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal
5786	27.07.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
9547	04.06.2019	HFO	Normal	Normal	Normal	Normal	Normal	Normal
6571	01.03.2023	VLSFO	Normal	Normal	Normal	Normal	Normal	Normal

Silindir başlığı ve piston arızalarında da enjektör ve yakıt pompalarında olduğu gibi arıza oluşumunu etkileyen temel değişkenin yakıt tipi olduğu görülmektedir. Düşük sülfürlü yakıt kullanımı durumunda 77 silindir başlığı arızasının 47 adeti, 38 piston arızasının ise 26

adeti ortaya çıkmaktadır. Bununla beraber; egzoz sıcaklığı, yakıt indeks değeri, yağ ve soğutma suyu basınç sıcaklık değerleri arıza durumlarında normal değer aralığında bulunmaktadır.

3.2. Yakıt Değerlerinin Arızalara Etkisinin İstatistikî Bulguları

Bu bölümde arızalara etki eden faktörlerin belirlenmesi amacıyla yakıt analiz değerleri irdelenmiştir. Yakıtta sülfür oranı, Vanadyum, Al+Si, Mikro karbon kalıntısı, Karbon Aromatik İndeks Değeri (CCAI) ve Makine Dostu Yakıt Standartı olarak belirtilen (EFN) faktörleri incelenmiştir. Yakıtın arızalara etkisini gösteren, yakıt özellikleri ve arıza varlığı arasındaki korelasyonu belirleyen Spearman korelasyon katsayılarına ait istatistikî bulgular Tablo 15’te gösterilmektedir.

Tablo 15. Yakıt özellikleri ve arıza varlığı arasındaki korelasyon

	Sülfür	Vanadyum	Al+Si	Mikro karbon kalıntısı	CCAI	EFN	Arıza
Sülfür	1	0,513**	0,127*	0,429**	0,428**	-0,280**	0,150**
Vanadyum	0,513**	1	0,193**	0,581**	0,303**	-0,341**	0,220**
Al+Si	0,127*	0,193**	1	0,301**	0,536**	-0,693**	0,102*
Mikro karbon	0,429**	0,581**	0,301**	1	0,515**	-0,521**	0,145**
CCAI	0,428**	0,303**	0,536**	0,515**	1	-0,683**	0,046
EFN	-0,280**	-0,341**	-0,693**	-0,521**	-0,683**	1	-0,101
Arıza	0,150**	0,220**	0,102*	0,145**	0,046	-0,101	1

** Korelasyon 0,01 düzeyinde anlamlıdır.

* Korelasyon 0,05 düzeyinde anlamlıdır.

Öncelikle uyum testlerinden Kolmogorov-Smirnov testi uygulanmıştır. Bu test, bir veri setinin belirli bir teorik dağılıma ne kadar uyduğunu değerlendiren parametrik olmayan bir testtir. Verilerin dağılımını, teorik bir dağılımın kümülatif dağılım fonksiyonu ile karşılaştırarak bir test istatistiği hesaplar. Bu istatistik, gözlemlenen değerlerin teorik dağılımdan ne kadar farklı olduğunu belirler. Yani, veri seti ile teorik dağılım arasındaki farkı ölçmek için kullanılmaktadır. Bu test ile daha çok veri setinin teorik dağılıma uygunluğu test edilmektedir

Sülfür, Vanadyum, Al-Si ve mikro karbon kalıntısı bileşenlerinde etki tespit edilirken ($p < 0,05$); CCAI ve EFN değerlerinde etki tespit edilmemiştir. Analiz verilerine ait p değeri $< 0,01$ bulunduğundan verilerin normal dağılmadığı görülmüştür. Bu nedenle verilerin analizinde korelasyonun belirlenmesi amacıyla parametrik olmayan verilere uygulanabilen

Spearman Korelasyon katsayıları belirlenmiştir. Arıza varlığının sülfür, vanadyum, mikro karbon kalıntısı ile çok önemli ($p<0,01$) ve Al+Si içeriği ile önemli ($p<0,05$) düzeyde pozitif korelasyon içerisinde olduğu görülmektedir. Farklı değişkenler arasındaki en yüksek korelasyon negatif düzeyde 0,693 ile Al+Si ve EFN arasında görülmektedir (katsayı 1'e ne kadar yakınsa korelasyon yüksek düzeyde denilebilmektedir). Tablo 16'da ise arıza verilerine bağlı olarak U testi değerleri gösterilmektedir.

Tablo 16. Yakıt için arıza varlığına bağlı olarak U değerlerinin hesaplanması


	Arıza	N	Sıralar ortalaması	U	p
Sülfür % m/m	Var	220	201,62	20176	0,004**
	Yok	175	169,22		
Vanadyum mg/kg	Var	220	207,74	21467,5	<0,001**
	Yok	175	159,98		
Al+Si mg/kg	Var	220	197,14	19231,5	0,049*
	Yok	175	175,02		
Mikro Karbon Kalıntısı % m/m	Var	220	201,28	20104	0,005**
	Yok	175	169,66		
CCAI	Var	220	191,86	18116	0,375
	Yok	175	181,86		
EFN	Var	220	177,99	15189,5	0,052
	Yok	175	199,81		

* $P<0.05$ ** $P<0.01$

Arıza varlığında yakıt özelliklerinin farklılaşıp farklılaşmadığını incelemek için yapılan Mann Whitney U Testi sonuçlarına göre; yakıt özelliklerinin ortalamaları arasında istatistiksel olarak anlamlı bir farklılık; Sülfür, Vanadyum, Al-Si ve mikro karbon kalıntısı bileşenlerinde tespit edilirken ($p<0,05$), CCAI ve EFN değerlerindeki değişimin arıza varlığı ile ilgili olmadığı görülmektedir ($p>0,05$).

3.3. Yapay Sinir Ağları ile Çalışma Saati Bazlı Arıza Tahminlemesi


Bu bölümde öncelikli olarak tahminleme ile ilgili Yapay Sinir Ağları (YSA) yöntemi kullanılmıştır. Veri setindeki arızalara (toplam 220 adet) ait verilerin %70 ve %80'i eğitim verisi olarak kullanılırken, geri kalan veriler test verisi olarak kullanılmıştır. Arızaların YSA modeli sonucunda ortaya çıkan sonuçları Şekil 17'de gösterilmektedir.



Şekil 17. Yapay sinir ağı ile tahminleme sonucu 1

YSA ile ilk tahminlemede veri setinin %80'i eğitimde, %20'si ise testte kullanılmaktadır. YSA yapısı tek katmanlıdır. Tek katmanlı yapıda, her bir katmanda 3 nöron bulunmaktadır. Bununla beraber korelasyon analiz değeri düşük kalmaktadır ($R=0,21569$).


Şekil 18'de ise ilk YSA modelinden farklı olarak her bir katmanda 5 nöron bulunmaktadır. Yapıda veri setinin %80'i, testte ise %20'si kullanılmaktadır ve yapı yine tek katmanlıdır.



Şekil 18. Yapay sinir ağları ile tahminleme sonucu 2

YSA ile tahminlemede bu sefer yapı yine tek katmanlıdır. Bu tahminlemede de veri setinin %80'i eğitim seti olarak kullanılmıştır. Ancak her katmandaki nöron sayısı 1'den 5'e yükseltilmiştir. Sonuç olarak korelasyon analiz değeri $R=0,52311$ bulunmaktadır.


Şekil 19'da ise her bir katmandaki nöron sayısı artırılarak elde edilen sonuçlar gösterilmektedir.



Şekil 19. Yapay sinir ağları ile tahminleme sonucu 3

Şekil 19'daki yapıda eğitim seti olarak veri setinin yine %80'i kullanılmıştır. Yapı tek katmanlı bir yapıdır. YSA ile 2 numaralı tahminlemede katmandaki nöron sayısı artırıldığında R değeri yükseldiğinden bu yapıda da katmandaki nöron sayısı 10'a yükseltilmiştir. Sonuç olarak korelasyon analiz değeri yükselse de tahminleme açısından yine de düşük kalmaktadır ($R=0,67289$).

Şekil 20'de YSA modelinde katman sayısı 3, her bir katmandaki nöron sayısı 10 olarak belirlenmiştir. Bununla beraber veri setinin %80'i eğitim ve %20'si ise test verisi olarak kullanılmıştır.



Şekil 20. Yapay sinir ağı ile tahminleme sonucu 4

YSA ile 4. tahminlemede önceki tahminlemelerde olduğu gibi veri setinin %80'i eğitim seti olarak kullanılmıştır. Korelasyon analiz değerini yükseltmek amacıyla, YSA modelinde katman sayısı artırılmıştır. Bu yapıda 3 katman bulunmakta olup her bir katmanda 10 adet nöron bulunmaktadır. Sonuç olarak korelasyon analiz değeri, $R=0,51944$ bulunmaktadır. YSA modellerinde bulunan bu değerler güvenilirlik ve doğru tahminleme açısından düşük kalmaktadır. Çalışma saati olarak arıza tahminlemesi yapılırken arızaların oluşum saatlerinde düzensiz bir dağılım olduğundan arıza tahminlemesi, diğer makine öğrenme algoritmaları ile arıza var veya yok şeklinde durum bazlı yapılacaktır.

3.4. WEKA Programı ile Durum Bazlı Arıza Tahminlemesi

Makine öğrenme algoritmaları veri sınıflandırma işlemleri için WEKA programı kullanılmıştır. Veri madenciliği ve makine öğrenme dallarında sıklıkla tercih edilen bir yazılım olarak WEKA karşımıza çıkmaktadır. Ara yüz kolaylığı, ileri seviye özellikleri ve WEKA, özellikle veri madenciliği ve makine öğrenimi alanında yaygın olarak tercih edilen bir yazılımdır. Gelişmiş özellikleri, kolay ara yüz ve geniş algoritma seçenekleri WEKA'nın kullanım alanını genişletmiştir (Aksu ve Doğan, 2019; Bouckaert vd., 2010). WEKA'da seçilen yöntemlerin bir arada kullanılması, veri setinin karmaşıklığına ve çeşitliliğine bağlı olarak daha fazla bilgi ve farklı bakış açıları sunmaktadır. Çalışmada kullanılan öğrenme algoritmaları; Rastgele Orman (Random Forest), Sıralı Minimum Optimizasyon (SMO), Çok Katmanlı Algılayıcı (MLP) ve K-En Yakın Komşu (KNN) algoritmalarıdır. Her bir algoritmanın kendine özgü avantajları, çalışmada farklı veri özelliklerini daha iyi yakalayabilme olanağı sağlamıştır. Özellikle, farklı algoritmaların bir arada kullanılması, modelin genel performansını artırmakta ve daha güvenilir sonuçlar elde edilmesini sağlamıştır. Naive Bayes'in hızı ve basitliği, MLP'nin derin öğrenme kapasitesi, SMO'nun yüksek doğruluğu, KNN'nin anlaşılabilirliği ve Rastgele Orman algoritmasının genel izleme yeteneği, bu yöntemlerin kombinasyonunu etkili kılmaktadır (Lang vd., 2019).


Tablo 17'de makine öğrenme algoritmalarının WEKA metriklerine göre sonuçları tablo halinde görülmektedir. Bu tahminleme yapılırken veri setinde (Ek Tablo 1) sadece arızalara etki eden faktörler baz alınmıştır.

Tablo 17. Makine öğrenme algoritmaları sonuçları

Makine Öğrenme Algoritmaları	Doğruluk	Kesinlik	Hassasiyet	F1 Skoru	MCC	ROC Alanı	PRC Alanı
Naive Bayes	0,843	0,856	0,843	0,843	0,698	0,926	0,914
Rastgele Orman	0,947	0,948	0,947	0,947	0,893	0,985	0,982
MLP	0,942	0,943	0,942	0,941	0,883	0,963	0,950
SMO	0,899	0,900	0,899	0,898	0,795	0,894	0,857
Ibk (Knn)	0,947	0,947	0,947	0,947	0,892	0,943	0,925


Tabloda doğruluk, kesinlik, hassasiyet, F1 skoru, MCC, ROC alanı ve PRC alanı gibi WEKA programında kullanılan metrikler görülmektedir. Makine öğrenme algoritmalarının kıyaslanması açısından WEKA metriklerini içeren grafikler aşağıda görülmektedir.

Şekil 21’de makine öğrenme algoritmalarının doğruluk değerlerini gösteren grafik görülmektedir.



Şekil 21. Doğruluk metriği grafiği


Modelin genel doğruluğunu başka bir ifadeyle doğru sınıflandırılan örneklerin toplam örneklere oranı incelendiğinde; Rastgele Orman ve İBk (en yakın komşu algoritma) %94,7 oranla en yüksek değerde olduğu görülmektedir. Naive Bayes’te ise %84,3 hassasiyetle doğruluk oranı bulunmuştur.



Şekil 22. Kesinlik metriği grafiği

Pozitif tahminlerin doğruluğunu gösteren kesinlik değerinde, pozitif olarak sınıflandırılan örneklerin ne kadarının gerçek pozitif olduğunu belirtmektedir. Yüksek kesinlik değeri modelin yanlış pozitif oranının düşük olduğunu göstermektedir. Rastgele Orman ve IBk (en yakın komşu algoritma) sırasıyla %94,8 ve %94,7 oranlarla en yüksek kesinlik değerine sahipken, Naive Bayes'te ise %85,6 hassasiyetle kesinlik değeri bulunmuştur.


Gerçek pozitif örneklerin ne kadarının doğru bir şekilde pozitif olarak sınıflandırıldığını gösteren Hassasiyet kriteri Şekil 23'te gösterilmektedir.



Şekil 23. Hassasiyet metriği grafiği

Doğruluk ve Kesinlik metriklerinde olduğu gibi Hassasiyet metriğinde de Rastgele Orman ve IbK %94,7 oranla en yüksek değerde sonuç veren algoritmalarıdır. Öte yandan Naive Bayes %84,3 ile en düşük değerde olan makine öğrenme algoritmasıdır. Yüksek hassasiyet değeri modelin gerçek pozitifleri iyi bir şekilde yakaladığını göstermektedir.


Kesinlik ve Hassasiyet metriklerinin harmonik ortalamasını belirten F1 Skoru metriğinin makine öğrenme algoritmaları açısından karşılaştırmasını gösteren grafik Şekil 24'te gösterilmektedir.



Şekil 24. F1 skoru metriği grafiği

F1 Skoru, modelin genel performansını tek bir ölçümle özetler ve özellikle sınıf dengesizliğinin olduğu durumlarda fayda sağlamaktadır. Makine öğrenme algoritmaları arasında F1 Skoru değerlerine bakıldığında; en yüksek değerler %94,7 oranlarla Rastgele Orman ve IBk'da görülürken, en düşük değer %84,3 ile Naive Bayes'te görülmektedir.

Modelin ayırım gücünü ölçen ROC eğrisinin altında kalan alanı ifade eden ROC Alanı metriğinde makine öğrenme algoritmalarının değerlerini gösteren grafik Şekil 25'te gösterilmektedir.



Şekil 25. ROC alanı metriği grafiği

ROC Alanı metriğine göre en yüksek değerler %98,5, %96,3 ve %94,3 ile sırasıyla Rastgele Orman, MLP ve IBk'da görülmektedir. En düşük değer ise %89,4 ile SMO Algoritmasında görülmektedir. ROC eğrisi, yanlış pozitif oranına karşı doğru pozitif oranını göstermektedir. ROC alanı 0.5 ile 1 arasında değişmekle beraber 0,5 değeri modelin rastgele tahmin yaptığını, 1 değeri ise mükemmel bir ayırım yapıldığını ifade etmektedir.

Şekil 26'da WEKA metriklerinin hepsinde en iyi sonuçları veren Rastgele Orman algoritmasının WEKA programı üzerinden ekran görüntüsü gösterilmektedir.

```

=== Run information ===

Scheme:          weka.classifiers.trees.RandomForest -P 100 -I 100 -num-
slots 1 -K 0 -M 1.0 -V 0.001 -S 1
Relation:        ariza_siniflandirma
Instances:       395
Attributes:      5
                  Sulfur
                  Vanadyum
                  Al_Si
                  MKA
                  Ariza_adedi
Test mode:       10-fold cross-validation

=== Classifier model (full training set) ===

RandomForest

Bagging with 100 iterations and base learner

weka.classifiers.trees.RandomTree -K 0 -M 1.0 -V 0.001 -S 1 -do-not-check-
capabilities

Time taken to build model: 0.07 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances Kappa      374                94.6835 %
statistic                               0.8917
Mean absolute error                     0.0693
Root mean squared error                  0.1927
Relative absolute error                  14.0363 %
Root relative squared error              38.7849 %
Total Number of Instances                395

=== Detailed Accuracy By Class ===

ROC Area   PRC Area   TP Rate   FP Rate   Precision   Recall   F-Measure   MCC
Class
0,985      0,980      0,914     0,027     0,964       0,914     0,938       0,893
0          0,973     0,086     0,934     0,973     0,953     0,893
0,985      0,983      1         0,060     0,948     0,947     0,947     0,893
Weighted Avg.
0,985      0,982      0,947

```

```

=== Confusion Matrix ===

  a    b    <-- classified as
160  15 |    a = 0
 6 214 |    b = 1

```

Şekil 26. WEKA programında Rastgele Orman algoritması ekran görüntüsü

Rastgele Orman algoritması ekran görüntüsünde üst kısımda veri adeti görülmektedir. Hemen alt kısımda arızaya etki eden 4 parametre (Sülfür, Al+Si, Vanadyum, mikro karbon kalıntısı) belirtilmektedir. Veri seti rastgele şekilde 10 gruba ayrılarak ayrı ayrı eğitilmektedir (cross validation). Böylece aşırı öğrenme ve ezberlemenin önüne geçilmektedir. Alt kısımda doğru pozitif, yanlış pozitif değerleri, doğruluk, hassasiyet, kesinlik, F1 skoru, ROC alanı gibi WEKA metriklerinin değerleri görülmektedir. Sınıflandırma olarak arıza olduğu durumlarda “1”, arıza olmadığı durumlarda ise “0” sınıflandırması yapılmaktadır. Arıza durumunda ve arıza olmadığı durumlarda WEKA metriklerine göre ayrı ayrı sonuçlar ortaya çıkmaktadır. Daha sonra bu sonuçların ağırlıklı ortalaması alınmaktadır. Modelin başarısını doğru şekilde ölçmek ve değerlendirmek için hata matrisi (confusion matrix) kullanılmaktadır. Böylece yapılan sınıflandırma modeli de değerlendirilmektedir. Ekran görüntüsünün en alt kısmında bulunan hata matrisi değerleri ile doğru pozitif ve yanlış pozitif değerleri bulunmaktadır.

Ana makine yanma iş elemanları arızalarının tahminlenmesinde çalışma saati bazlı tahminlemede ilk etapta kullanılan Yapay Sinir Ağları bulgularında; veri setinde eğitim seti %80 ve test seti %20 olarak kullanıldığında modelin bağımsız değişkenlerin bağımlı değişkeni ne kadar açıkladığını gösteren R değeri düşük bulunmuştur. Tek katmanlı ve her bir katmanda 3 nöron bulunan yapıda $R=0,21569$, tek katmanlı ve her bir katmanda 5 nöron bulunan yapıda $R=0,51944$, 3 katmanlı ve her katmanda 10 nöron bulunan yapıda $R=0,52311$, son olarak tek katmanlı ve her katmanda 10 nöron bulunan yapıda $R=0,67289$ değerleri bulunmuştur. Yapay Sinir Ağlarında modelin doğruluğunun ve etkin sonuç vermesi açısından R değerinin 1'e yakın olması istenmektedir (Öztemel, 2003). Halihazırda literatürde bulunan ana makine egzoz sıcaklıklarının tahminlenmesi (Lazakis vd., 2018; Raptodimos&Lazakis, 2020), ana makine durumunun görüntülenmesi (Gkerekos vd., 2017) ve tüm ana makineye bağlı sistemlerin çalışma saatleri üzerinden arıza tahminlenmesi (Göksu&Erginer, 2020) gibi çalışmalarda R değeri 1'e yakın değerlerdedir. Dolayısıyla çalışma saatine bağlı arıza tahminlemesi etkin sonuç vermemiştir. Bu sonuçların ortaya çıkmasında arızaların saatlerindeki dağılımın normal olmaması temel etkenlerden biridir.

WEKA programı vasıtasıyla diğer makine öğrenme algoritmaları ile duruma bağlı arıza tahminlenmesi (arıza var veya arıza yok) modelinde elde edilen sonuçlarda ise doğruluk, kesinlik, hassasiyet, F1 skoru ve ROC alanı gibi metriklerde modelin genel başarı oranı 0,843 ile 0,947 arasında değişmektedir. Bu sonuçlar, literatürde farklı alanlarda WEKA programı ile yapılan çalışmalarda elde edilen başarılı bulgularla paralellik göstermektedir

(Frank vd., 2004; Merlini&Rossini, 2021; Lang vd., 2019). Bu modelde arızaya etki eden faktörler olarak yakıt sülfür değeri, Al+Si değeri, Vanadyum değeri ve mikro karbon kalıntısı değerler olarak bulunmuştur. 2016-2024 yılları arasında oluşan toplam 220 arızanın 73 adeti yüksek sülfür oranına sahip HFO yakıt kullanımında oluşurken, 147 adeti ise düşük sülfürlü yakıt kullanımında oluşmuştur. Bu durum gemilerde düşük sülfürlü yakıt kullanımına bağlı olarak gemi ana makine arızaları ortaya çıkmasına yönelik literatürdeki çalışmalarla (Vedachalam vd., 2022) uyumluluk göstermektedir. Ayrıca çalışmada yakıt içerisinde bulunan diğer maddelerin arızalara olan etkisi literatürde yapılan çalışmalarla şu şekilde desteklenmektedir; katalitik ince partiküller olarak adlandırılan Al+Si değerlerinin gemi ana makine parçalarına olan olumsuz etkisi (JHC Report, 2025; Vukicevic vd., 2019), Vanadyumun arızalara etkisi (Surawski vd., 2017), mikro karbon kalıntısının olumsuz etkisi (Lin, 2000; Chybowski vd., 2023).

Ana makine yanma iş elemanlarına etki eden bir diğer faktörün de yağlama yağı olduğu bilinmektedir. Çalışmada iki zamanlı gemi dizel makinelerinde yağlama yağının silindir içerisinde yağlama yapıldıktan sonra yakılmasından ve bundan ötürü yağlama yağı analiz değerleri olmadığından yağlama yağının etkisi ortaya koyulamamıştır. Ancak, düşük sülfürlü yakıtlarda yağlama yağında oluşabilecek asitleri nötralize eden baz düşük sülfürden dolayı yanma sonrası daha fazla bir tortu oluşturmaktadır. Bu tortu iki zamanlı gemi dizel makinelerinde, piston tepesinde birikebilmektedir. Aşırı tortu oluşma durumunda ise yağ filmi bozularak sürtünme kaynaklı ani ve ciddi aşınmalar meydana gelmektedir (CIMAC, 2025b; Thomas vd., 2019; Bozic, 2021).

4. SONUÇLAR

Dünyada 2013-2018 yılları arasında ticari gemilerde oluşan kazaların yaklaşık %30'u makine ekipmanlarından meydana gelen arızalardan oluşmaktadır, bununla birlikte ticari gemilerde makine arızaları sonucu oluşan maddi hasarlar toplam maddi kayıpların %12'sini oluşturarak 1 milyar doları aşmaktadır. Ticari gemilerin büyük bir çoğunluğu halen ağır yakıt (HFO) yakıt kullanmaktadır. Bu ağır yakıtın yanması sonucu gemi makinelerinde ciddi hasarlar ve arızalar oluşmaktadır. Özellikle ana makine yanma iş elemanları olarak adlandırılan enjektör, yakıt pompası, silindir başlığı ve piston üzerinde ciddi hasarlar ve arızalar meydana gelmektedir. Geminin manevra, kanal-boğaz geçişi ve deniz trafiğinin yoğun olduğu yerlerde yanma iş elemanları arızası gemi güvenliği açısından risk teşkil etmektedir. Ayrıca, oluşan arızaların ortalama giderilme süresi 6 saate kadar uzamakta ve beklenmedik makine arızaları daha büyük arızalara ve dolayısıyla gemi işletmecileri için daha büyük maddi ve iş kayıplarına yol açmaktadır. Dolayısıyla yanma iş elemanlarının planlı bakım tutumuna büyük önem verilmelidir. Planlı bakım tutum zamanları ve prosedürleri ana makine üretici firmaların operasyon manuellere göre gemilerce yapılmaktadır. Ancak planlı bakım tutum zamanları daha çok fabrika üretim tesislerinde deneysel olarak uygulandığından geminin seyir koşullarında farklı parametrelerin işin içine girmesiyle her zaman olası arızaların önüne geçmemektedir. Ülkemizdeki Türk bayraklı gemilerde de ana makine üretici firmaların operasyon manuellere göre planlı bakım tutum zamanları belirlenmiş olup gemiler belirlenen bu zamanlara bağlı kalıp planlı bakım tutum işlemlerini yapmaktadır. Planlı bakım tutumların yapılması her zaman arızaların olasılığını azaltsa da gemi ana makine yanma iş elemanlarının farklı birçok parametre ışığında olası arızalarının tahminlenmesi büyük önem arz etmektedir.

Çalışmada ilk aşamada 2016-2024 yılları arasında iki zamanlı gemi ana makinesine sahip 14 geminin ay sonu evrakları, arıza raporları ve yakıt analiz raporları neticesinde arızalar irdelenmiştir. Gemi ana makine yağ sıcaklık ve basınç değerleri, egzoz sıcaklık değerleri, HT basınç ve sıcaklık değerleri, silindir Pmax-Pcomp değerleri ve yakıt indeks değerlerinde ortalama değerlerden kayda değer derecede bir farklılık görülmediğinden bu değerler analiz edilmemiştir. Daha sonra gemilerde arızalara etki eden faktörler literatürdeki çalışmaların taranmasıyla belirlenmiştir. Bu arızalar veri setinde irdelenerek arızalara etki

eden temel faktörler istatistiki yöntemlerle belirlenmiştir. Bu faktörler yakıt içeriğinde sülfür oranı, Al+Si, Vanadyum ve mikro karbon kalıntısı olarak bulunmuştur.

Zamana bağlı arızaların tahminlenmesi için ilk aşamada Yapay Sinir Ağları kullanılmıştır. Ancak, arızaların oluşma saatlerinin normal dağılım göstermemesi neticesinde Yapay Sinir Ağları modeli modelin bağımsız değişkenlerin bağımlı değişkeni ne kadar açıkladığını gösteren R değeri düşük bulunmuştur ($R=0,67289$).

Sonrasında durum bazlı (arıza var veya arıza yok) arıza tahminlemesine geçilmiştir. Bu aşamada WEKA programı ve diğer makine öğrenme algoritmaları kullanılmıştır. Çalışmada kullanılan öğrenme algoritmaları; Rastgele Orman (Random Forest), Sıralı Minimum Optimizasyon (SMO), Çok Katmanlı Algılayıcı (MLP) ve K-En Yakın Komşu (KNN-WEKA'da İbk olarak adlandırılmaktadır.) algoritmalarıdır. Her bir algoritmanın kendine has olumlu yanları, veri setinin özelliklerinin kavranabilmesine olanak sağlayarak, modelin genel performansını ve güvenilirliğini artırmıştır. Veri setinde bulunan arıza durumundaki ve arıza olmayan durumlardaki toplam 395 adet veri kullanılmıştır. Makine öğrenme algoritmaları ile en yüksek tahminleme doğruluğunun ve kesinliğinin belirlenmesi amacıyla WEKA programı ile çeşitli metotlar arasında karşılaştırma yapılmıştır. Sonuç olarak; arıza tahminlemede modelin genel doğruluğunda, Rastgele Orman ve İbk algoritması %94,7, MLP %94,2, SMO %89,9, Naive Bayes %84,3 oranında başarı sağlamıştır. Pozitif tahminlerin doğruluğunu ifade eden Kesinlik sonuçlarına göre; Rastgele Orman %94,8, İbk %94,7, MLP %94,3, SMO %90, Naive Bayes ise %85,6 oranlarını yakalamıştır. Gerçek pozitiflerin yakalama oranını gösteren Hassasiyet metriğinde ve modelin genel performansını tek bir ölçümle belirten F1 skorunda ise Rastgele Orman ve İbk algoritmaları %94,7 değerine ulaşmıştır. Modelin yanlış pozitif oranına karşı, doğru pozitif oranın gösteren başka bir deyişle modelin rastgele tahmin yaptığını (0,5) veya mükemmel seviyede tahmin yaptığını (1) gösteren ROC alanı metriğinde; Rastgele Orman %98,5 başarı oranı ile ilk sırada yer alırken, MLP ve İbk sırasıyla %96,3 ve %94,3 oranlarına sahiptir.

5. ÖNERİLER

Doktora tezi olarak sunulan bu çalışmada, gemi makine yanma iş elemanları arızalarının tahminlenmesinde doğruluk ve kesinlik açısından en uygun yöntemin belirlenmesi amaçlanmıştır. Ayrıca, arızalara etki eden yakıt içerikleri çeşitli yöntemler ve literatür ışığında belirlenerek çalışma yapmak isteyen araştırmacılara ve uygulayıcılara iletilmek istenen öneriler aşağıdaki gibi belirtilmiştir:

- Durum bazlı arıza tahminlemede Rastgele Orman, İbk ve MLP makine öğrenme algoritmaları doğruluk, kesinlik, hassasiyet, F1 skoru ve ROC alanı metrikleri açısından kullanılabilir.
- Rastgele orman algoritması ile oluşturulan durum bazlı tahminleme algoritması ile gemiler anlık yakıt değerlerini girerek durum bazlı arıza tahminlemesi yapılabilir. Bu durumda gemi personelinin farkındalığı artarak önleyici faaliyetleri gerçekleştirmesi sağlanır.
- Çalışmayı geliştirmek için daha karmaşık yapıdaki etkenler veri setine eklenebilir. Bu kapsamda gemi ana makinelerinde kullanılan parçaların malzeme özellikleri ve varsa malzemelerin laboratuvar test sonuçları veri setine katılabilir.
- Gemilerin günlük makine jurnallerindeki veya otomasyon sistem kayıtlarındaki günlük hatta saatlik egzoz sıcaklığı, yağ ve soğutma suyu basınç sıcaklık değerleri alınıp veri setine eklenebildiğinde kapsamlı bir çalışma yapılabilir.
- Çalışmada, arıza raporlarında planlı bakım tutum dışında silindir gömleği değişimine rastlanmadığından silindir gömleği ile ilgili veriler bulunmamaktadır. Bu kapsamda, farklı gemilerden silindir gömleği arızaları ile ilgili veriler bulunarak çalışma genişletilebilir.
- Planlı bakım tutum esnasında piston ve silindir gömleği aşınma ölçüm değerlerine ulaşılmadığından bu değerler de çalışmada kullanılmamıştır. Bu değerlere ulaşılarak çalışma kapsamı artırılabilir.
- Ayrıca gemilerde planlı bakım tutum ve arızaların giderilmesi için yapılan işlemlerde insan faktörünün ciddi bir önemi bulunmaktadır. Denizcilik şirketleri teknik departmanlardan uzman görüşleri ve gemi personelinin deneyim, bilgi birikim (gemi personelinin tecrübesi, varsa şirket tarafından değerlendirilme raporları) ilgili bilgiler

de veri setine eklenebilir. Bu sayede arızaya etki eden diğer etkenlerle çalışma daha da genişletilip ilerletilebilir.

- Yağlama yağının içeriğindeki maddelerin etkisinin net bir şekilde belirlenmesi amacıyla temiz yağın laboratuvar analizi yapılarak bu bilgiler çalışmaya eklenebilir.
- Çalışmada iki zamanlı gemi dizel ana makine verileri kullanılmıştır. Çalışmanın bulgularını genellemek amacıyla dört zamanlı gemi dizel ana makine arızaları da veri setine eklenebilir.
- Çalışmada sadece ana makine yanma iş elemanları arızaları ele alınmıştır. Gemi yardımcı makineler ve diğer sistemlerde de oluşan arızalar bu çalışma gibi ele alınabilir.
- Gemi işletmecileri açısından ise; gemi yakıtlarındaki arızaya sebep olan maddelerin gemi ana makine yanma iş elemanlarına olumsuz etkilerini azaltmak amacıyla yakıt ayırıştırıcılarının debisinin ana makine saatlik yakıt tüketiminden sonra servis tankı taşıracak seviyede olması sağlanmalıdır. Daha fazla bir debi değeri ayırıştırıcının ayırıştırma kalitesini düşürmektedir. Yine ayırıştırıcılarda sıcaklık ve basınç değerlerinin doğru bir şekilde ayarlanması, dip tanklardan ana makineye kadar filtreleme işlemlerinin ve filtre verimliliğinin sağlanması, düzenli tank temizliğinin yapılması, tank sıcaklıklarının düzenli kontrol edilmesi ve tank dreynlerinin düzenli yapılması gerekmektedir.
- Yakıt alımında Al+Si değerinin 50 (mg/kg), vanadyum değerinin 150 (mg/kg), mikro karbon kalıntısı oranının 15 (%m/m) değerlerini geçmediğinden emin olunmalıdır.
- Düşük sülfürlü yakıt kullanımında yağlama yağının bozulmaması adına; gemi işletmecilerinin gerekli yağ ıslahını yapması, ana makine yapımcı firma önerileri doğrultusunda yağlama yağı katkısının kullanılması ve gerekirse öneriler doğrultusunda farklı tipte bir silindir yağlama yağı kullanması gerekmektedir.
- Gemi işletmecileri ay sonu evraklarında bakım tutum, tamir ve arıza raporlarını daha detaylı düzenleyebilirler. Arıza öncesindeki tüm verilerin değişimi (özellikle otomasyon gemilerde kolaylıkla yapılabilir), arıza öncesindeki alarmları, arızanın olduğu makine parçasının geçmişi (rektifiye yapıp yapılmadığı, orijinal yedek parça veya muadilinin kullanımı) bahsedilen bakım tutum ve tamir raporlarına eklenebilir.

- Gemi makineleri işletmecileri için birçok arıza ve durum değerlenmesinde önem taşıyan P_{max} ve P_{comp} değerlerinin haftalık olarak kayıt altına alınması yine verimli bir işletim için gereklidir.



6. KAYNAKLAR

- Aksu G., & Doğan, N. (2019). Veri Madenciliğinde Kullanılan Bir Analiz Programı: WEKA. *Eğitimde ve Psikolojide Ölçme ve Değerlendirme Dergisi*, 10(1), 80-95.
- Alagumai, A. (2014). Internal Combustion Engines: Progress and Prospects. *Renewable and Sustainable Energy Reviews*, 38, 561-571.
- Alkaff, A.S., Mukbel, M.A., Wazeer, A.B., & Namori, S.A. Heavy Fuel Oil (HFO) Operated Diesel Engine and Impacts of Sulphur Content on the Engine Life. *Conference: The 4th International Operation and Maintenance Conference & Exhibition In the Arab Countries (OMAINTEC) In the Arab Countries (OMAINTEC)*, Conference Book. Beirut.
- Allianz Global Corporate & Specialty. (2021, Şubat 10). *Safety and Shipping Review 2019*. <https://www.agcs.allianz.com/news-and-insights/news/safety-shipping-review-2019.html> adresinden alınmıştır.
- Asuquo, M.P. (2017). *Development of an Efficient Planned Maintenance Framework for Marine and Offshore Machinery Operating Under Highly Uncertain Environment*. Liverpool John Moores University, Doktora Tezi, Liverpool.
- Bejger, A., & Drzewieniecki, J.B. (2020). A New Method of Identifying the Limit Condition of Injection Pump Wear in Self-Ignition Engines. *Energies*, 13.
- Bilgili, L. (2014). A Systematic Review on the Acceptance of Alternative Marine Fuel. *Applied Thermal Engineering*, 65 (1), 469-476.
- Bouckaert, R.R., Frank. E., Hall, M.A., Holmes, G., Pfahringer, B., & Witten, I.H. (2010). WEKA—Experiences with a Java Open-Source Project. *Journal of Machine Learning Research*, 11, 2533-254.
- Bozic, R. (2021). Results of the Analysis of the Effects of Low-sulphur Fuel Oil on the Operation of the Marine Two-stroke Slow-speed Diesel Engine. *International Journal of Mechanical Engineering*, 6.
- Buksa, A., Segulja, I., & Tomas, V. (2009). Ship Machinery Maintenance Concept Adjustment and Design. *Strojarstvo*, 51(3), 227-238.
- Caterpillar. (2008). *Engine Operating Instructions*. Kiel.
- Chan, K.Y., Abu-Salih, B., Qaddoura, R., Al-Zoubi, A.M., Palade, V., Pham, D.S., Del Ser, J., & Muhammad, K. (2023). Deep Neural Networks in the Cloud: Review, Applications, Challenges and Research Directions. *Neurocomputing*, 545.
- Chen, H., Hu, S., Hua, R., & Zhao, X. (2021). Improved Naive Bayes Classification Algorithm for Traffic Risk Management. *EURASIP Journal on Advances in Signal Processing*, 30.

- Chybowski, L., Myskow, J., & Kowalak, P. (2023). Analysis of Fuel Properties in the Context of the Causes of Three Marine Auxiliary Engines Failure – A case study. *Engineering Failure Analysis*, 150.
- Chybowski, L., & Matuszak, Z. (2007). Marine Auxiliary Diesel Engine Turbocharger Damage (Explosion) Cause Analysis. *Journal of Polish CIMAC*, 2(2), 99-105.
- CIMAC. (2025a, Ocak 11). *Fuel Quality Guide-Ignition and Combustion* .: https://www.cimac.com/cms/upload/Publication_Press/WG_Publications/CIMAC_WG07_2011_Guideline_Fuel_Quality_Ignition_Combustion.pdf adresinden alınmıştır.
- CIMAC. (2025b, Ocak 11). Guidelines for Diesel Engine Lubrication. Impact of Low Sulfur Fuel on Lubrication of Marine Engines: https://www.cimac.com/cms/upload/Publication_Press/Recommendations/Recommendation_26.pdf adresinden alınmıştır.
- Dhillon, B.S., & Liu, Y. (2006). Human Error in Maintenance: A Review. *Journal of Quality in Maintenance Engineering*, 12(1), 21-36.
- Dikis, K., & Lazakis, I. (2018). Dynamic Predictive Reliability Assessment of Ship Systems. *Journal of LATEX Templates*, 1-42.
- DNV. (2024, Aralık 15). *Maritime Forecast to 2050*.: <https://www.dnv.com/maritime/publications/maritime-forecast/> adresinden alınmıştır.
- Facchinetti, S. (2009). A Procedure to Find Exact Critical Values of Kolmogorov-Smirnov Test. *Italian Journal of Applied Statistics*, 21, 3-4.
- Forti, N., Afflisio, E., Braca, P., Millefiori, L.M., Willett, P., & Carniel, S. (2021). Maritime Anomaly Detection in a Real-World Scenario: Ever Given Grounding in the Suez Canal. *IEEE Transactions on Intelligent Transportation Systems*, 1-7.
- Frank, E., Hall, M., Holmes, G., Kirkby, R., Pfahringer, B., Witten, H.I., & Trigg, L. (2024, Eylül 10). *A Machine Learning Workbench for Data Mining*: <https://www.researchgate.net/publication/227012674> adresinden alınmıştır.
- Frank, E., Hall, M., Trigg, L., Holmes, G., & Witten, I. (2004). Data Mining in Bioinformatics Using Weka. *Bioinformatics*, 20(15), 2479-2481.
- Gamgam, H., & Altunkaynak, B. (2008). *Parametrik Olmayan Yöntemler*. Ankara: Gazi Kitabevi.
- Gkerekos, C., Lazakis, I., & Theotokatos, G. (2017). Ship Machinery Condition Monitoring Using Performance Data Through Supervised Learning. *Smart Ship Technology, Conference Book*. London.
- Göksu, B., & Erginer, K.E. (2020). Prediction of Ship Main Engine Failures by Artificial Neural Networks. *JEMS*, 8(2), 98-113.

- Gürsoy, M.Ü., Çolak, U.C., Gökçe, M.H., Akkulak, C., & Ötleş, S. (2019). Endüstri İçin Kestirimci Bakım. *International Journal of 3D Printing Technologies and Digital Industry*, 3(1), 56-66.
- Hamzaçebi, C. (2011). *Yapay Sinir Ağları*. Bursa: Ekin Yayınları.
- Hassan, A., Carbognani, L., & Pereira-Almao, P. (2008). Development of An Alternative Setup for the Estimation of Microcarbon Residue for Heavy Oil and Fractions: Effects Derived from Air Presence, *Fuel*, 87(17-18), 3631-3639.
- IMO. (2024, Aralık 14). *IMO 2020. Cleaner Shipping for Cleaner Air.:* <https://www.imo.org/en/MediaCentre/PressBriefings/pages/34-IMO-2020-sulphur-limit-.aspx> adresinden alınmıştır.
- ISM Code. (2018). *ISM Code&Guidelines 2018 Edition*. London: IMO Publishing.
- JHC Report. (2025, Ocak 12). *Marine Engine Damage due to Catalytic Fines in Fuel.:* https://iumi.com/images/documents/JHC_Catfines_Pack.pdf adresinden alınmıştır.
- Jiang, Q., Shen, Y., Li, H., & Xu, F. (2018). New Fault Recognition Method for Rotary Machinery Based on Information Entropy and a Probabilistic Neural Network. *Sensors*, 18(337), 1-13.
- Jimenez, V.J., Bouhmala, N., & Gausdal, A.H. (2020). Developing a Predictive Maintenance Model for Vessel Machinery. *Journal of Ocean Engineering and Science*, 5, 358-386.
- Kandemir, C., & Celik, M. (2020). A Human Reliability Assessment of Marine Auxiliary Machinery Maintenance Operations Under Ship PMS and Maintenance 4.0 Concepts. *Cognition, Technology & Work*, 22, 473-487.
- Kaya, M.S., & İnce, K. (2021). Nesnelerin İnternetinde Çok Katmanlı Algılayıcı Kullanarak Zamanlama Analizi Saldırısı ile Özel Anahtar Tahminlemesi. *Journal of Computer Science*, 385-390.
- Khadersab, A., & Shivakumar, S. (2018). Vibration Analysis Techniques for Rotating Machinery and its Effect on Bearing Faults. *Procedia Manufacturing*, 20, 247-252.
- Kimera, D., & Nangolo, F.D. (2020). Predictive Maintenance for Ballast Pumps on Ship Repair Yards via Machine Learning. *Transportation Engineering*, 2.
- Kjemtrup, L., Cordtz, R.F., Jensen, M.V., & Schramm, J. (2020). An Experimental Investigation of the Corrosive Influence of SO₂ Relative to H₂SO₄ of Marine Engine Cylinder Liners. *Lubrication Science*, 32(3), 131-144.
- Kowalski, J. (2014). An Experimental Study of Emission and Combustion Characteristics of Marine Diesel Engine with Fuel Pump Malfunctions. *Applied Thermal Engineering*, 65 (1), 469-476
- Kowalski, J. (2016). An Experimental Study of Emission and Combustion Characteristics of Marine Diesel Engine with Fuel Injector Malfunctions. *Polish Maritime Research*, 1 (89), 77-84.

- Küçükşahin, F. (2016). *Dizel Makinelerinin Arızaları*. İstanbul: Birsen Yayınevi.
- Küçükşahin, F. (2008). *Dizel Motorları Teorisi*. İstanbul: Birsen Yayınevi.
- Küçükşahin, F. (1999). *Dizel Motorları*. İstanbul: Güven Kitabevi.
- Lang, S., Bravo-Marquez, F., Beckham, C., Hall, M., & Frank, E. (2019). A Deep Learning Package for Weka Based on Deeplearning4j. *Knowledge-Based Systems*, 178, 48-50.
- Lazakis, I., Raptodimos, Y., & Varelas, T. (2018). Predicting Ship Machinery System Condition Through Analytical Reliability Tools and Artificial Neural Networks. *Ocean Engineering*, 152, 404-415.
- Lazakis, I., Turan, O., & Aksu, S. (2010). Increasing Ship Operational Reliability Through the Implementation of a Holistic Maintenance Management Strategy. *Ships Offshore Struct.*, 5, 337-357.
- Li, X., Zhang, W., Ding, Q., & Sun, J.Q. (2018). Intelligent Rotating Machinery Fault Diagnosis Based on Deep Learning Using Data Augmentation. *Journal of Intelligent Manufacturing*, 31, 433-452.
- Li, X., Zhang, W., Ma, H., Luo, Z., & Li, X. (2020). Data Alignments in Machinery Remaining Useful Life Prediction Using Deep Adversarial Neural Networks. *Knowledge-Based Systems*, 197, 105843.
- Lin, C.Y. (2000). Influences of Vanadium Compound on Burning Characteristics of Emulsified Marine Fuel Oil C, *Ocean Engineering*, 27, 589-601.
- Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial Intelligence for Fault Diagnosis of Rotating Machinery: A Review. *Mechanical Systems and Signal Processing*. 108, 33-47.
- Lobato, T.H.G., Silva, R.R., Costa, E.S., & Mesquita, A.L.A. (2020). An Integrated Approach to Rotating Machinery Fault Diagnosis Using, EEMD, SVM, and Augmented Data. *Journal of Vibration Engineering & Technologies*, 8, 403-408.
- Merlini, D., & Rossini, M. (2021). Text Categorization with WEKA: A Survey. *Machine Learning with Applications*, 4.
- Öztemel, E. (2003). *Yapay Sinir Ağları*. İstanbul:Papatya Yayıncılık.
- Panic, I., Celic, J., & Cuculic, A. (2018). Wireless Condition Monitoring of Machinery and Equipment in Maritime Industry: An Overview. *Scientific Journal of Maritime Research*, 32, 201-210.
- Piltan, F., Prosvirin, A.E., Jeong, I., Im, K., & Kim, J.M. (2019). Rolling-Element Bearing Fault Diagnosis Using Advanced Machine Learning-Based Observer. *Applied Sciences*, 9, 1-22.

- Raptodimos, Y., & Lazakis, I. (2020). Application of NARX Neural Network for Predicting Marine Engine Performance Parameters. *Ships and Offshore Structures*, 15(4), 443-452.
- Sarker, I.H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN: Computer Science*, 2(160).
- Shinde, S., & Jadhav, P.V. (2016). Failure Investigation and Thermo-Mechanical Analysis of Cylinder Liner. *IJSRSET*, 2 (2), 972-977.
- Stazic, L., Knezevic, V., Orovic, J., & Mihanovic, L. (2020). Maintenance Interval Adjustment Based on the Experience, Case Study of Marine Air Compressor System. *International Journal of Maritime Science & Technology*, 67(2), 146-152.
- Stazic, L., Komar, I., & Racic, N. (2017). Evaluation Methodology for Ship's Planned Maintenance System Database. *Trans. Marit. Sci.*, 02, 109-116.
- Stone, R. (1999). *Solutions Manual for Introduction to Internal Combustion Engines*. London: Springer.
- Surawski, N., Van, C.T., Ristovski, Z., Cong, N.L., Lan, H.N., Yuan, J.S., Rahman, A.S.M., Hossain, F.M., Guo, Y., Milic, A., Rainey, T., Garaniya, V., & Brown, R.J. (2017). Effects of Sulphur and Vanadium Contents in Diesel Fuel on Engine Performance and Emissions: Principal Component Analysis (PCA). *11th Asia-Pacific Conference on Combustion, Conference Book*. Sydney.
- Tanrıverdi, E. (2019). *Parametrik Olmayan Testler: Teori ve Uygulama*. İnönü Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Malatya.
- The Swedish Club. (2018). *Main Engine Damage*. Gothenburg: RR Offset.
- Thomas, J.F., Sluder, C.S., Kass, M.D., & Theiss, T. (2019). *Oak Ridge National Laboratory. A Guide to Fuel, Lubricant, and Engine Concerns Relative to the IMO 2020 Fuel Oil Sulfur Reduction Mandate*: <https://info.ornl.gov/sites/publications/Files/Pub135391.pdf> adresinden alınmıştır.
- Uddin, S., Haque, I., Lu, H., Moni, M.A., & Gide, E. (2022). Comparative Performance Analysis of K-Nearest Neighbour (KNN) Algorithm and its Different Variants for Disease Prediction. *Scientific Reports*, 12.
- UNCTAD. (2024, Mayıs 10). *Review of Maritime Transport 2023*. https://unctad.org/system/files/official-document/rmt2023_en.pdf adresinden alınmıştır.
- URL-1. (2025, Nisan 11). <https://marineshelf.blogspot.com/2012/10/exhaust-valve-defects.html> adresinden alınmıştır.
- URL-2. (2025, Ocak 1). Service Letter: https://www.man-es.com/docs/default-source/service-letters/sl2017-638.pdf?sfvrsn=607695b4_4 adresinden alınmıştır.

- URL-3. (2025, Ocak 1). Yakıtın Gerçek Değeri: <https://ilkfer.com.tr/wp-content/uploads/2021/08/TECHNICAL-UPDATE-400.pdf> adresinden alınmıştır.
- Vedachalam, S., Baquerizo, N., & Dalai, A.K. (2022). Review on Impacts of Low Sulfur Regulations on Marine Fuels and Compliance Options. *Fuel*, 310.
- Vizentin, G., Vukelic, G., Murawski, L., Recho, N., & Orovic, J. (2020). Marine Propulsion System Failure: A Review. *J. Mar. Sci. Eng.*, 8(662), 1-14.
- Vorkapic, A., Kralj, P., & Martinovic, D. (2017). The Analysis of The Maintenance Systems of a LPG Carrier's Liquefaction System Main Components. *Scientific Journal of Maritime Research*, 31, 3-9.
- Vukicevic, M., Racic, N., & Ivosevic, S. (2019). Piston Ring Material in a Two-stroke Engine Which Sustains Wear Due to Catalyst Fines. *Brodogradnja*, 70 (2).
- Wang, L., Cai, G., You, W., Huang, W., & Zhu, Z. (2017). Transients Extraction Based on Averaged Random Orthogonal Matching Pursuit Algorithm for Machinery Fault Diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 66(12), 3237-3247.
- Farhan, M.F., & Wang, P. (2022). Post-Injection Strategies for Performance Improvement and Emissions Reduction in DI Diesel Engines—A Review. *Fuel Processing Technology*, 228.
- Wang, B., Lei, Y., Yan, T., Li, N., & Guo, L. (2020). Recurrent Convolutional Neural Network: A New Framework for Remaining Useful Life Prediction of Machinery. *Neurocomputing*, 379, 117-129.
- Wu, L., Cui, B., & Xiao, Z. (2023). Artificial Neural Network-Based One-Equation Model for Simulation of Laminar-Turbulent Transitional Flow. *Theoretical and Applied Mechanics Letters*, 13(1).
- Yıldırım, N., & Gökpınar, F. (2012). Bazı Normallik Testlerinin 1.Tip Hataları ve Güçleri Bakımından Kıyaslanması. *Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 16(1), 109-115.

7. EKLER

Ek Tablo 1. Veri Seti

Arıza adedi	Sülfür (% m/m)	Vanadyum (mg/kg)	Katalitik ince partiküller (mg/kg)	Mikro karbon kalıntısı (% m/m)
1	2,97	116,00	6,00	10,83
1	0,49	17,00	14,00	3,56
1	0,42	17,00	13,00	7,40
1	0,46	12,00	13,00	7,72
1	0,45	17,00	7,00	6,86
1	0,46	21,00	2,10	8,63
1	0,45	21,10	2,20	8,64
1	0,44	21,20	2,30	8,65
1	0,48	21,30	2,40	8,66
1	0,47	21,40	2,50	8,67
1	0,48	21,50	2,60	8,68
1	0,48	21,60	2,00	8,69
1	3,27	176,40	25,60	11,40
1	3,28	176,30	25,50	11,50
1	3,29	176,20	25,40	11,60
1	3,30	176,10	25,30	11,70
1	3,31	175,00	25,10	11,80
1	3,32	175,10	25,10	11,90
1	3,33	175,20	24,00	11,30
1	3,34	175,30	24,10	11,40
1	3,35	175,40	24,20	11,50
1	3,36	175,50	24,30	11,60
1	3,37	175,60	24,60	11,70
1	3,38	175,70	24,70	11,80
1	3,39	175,80	24,80	12,00
1	3,40	175,90	24,90	12,20
1	3,41	176,00	25,00	12,30
1	0,48	16,00	9,00	14,27
0	0,48	8,00	5,00	8,75
0	0,45	11,00	8,00	8,66
0	0,49	10,00	6,00	2,43
0	0,50	7,00	4,00	2,49
1	0,47	12,10	31,10	6,25
1	0,46	12,20	31,20	6,26
1	0,45	12,30	31,30	6,27
1	0,44	12,40	31,40	6,28
0	0,48	2,00	7,00	5,54
0	0,47	5,00	6,00	7,74

Ek Tablo 1'in devamı

0	0,47	12,00	7,00	8,55
0	0,46	9,00	6,00	2,45
0	0,50	2,00	2,00	4,08
1	0,46	5,00	24,00	16,36
1	0,45	6,00	25,00	16,37
0	0,46	11,00	12,00	7,24
0	0,44	4,00	4,00	6,06
0	0,44	8,00	10,00	8,90
0	2,04	92,00	14,00	12,62
0	3,34	118,00	11,00	7,00
0	3,14	75,00	13,00	9,33
0	2,17	78,00	11,00	13,14
0	0,42	7,00	3,00	9,47
1	0,50	5,00	21,10	14,98
1	0,51	5,10	21,00	14,97
0	0,50	5,00	6,00	8,31
0	0,46	6,00	1,00	3,63
0	0,47	10,00	7,00	6,46
0	0,45	6,00	1,00	1,60
0	0,48	9,00	12,00	5,21
1	0,45	6,00	41,00	10,09
0	0,38	3,00	5,00	3,43
0	0,48	10,00	6,00	5,90
0	0,46	4,00	7,00	2,67
1	0,49	13,10	3,10	13,51
1	0,48	13,20	3,20	13,52
1	0,47	13,30	3,30	13,53
0	0,47	4,00	3,00	4,66
1	0,47	8,00	12,00	5,12
0	2,28	130,00	18,00	7,05
1	3,47	62,30	51,20	10,17
1	3,48	62,40	51,00	10,16
1	3,49	62,50	51,30	10,15
1	3,46	62,60	51,10	10,18
0	3,46	69,00	5,00	12,10
0	0,49	8,00	5,00	6,38
0	0,48	9,00	2,00	3,61
0	0,51	5,00	13,00	6,71
0	0,47	3,00	8,00	4,30
0	0,50	8,00	3,00	9,50
0	0,48	10,00	4,00	5,38
0	0,49	4,00	11,00	2,71
0	0,39	3,00	10,00	1,08
0	0,47	3,00	3,00	6,61
0	0,48	8,00	1,00	2,98
0	0,47	9,00	4,00	2,59

Ek Tablo 1'in devamı

0	0,48	9,00	1,00	8,10
0	0,44	3,00	4,00	6,51
1	0,48	6,00	24,00	9,13
1	0,46	28,20	6,20	9,55
1	0,47	28,10	6,10	9,54
1	0,48	28,00	6,00	9,53
1	0,45	28,30	6,30	9,56
0	0,49	5,00	4,00	4,07
0	0,29	2,00	9,00	8,00
0	0,42	5,00	2,00	3,89
0	0,50	3,00	1,00	4,18
1	3,47	92,00	13,00	14,94
1	3,46	92,10	13,10	14,95
1	3,45	92,20	13,20	14,96
0	0,47	3,00	2,00	3,95
0	0,48	3,00	2,00	2,54
1	0,48	10,00	12,00	9,20
1	0,47	10,10	12,10	9,21
1	0,46	10,20	12,20	9,22
0	0,48	8,00	3,00	8,02
0	0,48	4,00	9,00	6,49
0	0,49	2,00	4,00	8,90
0	0,47	6,00	6,00	3,00
0	0,45	8,00	5,00	4,31
0	0,47	6,00	6,00	3,97
0	0,44	10,00	5,00	5,27
0	0,48	10,00	6,00	4,47
0	0,44	4,00	10,00	3,18
1	0,43	6,00	12,00	9,56
1	3,43	23,30	12,30	10,76
1	3,42	23,20	12,20	10,75
1	3,41	23,10	12,10	10,74
1	3,40	23,00	12,00	10,73
0	3,35	24,00	6,00	8,52
0	3,24	79,00	40,00	13,51
0	0,49	10,00	6,00	5,97
0	0,47	8,00	4,00	2,80
0	0,49	1,00	8,00	4,52
0	0,48	6,00	2,00	4,69
0	0,48	1,00	7,00	4,13
0	0,49	3,00	7,00	4,66
0	0,47	5,00	9,00	6,61
0	0,46	5,00	7,00	3,04
0	0,45	2,00	2,00	3,25
0	0,47	8,00	5,00	4,41
0	0,46	8,00	3,00	2,81

Ek Tablo 1'in devamı

1	0,50	8,00	6,00	11,69
1	0,47	9,00	7,00	13,39
1	0,46	7,00	8,00	7,19
1	0,47	11,00	8,00	10,15
1	0,48	12,00	9,00	11,15
1	3,44	97,00	25,00	12,28
1	3,45	97,10	25,10	12,29
0	3,44	57,00	3,00	16,93
0	0,49	6,00	8,00	3,84
0	0,49	7,00	4,00	6,25
0	0,49	3,00	3,00	3,45
0	0,46	3,00	7,00	8,47
1	0,46	11,80	9,10	8,21
1	0,47	11,90	9,20	8,22
1	0,46	12,00	9,30	8,23
1	0,45	12,10	9,40	8,24
1	0,44	12,20	9,50	8,25
1	0,43	12,30	9,60	8,26
1	0,48	11,00	6,00	12,04
0	0,43	7,00	2,00	3,15
0	0,26	2,00	12,00	7,97
0	0,45	9,00	8,00	3,93
0	0,46	4,00	11,00	7,70
0	0,44	11,00	4,00	2,59
0	0,50	7,00	9,00	6,17
0	0,38	2,00	2,00	7,59
1	0,36	8,00	8,00	14,95
0	0,48	3,00	2,00	4,77
1	0,46	9,00	15,00	11,33
1	0,47	7,00	12,00	14,86
1	0,46	9,00	12,10	14,85
1	2,78	112,00	14,70	10,01
1	2,77	112,10	14,80	10,02
1	2,76	112,20	14,90	10,03
1	2,75	112,30	15,00	10,04
0	0,47	4,00	5,00	6,81
0	0,46	3,00	2,00	2,68
0	0,43	2,00	9,00	2,55
0	0,48	4,00	7,00	6,17
1	0,49	12,00	19,00	14,50
0	0,46	3,00	5,00	2,36
0	0,48	8,00	8,00	4,77
0	0,49	6,00	4,00	3,15
1	0,36	14,00	13,20	10,35
1	0,37	11,00	13,10	10,34
0	0,49	8,00	9,00	2,86

Ek Tablo 1'in devamı

0	0,45	7,00	5,00	3,18
1	0,45	15,00	29,00	7,44
0	0,47	6,00	2,00	7,03
1	3,34	130,10	5,10	12,67
1	3,35	130,00	5,00	12,66
1	0,48	3,00	37,00	14,53
1	0,47	3,10	37,10	14,54
1	0,49	11,00	26,00	11,83
1	0,48	11,10	26,10	11,84
1	0,47	11,20	26,20	11,85
0	0,48	8,00	6,00	3,21
0	0,46	4,00	8,00	8,28
0	0,48	2,00	4,00	5,00
0	0,45	2,00	3,00	2,35
0	0,27	3,00	1,00	4,43
0	0,39	3,00	1,00	2,19
0	0,44	6,00	9,00	3,81
0	0,48	8,00	6,00	5,06
0	0,47	3,00	6,00	4,89
1	0,45	16,00	9,00	12,72
0	0,49	8,00	1,00	3,12
1	0,49	6,00	15,00	11,77
1	0,47	17,00	11,00	10,30
0	0,46	9,00	6,00	2,45
1	0,49	21,00	9,00	7,56
1	0,47	9,20	10,20	11,86
1	0,48	9,10	10,10	11,85
1	0,46	9,30	10,30	11,87
1	0,41	19,20	16,20	7,15
1	0,42	19,10	16,10	7,14
1	0,43	19,00	16,00	7,13
1	1,41	53,00	16,90	8,52
1	1,42	52,90	16,80	8,51
1	1,43	52,80	16,70	8,50
1	1,44	52,70	16,60	8,49
1	1,45	52,60	16,50	8,48
1	1,46	52,50	16,40	8,47
1	1,47	52,40	16,30	8,46
1	1,48	52,30	16,20	8,45
1	1,49	52,20	16,10	8,44
1	1,50	52,00	16,00	8,43
0	0,45	8,00	2,00	5,07
0	0,47	5,00	1,00	3,32
1	0,89	26,00	12,80	7,19
1	0,88	25,90	12,70	7,18
1	0,87	25,80	12,60	7,17

Ek Tablo 1'in devamı

1	0,86	25,70	12,50	7,16
1	0,85	25,60	12,40	7,15
1	0,84	25,40	12,30	7,14
1	0,83	25,30	12,20	7,13
0	0,21	1,00	4,00	5,49
0	0,50	7,00	5,00	2,90
0	0,48	6,00	6,00	2,77
1	0,47	11,00	12,00	11,87
1	0,46	11,20	13,20	8,83
1	0,47	11,10	13,20	8,82
1	0,48	11,00	13,00	8,81
1	0,43	15,70	8,60	10,82
1	0,44	15,60	8,50	10,81
1	0,45	15,50	8,40	10,80
1	0,46	15,40	8,30	10,79
1	0,47	15,30	8,20	10,78
1	0,48	15,20	8,10	10,77
1	0,49	15,10	8,00	10,76
1	0,45	13,50	9,50	12,12
1	0,46	13,40	9,40	12,11
1	0,47	13,20	9,30	12,10
1	0,48	13,10	9,20	12,00
1	0,49	13,00	9,10	11,99
1	0,39	13,80	10,80	11,92
1	0,40	13,70	10,70	11,91
1	0,41	13,60	10,60	11,90
1	0,42	13,50	10,50	11,89
1	0,43	13,40	10,40	11,88
1	0,44	13,30	10,30	11,87
1	0,45	13,20	10,20	11,86
1	0,46	13,10	10,10	11,85
1	0,47	13,00	10,00	11,84
1	0,43	13,60	16,00	9,99
1	0,44	13,50	15,90	9,98
1	0,45	13,40	15,80	9,97
1	0,46	13,30	15,70	9,96
1	0,47	13,20	15,60	9,95
1	0,48	13,10	15,50	9,94
1	0,48	18,00	9,00	8,79
0	0,49	5,00	7,00	3,19
1	0,44	13,00	27,00	9,39
1	0,45	12,90	26,90	9,38
1	0,46	12,80	26,80	9,37
1	0,47	12,70	26,70	9,36
1	0,48	12,60	26,60	9,35
1	0,49	12,50	26,50	9,34

Ek Tablo 1'in devamı

1	0,50	12,40	26,40	9,33
1	0,44	13,40	17,40	11,62
1	0,45	13,30	17,30	11,61
1	0,46	13,20	17,20	11,60
1	0,47	13,10	17,10	11,60
0	0,46	6,00	4,00	3,35
0	0,47	4,00	6,00	4,62
0	0,40	4,00	8,00	5,62
1	0,46	16,00	19,00	10,80
1	0,47	15,90	18,90	10,79
1	0,48	15,80	18,80	10,78
0	0,47	7,00	1,00	3,17
1	0,49	8,00	25,00	7,27
1	0,41	9,60	13,60	10,47
1	0,42	9,50	13,50	10,46
1	0,43	9,40	13,40	10,45
1	0,44	9,30	13,30	10,44
1	0,45	9,20	13,20	10,43
1	0,91	27,20	14,20	11,87
1	0,92	27,10	14,10	11,86
1	0,93	27,00	14,00	11,85
1	3,26	109,00	16,00	13,71
1	3,27	108,90	15,90	13,70
1	3,28	108,70	15,80	13,69
1	3,29	108,60	15,70	13,68
1	3,30	108,50	15,60	13,67
1	3,31	108,40	15,50	13,66
1	3,50	115,00	46,00	16,35
1	0,46	10,00	27,00	13,22
1	0,47	9,90	26,90	13,21
1	0,48	9,80	26,80	13,20
0	0,44	5,00	8,00	7,10
1	0,48	12,00	16,00	14,22
0	0,47	2,00	2,00	4,46
0	0,49	7,00	2,00	6,26
1	0,48	23,00	29,00	8,94
0	0,34	5,00	2,00	6,54
0	0,50	6,00	7,00	8,71
0	0,45	3,00	7,00	3,94
0	0,47	7,00	8,00	5,62
0	0,46	2,00	7,00	4,06
0	0,46	3,00	6,00	7,00
0	0,46	2,00	8,00	6,18
0	0,46	6,00	3,00	2,86
0	0,38	5,00	1,00	1,42
0	0,50	5,00	3,00	6,44

Ek Tablo 1'in devamı

0	0,49	4,00	4,00	3,93
0	0,46	8,00	3,00	6,21
0	0,46	3,00	2,00	3,36
0	0,47	3,00	6,00	3,00
0	0,46	6,00	2,00	3,94
0	0,46	7,00	2,00	3,78
1	0,44	9,00	39,00	11,66
1	0,47	15,00	29,00	9,25
1	0,48	14,90	28,90	9,24
1	2,63	101,00	33,00	12,45
1	2,64	100,90	32,00	12,44
1	2,65	100,80	31,00	12,43
0	0,48	5,00	9,00	5,20
0	0,48	1,00	3,00	2,57
0	0,46	3,00	8,00	4,55
0	0,47	6,00	3,00	1,10
1	0,46	10,00	44,00	10,49
0	0,44	5,00	9,00	3,63
0	0,45	5,00	5,00	1,99
0	0,47	7,00	4,00	3,67
0	0,28	2,00	3,00	4,40
0	0,46	5,00	2,00	5,47
0	0,48	9,00	1,00	2,44
0	0,47	5,00	7,00	5,79
0	0,39	9,00	6,00	8,97
0	0,57	7,00	8,00	2,17
0	0,31	3,00	4,00	9,34
0	0,48	3,00	4,00	3,78
1	0,47	10,20	16,10	13,13
1	0,48	10,10	16,00	13,12
1	0,49	10,00	15,90	13,11
1	0,45	13,00	24,00	9,87
1	0,44	37,00	19,00	10,56
1	0,45	36,90	18,99	10,55
1	0,46	36,80	18,98	10,54
1	0,47	36,60	18,97	10,53
1	0,48	36,50	18,96	10,52
1	0,42	12,00	7,00	10,62
0	3,26	121,00	18,00	16,14
0	3,35	143,00	2,00	13,84
0	2,63	101,00	33,00	12,45
0	3,37	65,00	53,00	11,99
0	1,93	74,00	15,00	10,88
0	0,45	5,00	5,00	6,67
0	0,49	2,00	3,00	3,65
0	0,46	7,00	1,00	4,91

Ek Tablo 1'in devamı

1	0,41	13,50	51,00	10,45
1	0,42	13,40	50,99	10,44
1	0,43	13,30	50,98	10,43
1	0,44	13,20	50,97	10,42
1	0,45	13,10	50,96	10,41
1	0,46	13,00	50,95	10,40
0	0,48	8,00	10,00	6,43
0	0,49	6,00	9,00	4,99
1	0,46	11,00	19,00	10,13
0	0,47	6,00	7,00	5,38
0	0,49	6,00	1,00	8,04
0	0,50	5,00	7,00	4,80
0	0,45	5,00	2,00	2,46
0	0,49	5,00	3,00	3,75
0	0,47	7,00	11,00	5,76
1	0,50	11,00	20,00	11,42
0	0,47	5,00	2,00	2,80
0	0,47	6,00	9,00	1,75
1	0,50	11,00	25,00	10,92
0	0,43	6,00	3,00	3,00
0	0,48	5,00	2,00	2,05
1	0,47	14,00	15,00	10,70
1	0,47	14,00	23,00	6,86
0	0,46	6,00	3,00	2,52
0	0,46	9,00	6,00	2,45
0	0,48	7,00	7,00	3,73
0	0,48	5,00	1,00	3,32
1	0,43	10,40	14,40	11,13
1	0,44	10,30	14,30	11,12
1	0,45	10,20	14,20	11,11
1	0,46	10,10	14,10	11,10
0	0,43	7,00	1,00	2,03
0	0,45	4,00	5,00	4,28
0	0,41	5,00	1,00	1,42
0	0,49	7,00	7,00	4,90
Toplam: 220				

THE PLANNED MAINTENANCE PROCEDURE

REG.NO: 551
FORM NO: 551-11

MAINTENANCE / REPAIR REPORT – BAKIM TUTUM / TAMİR RAPORU

M/V DÖKME 10	Date - Tarih 17.07.2024	Maintenance & Repair Report No: 38/24
Place - Yer AT SEA		Bakım Tutum & Tamir Raporu No:

1. Reason – Sebep

Overhauling Yenileme	☐	Planned Maintenance Planlı Bakım	☐	Failure Arıza	☒	3 rd party request 3. Parti isteği	☐	☐
-------------------------	--------------------------	-------------------------------------	--------------------------	------------------	-------------------------------------	--	--------------------------	--------------------------

2. Category – Kategorisi

Navigation Equipment – Seyir Ekipmanı	☐	Main Engine – Ana Makine	☒
Communication Equipment – Haberleşme Ekipmanı	☐	Auxiliary Engine – Yardımcı Makineler	☐
Cargo Systems – Yük Sistemleri	☐	Boiler - Kazan	☐
Mooring Machinery, Cranes – Manevra Sistemleri, Kreyinler	☐	Compressors - Kompresörler	☐
Coating - Boya	☐	Purifiers - Seperatörler	☐
Steel Work – Çelik İşçiliği	☐	Alarm Monitoring System – Alarm Takip Sistemleri	☐
Safety Equipment – Emniyet Teçhizatı	☐	Valves, Piping – Valflar, Devreler	☐
Pumps-Pompalar	☐		☐

3. Description of Reason & Job to Be Done – Yapılacak İşin & Sebeplerinin Tanımlaması:

M/E NO:3 CYL. EXH. VALF DEĞİŞİMİ VE PİSTON&STUFFING BOX OVERHAUL'Ü

4. Cause Analysis - Olayın sebep analizi

Personal Factors - Kişisel Etkenler	Organisational Factors - Kurumsal Etkenler	Job Factors - İş Etkenleri
Disregard of Instructions. Talimatları hiçe saymak	☐ Lack of Discipline. Disiplin Eksikliği	☐ Abuse and Misuse Kötü kullanım ve suiistimal.
Failure to Understand. Anlamada Hata	☐ Inadequate Planning Yetersiz planlama	☐ Inadequate Engineering. Yetersiz Mühendislik idaresi
Inadequate Capability Uygunsuz yeterlilik	☐ Inadequate Supervision Yetersiz Nezaret	☐ Inadequate Purchasing Yetersiz Satın alma
Insufficient Thought and Care. Yetersiz düşünce/dikkat	☐ Inadequate Routines Sıra dışı Operasyonlar	☐ Inadequate Maintenance Yetersiz bakım
Lack of Anticipation - Tahmin eksikliği	☐ Inadequate Resources - Yetersiz Kaynaklar	☐ Inadequate Equipment - Yetersiz Ekip.
Lack of Knowledge - Bilgi Eksikliği	☐ Inadequate Training - Yetersiz Eğitim	☐ Wear and Tear - Yıpranma
Others Pls specify - Diğer Ltř. belirtiniz:	☐ PLANLI BAKIM.	☒

5. Spare Parts Used - Kullanılan Yedek Parça

M/E SEGMAN SETİ

1. Comments – Açıklamalar

M/E NO:3 CYL. SEGMAN DAĞITMASI SEBEBİ İLE KAVER ALINARAK PİSTON ÇEKİLMİŞTİR. YEDEKTEKİ PİSTON SEGMANLARLA DONATILMIŞ, ÇIKAN STUFFING BOX TEMİZLİĞİ YAPILARAK PİSTON ROD ÜZERİNE BAĞLANMIŞ VE PİSTON YERİNE MONTE EDİLMİŞTİR. KAVER ÜZERİNDEKİ EXH. VALFİ DE YEDEĞİ İLE DEĞİŞTİRİLEREK KAVER YERİNE MONTE EDİLMİŞTİR.

Chief Engineer – Başmühendis

Superintendent - Enspektör

**THE PLANNED MAINTENANCE AND
INSPECTION OF
ENGINE DEPARTMENT**

REG.NO: XXX 552-40
FORM NO: XXX 552-40-15

MAIN ENGINE PERFORMANCE REPORT - ANA MAKİNE PERFORMANS RAPORU

Ship name - Gem adı	DÖKME 10	Report No - Rapor No	03/24	Date - Tarih	22/06/2024
Voyage No Sefer No	02/24	Time Saat	16.00		
Vessel Speed Gemi Hızı (knot)	12.6	Cargo Loading & Quantity	0		
Ships Position Gemi Pos.	25° 35,2'N 035° 07,2'E	Weather Condition Hava Durumu	2		
Engine Type & No	MITSUI MAN B&W 6S50MC	Sea Condition Deniz Durumu	1		
Engine Power Mk. Gücü (kw)	7800	Draught Fore / Aft	3.90/6.30		
Atm. Pressure Atm Basıncı	1003	Engine Total Working Hours	95469		
Bunker Type Yakıt tipi	VLSFO	Working Hours after O/H	5797		
Bunker S.G at 15 °C	0,9160	Pitch Indicator Pitch Göstergesi %			
Bunker Consumption (mt/day)	19	Load Indicator Yük Göstergesi %	52		
Lube Oil Consumption (lt/day)	180	E/R Temperature Mak. Dairesi Sic. (°C)	47		
		S.W Temp. Deniz Suyu Sic. (°C)	30		

	1	2	3	4	5	6	7	8	9	Average
Exhaust Temp. (°C)	350	360	350	350	350	330				348,33
Fuel Index (mm)	55	54	54	54	53	54				54
P _{Max} (kg/cm ²)	99	99	99	100	100	100				99,5
P _{Comp} (kg/cm ²)	65	65	64	65	65	66				65
P _{Static} (kg/cm ²)	34	34	35	35	35	34				34,5

TEMPERATURE	°C	PRESSURE	Bar	REVOLUTION	rpm
H.T. Cooling In/Out	80/70	H.T. Cooling Water	4,2	Main Engine	94
L.T. Cooling In/Out		L.T. Cooling Water		Propeller Shaft	52
Turbo Ch. Exh. In/Out	320/300	T/C Lube Oil	2,3	Turbo Charger	11600
Lub-Oil ME In/Out	47/54	Lube Oil before ME	2,3	LOAD	kW
Charge Air In/Out	51	Charge Air	1	Shaft Alt. Load	
Fuel Oil	112	Fuel Oil	7,5		
R/G Lube Oil		R/G Lube Oil			
Servo Oil		Servo Oil			
Clutch Oil		Crank Case			
Thrust Bearing	63	Seawater	2,9		
Stern Tube Fwd./ After	36/38	Exh. Gas Back Press.			

Remarks - Notlar :

Performed by - İş yapan

Chief Engineer – Başmühendis

Note : M/E performance report shall be submitted to company monthly.

Not : Ana makine performans raporu her ay şirkete aysonu evrakları ile birlikte gönderilecektir.

10.07.2014

Rev.0

1 / 1

Ek Şekil 2. Örnek ana makine performans raporu

MAIN ENGINE RUNNING HOURS – ANA MAKİNA ÇALIŞMA SAATLERİ

Vessel –Gemi: DÖKME 10			Main Engine Serial No 4171 Ana Makine Seri No				Engine Type – Makine Tipi (MITSUI – MAN B&W 6550MC)				Working Hours – Çalışma Saatleri						
Date - Tarih: 31.07.2024			Monthly 570											Total		96048	
PMS RUNNING HRS.	LINER INSPECTION	PISTON	CYLINDER HEAD	PISTON ROD STUFFING BOX	FUEL PUMP OVERHAUL& TIMING		EXHAUST VALVE (Nimonic/Dura/ Conventional)	Exhaust Valve Actuator	Fuel Valve	Indicator Valve	Starting Valve	Deflection	Scav.chng& Piston Ring Inspection				
					After O/H	Total R. Hr.								After O/H	Total R. Hr.	After O/H	After O/H
	12000	12000	12000	12000	12000	6000	16000	8000	4000	8000	8000	3 Mnt	2000				
1	6381	96048	6381	96048	6381	96048	680	96048	11584	1174	1588	6381	1172	4			
2	6381	96048	6381	96048	6381	96048	6381	96048	11584	1174	1588	6381	1172	4			
3	6381	96048	196	96048	6381	96048	196	96048	11584	1174	1588	6381	1172	4			
4	6381	96048	6381	96048	6381	96048	234	96048	11584	1174	1588	6381	1172	4			
5	6381	96048	6381	96048	6381	96048	6381	96048	11584	1174	1588	6381	1172	4			
6	6381	96048	6381	96048	6381	96048	680	96048	11584	1174	1588	6381	1172	4			
TURBOCHARGER																	
BODY NO	TOTAL RUNNING HOURS	AIR FILTER		OVERHAUL	OIL REPLACEMENT		AIR COOLER		SCREW&BOLTS CHECK IN CRANKCASE			L/O 2ND FILTERS CLEAN		F/O 2ND FILTERS CLEAN			
		500	0		24000	BASED ON ANALYSIS REPORT	OBSERVATION	OBSERVATION	C/W SIDE	OBSERVATION	4000	OBSERVATION	OBSERVATION				
PMS RUN. HOURS	96048			6951			1744		1742					117			

Chief Engineer – Başmüh.

Ek Şekil 3. Örnek ana makine ve parçalarının çalışma saatleri evrakı



FUEL ANALYSIS REPORT

REPORT ID: U240452619 CUSTOMER: UNISERVICE TURKEY -

SHIP(IMO NO):

CONFORMANCE

The fuel sample tested conforms to Table 2 of ISO 8217:2017 specifications for grade IFO 180 - RME 180 0.5%

*Conformance to table 1 or table 2 of ISO 8217 does not imply conformance to other sections of ISO 8217 such as para 5.

CUSTOMER PROVIDED INFORMATION

BUNKER INFORMATION		BDN/CLIENT INFORMATION		SAMPLE DETAILS	
BUNKER PORT	COLOMBO	GRADE	RME 180 0.5%	PO NUMBER	
BUNKER DATE	12-Apr-2024	DENSITY@15°C	968.5	SENT DATE	15-Apr-2024
SUPPLIER	LANKA MARINE	VISCOSITY@50°C	159.4	REPORT DATE	24-Apr-2024
BARGE	MT LM NILWALA	SULFUR	0.474	SENT FROM	SRILANKA
SAMPLING POINT	MANIFOLD	WATER	-	TEST DATE	23-Apr-2024
SAMPLING METHOD	DRIP	QUANTITY (MT)	499.434	RECEIVED DATE	23-Apr-2024
BDN RCPT NO	1223			RETENTION DATE	23-Jun-2024

SEAL INFORMATION

LAB SEAL	MARPOL SEAL	SHIP SEAL	BARGE SEAL
C899079(Sealed)			

TEST PARAMETERS	UNITS	LIMITS	RESULTS	METHOD
Density @15°C	kg/m³	Max 991.0	936.2	ISO 12185
Viscosity @ 50°C	cSt	Max 180.0	174.2	ISO 3104
Viscosity @100°C	cSt	-	21.58	Calculated
Flash Point	°C	Min 60.0	> 70.0	ISO 2719
Pour Point	°C	Max(Summer) 30	27	ISO 3016
Micro Carbon Residue	% m/m	Max 15.00	6.86	ISO 10370
Ash	% m/m	Max 0.070	0.016	Calculated
Water	% v/v	Max 0.50	0.15	ASTM D6304
Sulfur	% m/m	Max 0.50	0.50	ISO 8754
Total Sediment Aged	% m/m	Max 0.10	0.03	ISO 10307-2
Vanadium	mg/kg	Max 150	14	IP 501 (Mod)
Al+Si (Catfines)	mg/kg	Max 50	23	IP 501 (Mod)
Sodium	mg/kg	Max 50	10	IP 501 (Mod)
Aluminum	mg/kg	-	14	IP 501 (Mod)
Silicon	mg/kg	-	9	IP 501 (Mod)
Iron	mg/kg	-	14	IP 501 (Mod)
Nickel	mg/kg	-	18	IP 501 (Mod)
Calcium ⁺	mg/kg	Max 30	14	IP 501 (Mod)
Phosphorous ⁺	mg/kg	Max 15	< 1	IP 501 (Mod)
Zinc ⁺	mg/kg	Max 15	< 1	IP 501 (Mod)
Potassium	mg/kg	-	< 1	IP 501 (Mod)
Lead	mg/kg	-	< 1	IP 501 (Mod)
Magnesium	mg/kg	-	< 1	IP 501 (Mod)
CCAI	-	Max 860	805	Calculated
Acid Number	mgKOH/g	Max 2.50	0.69	ASTM D664
API Gravity	-	-	19.56	-
Net Specific Energy	MJ/kg	-	41.72	Calculated
Gross Specific Energy	MJ/kg	-	44.23	Calculated
EFN*	-	-	60	-

EFN* - EFN will not be reported for any offspec or interim reports. For further details about Engine Friendliness Number refer our Website.

LDI** - LAB DEVELOPED METHOD

* A fuel shall be considered to contain ULO when either one of the following conditions is met:

- Calcium > 30 and Zinc > 15 ; Calcium > 30 and Phosphorus > 15 (ISO 8217 : 2010 / 2012 / 2017 Standards). - Calcium > 30, Zinc > 15 and Phosphorus > 15 (ISO 8217:2005 standard)

www.theviswagroup.com

Page 1 of 3



FUEL ANALYSIS REPORT

REPORT ID: U240452619 CUSTOMER: UNISERVICE TURKEY - INCE SHIPPING SHIP(IMO NO): INCE INEBOLU(9254472)

RECOMMENDED TEMPERATURES

MINIMUM TRANSFER TEMPERATURE	PURIFICATION TEMPERATURE
37°C	98°C

INJECTION TEMPERATURES

8 cSt	140°C	10 cSt	130°C	11 cSt	125°C	12 cSt	122°C	13 cSt	118°C	15 cSt	113°C
18 cSt	106°C	20 cSt	103°C								

ADDITIONAL TESTS

1	Strong Acid Number	mg KOH/g	0.00	ASTM D664
---	--------------------	----------	------	-----------

CALCULATION OF QUANTITY SUPPLIED BASED ON LAB TESTS

Quantity supplied as per ship (MT)	499.434
Density as per BDN (kg/m ³)	968.500
Water as per BDN (%v/v)	NA
Density as per lab test (kg/m ³)	936.200
Water as per lab test (%v/v)	0.150
Quantity shortage due to density (MT)	16.656
Quantity shortage due to water (MT)	NA
Total Quantity Shortage (MT)	16.656

*Above figures do not account for ISO 4259 criteria given in ISO 8217 Annex F. (This is not applicable for delivery made by mass flowmeter)

SUGGESTIONS AND RECOMMENDATIONS TO SHIP OWNERS / OPERATORS / TECHNICAL STAFF

Pour Point

Heat and store this fuel at 10°C above the measured pour point temperature.

Sulphur

High alkalinity of some cylinder oils can cause scuffing and excess wear of cylinder liners.

Make sure cylinder oil used can handle low sulfur fuel.

ÖZGEÇMİŞ

Selim BAŞTÜRK, İlköğrenimini Cumhuriyet Ortaokulu'nda bitirdikten sonra lise eğitimini Trabzon Kanuni Anadolu Lisesi'nde tamamladı. 2009 yılında İstanbul Teknik Üniversitesi Denizcilik Fakültesi Gemi Makineleri İşletme Mühendisliği bölümünden mezun oldu. Yaklaşık 8 yıl Uzakyol Vardiya Mühendisi ve Uzakyol İkinci Mühendisi olarak ticari gemilerde çalıştı. 2017 yılında Karadeniz Teknik Üniversitesi/ Deniz Ulaştırma İşletme Mühendisliği Anabilim Dalında “Geminin Taşıdığı Yük Miktarına Göre En Uygun Gemi Hızının ve Yakıt Tüketiminin Belirlenmesi: Ro-Ro Gemileri Üzerine Bir Uygulama” tezi ile tezli yüksek lisansını tamamladı. 2018 yılında Karadeniz Teknik Üniversitesi/ Gemi İnşaatı ve Gemi Makineleri İşletme Mühendisliği Anabilim Dalında doktora başladı. 2015 yılından itibaren Karadeniz Teknik Üniversitesi Deniz Ulaştırma İşletme Mühendisliği bölümünde Öğretim Görevlisi olarak görev yapmaktadır. İyi derece İngilizce bilmektedir.