

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

GEMİ ELEKTRİK ŞEBEKELERİNDE DERİN ÖĞRENME UYGULAMALARI



DOKTORA TEZİ

Tayfun UYANIK

Deniz Ulaştırma Mühendisliği Anabilim Dalı

Deniz Ulaştırma Mühendisliği Programı

MAYIS 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

GEMİ ELEKTRİK ŞEBEKELERİNDE DERİN ÖĞRENME UYGULAMALARI

DOKTORA TEZİ

**Tayfun UYANIK
(512162010)**

Deniz Ulaştırma Mühendisliği Anabilim Dalı

Deniz Ulaştırma Mühendisliği Programı

**Tez Danışmanı: Prof. Dr. Yasin ARSLANOĞLU
Eş Danışman: Prof. Dr. Özcan KALENDERLİ**

MAYIS 2023

ISTANBUL TECHNICAL UNIVERSITY★ GRADUATE SCHOOL

DEEP LEARNING APPLICATIONS ON SHIP ELECTRIC GRIDS



Ph.D. THESIS

**Tayfun UYANIK
(512162010)**

Department of Maritime Transportation Engineering

Maritime Transportation Engineering Programme

**Thesis Advisor: Prof. Dr. Yasin ARSLANOĞLU
Thesis Co-Advisor: Prof. Dr. Özcan KALENDERLİ**

MAY 2023

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 512162010 numaralı Doktora Öğrencisi Tayfun UYANIK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "GEMİ ELEKTRİK ŞEBEKELERİNDE DERİN ÖĞRENME UYGULAMALARI" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Yasin ARSLANOĞLU**
İstanbul Teknik Üniversitesi

Eş Danışman : **Prof.Dr. Özcan KALENDERLİ**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Suat İLHAN**
İstanbul Teknik Üniversitesi

Doç. Dr. Hakan Demirel
İstanbul Teknik Üniversitesi

Prof. Dr. Uğur Buğra ÇELEBİ
Yıldız Teknik Üniversitesi

Doç. Dr. Mustafa BAYSAL
Yıldız Teknik Üniversitesi

Doç. Dr. Hasan Bora USLUER
Galatasaray Üniversitesi

Teslim Tarihi : **7 Nisan 2023**
Savunma Tarihi : **10 Mayıs 2023**



ÖNSÖZ

Tez çalışmamı hazırlamamda ve bir akademisyen olarak yetişmemde katkısı büyük olan değerli danışman hocalarım Prof.Dr. Yasin ARSLANOĞLU ve Prof. Dr. Özcan KALENDERLİ'ye ve Prof. Dr. Josep M. GUERRERO'ya ve değerli tez izleme komisyonu üyesi hocalarıma yaptığı katkılardan dolayı çok teşekkür ederim.

Tez çalışmam için gerekli olan altyapıyı sağlayan İTÜ Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne 42104 numaralı projeme desteklerinden ötürü teşekkür ederim. Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na 2214-A Yurt Dışı Araştırma Burs Programı kapsamında 1059B142100334 numaralı projemde yaptığı katkılar için teşekkür ederim.

Son olarak beni her koşulda destekleyen aileme destekleri için çok teşekkür ederim.

Mayıs 2023

Tayfun UYANIK
(Elektrik-Elektronik Yüksek Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xviii
ÖZET	xix
SUMMARY	xxiii
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM.....	21
2.1 Makine Öğrenmesi ve Derin Öğrenme Yöntemleri	21
2.1.1 Çoklu doğrusal regresyon	21
2.1.2 Destek vektör makinesi	22
2.1.3 Ridge	24
2.1.4 Karar ağacı	24
2.1.5 Rastgele orman.....	25
2.1.6 Gradyan artırma algoritması	26
2.1.7 Elastik ağ.....	27
2.1.8 Yapay sinir ağı	28
2.1.9 Derin sinir ağı.....	29
2.1.10 Ekstrem gradyan artırma yöntemi.....	31
2.1.11 Bayesian ridge yöntemi.....	32
2.1.12 Kernel ridge yöntemi	33
2.1.13 K-en yakın komşuluk yöntemi.....	34
2.1.14 Ada artırma yöntemi	35
2.1.15 Hist gradyan artırma yöntemi	36
2.2 Hata Ölçüm Metrikleri	37
2.2.1 Kök ortalama karesel hata (RMSE)	37
2.2.2 Ortalama mutlak hata (MAE)	37
2.2.3 Ortalama mutlak yüzde hata (MAPE).....	38
2.2.4 Belirleme katsayısı (R^2)	38
2.3 Doğrulama Yöntemi	39
2.3.1 K-katlamalı çapraz doğrulama	39
3. VAKA ÇALIŞMALARI VE SONUÇLARI.....	41
3.1 Konteyner Gemisindeki Elektriksel Gücün Tahmini Uygulaması.....	41
3.2 Kimyasal Tanker Gemisinde Jeneratör Yükleri Tahmini Uygulaması	52
3.3 Konteyner Gemisinde Şaft Jeneratörü Gücü Tahmini Uygulaması	62
4. SONUÇLAR VE TARTIŞMA	67
4.1 Konteyner Gemisindeki Elektriksel Gücün Tahmini Uygulaması.....	67
4.1 Kimyasal Tanker Gemisinde Jeneratör Yükleri Tahmini Uygulaması	69

4.3 Konteyner Gemisinde Şaft Jeneratörü Gücü Tahmini Uygulaması	70
KAYNAKLAR.....	73
ÖZGEÇMİŞ.....	85



KISALTMALAR

YSA	: Yapay Sinir Ađı
ANN	: Artificial Neural Network
DSA	: Derin Sinir Ađı
DNN	: Deep Neural Network
KNN	: K-Nearest Neighbor
KEK	: K-En Yakın Komşuluk
RMSE	: Root Mean Squared Error
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
IMO	: International Maritime Organization
t	: Ton
dk	: Dakika
kW	: Kilowatt
rpm	: Devir/Dakika



SEMBOLLER

R^2 : Belirleme Katsayısı





ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Veri setindeki değişkenlerin istatistiksel özeti	44
Çizelge 3.2 : Ayarlanan parametre değerlerinin algoritma bazında gösterilmesi.....	47
Çizelge 3.3 : Güç üretimi için k-katlamalı çapraz doğrulama işlemi sonuçları.....	48
Çizelge 3.4 : Yakıt tüketimi için k-katlamalı çapraz doğrulama işlemi sonuçları.....	48
Çizelge 3.5 : Güç tahmini simülasyon sonuçları (Öncül bulgular)	48
Çizelge 3.6 : Yakıt tüketimi tahmini için simülasyon sonuçları (Öncül bulgular)....	49
Çizelge 3.7 : Güç tahmini için nihai simülasyon sonuçları.	49
Çizelge 3.8 : Yakıt tüketimi tahmini için nihai simülasyon sonuçları.....	49
Çizelge 3.9 : Gemi özellikleri.....	55
Çizelge 3.10 : Veri setinin istatistiksel özeti	55
Çizelge 3.11 : Ayarlanan model parametreleri	59
Çizelge 3.12 : Jeneratör bazında algoritmaların tahmin performansları.....	61
Çizelge 3.13 : Toplam güç tahmini simülasyon sonuçları.....	62
Çizelge 3.14 : Çapraz doğrulama işlemi simülasyon sonuçları.....	62
Çizelge 3.15 : Veri setinin istatistiksel özeti	64
Çizelge 3.16 : Hata metrikleri.....	64
Çizelge 3.17 : Algoritma parametreleri	64



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : İncelenen Handymax tipi tankere ait sevk sistemi.	3
Şekil 1.2 : Java Agent Development Framework uygulaması (JADE).	6
Şekil 1.3 : Sisteme ait takviyeli derin öğrenme şeması.	7
Şekil 1.4 : Çalışmada kullanılan akış şeması.	8
Şekil 1.5 : Sistemin hata değerlerinin karşılaştırılması.	8
Şekil 1.6 : Gemideki elektrik yükünün dağılımı.	12
Şekil 1.7 : Çalışmada kullanılan yöntemlerin akış şeması.	15
Şekil 1.8 : Gemi yakıt tüketimi değerleri ve tahmini değerlerin karşılaştırılması.	16
Şekil 1.9 : Makine öğrenmesi yöntemleri ile gemi yakıt tüketim tahmin modeli	16
Şekil 1.10 : Makine öğrenmesi yöntemleri ile gemi yakıt tahmini sonuçları.	17
Şekil 2.1 : Çoklu doğrusal regresyon.	22
Şekil 2.2 : Destek vektör makinesi algoritması.	23
Şekil 2.3 : Karar ağacı algoritmasının yapısı.	25
Şekil 2.4 : Rastgele orman algoritması yapısı	26
Şekil 2.5 : Gradyan arttırma algoritmasının gösterimi	26
Şekil 2.6 : Elastik ağ algoritmasının iki yöntem arasındaki görüntüsü.	27
Şekil 2.7 : Yapay sinir ağı yapısı.	29
Şekil 2.8 : Tipik bir derin sinir ağı yapısı	30
Şekil 2.9 : Ekstrem gradyan arttırma yönteminin akış şeması.	31
Şekil 2.10 : Gauss dağılımlı bir Bayes veri kümesi örneği.	33
Şekil 2.11 : K-en yakın komşuluk yönteminin akış şeması.	35
Şekil 2.12 : Ada arttırma algoritması işleyiş şeması	36
Şekil 2.13 : K-en yakın komşuluk yönteminin akış şeması.	40
Şekil 3.1 : Çalışmada yapılan işlemlerin anlatılması.	43
Şekil 3.2 : Geminin elektrik şebekesi.	44
Şekil 3.3 : Pearson korelasyon analizi sonucu.	45
Şekil 3.4 : Değişkenlerin ikili grafikler ile gösterimi.	46
Şekil 3.5 : Gerçek güç verileri ile tahmini değerlerin karşılaştırılması.	50
Şekil 3.6 : Gerçek yakıt tüketimi verileri ile tahmini değerlerin karşılaştırılması.	51
Şekil 3.7 : Çalışmada izlenen yöntemin anlatılması.	53
Şekil 3.8 : İncelenen geminin elektrik mikro şebekesi planı.	54
Şekil 3.9 : Veri setinin Pearson korelasyon matrisi.	56
Şekil 3.10 : Yüksek korelasyon katsayısına sahip değişkenlerin ikili grafikleri	57
Şekil 3.11 : Değişkenler ile jeneratörlerin toplam yükü arasındaki ikili ilişkiler.	57
Şekil 3.12 : Giriş değişkenlerinin çıkış değişkeni üzerindeki etkisi.	57
Şekil 3.13 : Çalışmanın metodolojisi.	58
Şekil 3.13 : Gerçek güç verileri ile tahmini değerlerin karşılaştırılması.	63
Şekil 3.14 : Algoritma tahminlerinin gerçek güç değeri ile karşılaştırılması.	65



GEMİ ELEKTRİK ŞEBEKELERİNDE DERİN ÖĞRENME UYGULAMALARI

ÖZET

Denizcilik sektörü çok geniş kapsamda denetlenmesi gereken uluslararası bir sektördür. Bu sektördeki paydaşların denetlenmemesi durumunda büyük çevresel felaketler oraya çıkabilir, bu da doğaya ve insan yaşamına çok büyük zararlar verebilir.

Denizcilik sektörünün denetleyici tepe organizasyonu olan Uluslararası Denizcilik Örgütü, sektördeki paydaşların faaliyetlerinin denetlenip düzenlenmesi adına çeşitli kural ve yönetmelikler uygulamaktadır. Sektörde faaliyet gösteren firmaların ise bu kural ve yönetmeliklere uyma yükümlülüğü vardır.

Son yıllarda denizcilik sektörü vasıtasıyla taşınan ticari mal miktarının artması nedeniyle birtakım çevresel problemler baş göstermiştir. Bu problemler nedeniyle Uluslararası Denizcilik Örgütü çeşitli tedbirler almak zorunda kalmıştır. Bu tedbirler çerçevesinde çevre kirliliği ve emisyonların azaltılması adına çeşitli kurallar yayınlanmıştır.

Denizcilik sektöründe Uluslararası Denizcilik Örgütü'nün koyduğu kuralların uygulanması yeni nesil teknolojilerin ve çevreci yöntemlerin denizcilik sektörüne dahil edilmesinin de önünü açmıştır. Bu bağlamda denizcilik firmaları çeşitli araştırma ve geliştirme faaliyetlerine ağırlık vermeye ve çevreci teknolojilerle emisyon oranını düşürmeye çalışmaktadır. Büyük firmalar açısından Uluslararası Denizcilik Örgütü'nün koyduğu emisyon sınırlamalarına uymak sahip oldukları büyük ekonomik güç sayesinde yaptıkları çalışmalar çerçevesinde daha kolay olabilirken nispeten küçük firmalar için ise bu süreçte bazı zorluklar olabilmektedir. Küçük firmalar bu süreçte fayda-maliyet analizi yaparak verimli ve ekonomik yöntemler araştırıp geliştirme ihtiyacı içindedir.

Veriye dayalı teknikler, son yıllarda bilim dünyasının gündeminde yer almaya başlamıştır. Özellikle gelişen teknoloji sayesinde her türlü sistemden veri almanın geçmişe göre nispeten kolaylaşması veriye dayalı algoritmaların önemini arttırmıştır. Bu nedenle veriye dayalı algoritmaların son yıllarda uygulama alanı artmıştır. Hemen hemen bütün sektörlerde veriye dayalı algoritmaların çok çeşitli uygulamaları gündeme gelmekte ve yapılan uygulamalarda başarılı sonuçlar elde edilmektedir.

Veriye dayalı yaklaşımlar bu noktada da öne çıkmakta ve başka endüstri alanlarına uygulanan teknikler denizcilik sektöründeki problemlerin çözümünde de katkı vermektedir. Denizcilik sektörü, gelişen teknolojiye nasibini almakta ve veriye dayalı uygulamalar sektörde bazı problemlerin çözümüne katkı vermeye başlamıştır. Örneğin; sisli ve olumsuz hava koşullarının hüküm sürdüğü sularda görüş mesafesinin bilinmesi denizcilik sektöründe seyir güvenliğinin sağlanması adına önemli bir problemdir. Bu problemin çözümünde çevresel koşulları kullanarak görüş mesafesinin hesaplanması gerekmektedir. Bu alanda yapılan çalışmalarda elde edilen başarılı sonuçlar sayesinde her türlü hava koşulunda görüş mesafesi tahmin edilebilmektedir.

Denizcilik sektöründe en önemli gider kalemi yakıt tüketimi olarak öne çıkmaktadır. Bu nedenle denizcilik firmaları yakıt tüketimini azaltıcı teknolojilerin geliştirilmesi için yatırım yapmaktadır. Büyük firmalar açısından bu yatırımların maliyetinin karşılanması nispeten kolay olsa da küçük firmalarda durum böyle değildir. Yenilikçi teknolojiler ile gemilerini donatamayan firmalar zaman içinde piyasadaki yerini kaybetmekte, bazı firmalar ise Uluslararası Denizcilik Örgütü kurallarını sağlayamadıkları için çeşitli cezalar ve yaptırımlarla karşı karşıya kalmakta ve maddi zararlara uğramaktadır.

Denizcilik sektöründe en önemli gider kalemi olan yakıt tüketiminin tahmini işlemi ile bir seferde karşılaşılabilecek bütün durumlar için sefer boyunca harcanan yakıt tüketiminin tahmin edilmesiyle ortaya çıkabilecek emisyonların hesabı yapılabilmektedir. Veriye dayalı algoritmalarla önce de yakıt tüketimi çeşitli yöntemlerle hesaplanıyordu ancak bu yöntemler sayesinde hesaplama süreçleri hızlanmış ve hesap karmaşası azalmıştır.

Veriye dayalı yaklaşımlar başarılı olması yanında fayda-maliyet olarak verimli yöntemler olarak öne çıkmaktadır. Bu sayede ekonomik gücü nispeten düşük olan denizcilik firmaları da bu yeni teknolojiye erişebilmekte ve faaliyet gösterdiği sırada karşılaştığı problemleri veriye dayalı yöntemler yardımıyla çözebilmektedir.

Bu tez çalışmasında, denizcilik sektöründe yer alan üç adet problem seçilmiş ve veriye dayalı yöntemler yardımıyla çözümler üretilmeye çalışılmıştır. "Gemi Elektrik Şebekelerinde Derin Öğrenme Uygulamaları" ile makine öğrenmesi ve derin öğrenme yöntemlerinin gemi elektrik şebekeleri üzerinde uygulanması sayesinde şebeke problemlerinin azaltılması, veriminin artması bu sayede de doğaya salınan emisyonların azaltılması gibi hedefleri gerçekleştirilmede önemli bir çalışma olacağı öngörülmüş ve gemi elektrik şebekesinde oluşan sorunların çözümünde veriye dayalı yaklaşımlar kullanılmıştır. Literatürdeki çalışmalar incelendiğinde ülkemizde bu alanda yapılan çalışmaların kısıtlı olduğu tespit edilmiştir ve Uluslararası Denizcilik Örgütü kuralları ile ilgili cezalar, emisyonların azaltılamaması ve gemi enerji verimliliğinin artırılmamasının gelecek yıllarda Türk denizcilik sektörüne maddi zararları olacağı tespit edilmiştir. Yapılan çalışmanın çıktılarının ülkemiz denizcilik sektörü paydaşları ile paylaşılması sayesinde ülkemizin bu alanda güncelliği yakalaması ve uğrayacağı kayıpların en aza indirilmesi konusunda katkı verilmesi hedeflenmiştir.

Tez kapsamında ele alınan ilk vaka çalışmasında ticari amaçla kullanılan bir konteyner gemisi seçilmiş ve bu konteyner gemisini işleten firmadan geminin belirli bir zamandaki sefer verisi elde edilmiştir. Elde edilen bu veri seti işlenip veriye dayalı algoritmaların üzerinde çalışabileceği işlenmiş bir veri setine dönüştürülmüştür. Elde edilen veri setindeki çok sayıda giriş değişkeninin yardımıyla veriye dayalı algoritmalarla çıkış değişkenini hesaplaması istenmiştir. Bu vaka çalışmasında literatürde sıklıkla karşılaşılan veriye dayalı algoritmalar yardımıyla yakıt tüketimi tahmini yanında gemide üretilen elektriksel gücün de tahmini yapılmıştır. Bu yeni çıkış değişkeni de çalışmayı özgünleştirmiştir. Elektriksel gücün tahmin edilmesi sayesinde verimlilik hesaplarında kullanılan bir değişken de pratik bir yöntem yardımıyla bulunmuştur. Çalışmada ayrıca veri setindeki değişkenlerin birbiri arasındaki ilişkilerin modellenmesi adına Pearson Korelasyon Matrisi ve çeşitli ikili grafikler kullanılmıştır. Algoritmalar ilk aşamada istenilen başarıyı sağlayamamışlar ve bu nedenle algoritma parametreleri ayarlanmıştır. Yapılan bu ayarlama işlemi sonrasında algoritmalar istenilen tahmin başarısını yakalamış ve tahmin işlemi sonlandırılmıştır.

Bu aşamada algoritmaların bir ezberleme problemi olup olmadığının belirlenmesi ve elde edilen sonuçların doğrulanması adına K-katlamalı çapraz doğrulama yöntemi kullanılmıştır. Elde edilen doğrulama sonuçları herhangi bir ezberleme durumu olmadığını ve simülasyon sonuçlarını doğrulamıştır. Simülasyonlar sonucunda gemideki elektriksel gücün tahmini için Derin Sinir Ağı algoritması en başarılı yöntem olarak ortaya çıkmıştır.

Tez konusu ile ilgili yapılan ikinci vaka çalışmasında bir kimyasal tanker gemisinde elektrik ihtiyacını sağlayan jeneratörlerin ürettiği elektriksel gücün tahmini veriye dayalı yöntemler yardımıyla gerçekleştirilmiştir. Çeşitli giriş değişkenlerinin yardımıyla çıkış değişkeni olan sistemde yer alan üç adet jeneratörün yükleri algoritmalar tarafından ayrı ayrı tahmin edilmiştir. Bu vaka çalışmasında önceki çalışmadan farklı olarak giriş değişkenlerinin tahmin sürecinde çıkış değişkeninin bulunmasında nasıl bir etkisinin olduğu da gösterilmiştir. Çalışma sonuçları incelendiğinde her bir jeneratörün gücünün ayrı ayrı tahmin edildiği senaryoda Karar Ağacı yöntemi en başarılı yöntem olurken, toplam yük tahmini senaryosunda ise Derin Sinir Ağı en başarılı algoritma olarak öne çıkmıştır.

Tez kapsamında yapılan son vaka çalışmasında ise bir konteyner gemisi incelenmiştir. Sefer sırasında genelde seyir durumunda faydalanılan ve ana makinanın ürettiği enerjinin bir kısmını elektrik enerjisine çevirerek gemide enerji verimliliğine katkıda bulunan shaft jeneratörünün ürettiği güç tahmin edilmiştir. Yapılan simülasyonlar sonucunda Çoklu Doğrusal Regresyon algoritması bu problem için en başarılı yöntem olmuştur.

Tez çalışması kapsamında incelenen üç problem ve elde edilen sonuçlar ışığında veriye dayalı algoritmaların gemide ani güç dalgalanmaları karşısında alınabilecek önlemler, enerji verimliliğinin artırılması konusunda yapılacak işlemler, iş güvenliği ve yapılan operasyonların güvenli bir şekilde tamamlanması hususlarında Denizcilik sektörü paydaşları açısından yararlı olabileceği saptanmıştır. İlerleyen yıllarda teknolojinin gelişmesiyle gemilerden anlık olarak veri alma işlemi yapılabilecek ve çok daha güçlü modeller yardımıyla tüm bu problemlere ilişkin çözümler daha da geliştirilebilecektir.



DEEP LEARNING APPLICATIONS ON SHIP ELECTRIC GRIDS

SUMMARY

The maritime sector is an international sector that must be inspected on a large scale. If the stakeholders in this sector are not audited, major environmental disasters can occur, which can cause enormous damage to nature and human life.

The International Maritime Organization, which is the top supervisory organization of the maritime sector, applies various rules and regulations to supervise and regulate the activities of the stakeholders in the sector. Companies operating in the sector must comply with these rules and regulations.

Some environmental problems have arisen in recent years due to increased commercial goods transported through the maritime sector. Due to these problems, the International Maritime Organization had to take various measures. Within the framework of these measures, various rules have been published to reduce environmental pollution and emissions.

Implementing the rules set by the International Maritime Organization in the maritime sector paved the way for including new-generation technologies and environmentalist methods in the maritime sector. In this context, maritime companies are focusing on various research and development activities and reducing the emission rate with environmentally friendly technologies. While it may be easier for large companies to comply with the emission limits set by the International Maritime Organization within the framework of their work, thanks to their great economic power, there may be some difficulties in this process for relatively small companies. Small companies require researching and developing efficient and economical methods by making cost-benefit analyses in this process.

Data-driven techniques have been on the agenda of the scientific world in recent years. Mainly thanks to the developing technology, getting data from all kinds of systems has become relatively more straightforward compared to the past, increasing the importance of data-driven algorithms. For this reason, the application area of data-driven algorithms has increased in recent years. A wide variety of applications of data-driven algorithms are on the agenda in almost all sectors, and successful results are obtained in the applications.

Data-driven approaches also come to the fore at this point, and techniques applied to other industrial areas also contribute to solving problems in the maritime sector. The maritime sector is getting its share from developing technology, and AI-based applications have started to solve some problems in the sector. For example, Knowing the visibility in foggy and unfavourable weather conditions is an important problem in the maritime industry to ensure navigational safety. To solve this problem, it is necessary to calculate the viewing distance using environmental conditions. Thanks to the successful results obtained in the studies in this field, the visibility distance can be estimated in all weather conditions.

The essential expense item in the maritime sector is fuel consumption. For this reason, maritime companies invest in developing technologies that reduce fuel consumption. While it is relatively easy for large firms to cover the cost of these investments, this is not the case for small firms. Companies that cannot equip their ships with innovative technologies lose their place in the market over time. Some companies face various penalties and sanctions and suffer material losses because they cannot meet the rules of the International Maritime Organization.

With the estimation of fuel consumption, which is the most important expense item in the maritime sector, the emissions that may arise can be calculated by estimating the fuel consumption spent during the voyage for all situations that may be encountered at a time. Before data-driven algorithms, fuel consumption was calculated with various methods, but thanks to these methods, calculation processes were accelerated and calculation complexity was reduced.

In addition to being successful, data-driven approaches stand out as cost-effective methods. In this way, maritime companies with relatively low economic power can also access this new technology and solve the problems they encounter while operating with the help of data-driven methods.

In this thesis, three problems in the maritime sector were selected and solutions were tried to be produced with the help of the AI-based methods. With the "Deep Learning Applications in Ship Electric Grids", it is predicted that it will be an important study in realizing the objectives such as reducing network problems, increasing efficiency, and thus reducing emissions released to the nature, with the help of the application of machine learning and deep learning methods on ship electrical grids. When the studies in the literature are examined, it has been determined that the studies in this field are limited in our country and it has been determined that the penalties related to the rules of the International Maritime Organization, the inability to reduce emissions and the failure to increase ship energy efficiency will cause financial losses to the Turkish maritime sector in the coming years. It is aimed to contribute to our country's keeping up-to-date in this field and minimizing the losses it will suffer.

In the first case study covered in the thesis, a container ship used for commercial purposes was selected, and the ship's voyage data at a particular time were obtained from the company operating this container ship. This obtained data set was processed and transformed into a processed one on which data-based algorithms can work. With the help of many input variables in the obtained data set, data-driven algorithms were asked to calculate the output variable. In this case study, with the help of data-driven algorithms frequently encountered in the literature, the electrical power produced on the ship is also estimated, besides the fuel consumption estimation. This new output variable has also made the study unique. With the help of the estimation of the electrical power, a variable used in the efficiency calculations was also found with the help of a practical method. The study used Pearson Correlation Matrix and various binary graphs to model the relations between the variables in the data set. Algorithms could not achieve the desired success in the first stage, so algorithm parameters were adjusted. After this adjustment process, the algorithms achieved the desired prediction success and the estimation process was terminated. At this stage, the K-fold cross-validation method was used to determine whether the algorithms have a memorization problem and to verify the results obtained. The obtained validation results confirmed no memorization and the simulation results. As a result of the simulations, the Deep

Neural Network algorithm has emerged as the most successful method for estimating the electrical power on the ship.

In the second case study on the subject of the thesis, the electrical power produced by the generators providing the electricity needed on a chemical tanker ship was estimated with the help of data-driven methods. With the help of various input variables, the algorithms separately estimated the loads of the three generators in the system with the output variable. This case study, unlike the previous study, it is also shown how the input variables have an effect on finding the output variable in the estimation process. When the results of the study are examined, the Decision Tree method is the most successful in the scenario where the power of each generator is estimated separately. At the same time, the Deep Neural Network stands out as the most successful algorithm in the total load estimation scenario.

In the last case study on the thesis, a container ship was examined. The power produced by the shaft generator, which is generally used during the voyage and contributes to the energy efficiency of the ship by converting some of the energy produced by the main engine into electrical energy, has been estimated. As a result of the simulations, the Multiple Linear Regression algorithm has been the most successful method for this problem.

In the light of the three problems examined within the scope of the thesis and the results obtained, it has been determined that data-driven algorithms can be beneficial for the maritime sector stakeholders in terms of measures to be taken against sudden power losses and fluctuations on the ship, actions to be taken to increase energy efficiency, occupational safety and the safe completion of operations. In the following years, with the development of technology, instant data can be obtained from ships and solutions for all these problems will be developed further with the help of much more powerful models.



1. GİRİŞ

Uluslararası Denizcilik Örgütü (IMO) gemi kaynaklı emisyon miktarlarını 2020 yılından itibaren ağırlıkça %0,1'e kadar azaltacak yönde kurallar yayınlamıştır (Bazari ve Longva, 2011). Denizcilik sektörünün paydaşları IMO'nun yayınladığı kuralları ve gereklerini sağlayabilmek, emisyonları azaltmak ve verimi artırmak için gemilerle ilgili çeşitli geliştirmeler yapmaya, teknolojidен daha fazla faydalanmaya ve yeni yöntemler denemeye yönelmişlerdir (Ahmadabadi vd., 2023; Aksoy ve Genc, 2023; Alonso vd., 2007). Bu geliştirmeler denizcilik işletmeleri için oldukça maliyetlidir. “Gemi Elektrik Şebekelerinde Derin Öğrenme Uygulamaları” ile makine öğrenmesi ve derin öğrenme yöntemlerinin gemi elektrik şebekeleri üzerinde uygulanması sayesinde şebeke problemlerinin azaltılması, veriminin artması bu sayede de doğaya salınan emisyonların azaltılması gibi hedefleri gerçekleştirmede önemli bir çalışma olacağı öngörülmektedir. Literatürdeki çalışmalar incelendiğinde ülkemizde bu alanda yapılan çalışmaların kısıtlı olduğu tespit edilmiştir ve IMO kuralları ile ilgili cezalar, emisyonların azaltılamaması ve gemi enerji verimliliğinin artırılmamasının gelecek yıllarda Türk denizcilik sektörüne maddi zararları olacağı tespit edilmiştir. Yapılan çalışmanın çıktılarının ülkemiz denizcilik sektörü paydaşları ile paylaşılması sayesinde ülkemizin bu alanda güncelliği yakalaması ve uğrayacağı kayıpların en aza indirilmesi konusunda katkı verilmesi hedeflenmiştir.


Makine öğrenmesi ve derin öğrenme algoritmaları birçok sektörde uygulanmaya başlanmış ve başarılı sonuçlar alınmıştır (Alzahrani vd., 2017; Anguita vd., 2012; Assaf vd., 2019; Babarinde ve Madyira, 2022; Bao vd., 2021; Bazari ve Longva, 2011). Denizcilikte ise bu çalışmalar henüz yüzeysel kalmış, daha çok uzaktan gelen bir geminin cinsinin tespitinin yapılması gibi genelde görüntü tanıma gibi uygulamalar yapılmıştır (B. Jiang vd., 2019). Bu bakımdan bilinen yöntemlerin yeni bir alana uygulanması tezi çalışmasının özgün değerini artıracaktır. Ülkemiz denizcilik sektöründe ilklerden olacak bu çalışmadan elde edilecek çıktılar sayesinde gemilerdeki elektrik sisteminin detaylı bir incelemesi yapılacak, makine öğrenmesi ve derin öğrenme algoritmalarının gemi elektrik mikro-şebekesine uygulanması sonucunda

şebekenin veriminin, güvenilirliğinin ve kararlılığının artması gibi amaçların gerçekleştirilmesi için çaba gösterilecektir. Tez çalışmasının hipotezi; “Gemilerde elektrik mikro-şebeke veriminin, sürekliliğinin, kararlılığının ve şebekedeki jeneratörler üzerine düşen yükün daha dengeli olduğu durumda gemide genel enerji verimi artacak, daha düşük miktarda yakıt ile de aynı performans elde edileceğinden dolayı gemilerden doğaya salınan emisyon oranının azalması sağlanacaktır.” olarak belirlenmiştir. Çalışmanın literatürde bu alandaki eksikliği gidermesi ve bu alana dikkati çekmesi de hedeflenmektedir. Tez çalışması kapsamında incelenen literatür aşağıda özetlenmiştir.

Gemilerde yakıt tüketimi işletme giderlerinin yaklaşık %25’ini oluşturur. Bu maliyetin dikkatli bir şekilde tahmin edilmesi denizcilik işletmeleri açısından önemlidir. Gemi yakıt tüketiminin makine öğrenmesi yöntemleriyle tahmin edilmesi konusunda yapılan bir çalışmada (Gkerkos vd., 2019) Çoklu Doğrusal Regresyon (MLR) yöntemi, Random Forest Regression (RF) (Rastgele Orman) yöntemi, Extra Trees (ET) regresyon yöntemi ve Yapay Sinir Ağı (Artificial Neural Networks, ANN) gibi yöntemler kullanılmıştır. Bu çalışma sonucunda yapılan tahminlerin başarısı hata metrikleriyle belirlenmiştir. Bu hata metrikleri sayesinde hata sayısal değerler olarak ifade edilebilmiştir. Ancak, kullanılan makine öğrenmesi yöntemleri ve yapay sinir ağı yöntemi literatürde yeterince başarılı yöntemler olarak görülmemiştir. Bu yöntemlerin yanına daha başarılı ve daha güncel yöntemler eklenebilirse hem bu yöntemlerin başarısı daha net olarak görülebilecektir hem de daha başarılı tahminler yapabilme imkânı doğacaktır.

Kimyasal ürün yüklü bir tankerin enerji tüketimi optimizasyonunun ele alındığı bir çalışmada (Coraddu vd., 2017) kullanılan gemi sevk sisteminin şematize edilmiş hali Şekil 1.1’deki gibidir. Verilen şemaya göre bu gemide iki adet ana makine (ME1,2), bir adet vites kutusu (gearbox, GB), bir adet şaft jeneratörü (SG) bulunmaktadır. Bu mikro-şebekede yukarıda sayılan elemanlara ek iki adet yardımcı makine (AE1,2) vardır. Bu yardımcı makineler ve şaft jeneratörü geminin ana dağıtım tablosunu beslemektedir. Bu çalışmada çeşitli veri işleme teknikleri kullanılarak geminin yakıt harcaması ve trim optimizasyonu yapılmıştır. Çalışma incelendiğinde gemide kullanılan enerji üretim ve dağıtımına ait temel bilgiler verildiği için tez çalışması açısından faydalı bir kaynak olarak ele alınmıştır. Çalışmadan hareketle gemilerde hareketi sağlayan temel sevk sistemi elemanlarının ve gemide kullanılan jeneratörlerin

geminin enerji üretimi ve tüketimi kalemlerindeki en büyük aktörlerden olduğu görülmüştür.



Şekil 1.1: İncelenen Handymax tipi tankere ait sevk sistemi (Coraddu vd., 2017).

Açık bir petrol sahasındaki mikro-şebekenin enerji ihtiyacı tahmini için bir çalışmada Destek Vektör Makinesi (Support Vector Machine, SVM) regresyonu kullanımı ele alınmıştır (Yating Feng, Pengxiang Zhang, Miao Yang, Quian Li, 2019). Bu çalışmada ayrıca şebekenin kısa süreli yük tahmini yapılmıştır. Tahminler yapılırken Dragonfly algoritması, parçacık sürü optimizasyonu algoritması ve genetik algoritmalar yoluyla hibritlenmiş yöntemler kullanılmıştır. Bu yöntemler mikro-şebeke verileri üzerine uygulandığında Dragonfly algoritmasının daha başarılı tahminler yaptığı belirtilmiştir. Çalışma incelendiğinde denizel yapılar için makine öğrenmesi yöntemleri ile sezgisel yöntemleri hibritlemesi bakımından teze katkısı olacağı tespit edilmiştir. Çeşitli regresyon yöntemleri ile farklı türden meta-sezgisel optimizasyon algoritmalarının hibritlendiği bir çalışmadır. Bu hibritleme sayesinde yapılan işlemler sırasında sadece makine öğrenmesi tahminleri ile yetinilmemiş, optimizasyon için çeşitli meta-sezgisel algoritmalar kullanılarak daha faydalı bir model geliştirilmiştir.

Derin öğrenmenin denizcilik alanında insansız deniz aracının çalışabilmesi konusunda kullanıldığı bir çalışmada derin Q-ağı kullanılarak Engelden Kaçınma Tabanlı Takviyeli Derin Öğrenme Algoritması (Deep Reinforcement Learning Obstacle Avoidance, CDRLOA) algoritması yardımıyla aracın engelden kaçma hedefe yönelme gibi çeşitli görevleri düzenlenmiştir (Y. Cheng ve Zhang, 2018). Çalışma analiz edildiğinde sensörlerden alınan bilgiler (Örn. görüntü) işlenerek elde edilen verilerin takviyeli derin öğrenme yöntemi yardımıyla bir karar sistemi oluşturulup ele alınan aracın engellerden kaçınması anlatılmıştır. Çalışma literatür açısından faydalı olmakla birlikte farklı yöntemler denenerek geliştirilebilecek bir yayındır.

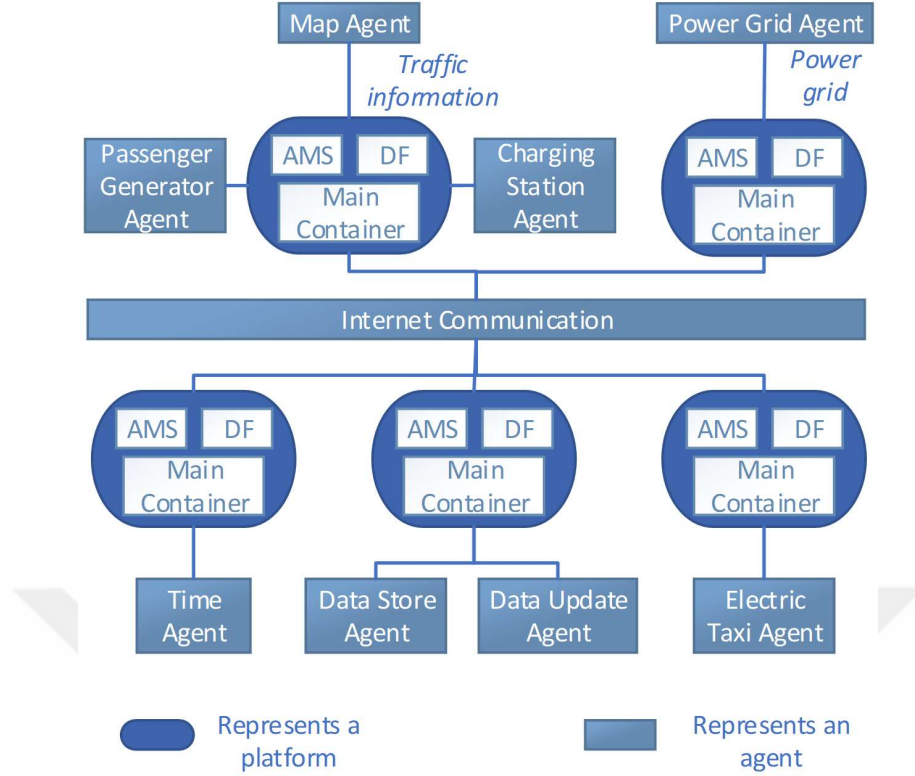
Bilgi tabanlı sistemlerde makine öğrenmesi kullanılarak daha başarılı çıkarımlar elde edilmesi, daha tutarlı tahminler yapılması günümüzde hızla yaygınlaşan bir problem çözme tekniğidir. Makine öğrenmesi tabanlı sistemlerin kullanılagelen sistemlerden çok daha başarılı şekilde çalıştığı, bu yüzden makine öğrenmesi yöntemlerinin çok farklı alanlarda kullanılmaya başlandığı görülmektedir. Bu bakımdan makine öğrenmesi ve derin öğrenme yöntemlerin yeni bir alana uygulanması tez çalışmasının özgün değerine katkı sağlayacağı saptanmıştır. Makine öğrenmesi tabanlı elektrik sürücü sistemi uygulamasını ele alan bir çalışmada bu olgular ayrıntılarıyla işlenmiştir (Mayr vd., 2018). Çalışma klasik yöntemlerle makine öğrenmesi gibi daha güncel yöntemleri problem çözme süreçlerindeki etkinlikleri açısından kıyaslaması nedeniyle literatürde önemli bir çalışmadır.

Derin öğrenme ile elektrik şebekelerinin birlikte ele alındığı bir çalışmada üç fazlı enerji sistemlerin kontrolü yapılmıştır. Bu çalışmada enerji sisteminin veriminin artması, maliyetlerin düşürülmesi adına genişletilebilir bir derin öğrenme yöntemi kullanılmıştır (Yin vd., 2019). Bu çalışma, derin öğrenme yöntemlerinin elektrik şebekesi problemlerinde kullanılabileceğini göstermesi ve şebeke veriminin artırılması ilkesini ele alması açısından güncel literatür kapsamında incelenen faydalı çalışmalardan biridir.

Derin öğrenme yöntemlerinin son yıllarda yalnızca stabil sistemlerde değil hareketli sistemlerde de birtakım problemleri çözmek için kullanıldığı bazı çalışmalarda ele alınmıştır. Hibrit elektrikli otobüs için enerji yönetiminin deep reinforcement learning yöntemi kullanılarak yapıldığı bir çalışmada emisyonların azaltılması ve yakıt tüketiminden tasarruf edilmesi amacıyla bir strateji önerilmiştir. Elektrikli otobüs için

veriler uzun süreli sürüşlerde elde edilen istatistiki bilgilerden elde edilmiştir. Elde edilen verilerin Takviyeli Derin Öğrenme (Reinforcement Deep Learning, RDL) yöntemiyle ele alınmasıyla hibrit elektrikli araç için genel enerji verimliliğinin arttığı gözlemlenmiştir (Y. Wu vd., 2019). Literatür incelendiğinde, ele alınan bu çalışmanın; verilerin nasıl alınacağı, nasıl işleneceği, enerji verimliliğinin derin öğrenme yöntemi ile nasıl arttırılabileceği ve en önemlisi derin öğrenme yöntemlerinin taşıtlardaki enerji verimliliğinin arttırılması konusunda kullanılabileceği konusunda tez çalışması açısından faydalı bir makale olduğu tespit edilmiştir.

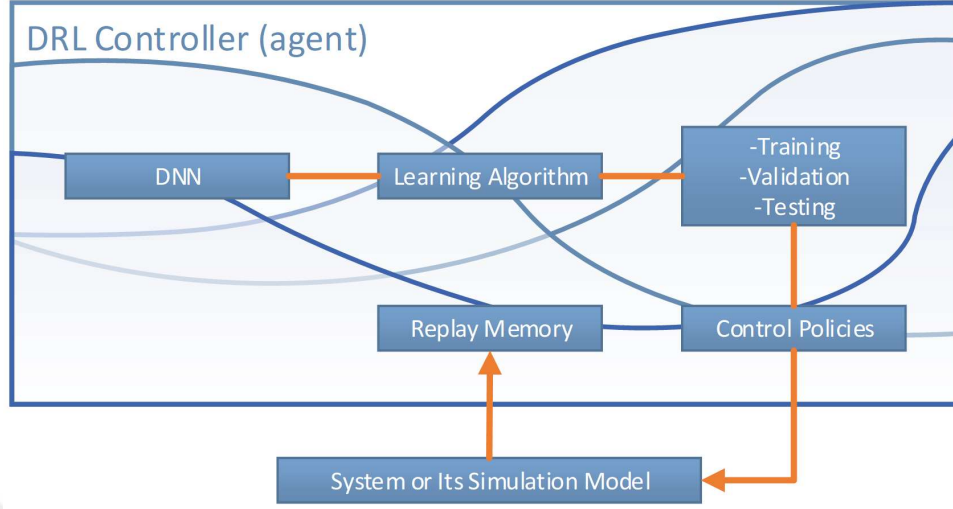
Derin öğrenme yöntemlerinin taşıtlarda var olan çeşitli problemlerin çözümünde kullanıldığı bir çalışmada elektrikli araçların şarj yükünün modellenmesi, ani güç dalgalanmaları, çökmeler, istikrarlı çalışabilme, güvenlik gibi sorunların elektrikli araçlar açısından son derece önemli olduğundan bahsedilmiştir. Yapılan çalışmada araçlar için kullanmak üzere klasik Monte Carlo yöntemi ve optimizasyon yöntemleri denenmiş ve iyi sonuçlar alınamamıştır. Araçlar ile ilgili sorunların çözümü için takviyeli derin öğrenme yöntemi kullanılarak java agent development framework (JADE) isimli ortamda bir uygulama geliştirilmiştir. Yapılan çalışma sayesinde elektrikli araçlara ait sorunların çözümünde aşama kat edilmiştir. Araçların şarj yükünün modellenmesi ve güç dalgalanmalarının önlenmesi geliştirilen takviyeli derin öğrenme uygulamasıyla mümkün olmuştur (C. X. Jiang vd., 2018). Bu uygulamanın şematize edilmiş hali Şekil 1.2’de verilmiştir. Bu çalışmada kullanılan yöntemin başarılı sonuçlar vermesi derin öğrenme yöntemlerinin taşıtın enerji yükünün modellenmesi ve güç dalgalanmalarının önlenebileceği konusunda tezin amaç ve hedefleri ile örtüşen bir çalışma olduğu görülmüştür.



Şekil 1.2: Java Agent Development Framework uygulaması (JADE)(C. X. Jiang vd., 2018).

Derin öğrenme yöntemleri elektrik şebekelerindeki problemleri çözme amacıyla da kullanılmaktadır. Takviyeli derin öğrenme kontrolündeki elektrik güç sistemi ile ilgili mevcut çalışmaların gözden geçirildiği bir çalışmada elektrik şebekeleri ile ilgili yaşanan bazı problemlere değinilmiştir (Glavic, 2019). Bu problemlerden ilki önleyici senaryoların oluşturulması gerekliliğidir. İkinci problem ise acil durumlarda şebekenin nasıl kararlar vermesi gerektiğinin bilinmemesidir. Çalışmada ele alınan son problem ise şebekenin bir arıza durumunda onarımının nasıl yapılacağı, iletimin böyle anlarda nasıl sağlanacağıdır. Bu problemler çalışmada genel bir elektrik şebekesi, mikro-şebeke gibi farklı elektrik şebekesi konfigürasyonlarında izlenmiştir. Bu şebekelerde ayrıca aşırı yük durumu analizi ve tahmini uygulamaları da yine derin öğrenme aracılığıyla gerçekleştirilmiştir. Çalışmada son olarak kısa vadeli yük tahmini yapılmış ve şebekenin ani yüklenmelere karşı nasıl bir tutum izleyeceği belirlenmeye çalışılmıştır (Glavic, 2019). Bu çalışmaya ait takviyeli derin öğrenme şeması Şekil 1.3'te verilmiştir. Çalışmada ele alınan ani yük dalgalanmalarında şebekenin davranışının yönetilmesi kısmı tezin amaç ve hedeflerinde yer alan şebekenin

sürdürülebilirliğinin ve kararlılığının sağlanması kısımları ile doğrudan ilişkili olduğundan tez açısından faydalı bir çalışma olarak değerlendirilmiştir.

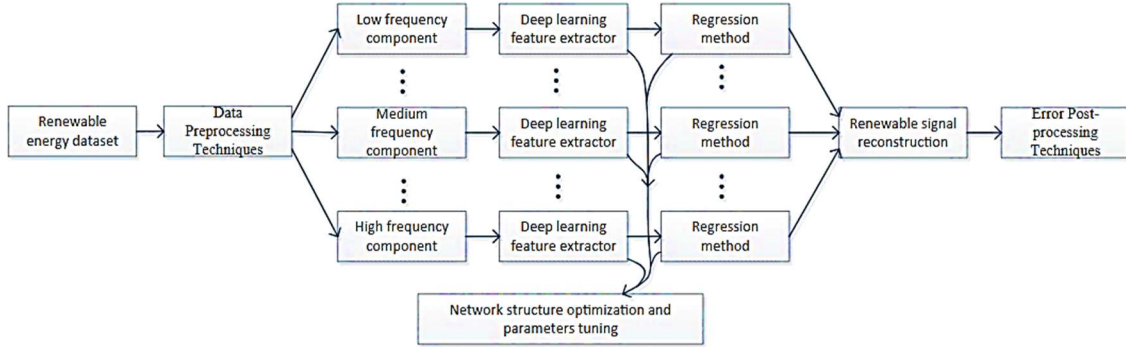


Şekil 1.3: Sisteme ait takviyeli derin öğrenme şeması (Glavic, 2019).

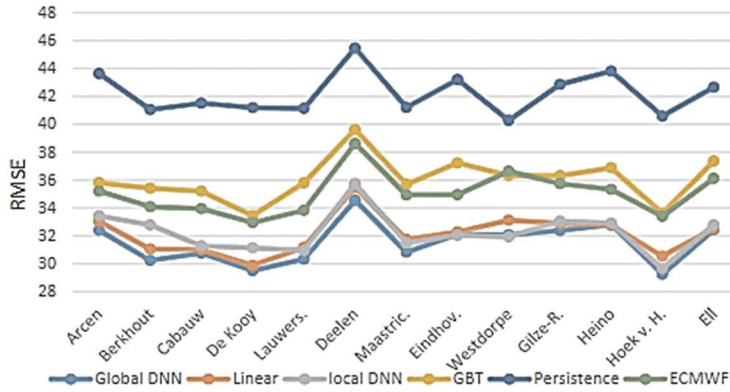
Dizel makinelerin yakıt tüketimi optimizasyonu emisyonların azaltılması için son derece önemli bir konudur. Genetik algoritma ve yapay sinir ağı yöntemleri ile yapılan bir hibrit optimizasyon çalışmasında emisyon seviyeleri ve yakıt tüketimi çıkış değişkeni olarak değerlendirilirken çeşitli parametreler ise giriş değişkeni olarak kullanılmıştır. Bu aşamada öncelikle YSA ile sistemin çıktıları tahmin edilmiş, GA ile optimizasyon işlemi yapılmıştır. Yapılan optimizasyon işlemi sonucunda emisyonlarda ve yakıt tüketiminde önemli bir verimlilik elde edilmiştir (Alonso vd., 2007).

Derin öğrenme yönteminin tahmin problemleri konusunda da kullanıldığı literatürde görülmüştür. Derin öğrenme yöntemiyle yenilenebilir enerjilerin tahmin edilmesi sürecinin ele alındığı bir çalışmada son yıllarda fosil yakıtların azalması, fosil yakıtların çevreye yaydığı emisyonların küresel ısınmaya sebep olması ve insan sağlığını kötü yönde etkilemesinden bahsedilmiştir (H. Wang vd., 2019). Bu durumların sonucunda yenilenebilir enerji kaynaklarının öneminin arttığı vurgulanmıştır. Ele alınan çalışmada problem olarak öncelikle yenilenebilir enerjinin toplam değerinin klasik yöntemlerle tam olarak istenilen hassasiyette belirlenemediği gösterilmiştir. Yenilenebilir enerjinin bir işletme için istenilen doğrulukta tahmin edilmesi için çeşitli derin öğrenme algoritmalarından faydalanılmıştır. Kullanılan akış şeması Şekil 1.4'te verilmiştir. Sistemin hata değerlerini karşılaştıran grafik Şekil

1.5’de gösterilmiştir. Bu grafik sayesinde hangi derin öğrenme algoritmasının bu problemde daha iyi çözüm ürettiği belirlenmiştir (H. Wang vd., 2019). Çalışmanın yöntemi tezde kullanılan yöntemler ile benzerlikler taşımaktadır. Bunun yanında sistemin elde ettiği çıkış değerleri ile gerçek değerler arasındaki hata değerlerini sayısallaştıran hata metriklerinin ele alınması açısından değerli bir çalışma olduğu görülmüştür.



Şekil 1.4: Çalışmada kullanılan akış şeması (H. Wang vd., 2019).



Şekil 1.5: Sistemin hata değerlerinin karşılaştırılması (H. Wang vd., 2019).

Derin öğrenme ile akıllı şebekelerin birlikte ele alındığı, Ren ve Zhang (2018) tarafından IEEE Transactions on Smart Grid isimli dergide yayınlanan "Generalized microgrid power flow" başlıklı çalışmada bir mikro-şebekenin gerçek zamanlı olarak ekonomik işletilmesini amaçlanmış ve bir dinamik enerji yönetim sistemi ortaya atılmıştır (Ren ve Zhang, 2018). Bu yapılırken de Markov karar verme sürecinden yararlanılmıştır. Gerçek zamanlı programlama politikasının oluşturulması için yaklaşık dinamik programlama ve derin yineleyen sinir ağını kullanılmıştır. Çalışma sonunda California’da bir merkezden gelen gerçek güç şebekesinin verilerini

kullanarak önerilen bu yöntemin benzetimini yapılmıştır (Ren ve Zhang, 2018). Bu çalışma mikro-şebekenin verimli işletilmesi açısından literatürde değerli bir örnektir.

Yapay zekâ ve elektrik şebekelerinin birleştirildiği, Khan vd. (2018) tarafından Third International Conference on Fog and Mobile Edge Computing (FMEC) isimli konferansta sunulan "Artificial intelligence framework for smart city microgrids: State of the art, challenges, and opportunities" başlıklı çalışmada akıllı şehir şebekelerinin son birkaç yılda yaygınlaştığından söz edilmiştir (Khan vd., 2018). Şebekelerin mikro-şebeke olarak ele alındığında meydana gelen sorunların yapay zekâ tabanlı yöntemler sayesinde çözülebileceği dile getirilmiştir. Bu çerçevede ele alınan yöntemde derin öğrenmeyi destekleyen ölçeklenebilir "BluWave-ai" isimli yapı ile yerleşim yerlerinde kullanılan mikro-şebekelerin enerji optimizasyonunu yapılmıştır (Khan vd., 2018). Bu çalışma özellikle mikro-şebeke ile ilgili problemlerin yapay zekâ yöntemleri ile çözülebileceğini göstermesi ve mikro-şebekelerin enerji optimizasyonunun ele alınması bakımından yol gösterici bir çalışmadır.

Derin öğrenme ile taşıtlarda elektrik mikro-şebekesindeki hataların belirlenmesi ve sınıflandırılması ile ilgili Haque vd. (2018) tarafından IEEE Transportation Electrification Conference (ITEC) isimli konferansta sunulan "Deep learning based micro-grid fault detection and classification in future smart vehicle" başlıklı çalışmada elektrikli taşıtlarda mikro-şebekenin güvenilirliğinin yüksek olması gerektiğinden söz edilmiştir (Haque vd., 2018). Herhangi bir arızanın meydana gelmesi durumunda can kayıplarının yaşanabileceğine değinilmiştir. Bu tür arızaların önüne geçebilmek ve mevcut koruma önlemlerinin yanında mikro-şebekeyi korumak için bir akıllı sürekli izleme ve hata sınıflandırma mekanizmasının olması gerektiğinden söz edilmiştir. Hata izleme yöntemi olarak kullanılan endüstriyel nesnelerin interneti uygulamasıyla verilerin toplanabileceğini savunulmuştur. Bu noktada verilerin hata sınıflandırılması için elle işlenmesinin zaman alıcı ve pratik olmayan bir yöntem olduğundan söz edilmiştir. Bu yöntemin yerine yapay sinir ağının kullanımının da zaman alıcı olduğundan söz etmişler ve en uygun iki yöntem olarak Derin Sinir Ağı (Deep Neural Network, DNN) ve Yinelemeli Sinir Ağı (Convolutional Neural Network, CNN) önermişlerdir. Çalışmada bu yöntemin geleneksel yapay sinir ağıyla kurgulanan yöntemlerden daha iyi sonuç verdiği doğrulanmıştır (Haque vd., 2018). Çalışmada kullanılan yöntemin geleneksel yapay sinir ağı yönteminden daha iyi sonuç vermesi ele alınacak problemin derin öğrenme ve makine öğrenmesi algoritmalarıyla

çözülebileceği yönünde motivasyonu artırmıştır. Bu çalışma mikro-şebekedeki hata belirlenmesi ve türünün tanımlanması gibi konularda önemlidir.

Derin öğrenme yönteminin elektrik mikro-şebekesindeki güneş enerjisi kaynaklı güç çıkışının ve yük tahmininin yapıldığı, Lulu vd. (2019) tarafından Energy dergisinde yayınlanan çalışmada, bir mikro-şebeke için toplam güç yükü ve fotovoltaiik güç çıkışının belirlenmesinde uzun ve kısa süreli bellek birimlerini kullanan derin tekrarlanan yapay sinir ağı geliştirilmiştir (Wen vd., 2019). Şebekedeki arz talep oranını dengelemek için ihtiyaç ve fotovoltaiik sistem çıkışı tahmin edilmiştir. Tahminler eski yöntemler kullanılarak elde edilen tahminlerle kıyaslanıp etkinliği incelenmiştir. Bu çalışma sonucunda derin öğrenmeye dayalı güneş enerjisi ve yük tahmini sayesinde %8,97 enerji tasarrufu yapılmıştır (Wen vd., 2019). Çalışma, derin öğrenme yöntemi ile elektrik şebekesinde enerji tasarrufu yapılabileceğini göstermesi bakımından değerlidir ve tezde kullanılan yöntemler ile uyuşması açısından motivasyon sağlayıcıdır.

Derin öğrenme yönteminin elektrik şebekesindeki güç kalitesi bozukluklarının ayırt edilmesi konusunda Wang ve Chen (2019) tarafından Applied Energy dergisinde yayınlanan çalışmada elektrik şebekesindeki güç kalitesi bozukluklarının tespit edilmesi için bir derin yinelemeli sinir ağı önerilmiştir (S. Wang ve Chen, 2019). Önerilen yöntem diğer modern derin sinir ağları ve geleneksel yöntemlerle karşılaştırıldığında mikro-şebekedeki güç kalitesi sorunlarının kaynağının tespitinde daha üstün olduğunu göstermiştir (S. Wang ve Chen, 2019). Bu çalışma, derin öğrenme yöntemlerinin elektrik şebekesindeki problemlerin çözümünde kullanılabileceğini göstermiştir ve literatürde bu alana dikkat çekmesi bakımından değerlidir.

Elektrik mikro-şebekesinin modellenmesi ile ilgili Alzahrani vd. (2017) tarafından Procedia Computer Science dergisinde yayınlanan çalışmasında mikro-şebeke; ana dağıtıcının şebekeye güç vermediği anlarda bile çalışabilen şebeke olarak tanımlanmıştır (Alzahrani vd., 2017). Modellenen mikro-şebekenin beslenebilmesi için ihtiyaç duyulan enerji güneş panelleri vasıtasıyla elde edilmiştir. Şebeke çıkış gücünü ve yük tahminini modelleyebilmek için MATLAB/SIMULINK programında yapay sinir ağlarından yararlanılmıştır. Bu çalışma elektrik mikro-şebekesinin modellenmesi açısından literatürde önemli bir çalışmadır. Simülasyon yoluyla da olsa

elektrik mikro-şebekesinin modellenmesinin yapılması ve şebekenin ihtiyaç duyduğu enerjinin sağlanmasının yapılması simülasyonlar ve simülatörlerle elektrik mikro-şebekesi ile ilgili problemlerin çözülebileceğini göstermesi açısından yol göstericidir (Alzahrani vd., 2017).

Akıllı elektrik şebekelerinde yük tahmini konusunda Coelho vd. (2016) tarafından Applied Energy Symposium and Forum isimli konferansta sunulan çalışmada yeni nesil sensörlerin duyarlılığının ve örnekleme sayısının artmasıyla sistemlerden daha fazla sayıda verinin alınabildiğinden söz edilmiştir (Coelho vd., 2016). Alınan verilerin işlenmesinde grafik güç birimlerinde yararlanılabileceğinden ve bu verilerden hareketle gelecek verilerin tahmininde çeşitli derin öğrenme algoritmalarının kullanılabileceğinden bahsedilmiştir. Yapılan örnek çalışmada ise bir evin enerji talebi derin öğrenme yöntemiyle tahmin edilmiştir (Coelho vd., 2016). Çalışma, sensörler vasıtasıyla veri alınması, derin öğrenme yöntemi için grafik güç biriminin gerektiğini anlatması gibi tezde ele alınan yöntemler ile yakından ilişkilidir.

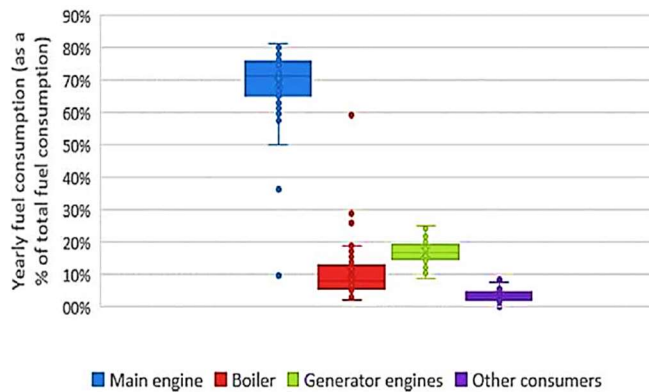
Gemi elektrik şebekesinin modellenip simülasyon programlarında bir benzetiminin oluşturulması konusunda Jia ve Dong (2017) tarafından IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC) isimli konferansta sunulan "Research on ship power plant simulation system based on LabVIEW and MATLAB mixed programming" başlıklı çalışmada, geminin kendi gücünü üreten dağıtan ve kullanan bir sistem olduğundan söz edilmiştir (Jia ve Dong, 2018). Sistemin aynı zamanda sistemin üretim, iletim ve dağıtım ağını birbirine bağladığı anlatılmıştır. Sistemin birbirine bağlı olmasından dolayı şebekenin herhangi bir noktasında oluşabilecek bir arızanın şebekenin tümünü etkileyebileceği belirtilmiştir. Bu problemin çözümü için çalışmada gemi elektrik şebekesi MATLAB/SIMULINK ve LabVIEW programları ile modellenmiştir (Jia ve Dong, 2018). Çalışma incelendiğinde gemi elektrik şebekesini modellemesi, simülasyon programlarında bir benzetimini oluşturması ve şebekedeki bir problemin çözümünü yapması nedeniyle önemli bir çalışma olarak tespit edilmiştir.

Wang vd. (2017), yayınlanan "Application of QFD and FMEA in ship power plant design" başlıklı çalışmada gemi elektrik şebekesinde ana problemin geminin işletilmesi için gerekli olan elektrik gücünün sürekli olarak sağlanabilmesi olduğuna değinmiştir (T. Wang vd., 2018). Bu problem dışında gemide şebekenin kararlılığının

sağlanması da çalışmada önemli bir problem olarak görülmüştür. Bu problemlerin çözümünde Kalite Fonksiyonu Geliştirilmesi (Quality Function Development, QFD) ve Hata Modu ve Etki Analizi (Failure Mode and Effect Analysis, FMEA) gibi yöntemler uygulanmıştır (T. Wang vd., 2018). Bu çalışma gemilerde elektrik şebekesinde kararlılığın sağlanabilmesi ve sürekli olarak şebekeye güç verilebilmesi problemlerini tanıtip ele alıp çözümler üretmesi nedeniyle tez açısından önemlidir.

Prousalidis vd. (2009), yılında yayınladıkları “Reactive power sharing in ship energy systems with shaft generators” isimli çalışmada gemi elektrik şebekesinde jeneratör setleri üzerine düşen yüklerin dengeli dağıtılması, shaft jeneratörü ve konvansiyonel jeneratörlerin birlikte çalışması, yük paylaşımı operasyonu sırasında sistemdeki elemanların davranışlarının modellenmesini amaçlamıştır (Prousalidis vd., 2009). Çalışma incelendiğinde tezde ele alınan gemi elektrik şebekesindeki jeneratörler üzerine düşen yüklerin dengeli dağıtılması problemini ele alması ve şebekedeki elemanların davranışlarının modellenmesi konusunda değerli bir çalışma olduğu görülmüştür (Prousalidis vd., 2009).

Gemide kullanılan jeneratörlerin geminin sefer boyunca harcadığı toplam yakıtın %15-%20’lik bir kısmını tükettiği Pagoropoulos vd., (2017) denizcilik alanında popüler bir dergi olan Ocean Engineering dergisinde “Applying Multi-Class Support Vector Machines for performance assessment of shipping operations: The case of tanker vessels” isimli çalışmada ele alınmıştır (Pagoropoulos vd., 2017). Bu çalışmada ele alınan gemideki elektrik yükünün dağılımı Şekil 1.6’da gösterilmiştir. Ayrıca bu çalışmada gemideki operasyonların makine öğrenmesi yoluyla modellenmesi tez çalışmasında gemi elektrik şebekesinde enerji yönetim modeli oluşturulması konusunda motive edici bir unsur olmuştur.



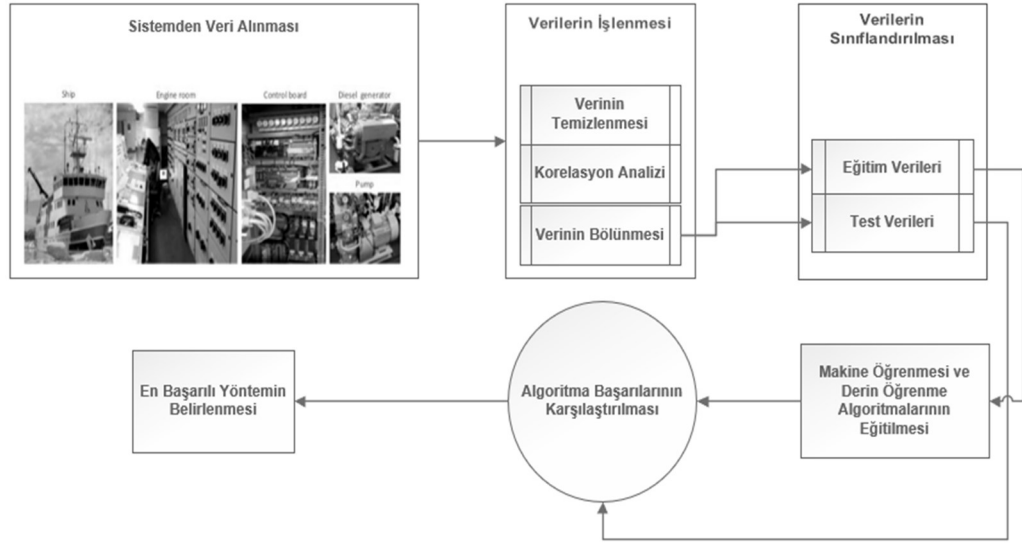
Şekil 1.6: Gemideki elektrik yükünün dağılımı (Pagoropoulos vd., 2017).

Çalışmada kullanılan makine öğrenmesi ve derin öğrenme yöntemleri son yıllarda araştırmacıların ilgisini çekmeye başlamıştır (Friedman, 2001; Gao vd., 2009). Ancak bu yöntemlerin gemi elektrik mikro-şebekeleri üzerinde uygulanması ve gemilerde oluşan problemlere çözümler bulması üzerine literatürde henüz az sayıda çalışma vardır. Bu yüzden yöntem bu alanda yenidir. Farklı alanlardaki problemlerin çözümünde başarılı sonuçlar alınması da gemi elektrik mikro-şebekeleri üzerinde makine öğrenmesi ve derin öğrenme yöntemlerinin başarılı sonuçlar vereceği, öngörülen hedef ve amaçları gerçekleştirme konusunda işlevsel olduğu konusunda motivasyon olmuştur.

Tez çalışmasında öncelikle gemi mikro-şebekesi incelemesi ve sistemden veri alınması işlemi yapılmıştır. Veri alınması işlemi gemide yer alan çeşitli sensörler vasıtasıyla gerçekleştirilmiştir. Bu sensörler akım, gerilim, güç ve sıcaklık verileri, jeneratör verileri, pompa verileri, kontrol sistemi verileri, makine dairesi verileri, güverte verileri gibi gemide bulunan çok çeşitli sistemlere ve dinamiklere ait verilerdir. Bu veriler temizlenmiş, korelasyon analizi yapılmış, eğitim ve test verisi olarak iki kısma rastgele seçilerek ayrılmıştır. Bu aşamada yapılan olan korelasyon analizi, değişkenler arasındaki ilişkiyi açıklamaya yardımcı olan istatistiksel bir yöntemdir ve iki değişken arasındaki ilişkinin durumunu, yönünü ve derecesini belirlemek için kullanılır (Rožić vd., 2011). Korelasyon analizinde Pearson yöntemi kullanılacaktır ve Pearson Korelasyon Katsayısının (r) hesaplanması analiz için önemlidir. “ r ” katsayısı, -1 ile +1 arasında değerler alabilir. Artı işareti ve katsayının önündeki eksi işareti sırasıyla pozitif korelasyonu ve negatif korelasyonu gösterir (Forrester ve Zhang, 2020). Verilerin bölünmesi ve sınıflandırılması işlemlerinde korelasyon analizi aşamasından geçirilmiş veriler 2 kısma ayrılır. Bu oran genelde %66 eğitim verisi, %33 test verisi olarak ele alınmıştır (Ahlgren vd., 2019). Eğitim verileri sistemde kullanılacak makine öğrenmesi ve derin öğrenme algoritmalarını eğitmek için kullanılmıştır. Böylelikle bu algoritmaların sisteme ilişkin istenen çıkış değişkenlerini tutarlı bir şekilde tahmin etmesi, sınıflandırması gibi hedeflerin gerçekleştirilmesi temin edilmiştir.

Tez çalışmasında ikinci adım olarak tahmin modelleri oluşturulmuş ve yöntemlerin başarımlar açısından sıralanması hata metrikleri (Root mean squared error (RMSE), mean absolute error (MAE) vb.) sayesinde yapılmıştır (Silonis ve Anyfantis, 2023). Bu aşamalar Şekil 7’de özetlenmiştir. Bunun haricinde algoritma başarımlarının

geliştirilmesi için algoritma parametrelerinin optimizasyonu yapılmıştır. Sistemde ele alınan algoritma başarımlarının karşılaştırılması aşamasında daha önceden test verisi olarak rastgele seçilen %33'lük veri seti parçası kullanılmıştır. Eğitim verileri sistem üzerinde kullanılacak makine öğrenmesi ve derin öğrenme algoritmalarının eğitilmesi için kullanılacaktır. Test verileri ise sistemdeki algoritmalara öğretilmeyecek, yöntemlerin başarılarını sınamak için kullanılacaktır. Gemi elektrik mikro-şebekelerinde makine öğrenmesi ve derin öğrenme uygulamalarının gerçekleştirilmesi aşamasında, makine öğrenmesi ve derin öğrenme algoritmalarına ait yazılan kodlar Python 3.0 programlama dili sürümü, Spyder 4.1.5 ara yüzü ortamında yazılmış olup her algoritmanın elde ettiği tahminler ve test verisi değişkenleri tek tek karşılaştırılarak, aradaki hata değerleri hata metrikleri (Lloyd ve Rebow, 2018) (RMSE, MAE vb.) ile sayısallaştırılmıştır. En başarılı yöntemin belirlenmesi aşaması hata metrikleri bakımından en küçük değerlere sahip algoritmanın seçilmesi aşamasıdır. Çalışmada Multiple-Linear, Ridge, Lasso, Kernel Ridge, Bayesian Ridge, Support Vector, K-Nearest Neighbors, Multi-Layer Perception, Decision Tree, Random Forest, Ada Boost, Gradient Boosting, Hist Gradient Boosting gibi makine öğrenmesi algoritmalarının yanında Deep Neural Networks, gibi derin öğrenme algoritmaları da kullanılmıştır. Bu uygulamalar sayesinde sistem ile ilgili çeşitli öngörülerin yanında sistemin veriminin artması gibi ana hedefin yanında, kararlılığının, sürekliliğinin artırılması, sistemdeki jeneratörler üzerine düşen yükün optimizasyonunun yapılması ve sistemin çalışma davranışının belirlenmesi gibi hedeflerin de gerçekleştirilmesi yönünde adımlar da atılmış olacaktır. Bu kapsamda incelenen Alonso vd. (2007) çalışmasında dizel makinenin emisyonlarını tahmin etmek ve emisyonları azaltmak için genetik algoritma ve yapay sinir ağının bir hibrit modeli geliştirilmiştir (Alonso vd., 2007). Emisyonların tahmininde yapay sinir ağı kullanılmış, azaltma ve optimizasyon kısmında ise genetik algoritmadan faydalanılmıştır. Bu çalışmada kullanılan yöntem araştırma önerisi açısından faydalı olmuştur. İncelenen çalışma sonucunda emisyon değerlerinin zararlı gaz türüne göre %0,3 ile %26,7 değeri arasında azaltılabildiği saptanmıştır (Alonso vd., 2007). Tez kapsamında gemi elektrik şebekesi üzerinde verim artışı sağlanabilmesi halinde emisyon oranında da düşüş görülebilir. Çalışmada kullanılan yöntemlerin genel akış şeması Şekil 1.7'de tasvir edilmiştir.

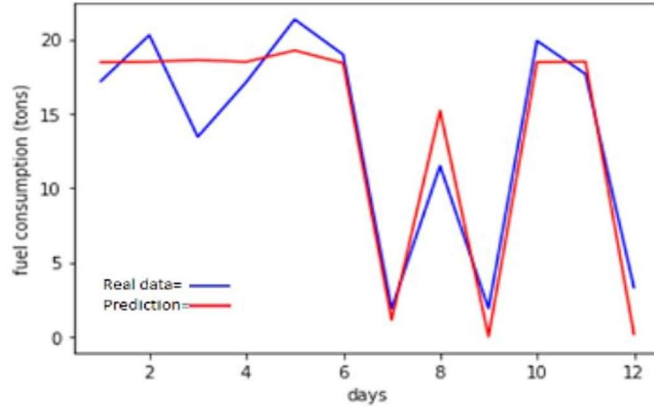


Şekil 1.7: Çalışmada kullanılan yöntemlerin genel akış şeması.

Çalışmada üçüncü aşama olarak kurulan modellerin mikro-şebeke sistemine entegrasyonu, simülasyon ve sistem üzerinde test edilmesi işlemleri yapılacaktır.

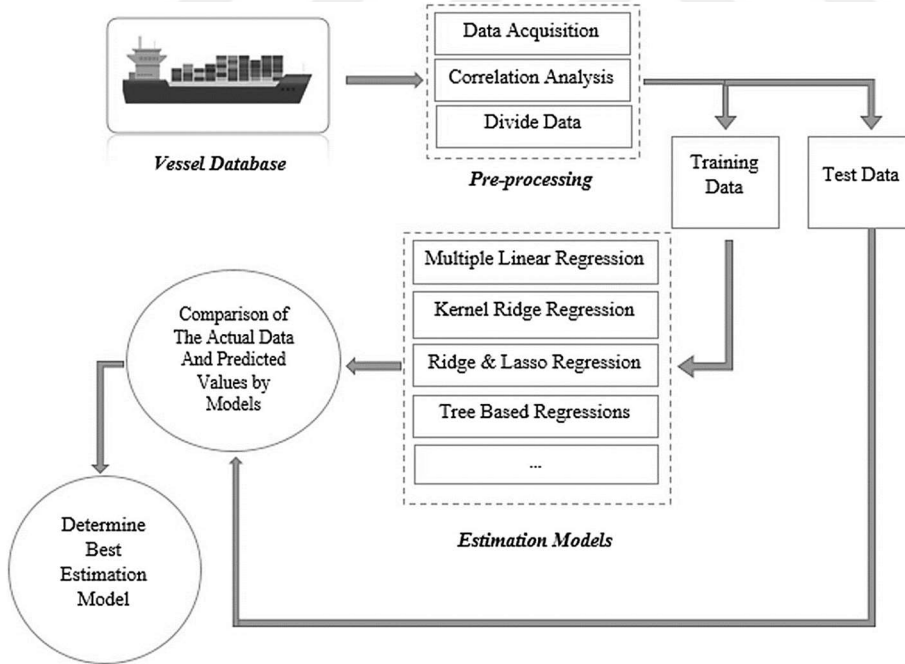
Çalışmanın dördüncü adımı olarak, gemi elektrik mikro-şebekesi güç yönetim modeli oluşturulması ve gemi elektriksel enerji verimliliğinin artırılması işleminde tez çalışması süresince oluşturulan modeller farklı gemi elektrik mikro-şebeke kombinasyonları üzerine de uyarlanacak, uygulanabilirliği artırılacak ve yaygınlaştırılması sağlanacaktır.

Tez çalışması kapsamında ön çalışma olarak öncelikle bir uluslararası bildiri hazırlanmış ve sunulmuştur (Uyanık vd., 2019). Çalışmada kısa süreli bir ticari gemi seferine ait yaklaşık 36 günlük bir veri seti alınmıştır. Ele alınan bu veri seti rastgele seçilmek suretiyle iki parçaya bölünmüştür. Bu parçalardan %66'sı eğitim verisi, %33'ü test verisi olarak ayrılmıştır. Çoklu doğrusal regresyon (Multiple-linear regression) yöntemi ile test verileri tahmin edilmiştir. Çalışma sonucunda RMSE değeri 1,61 olarak bulunmuştur. Veri setindeki gün sayısının artması, başarı oranını yükseltecektir. Çalışmadaki tahminler ile test verisinin karşılaştırıldığı grafik Şekil 1.8'de verilmiştir. Buradaki kısıtlı veri seti ve en basit yöntemlerden olan çoklu doğrusal regresyon ile birlikte elde edilen başarımdan hareketle daha geniş veri setleri ile çalışmak algoritmaların gemi elektrik mikro-şebekesinin davranışını çok daha iyi öğrenmesini sağlayacağından bu araştırma sonucunda başarılı sonuçlar elde edileceği öngörülmüştür.



Şekil 1.8: Gemi yakıt tüketimi değerleri ve tahmini değerlerin karşılaştırılması (Uyanık vd., 2019).


Tez kapsamında başka bir çalışmada bir konteyner gemisinin yakıt tüketimi modeli makine öğrenmesi algoritmalarının regresyon kısmıyla elde edilmiş ve bu model kullanılarak bir geminin sefer boyunca harcayacağı yakıt miktarı başarılı olarak belirlenmiştir (Uyanık vd., 2020). Çalışmada kullanılan yakıt tüketim tahmin modeli Şekil 1.9’da verilmiştir.



Şekil 1.9: Makine öğrenmesi yöntemleri ile gemi yakıt tüketim tahmin modeli (Uyanık vd., 2020).

Bu çalışmada elde edilen tahmin sonuçları ise Şekil 1.10’da verilmiştir. Çalışma Web of Science tarafından taranan Transportation Research Part D: Transport and Environment (Scopus Q1, Impact Factor:7) (Uyanık vd., 2020) isimli dergi tarafından

kabul edilmiş ve basılmıştır. Bu çalışmada elde edilen tecrübenin, çalışmayı hazırlarken Python programlama dilinin Spyder ara yüzünün başarılı bir şekilde öğrenilip kullanılmasının, makine öğrenmesi algoritmalarıyla ve regresyon bölümüyle önemli bir çalışma olduğu söylenebilir. Bu çalışma haricinde gemilerde şaft jeneratörünün elektriksel gücünün belirlenmesi ile ilgili bir çalışma da literatüre kazandırılmıştır (Uyanık, 2021) Bu çalışmada şaft jeneratörünün gemide yakıt verimliliğini artırıcı bir etken olduğundan, sefer sırasında diğer jeneratörlerden daha az yakıt harcanarak gemi elektriksel yükünün karşılanabileceğinden bahsedilmiştir. Ayrıca gemide ihtiyaçtan fazla güç üretmenin jeneratördeki parçaların ömrünün azalmasına yol açacağı bir problem olarak ortaya çıkmaktadır. Çalışmada şaft jeneratöründen çekilen elektriksel gücün tahmin edilmesinden şebekede kullanılacak elektriksel yükün karşılanabilmesi için bir model geliştirilebileceği öngörüsü oluşmuştur. Geliştirilecek bu modeller sayesinde gemide fazladan güç üretiminin önüne geçilebilir, dolayısıyla güç üretiminde yapılacak optimizasyonla yakıt tüketimi de azaltılabilir. Bu sayede fazladan güç üretimi azaltılacağından jeneratörün parçaları da daha az aşınacak ve arıza yapma periyodu uzayacaktır.



Şekil 1.10: Makine öğrenmesi yöntemleri ile gemi yakıt tahmini sonuçları (Uyanık vd., 2020).

Tez kapsamında yapılan bu iki ön çalışmada daha düşük hata metrikleri elde edebilmek için algoritmaların parametreleri makine öğrenmesi algoritmalarının parametrelerinin ayarlanmasında kullanılan “gridsearch” yöntemi ile optimize edilmiştir. Bu sayede makale çalışmasında en başarılı yöntemler olan Ridge ve Çoklu Doğrusal Regresyon

algoritmalarının tahmin başarısı %99.999 değerine yükselmiştir. Bu çalışmalar haricinde yapılan başka bir ön çalışmada ise gemi yakıt tüketiminde geminin gövde altı temizliğinin makine öğrenmesi ile tahmin edilip analiz edilmesi işlemi yapılmıştır (Elidolu vd., 2020). Bu analiz sırasında geminin gövde altı temizliği yapılmadan önce ve yapıldıktan sonra direncinin değiştiği ve daha az yakıt harcadığı makine öğrenmesi algoritmalarının regresyon modelleri yardımıyla tespit edilmiştir. Bu çalışma da makine öğrenmesi yöntemlerinin gemide oluşan anormal durumların ve değişimlerin tespiti için kullanılabileceğini göstermiştir (Elidolu vd., 2020).

Literatürden elde edilen bilgiler ve yapılan çalışmalar ışığında gemi elektrik şebekesinin güç tahmini modelinin oluşturulması işlemi tez kapsamında kullanılan makine öğrenmesi ve derin öğrenme algoritmalarının (Ada Boost (J. Zhu vd., 2009), Bayesian Ridge (Assaf vd., 2019), Decision Tree (Tso ve Yau, 2007), Elastic Net (W. Zhu ve Peng, 2020), XGBoost (Gu vd., 2020), Gradient Boost (Yao vd., 2022), Hist Gradient Boost (Nhat-duc ve Van-duc, 2023), Kernel Ridge (X. H. Wu vd., 2022), K Nearest Neighbors (Kaneko, 2023), Lasso (Melkumova ve Shatskikh, 2017), Multiple Linear (Caravaggi vd., 2016), Multi Layer Perceptron (Wen vd., 2019), Random Forest (Xie vd., 2021), Ridge (C. Saunders, A. Gammerman, 1998), Support Vector (D. Kim vd., 2020), Deep Neural Network (Das vd., 2020)) gibi regresyon modelleri ile yapılmıştır.

Literatürden incelenen başlıca çalışmalar ışığında gemilerde elektrik şebekesinde; şebekenin enerji ihtiyacının sürekli olarak karşılanabilmesi, şebekenin kararlılığının ve güvenilirliğinin sağlanabilmesi, şebekenin enerji veriminin artması, şebekede kullanılan jeneratörlerin yük paylaşımı optimizasyonunun sağlanabilmesi, şebekenin ani yük dalgalanmalarında, jeneratörlerin devreye girip devreden çıkma anlarında bozulmadan çalışabilmesi, şebekenin belirli bir çalışma davranışının tahmin edilmesinin belirlenmesi gerektiği gibi problemlerin var olduğu görülmüştür. Bunun yanında literatürde ele alınan çalışmalar incelendiğinde makine öğrenmesi ve derin öğrenme yöntemlerinin gemi elektrik şebekesinde bu tarz problemleri çözmekte işlevsel ve güncel bir yöntem olacağı ve de bu konuda henüz yeterli sayıda çalışma yapılmadığı görülmüştür. Bu bakımdan gemi elektrik şebekelerinde makine öğrenmesi ve derin öğrenme uygulamalarının denizcilikte bu alanda henüz gelişmekte olması nedeniyle özgün bir değer taşıdığı ortaya çıkmaktadır.

Bu tez çalışmasında literatürdeki çalışmaların ışığında aşağıdaki üç probleme makine öğrenmesi ve derin öğrenme yöntemleri yardımıyla çözümler üretilmiştir.

1. Gemide üretilen gücün bilinmesi emisyonlar açısından, verim açısından önemlidir. Bu sürecin gerçekleştirilmesi için gemi makine öğrenmesi ve derin öğrenme algoritmalarından güç tahmini işleminde faydalanılmıştır.
2. Jeneratörlerin üzerine düşen yüklerin bilinmesi gemi elektriksel verimi açısından, jeneratör çökmesi gibi durumlar açısından üzerinde durulması gereken bir konudur. Bu problemin çözümünde de algoritmaların tahmin modelleri kullanılmıştır.
3. Gemide şaft jeneratörü kullanımı sefer sırasında enerji verimliliğini artıran, diğer jeneratörlerin işletilmesinde de faydaları olan bir yöntemdir. Gemide şaft jeneratörünün sefer sırasındaki gücünün tahmin edilmesi seferdeki elektriksel yükün bilinmesi ve yeterli derecede güç üretilmesi ile verimliliğin artması ve elektriksek çökmelerin önüne geçilmesi açısından önemlidir. Bu süreçte makine öğrenmesi ve derin öğrenme algoritmalarının tahmin modellerinden yararlanılmıştır.



2. MATERYAL VE YÖNTEM


2.1 Makine Öğrenmesi ve Derin Öğrenme Yöntemleri

2.1.1 Çoklu doğrusal regresyon

Makine öğrenmesi yöntemlerin en bilinenlerinden olan çoklu doğrusal regresyon metodunda çıkış değişkeninin değerinin hesaplanması veya tahmin edilmesi sürecinde giriş değişkenlerinin (bağımsız değişken) belirli katsayılarla çarpılması ve bu çarpımların toplanması yoluyla çıkış değişkeni yada diğer bir değişke bağımlı değişken hesaplanır (Baldwin ve Larson, 2017; Vettor ve Guedes Soares, 2022). Başka bir değişle bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiden faydalanılarak bağımlı değişkenin hesaplanması prensibine dayanan bir yöntemdir. Çoklu doğrusal regresyon algoritmasında bağımlı değişkenin hesaplanabilmesi için bağımsız değişkenlerden oluşturulmuş bir fonksiyon kullanılır. Bu fonksiyon aşağıdaki denklemde ifade edilmiştir.

$$y_j = b_0 + b_1x_{j1} + \dots + b_px_{jp} = x_j^T b + \varepsilon_j \quad (2.1)$$

Bu denklemde; y_j bağımlı değişken, b_0 sabit, x_{jp} bağımsız değişken, $j = 1, 2, \dots, n$ ve ε_j ise hata katsayısıdır (Patonai vd., 2022). Çoklu doğrusal regresyon Şekil 2.1 ile ifade edilmiştir.

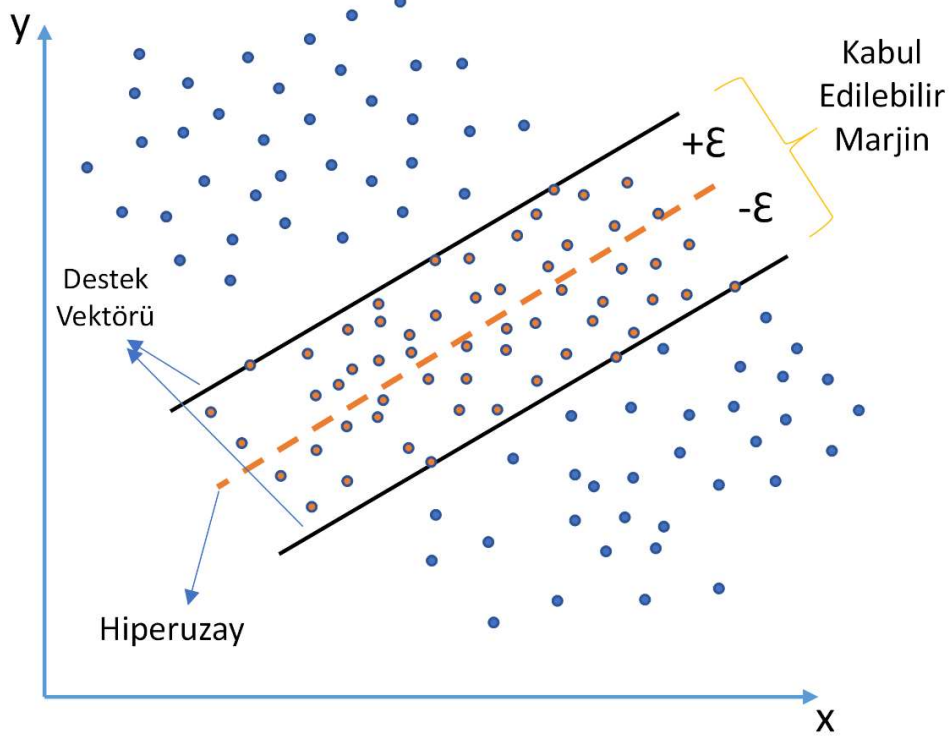


Şekil 2.1: Çoklu doğrusal regresyon.

Şekil 2.1 incelendiğinde, y bağımlı değişken, x bağımsız değişken, tahminlerin mavi noktalar, tahminler ile gerçek değerler arasındaki hata ise yeşil çizgilerle gösterilmiştir (Seal, 1967).

2.1.2 Destek vektör makinesi

Veriye dayalı tahmin algoritmalarının en bilinenlerinden olan Destek Vektör Makinesi (Support Vector Machine), literatürde regresyon ve sınıflandırma problemlerinde sıklıkla kullanılan bir yöntemdir. Bu yöntemin işleyiş sürecinde algoritmaya tanıtılan iki veya daha fazla eğitim verisi sayesinde algoritma eğitilir. Yeni bir veri geldiğinde (test verisi) bu verinin hangi gruba ait olduğunun tahmin edilmesi için algoritma bu test verisinin hangi gruba dahil olduğunu tahmin eden bir model oluşturur. Bu süreçte algoritma destek vektörlerinden faydalanır (Mell vd., 2023). Destek vektör makinesi algoritması Şekil 2.2’de gösterilmiştir.



Şekil 2.2: Destek vektör makinesi algoritması.

Şekil 2.2 incelendiğinde x ve y eksenlerinin kapsadığı bölgede iki adet destek vektörü ve bu vektörlerin ortasından geçen bir hiperuzay gösterilmiştir. Destek vektörleri kabul edilebilir bir marjin ile birbirilerine göre paralel olacak şekilde konumlandırılmıştır. Burada kabul edilebilir marjinin amacı başarılı ve başarısız tahminlerin belirlenmesini sağlamaktır. “ε” ile gösterilen uzunluklar ise hiperuzay ve destek vektörleri arasındaki mesafenin ölçüsüdür (Pagoropoulos vd., 2017). Destek Vektör Makinesi algoritması için;

$$f(x) = x^T w + w_0 \quad (2.2)$$

Denklem 2.2’de kullanılan “w” değeri aşağıdaki fonksiyon yoluyla elde edilir.

$$H(w, w_0) = \sum_{j=1}^N V(y_j - f(x_j)) + \frac{\lambda}{2} \|w\|^2 \quad (2.3)$$

Denklem 2.3’te kullanılan “V” parametresi Denklem 2.4 yoluyla elde edilir.

$$V_\epsilon(r) = \begin{cases} 0, & \text{eğer } |r| < \epsilon \\ |r| - \epsilon & \end{cases} \quad (2.4)$$

Burada λ düzenleme parametresidir. Ayrıca, denklemlerde kullanılan ε ibaresinden küçük hatalar ihmal edilebilir (Smola ve Schölkopf, 2004).

2.1.3 Ridge

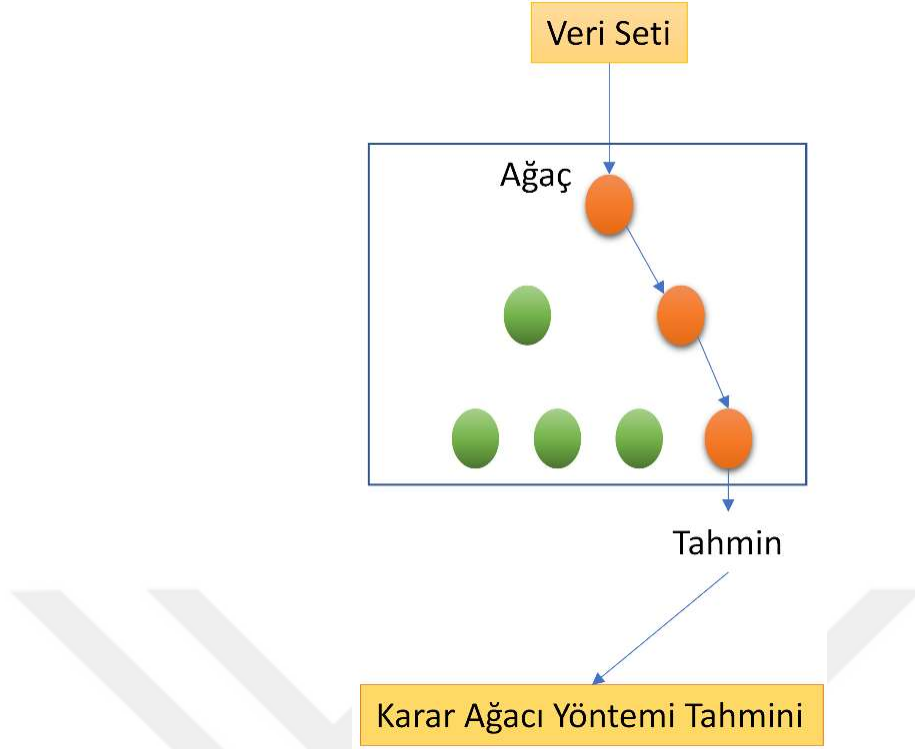
Ridge regresyon algoritması, temelde katsayı tahmininde kullanılan bir yöntem olmakla beraber, cezalandırma yöntemlerini de tahmin sürecinde kullanan bir algoritmadır. Tahmin edici sayısı ise alt küme seçimi gibi yöntemlerle düşürerek algoritma optimize edilebilmektedir. Ridge algoritması, temelde Çoklu Doğrusal Regresyon algoritmasına benzer bir yol izlemekle beraber, içinde bazı farklılıklar barındırmaktadır (Y. Zheng vd., 2023). Denklem 2.5'te algoritmanın “ w ” değerinin hesaplama süreci gösterilmiştir (X. Wang vd., 2023).

$$\hat{w}_{RR} = \underset{w}{\operatorname{argmin}}\{\sum_{j=1}^n (y_j - w_0 - \sum_{i=1}^D w_i x_{ji})^2 + \lambda \sum_{i=1}^D w_i^2\} \quad (2.5)$$

Burada, büzülmeyi kontrol eden “ λ ” hiperparametresi sıfır değerinden büyük olmalıdır (Yildirim ve Revan Özkale, 2019).

2.1.4 Karar Ağacı

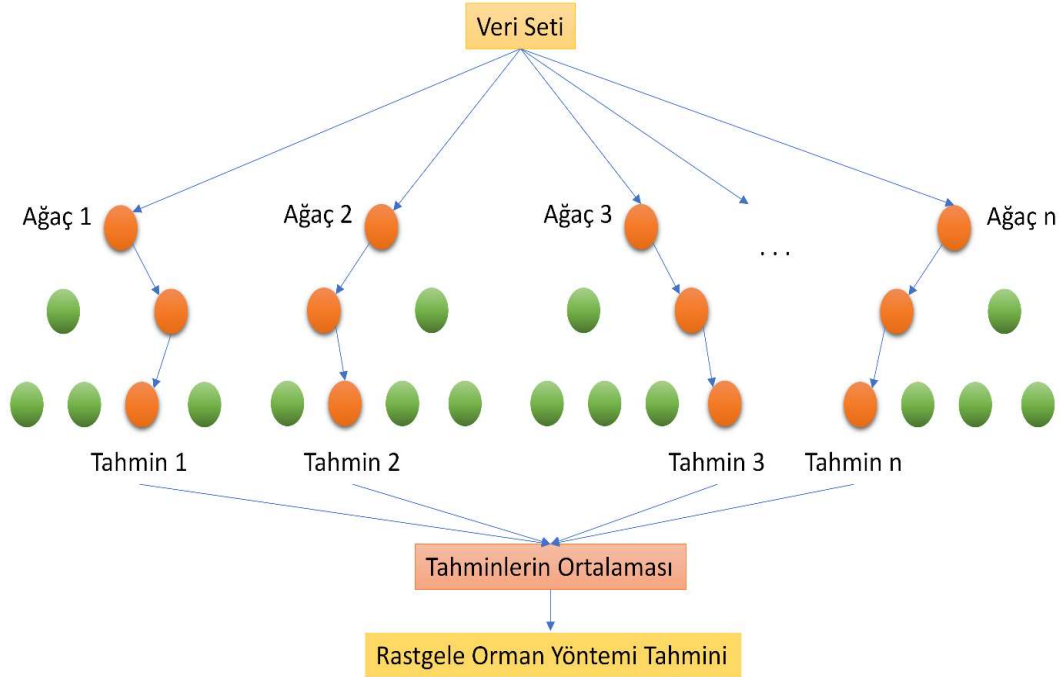
Karar Ağacı algoritması literatürde pek çok problem üzerinde denenmiş, basit ve etkili bir algoritmadır. Bu algoritmaya karar ağacı denmesinin nedeni özellik veya probleme göre değişen sayıda düğümlerden ve bağlantılardan oluşan bir yapıda olması nedeniyle bir ağacı andırmasıdır. Bu algoritmanın başka bir önemli noktası ise insan beyninin düşünme, problemleri algılama ve çözme sürecindeki yapısına benzemesidir (Dehghani vd., 2023). Karar Ağacı yönteminin bu özelliği sayesinde algoritmanın makine öğrenmesi yöntemi olmasının yanında pek çok karar alma probleminde de kullanılmasını sağlamıştır (Singh Kushwah vd., 2022). Karar Ağacı algoritmasının çalışma süreci Şekil 2.3'te ifade edilmiştir.



Şekil 2.3: Karar ağacı algoritmasının yapısı (Y. Liu vd., 2022).

2.1.5 Rastgele Orman

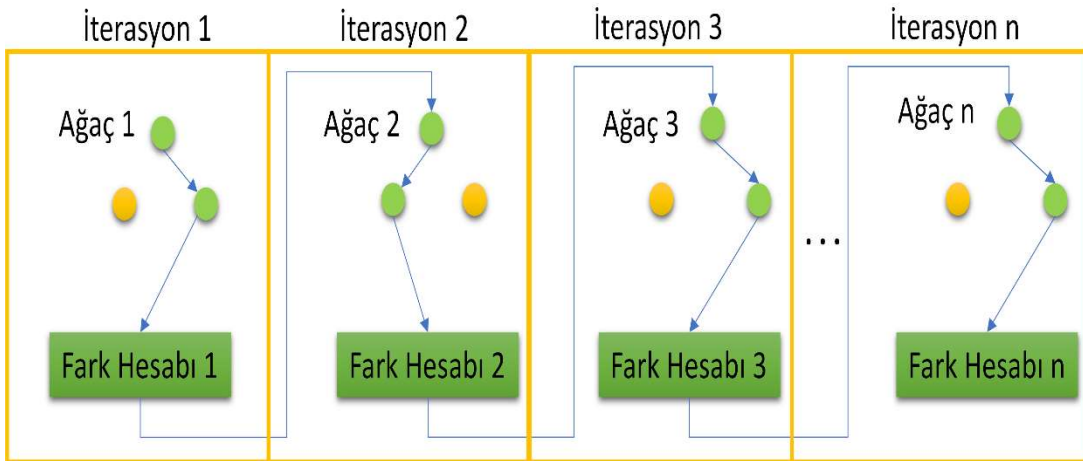
Rastgele Orman yöntemi, literatürde sınıflandırma ve regresyon çalışmalarında sıklıkla faydalanan, klasikleşmiş bir makine öğrenmesi algoritmasıdır. Bu algortmada regresyon problemlerinde hesaplanan veya tahmin edilen çıkış değeri, tüm ağaçların ürettiği sonuçların ortalamalarından elde edilir. Rastgele Orman algoritması, karar ağacının gelişmiş bir yapısı olması sayesinde literatürde "overfitting" ismi ile tabir edilen ezberleme problemi için de ortalama sonuç elde edilmesiyle çözüm üretebilmektedir (Gupta vd., 2022; Xie vd., 2021). Rastgele Orman algoritması, çok fazla çeşitte hiperparametre içermediğinden kullanımını basit bir algoritma olmakla beraber, geniş veri setleri üzerinde de başarılı sonuçlar elde edebilmesi sayesinde sıklıkla kullanılan bir algoritma durumuna gelmiştir. Algoritmanın yapısı Şekil 2.4'te gösterilmiştir.



Şekil 2.4: Rastgele orman algoritması yapısı (Giri vd., 2023).

2.1.6 Gradyan Arttırma Algoritması

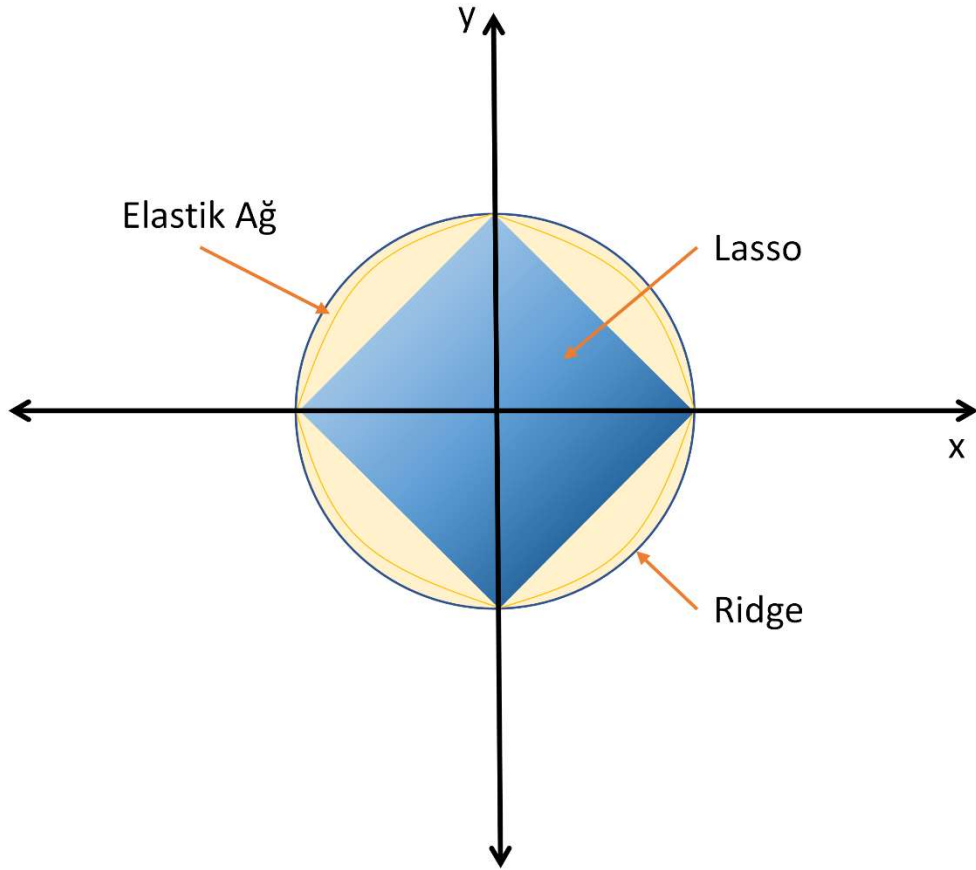
Friedman tarafından literatüre kazandırılan Gradyan Arttırma algoritması, regresyon ve sınıflandırma problemlerinde kullanılan güçlü bir makine öğrenmesi yöntemidir. Algoritma yapısı genellikle ağaç tabanlı algoritmalara yakındır. Gradyan Arttırma algoritması temel olarak algoritma içindeki zayıf öğrenicileri yaptığı iterasyonlar sayesinde bir adet güçlü öğrenicide bir araya getirir. Bu işlem sürecinde de bir önceki iterasyondaki hata değeri ile güncel hata değeri karşılaştırılarak yeni iterasyona geçilir (Friedman, 2001) (Şekil 2.5).



Şekil 2.5: Gradyan arttırma algoritmasının gösterimi.

2.1.7 Elastik Ağ

Elastik Ağ algoritması, literatürde yoğun olarak kullanılan yenilikçi metotlardan olmasının yanında, Lasso ve Ridge yöntemlerinin bazı özelliklerini bünyesinde birleştirmesi nedeniyle de ilgi çekici bir yöntemdir (Srinivasan ve Deepalakshmi, 2023). İki yöntemin özelliklerini bünyesinde barındırmasının nedeni Lasso yöntemindeki sınırlamaların (cezaların) üstesinden gelmenin hibrit yapıda bir algoritmayla üstesinden gelmenin daha kolay olmasıdır (Zou ve Hastie, 2005). Lasso regresyonun bir başka handikabı veri setinden örneklem seçerken hızlı bir şekilde örnekleme sayısını tamamlama eğiliminde olması ve büyük boyutlu verilerde özellikle belli bölgelerden yeterli ve homojen bir şekilde veri alınamamasıdır. Algoritma bu handikabın da üstesinden gelebilmek için bu noktada Ridge yönteminin özelliklerinden faydalanır (Z. Liu vd., 2022). Algoritmanın düzlemsel olarak iki farklı yöntemin arasında kaldığı Şekil 2.6’da tasvir edilmiştir.

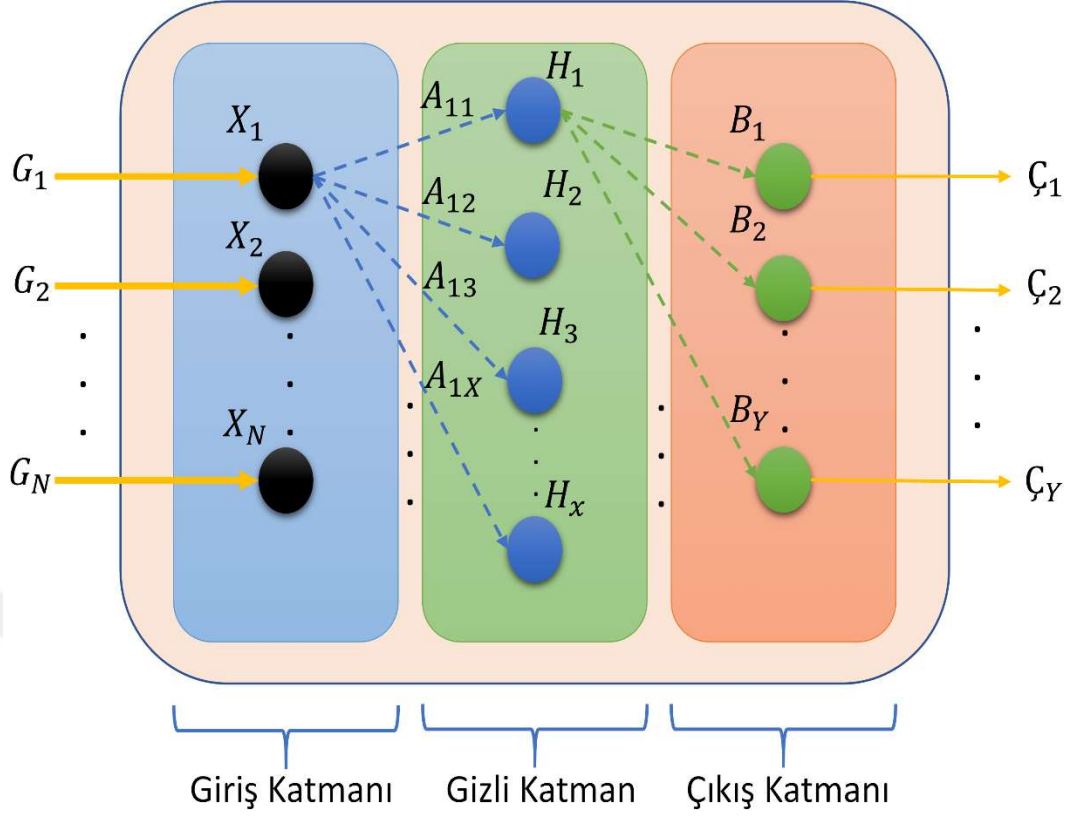


Şekil 2.6. Elastik ağ algoritmasının iki yöntem arasındaki görüntüsü.

2.1.8 Yapay Sinir Ağı

Yapay sinir ağı yöntemi, insan beyninin biyolojik yapısının taklit edilmesi sayesinde keşfedilen bir algoritmadır (Sathe vd., 2023). Bu algoritma insan beyninin basitleştirilmiş bir modelini temel alarak beyindeki nöronlar ve iletim yapılarının basitleştirilmiş versiyonlarını sinyallerin alınmasında, dönüştürülmesinde, ağırlıklandırılmasında, işlenmesinde ve iletilmesinde kullanır (Ahmadabadi vd., 2023). Bir nöron, kendisine gelen sinyal ancak belirli bir değeri aştıktan sonra bir sonraki katmana iletimin sağlanması için izin verir (Sinha vd., 2023).

Yapay sinir ağlarında nöron adı verilen yapılar sistemsal olarak katmanlar halinde bulunur denilebilir (Hirsch vd., 2023). İletim işlemleri için ise sinaps ismi verilen iletim yolları kullanılır (Ogunbo vd., 2020). Tipik bir sinir ağı giriş katmanı, gizli katman ve çıkış katmanı olarak üç kısma ayrılır denilebilir. Giriş katmanında bulunan nöronlar gelen veriyi alıp sinir ağının üzerinde çalışabileceği hale getirilmesini sağlar (Khanmohammadi vd., 2016). Veri işlendikten sonra ikinci katman olan gizli katmana iletilir. Gizli katman, veri üzerinde işlemlerin gerçekleştirildiği ana kısımdır denilebilir ve burada genelde ağırlıklar da bulunur (Rajasekaran vd., 2002). Veriler üzerinde işlemler gerçekleştirildikten sonra üçüncü katmana, bir diğer deyişle çıkış katmanına iletilir. Çıkış katmanı, verinin anlaşılabilir hale getirildiği ve dış çevreye iletiildiği katman olarak yapay sinir ağı yapısında önemli bir katmandır (Ghenai vd., 2022). Tüm bu işlemler sonucunda giriş katmanına gelen eğitim verileri ile eğitilen sinir ağı hedeflenen test verisini tahmin eder veya problem türüne göre sınıflandırma işlemi yapar (Choi vd., 2008). Yapay sinir ağının basitleştirilmiş bir yapısı Şekil 2.7'de gösterilmiştir.



Şekil 2.7: Yapay sinir ağı yapısı (Yuan vd., 2023).

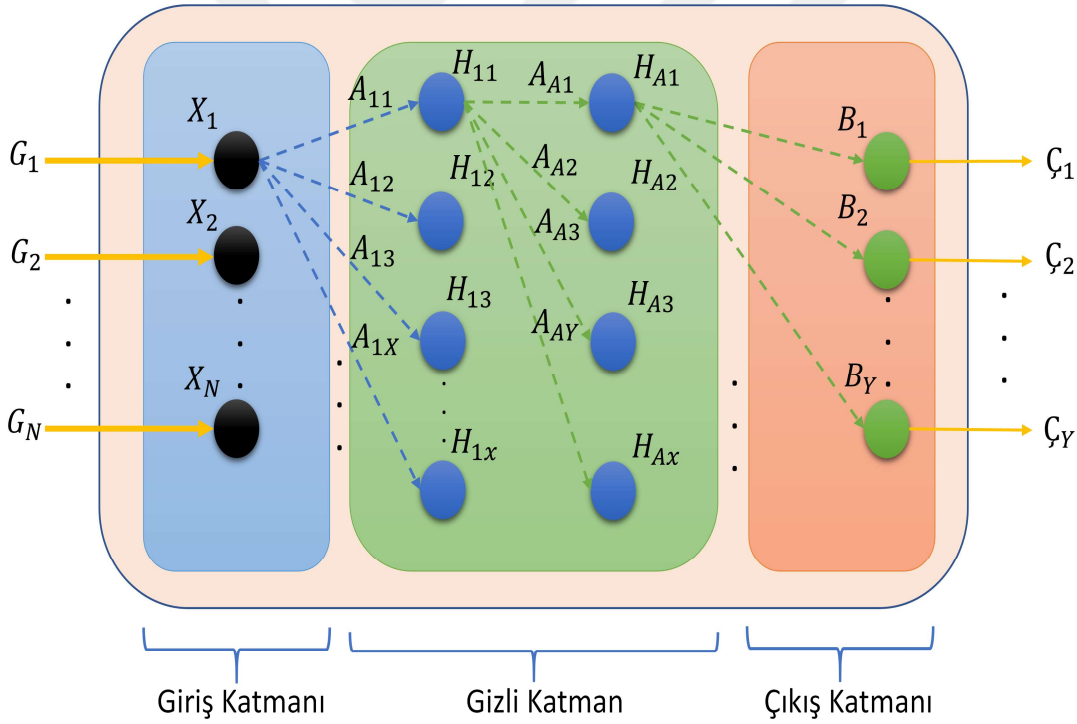
Şekil 2.7 incelenecek olursa, G ile temsil edilen kısım giriş verileridir. X harfi ile gösterilen kısım ise giriş katmanındaki nöronlardır. A harfi ile temsil edilen bölüm ise ağırlıklardır. Bu kısımda her bir ilişkinin belirli bir ağırlığı olduğundan iki adet indis ile gösterilmiştir. H değişkeni ile gösterilen kısım ise gizli katmanın nöronlarıdır. Şekilde B harfi ile gösterilen kısım ise çıkış katmanı nöronlarını ifade etmektedir. Son olarak Ç harfi ile gösterilen kısım ise çıkış verisi olarak isimlendirilebilir (Nakai ve Nishimoto, 2023).

2.1.9 Derin Sinir Ağı

Derin sinir ağı, yapay sinir ağı yönteminin geliştirilmiş versiyonu olarak tanımlanabilir. Derin sinir ağı algoritması, klasik yapay sinir ağının gizli katmanının çeşitli şekillerde geliştirilmesi ile elde edilmektedir (Howlader vd., 2023). Bir yapay sinir ağının derin sinir ağına dönüşmesi için öncelikli olarak gizli katman sayısının artırılması gerekmektedir (X. Cheng vd., 2023).

Derin sinir ağları, gelişmiş yapısı gereği yapay sinir ağları ile karşılaştırıldığında çok daha karmaşık problemlerin çözümünde etkin rol oynayabilmektedir (Thanki, 2023).

Derin sinir ađında da öncelikle yapay sinir ađında olduđu gibi bir eđitim süreci vardır (Yan vd., 2023). Eđitim süreci yardımıyla eđitilmiş olan ađ yeni gelen veriyi (test verisi) hesaplayabilir ya da bir diđer deyişle tahmin edebilir (Quondam-Antonio vd., 2023). Derin sinir ađının birden fazla sayıda katmanı olduđundan algoritma derin sinir ađı olarak isimlendirilmektedir (Luíza da Costa vd., 2021). Derin sinir ađları doğrusal olmayan problemler için çok verimli bir algoritmadır (J.-H. Kim vd., 2023). Derin sinir ađı veri setindeki deđişkenler arasında ilişkiler kurarak çıkış deđişkenini tahmin etmektedir. Katmanlar bu noktada algoritmaya çıkış deđişkeninin hesaplanmasında oldukça faydalı olmaktadır (X. Liu vd., 2022). Derin sinir ađı, genellikle ileri yönlü bir ađ mimarisine sahiptir (Magalhães vd., 2023). Sürecin başlangıcında farklı bir yaklaşım olmadığında algoritma ađırlıkları rastgele atar. Ađ eđitildikçe ađırlıklar belirli deđerlere yakınsar ve o deđerler ađırlıkların nihai deđerlerini oluşturur (Lundby vd., 2023). Derin sinir ađı yapısı Şekil 2.8’de şematize edilmiştir.



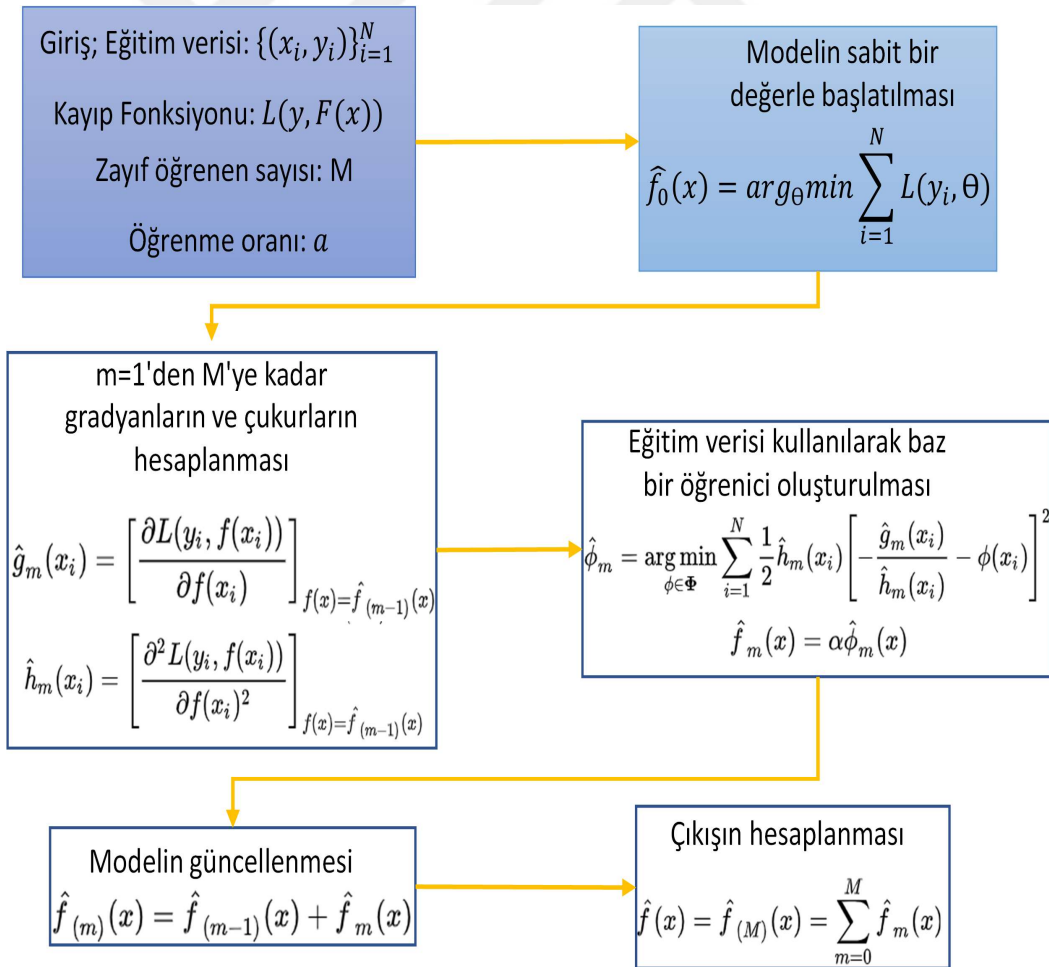
Şekil 2.8: Tipik bir derin sinir ađı yapısı (El vd., 2023).

Şekilde görüldüğü üzere ađın yapay sinir ađından bariz bir farkı vardır. Bu da yeşil renkli bölmede gösterilen gizli katman sayısının artmış olmasıdır. Gizli katman sayısının artması sayesinde algoritma farklı deđişkenler arasındaki ilişkileri daha iyi hesaplayarak çıkış deđişkeninin tahmininde daha verimli sonuçlar üretebilmektedir. Bunun bir avantajı da çözülmesi zor problemlerde ve doğrusal olmayan yapılarda

ortaya çıkmaktadır. Yapay sinir ağı ise yapısal olarak daha basit kaldığı için bu tür karmaşık problemlerde yeterince iyi sonuçlar üretememektedir.

2.1.10 Ekstrem Gradyan Arttırma yöntemi

İlk olarak bir araştırma projesi şeklinde tanıtılan Ekstrem Gradyan Arttırma Algoritması bir makine öğrenmesi yarışmasında kazanan çözümü içermesi sayesinde tanınırlığı artmıştır. Ekstrem Gradyan Arttırma yöntemi karar ağacının basit formlarından daha iyi performans elde edebilen bir algoritma olsa da karar ağaçlarında yer alan yorumlanabilirlik (Mumcu vd., 2022) bu algorithmada daha azdır. Ancak çoklu yapıda b nedenselliği tespit etmek çok zordur. Bu noktada Ekstrem Gradyan Arttırma algoritmasının avantajı ortaya çıkmaktadır (R. Wang vd., 2022). XGBoost, çözüm yöntemi olarak Taylor metodunu önceleyen bir Newton-Raphson metoduyla hesaplamaları gerçekleştirir (Dong vd., 2022). Algoritmanın işleyişi Şekil 2.9'da gösterilmiştir.



Şekil 2.9: Ekstrem gradyan arttırma yönteminin akış şeması (Dong vd., 2022).

2.1.11 Bayesian Ridge yöntemi

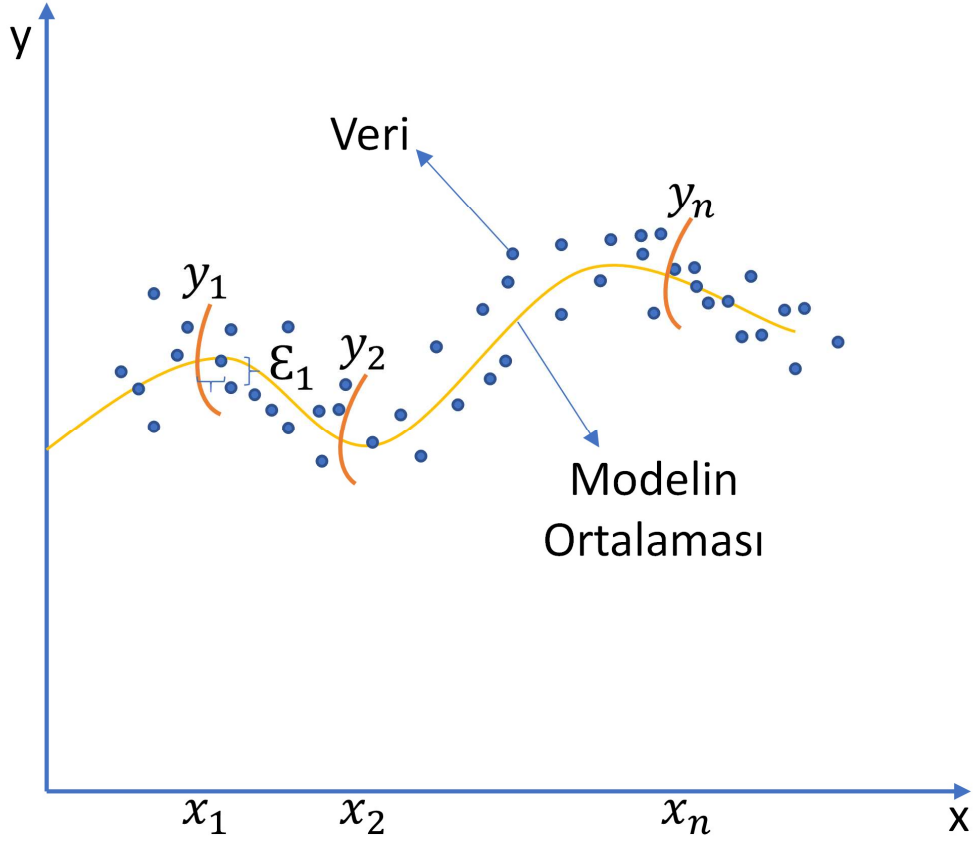
Temelde istatistikteki Bayes yaklaşımına benzeyen Bayes Algoritmasında olasılıksal bir tahmin mekanizması kullanılır. Bayes yönteminde kullanılan temel prensip giriş değişkeninin Gauss dağılımı oluşturduğu durumlarda geçerlidir. Aksi durumlarda tahmin işlemi sürecinde aksamalar gerçekleşir ve algoritma yeterince başarılı tahminler yapamayabilir. Bu durumda yine hibrit bir yaklaşımdan faydalanılabilir (Assaf vd., 2019). Genelde çoklu doğrusal regresyonun denklemi ile aynı yapıda olan giriş denklemi ile buna eşlik eden hata değişkeninin denklemi olmak üzere iki ayrı denklemle ifade edilir. Ridge yöntemi ile Bayes yönteminin hibrit bir kullanımı için parametreler aşağıdaki denklemdeki gibi hesaplanabilir (Trucco vd., 2008).

$$y = X\beta + u, u \sim N_n(0, \sigma^2 I_n) \quad (2.6)$$

Burada, bilinmeyen parametrelerin hesabı için ise;

$$\beta | \sigma \sim N_p\left(0, \frac{\sigma^2}{k} I_p\right), p(\sigma) \propto \sigma^{-1} \quad (2.7)$$

denklemden faydalanılır. Bu denklemde $k > 0$ koşuluna göre, σ^2 hata değişkeni önceden belirlenir (Assaf vd., 2019). Gauss dağılımlı bir Bayes veri kümesi örneği Şekil 2.10'da gösterilmiştir.



Şekil 2.10: Gauss dağılımlı bir Bayes veri kümesi örneği.

Şekil 2.10'da y değerleri modelin çıkış değerleri, x değerleri ise giriş değerleridir. ϵ değerleri ise hata değerleridir.

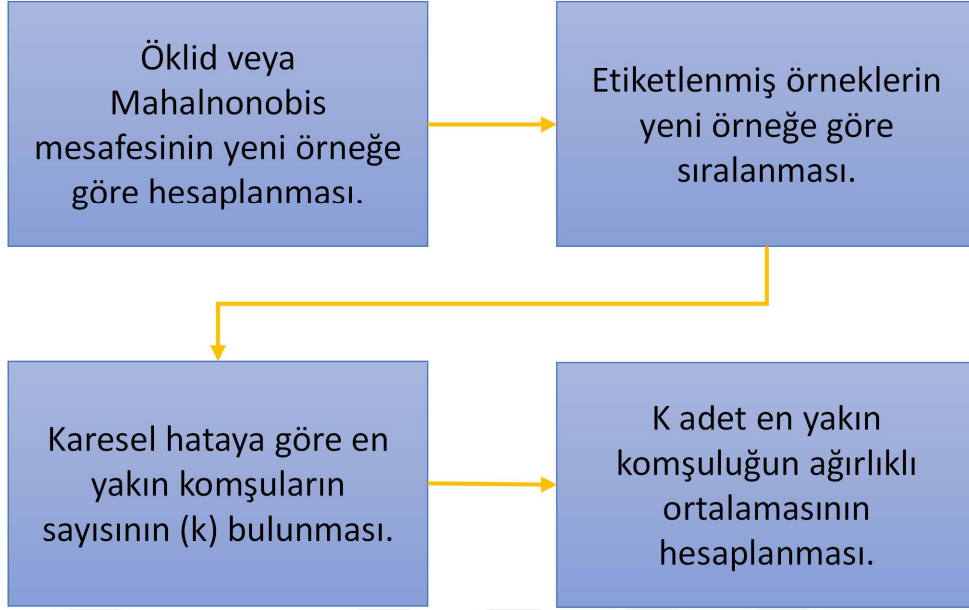
2.1.12 Kernel Ridge yöntemi

Kernel bazlı yöntemler, makine öğrenmesi terminolojisinde model analizi yapılabilmesine olanak sağlaması için geliştirilen yöntemlerdir. Algoritmaların problemlerde yer alan görevleri yapabilmek için veri setini özellik vektörüne dönüştürmesi gerekir. Kernel tabanlı yöntemler ise sadece kullanıcı tarafından belirlenen bir prensiple bu görevleri hızlıca yapabilir. Bu özelliğinin yanında Kernel tabanlı yöntemler büyük veri setlerinin işlenmesi için yavaş kalmaktadır, çünkü paralel işleme yetisi zayıftır (Sanjika Devi vd., 2022). Bunun yanında Kernel bazlı yöntemler verinin koordinatının hesaplanması yerine örüntüler arasındaki iç çarpımlar yardımıyla basit bir şekilde hesaplamaları gerçekleştirir. Bu metot hesaplama olarak daha hızlı ve verimlidir. Bu yaklaşıma "Kernel Trick" metodu denilmektedir. Temelde Destek Vektör Makinesi ile çok benzer olan bu algoritma, kayıp fonksiyonu olarak

kare hata yöntemlerinden faydalanırken Destek Vektör Makinesi ise düzenleme parametrelerine ihtiyaç duyar (Chen vd., 2022). Destek Vektör Makinesi'nden farklı olarak Kernel Ridge metodu çok büyük boyutlu olmayan veri setleri ile ilgili problemlerde hızlı ve verimli bir algoritmadır (Deo vd., 2023).

2.1.13 K-En Yakın Komşuluk yöntemi

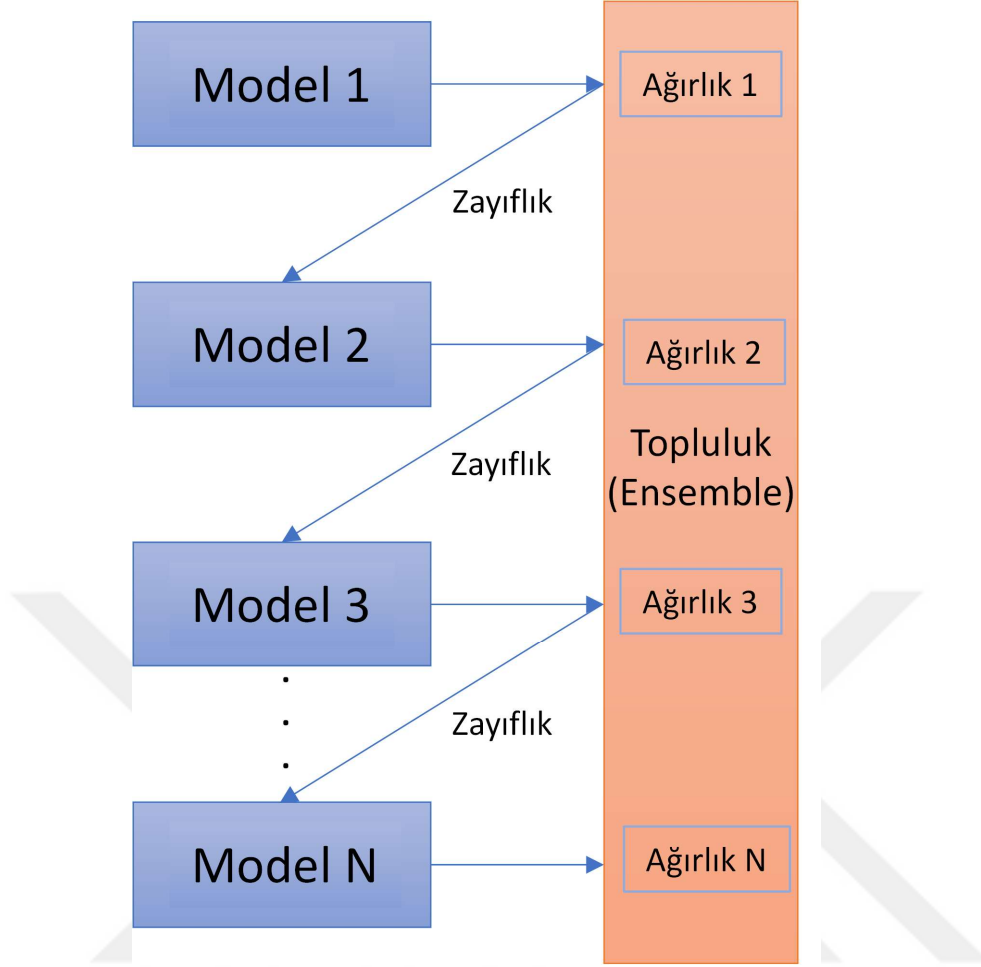
Parametrik olmayan makine öğrenmesi algoritmalarından olan K-En Yakın Komşuluk metodu denetimli bir algoritma olup sınıflandırma ve regresyon problemleri için literatürde sıklıkla kullanılmaktadır. Bu iki problem türünde giriş değişkeni veri setindeki k adet en yakın komşu olan eğitim veri örneğinden oluşur (Nethra Betgeri vd., 2023). Sınıflandırma problemlerinde çıkış değişkeni bir sınıf aidiyeti olarak değerlendirilir. Bir örnek k adet en yakın komşusu içinden en yakın olduğu sınıfa ait olarak nitelendirilir. Burada k sıfırdan büyük bir sayıdır ve probleme göre değişkenlik göstermektedir. Regresyon problemlerinde ise hesaplanan değer çıkışın sayısal değeridir. $K=1$ değeri baz alındığında çıkış değeri en yakın komşusunun değerine eşit olur (Y. Wang vd., 2023). Burada da k değeri probleme göre değişkenlik göstermektedir. K En Yakın Komşuluk algoritması için giriş değişkenleri üzerinden bir sınıflandırma yapılırken giriş değişkenlerinin hangi birimden olduğu incelenip birimler normalleştirilmelidir. Normalleştirme işlemi sonucunda modelin verimliliği ve başarı oranı büyük oranda artabilir. Sınıflandırma ve regresyon problemlerinde daha mantıklı bir yaklaşım komşuların yeni değere (tahmin edilmesi veya sınıflandırılması istenen değer) olan uzaklıklarına göre bir ağırlık olarak hesaplamaya katkı vermesidir (Li vd., 2022). Regresyon problemlerinde sürekli değişkenlerin hesaplanması sürecinde kullanılan bu algoritma k adet en yakın komşunun ağırlıklandırılmış bir ortalaması ile çıkış değişkenini hesaplar. Algoritmanın çalışması Şekil 2.11'de anlatılmıştır.



Şekil 2.11: K-en yakın komşuluk yönteminin akış şeması (Gao vd., 2009).

2.1.14 Ada Arttırma yöntemi

Uyarlanabilir Arttırma yönteminin kısaltması olarak kullanılan Ada Arttırma (Ada Boost) yöntemi il kez matematiksel olarak 1995'te formülize edilmiştir. Bu algoritmanın önemli bir avantajı birçok algoritma ile hibrit bir şekilde kullanılabilmesidir (Jain ve Jana, 2023). Zayıf öğrenen çıktılar diğer çıktılarla birlikte ağırlıklı ortalamayla hesaplanır. Burada tüm öğrencilerin bir şekilde ağırlıklı ortalamasının hesaplanması sayesinde algoritma güçlü bir öğrenciye doğru yaklaşır ve böylece aşırı öğrenme (overfitting) problemine karşı daha gürbüz bir algoritmadır (Jadhav, 2021). Algoritmanın bu şekildeki işleyişi sayesinde zayıf öğrencilerin elde ettiği tahmin sonuçlarını ağırlıklı olarak birleştirmenin yanında güçlü öğrenciler sayesinde başarılı bir algoritma elde edilmiştir. Ada Boost algoritması sınıflandırma problemleri özelinde en başarılı algoritmalarından biridir. Bunun nedeni parametrelerin ayarlanmasının daha kolay olmasıdır. Algoritmanın işleyiş şeması Şekil 2.12'de gösterilmiştir.



Şekil 2.12: Ada arttırma algoritması işleyiş şeması (Jadhav, 2021).

2.1.15 Hist Gradyan Arttırma yöntemi

Hist (Histogram) Gradyan Arttırma algoritması prensip olarak Gradyan Arttırma metoduyla aynı yapıda olsa da büyük çaptaki veri kümelerine uygulanmasında Gradyan Arttırma algoritmasının bir handikapı olan yavaş olmasının bu algortmada giderilmiş olması bu yöntemi daha verimli hale getirmektedir (Nhat-Duc ve Van-Duc, 2023). Bu algortmanın Gradyan Arttırma yönteminden farkı giriş değişkenlerini farklı ağaçlara hızlıca ayırması ve bu sayede algortmanın önemli derecede hızlandırılmış olmasıdır (Aksoy ve Genc, 2023). Bu yöntem Histogram Tabanlı Gradyan Arttırma Algoritması denmektedir. Arttırma (Boosting) tabanlı yöntemler, algortmaya ağaç modeli ekleyerek algortmanın çalışması sırasında elde edilen hata oranını azaltma işleviyle modellerin eğitim safhasında modeli basitleştirip hızlandıran bir yöntem olarak işlevselliği ile öne çıkmaktadır (Sobolewski vd., 2023). Gradyan Arttırma Algoritması genelde güçlü bir yöntem olsa da veri setinin boyutu arttıkça modeller

yavaşlamaktadır. Bu da istenmeyen bir durumdur. Bu durumla başa çıkabilmek için histogram metoduyla algoritmaya ağaç bazlı modeller eklenerek algoritmanın hem ürettiği hata oranı azaltılmakta hem de algoritmanın hızı arttırılmaktadır (M. Zheng vd., 2022).

2.2 Hata Ölçüm Metrikleri

2.2.1 Kök ortalama karesel hata (RMSE)

Kök Ortalama Karesel Hata, bir algoritma tarafından veya bir tahmin edici tarafından elde edilen değerlerin gerçek değerler ya da başka bir deyişle test verileri ile arasındaki farkı gösteren bir hata metriğidir (Karunasingha, 2022). Bu yöntem farklı test verileri ve elde edilen tahmin değerleri arasındaki farkı tek bir sayı şeklinde ölçmek için kullanılır. Bu metrikte sıfır değerinin ortaya çıkması çok çok zor bir ihtimaldir (Çalasan vd., 2020). Böyle bir durum olması durumunda "overfitting" terimi ile ifade edilen ezberleme veya aşırı öğrenme durumu ortaya çıkacaktır bu da modelde bir problem olduğu veya test verilerinin bazılarının eğitim verilerine karıştığı söylenebilir. Burada hesaplama yapılırken her bir sonuç için hatanın karelerinin ortalamasının karekökü alınarak sonuca ulaşılmış olur. Bu nedenle bu hata metriğinde yüksek miktardaki hataların genel hata skorunu büyük oranda değiştirebileceği göz önünde bulundurulmalıdır. Kök Ortalama Karesel Hata'nın hesaplanması Denklem 2.8'de gösterilmiştir.

$$KOKH = \sqrt{\frac{\sum_{i=1}^N (x_t - x_g)^2}{N}} \quad (2.8)$$

Bu denklemde N; terim sayısını gösterirken, x_t tahmin edilen değeri, x_g ise gerçek değeri ya da test verisini ifade etmektedir.

2.2.2 Ortalama mutlak hata (MAE)

Ortalama Mutlak Hata, gerçek değerler ile tahmin edilen değerler arasındaki farkın sayısallaştırılmış bir ölçüsü olarak ifade edilmektedir (Wun ve Pearn, 1991). Bu hata metriği hesaplanırken tahmin edilen değerler ile gerçek değerler arasındaki farkın mutlak değeri alınır, bütün örnekler için bu değerler toplanır ve örnek sayısına bölünür (Loce ve Dougherty, 1995). Hesaplama sonucunda Ortalama Mutlak Hata bulunmuş olur. Zaman serisi ile ilgili problemlerde sıklıkla kullanılan Ortalama Mutlak Hata

hesaplanırken aynı ölçüğe bağlı olan değişkenler ile işlem yapılmalıdır. Aksi halde Ortalama Mutlak Hata doğru değerler üretmemektedir (Frías-Paredes vd., 2018). Bu hata metriği türünde yer alan bir handicap ise pozitif hataların ve negatif hataların ayırt edilememesidir. Başka bir deyişle pozitif hata da negatif hata da genel hataya pozitif yönde etki edecektir. Bu da bazı problemlerde istenmeyen bir durum olabilir. Ortalama Mutlak Hata denklem 2.9'da ifade edilmiştir.

$$OMH = \frac{\sum_{i=1}^N |G_i - T_i|}{N} \quad (2.9)$$

Bu denklemde N terim sayısı, G_i gerçek değer ya da test verisi, T_i tahmin edilen değer veya hesaplanan değerdir (Joseph vd., 2022).

2.2.3 Ortalama mutlak yüzde hata (MAPE)

Ortalama Mutlak Yüzde Hata, veri setindeki gerçek değer, bir başka deyişle test verisi ile tahmin edilen değer arasındaki farkın yüzdelik olarak ifade edilmesidir (de Myttenaere vd., 2016). Hatanın ifade edilme ve hesaplanma yöntemi dolayısıyla regresyon problemlerinde hata metriği olarak sıklıkla kullanılmaktadır (McKenzie, 2011). Ortalama Mutlak Yüzde Hata hesaplanması itibariyle verimli ve basit bir yöntem olarak göze çarpmaktadır ancak birtakım handikaplar barındırmaktadır. Eğer hata sifıra çok yakın ise veya seçilen örnek sifıra çok yakın ise burada hesaplama problemleri ortaya çıkabilir (S. Kim ve Kim, 2016). Problemdaki veri setinde yer alan değerler düşük olduğunda çok büyük bir problem oluşmaz ancak yüksek değerli örnekler için hata değeri çok yüksek çıkabilir. Bu da bazen yanıltıcı olabilmektedir. Ortalama Mutlak Yüzde Hata'nın hesaplanması Denklem 2.10'da gösterilmiştir.

$$OMYH = \frac{100}{N} \sum_{i=1}^N \left| \frac{G_i - T_i}{G_i} \right| \quad (2.10)$$

Bu denklemde N terim sayısını ifade ederken, G_i gerçek değerleri, T_i ise tahmin edilen değerleri ifade eder (Babarinde ve Madyira, 2022).

2.2.4 Belirleme katsayısı (R^2)

İstatistikte Belirleme Katsayısı olarak tanımlanan R^2 , gerçek değerlerle tahmin edilen değerlerin arasındaki varyasyonun oranının genellenmiş hesabıdır. Bu yöntem, yapılan tahminlerin gerçek değerlere olan uzaklığı yanı sıra modelin ne kadar başarılı olduğunu da varyasyonlar sayesinde açıklayabilmektedir (C. L. Cheng vd., 2014).

Belirleme Katsayısı, korelasyon katsayısının karesi olarak ifade edilebilir. Hesaplama sonrasında ortaya çıkan sonuç sıfır ile bir değerleri arasında bir sayıdır. Belirleme katsayısı eğer negatif çıkarsa bu durumda model ile hesaplama yapılan değerler arasında bir ilişkisizlik bulunmaktadır. Bu sayı sıfıra ne kadar yakın olursa model o kadar başarısız, sayı bir değerine ne kadar yaklaşırsa model o kadar başarılı demektir. Belirleme Katsayısı, regresyon bazlı problemler için diğer hata metriklerinden daha açıklayıcı ve verimli bir yöntemdir. Yüzde hata yöntemlerinden hatayı belirlemede daha üstün olduğu ve test örneğinin değerinin yüksek olduğu zaman ortaya çıkan olumsuz duruma karşı çok daha gülbüz olduğu bir gerçektir. Yine karesel hata kullanan metriklerde ortaya çıkan yüksek hataların genel hata metriğini etkileme durumu da bu hata metriğinde çok daha azdır. Son olarak mutlak hata kullanan hata metriklerinde olan yöntemin negatif ve pozitif kısımda kalan hatalarda ortaya çıkan olumsuz durumlara karşı da güçlü bir yöntemdir. Belirleme Katsayısı Denklem 2.11’de ifade edilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (2.11)$$

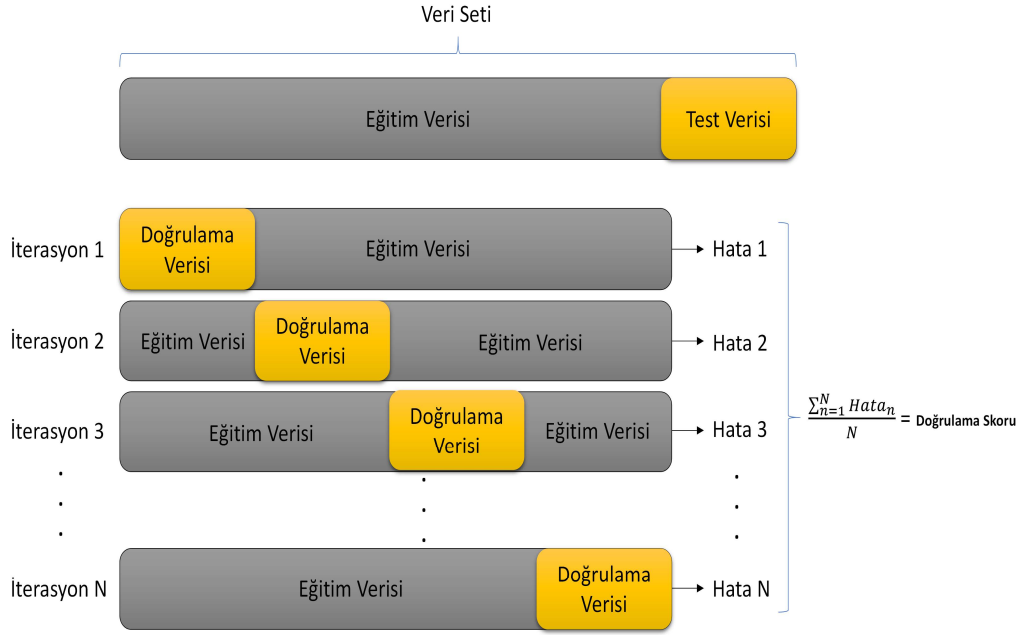
Bu denklemde N terim sayısı olmak üzere, y_i gerçek değerler, \hat{y} tahmin edilen ya da hesaplanan değerler, \bar{y} ise gerçek değerlerin ortalaması olarak ifade edilebilir. Bir başka ifadeyle Belirleme Katsayısı açıklanabilen varyasyonun toplam varyasyona oranıdır denilebilir.(C. L. Cheng vd., 2014)

2.3 Doğrulama Yöntemi

2.3.1 K-Katlamalı çapraz doğrulama

Veriye dayalı yöntemlerde modellerin başarısının birbiriyle karşılaştırılması son aşamada önem teşkil etmektedir. K-Katlamalı Çapraz Doğrulama (K-Fold Cross Validation) yöntemi modellerin doğruluğunun test edilmesi ve doğrulanması için son derece faydalı bir yöntemdir. Bunun yanında modellerde bir ezberleme durumu olup olmadığının anlaşılması da doğrulama yöntemlerinin yardımı ile tespit edilmektedir. Bu yöntemde veri seti öncelikle katlama sayısı kadar bölümlere ayrılır. Bu bölümlerin belli bir kısmı test ve belli bir kısmı eğitim verisi olarak kullanılır. Veri setindeki bütün bu bölümler eğitim ve test serisi olarak kullanıldıktan ve simülasyonlar sonuçlandıktan

sonra elde edilen deęerlerin ortalaması doęrulama skorunu verecektir. K-Katlamalı apraz Doęrulama Yöntemi Şekil 2.13’te ifade edilmiştir.



Şekil 2.13: K-katlamalı apraz doęrulama işlemleri (Saud vd., 2020).

3. VAKA ÇALIŞMALARI VE SONUÇLARI

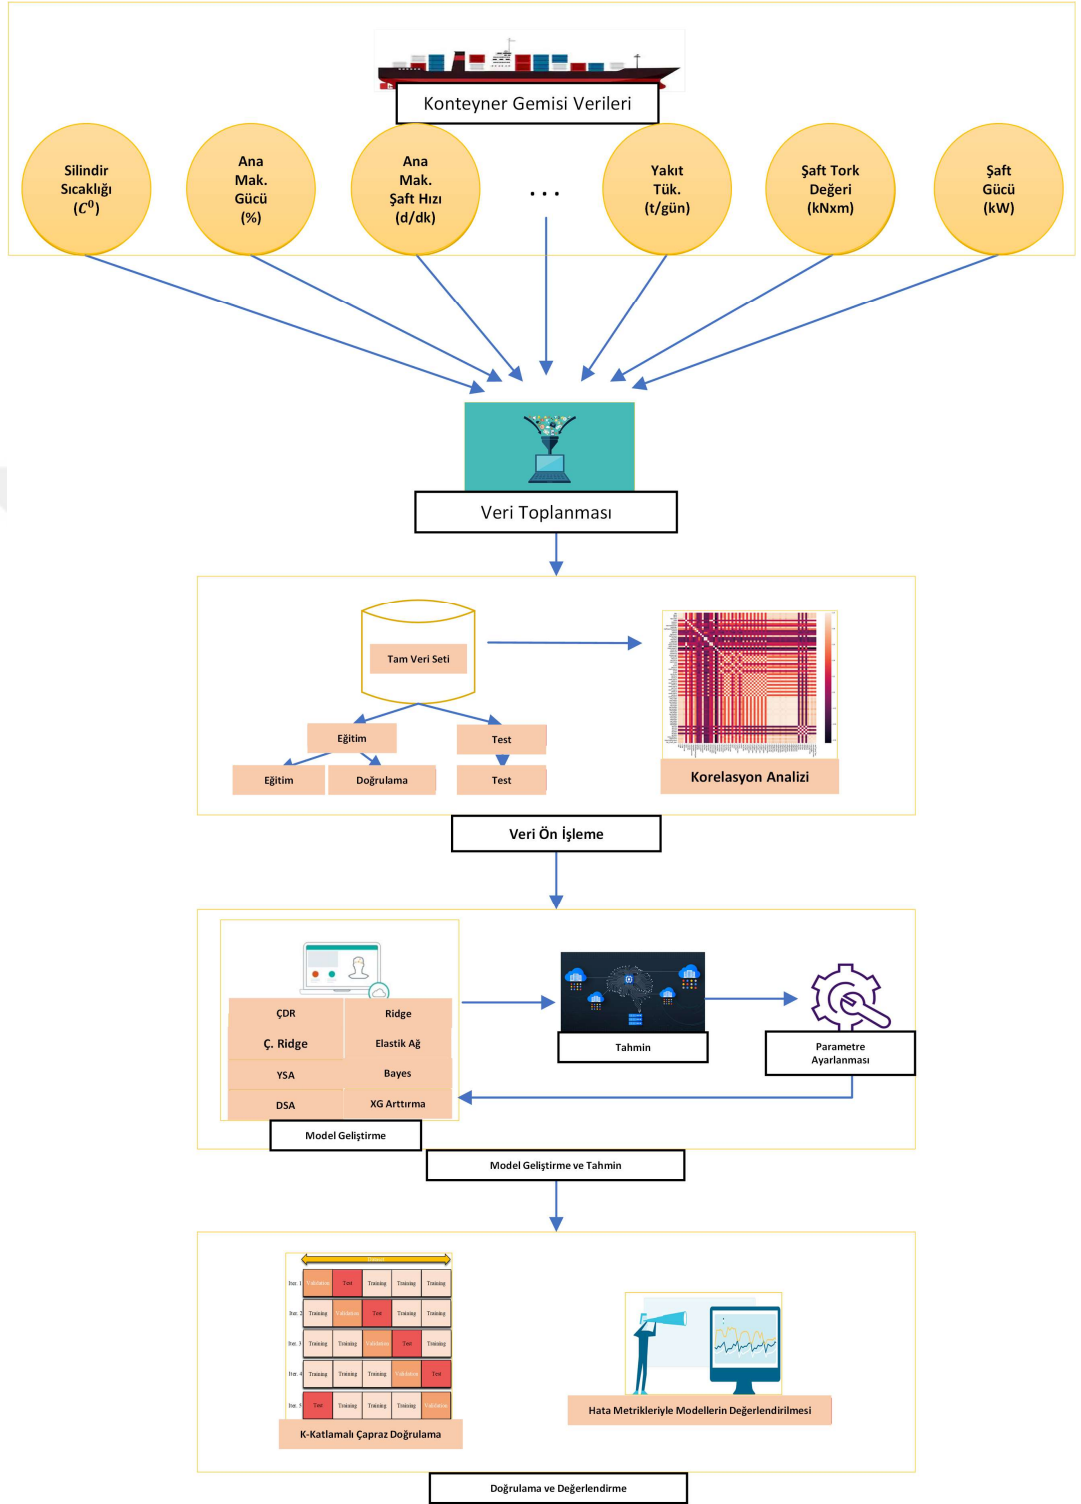
Bu tez çalışmasında üç adet vaka çalışması gerçekleştirilmiştir. Ele alınan vaka çalışmalarından ilkinde öncelikle ticari amaçla kullanılan bir konteyner gemisi için ana makinede üretilen elektriksel güç ve tüketilen yakıtın tahmini ayrı ayrı gerçekleştirilmiştir. Böylelikle; bir gemide üretilen elektriksel güç ve bu gücün elde edilmesi esnasında harcanan yakıt ve bu sürece etki eden diğer değişkenler arasındaki ilişki anlaşılmıştır. İkinci vaka çalışması olarak kimyasal tanker gemisinde operasyonel iş ve işlemler için kullanılan elektriksel gücün üretildiği jeneratörler incelenmiştir. Gemi dizel jeneratörlerinin ürettiği gücün tahmin edilmesinin gemide süregelen operasyon faaliyetleri açısından önemli olduğu ve ani güç dalgalanmalarına karşı önlem olarak gücün tahmin edilmesinin yararlı olduğu değerlendirilmiştir. Son olarak bir kimyasal tanker gemisinde sefer sırasında kullanılan şaft jeneratörünün elektriksel gücü tahmin edilmiştir. Şaft jeneratörleri genellikle sefer sırasında çok fazla manevraya ihtiyaç duyulmayan açık deniz koşullarında gemideki ana makine şaftı sayesinde çalıştırılan bir tür jeneratördür. Bu cihazın kullanımı geminin enerji verimliliğini arttırırken çevreye yayılan emisyonları da azaltmaktadır. Gemideki seyir durumundaki yükün tahmini açısından şaft jeneratörü elektriksel gücü önem teşkil etmektedir. Yapılan vaka çalışmalarıyla bu süreçler ayrıntılarıyla açıklanmıştır.

3.1 Konteyner Gemisindeki Elektriksel Gücün Tahmini Uygulaması

Bu çalışmada ticari bir gemide elektrik gücü ve yakıt tüketimi değerlerinin tahmin edilmesi için veriye dayalı yöntemler kullanılmıştır. Başlangıçta veri kümesi iki bölüme ayrılmıştır: eğitim ve test. Eğitim seti tahmin modellerini geliştirmek için, test seti ise algoritmaların tahmin başarısını hesaplamak için kullanılmıştır. Veriye dayalı metodolojiler, bir gemide seyir için kullanılan tahrik gücü ve yakıt tüketimini hesaplamak için kullanılabilir. Bu alandaki bir çalışmada, itme gücünü geleneksel yöntemlerden daha doğru bir şekilde tahmin etmek için destek vektör regresyonu (SVR) kullanılmıştır (D. Kim vd., 2020; K. S. Kim ve Roh, 2020). Başka bir çalışma,

makine öğrenimi yaklaşımlarının, AIS verilerini ve hava durumu verilerini kullanarak gemilerdeki şaft gücünü tahmin etmek için belirli durumlarda YSA yönteminden daha iyi performans gösterdiğini göstermiştir (M. Liu vd., 2020). Seyir için operasyonel optimizasyon konusunda Leifsson ve diğerleri gri kutu ve beyaz kutu modellerini YSA ile birleştirdi. Bu çalışmada gri kutu modelinin, bir konteyner gemisi için diğer tekniklere göre belirli avantajları olduğu tartışıldı (Leifsson vd., 2008). Petersen ve ark. itme gücünün gemi yakıt ekonomisinde önemli bir rol oynadığını ve itme gücünü tahmin etmek için yapay sinir ağları ve istatistiksel modeller kullandıklarını ve her iki tekniğin de iyi sonuçlar verdiğini savunmuşlardır (Petersen vd., 2012). Bu çalışmada bir konteyner gemisinin enerji verimliliğini araştırmak için, şaft gücü ve yakıt tüketimi faktörlerini tahmin etmek için çeşitli veriye dayalı tahmin modelleri kullanılmıştır. Şekil 3.1'de çalışmada ele alınan yaklaşım gösterilmiştir. Tahmin işlemi için bir konteyner gemisinden ilk 700 günlük sefer verileri toplanmıştır. Bu veri seti, çeşitli ekipmanlar yardımıyla gemideki 75 farklı veri kaynağından derlenmiştir. Şekil 3.3, Pearson Korelasyon Analizinin bulgularını göstermektedir. Çalışma, veri setindeki birkaç faktörün şaft gücü ve yakıt tüketimi değişkenleri ile daha yüksek bir korelasyona sahip olduğunu ortaya çıkarmıştır. Korelasyon matrisi incelenmiş ve bu değişkenlerle zayıf korelasyon gösteren veriler analiz ve tahmin işlemlerinden çıkarılmıştır. Güç ve yakıt tüketimi arasındaki ilişkiyi daha iyi anlamak için, Şekil 3.4'te gösterilen en yüksek korelasyonlarla bir ikili grafik oluşturuldu. Veri seti, bilgisayar tarafından eğitim verileri (%66) ve test verileri (%33) olarak rastgele seçilmiştir ve ikiye ayrılmıştır (Coraddu vd., 2017). Algoritmaları eğitmek için eğitim verileri kullanılırken, kalan test verileri saklanarak algoritma başarılarının testi işleminde kullanılmıştır. Çoklu Doğrusal Regresyon, Ridge Regresyon, Kement Regresyon, Kernel Ridge Regresyon, Elastik Ağ, Yapay Sinir Ağı, XGradient Boosting, Derin Sinir Ağı ve Bayesian Regresyon gibi veriye dayalı teknikler kullanılarak tahmin işlemi gerçekleştirildi. Tahmin sürecinin ilk aşamasında tahminden beklenen sonuçlar elde edilemediği için algoritmaların parametreleri değiştirilerek algoritmanın performansı artırılmıştır. Bulguları doğrulamak ve aşırı uyumu saptamak için K-Katlamalı Çapraz Doğrulama yöntemi kullanılmıştır (Ling vd., 2019). Simülasyon sonuçları Ortalama Hatanın Karekökü (RMSE), Ortalama Mutlak Hata (MAE) ve Belirleme Katsayısı (R^2) (Davoudi vd., 2019) gibi hata ölçüm

metrikleri kullanılarak karşılaştırılmıştır. Yapılan iş ve işlemler Şekil 3.1’de açıklanmıştır.




Şekil 3.1: Çalışmada yapılan işlemlerin anlatılması.

Veri toplama süreci, bilimsel prosedürde veri odaklı çalışmalar için büyük bir zorluktur (Feng vd., 2020). Btau analizdeki gemi gövdesinin uzunluğu 328 metre,

geniřlięi 46 metre ve draftı 9,7 metredir. Tahrik g¼c¼, ana makine modeli 10S90MEC9 tarafından saęlanmaktadır. Bu ana makine 9 silindirlidir ve 2 zamanlı olarak imal edilmiřtir. Veriler, ticari bir gemiden makine kayıt defteri, oęlen raporu ve ana makine sens¼rleri birleřtirilerek derlendi. Ana makine g¼c¼ (%), ana motor milinin dakikadaki d¼n¼ř¼, yakıt t¼keticimi (t/g¼n), ana makine mil tork deęeri (kNm), ana motor mil g¼c¼ (kW), ana makine ceket soęutma suyu sıcaklık deęerleri, ana makine ceket tatlı su sıcaklık deęeri, itme pedi, s¼p¼rme havası sıcaklıęı, silindir sıcaklıklarını ve dięer parametreler bu veri setine dahildir. izelge 3.1, veri setinin bir kısmının istatistiksel analizini g¼stermektedir. Veriler, ¼ç dizel jenerat¼r, bir řaft jenerat¼r¼ ve bir acil durum jenerat¼r¼ aracılıęıyla alındı. Bu geminin mikro řebekesi řekil 3.2'de temsil edilmektedir.

izelge 3.1: Veri setindeki deęiřkenlerin istatistiksel ¼zeti.

	Makine G¼c¼ (%)	Makine řaft Hızı (d/dk)	Yakıt T¼keticimi (t/g¼n)	Ana Mak. řaft Torku (kNxm)	Ana Mak. řaft G¼c¼ (kWx102)	...
Ortalama	21.153	39.324	53.697	1755.146	115.141	...
Std. S.	19.329	28.473	43.503	1408.702	98.616	...
En D¼ř¼k	0	0	0	0	0	...
25%	0	26.05	26.5	978.5	52.51	...
50%	20.589	51.1	53.05	1957	105.3	...
75%	38.794	63.7	89.41	2976.25	198.235	...
Maks.	62.307	72.6	168.26	4254	318.2	...



řekil 3.2: Geminin elektrik řebekesi.

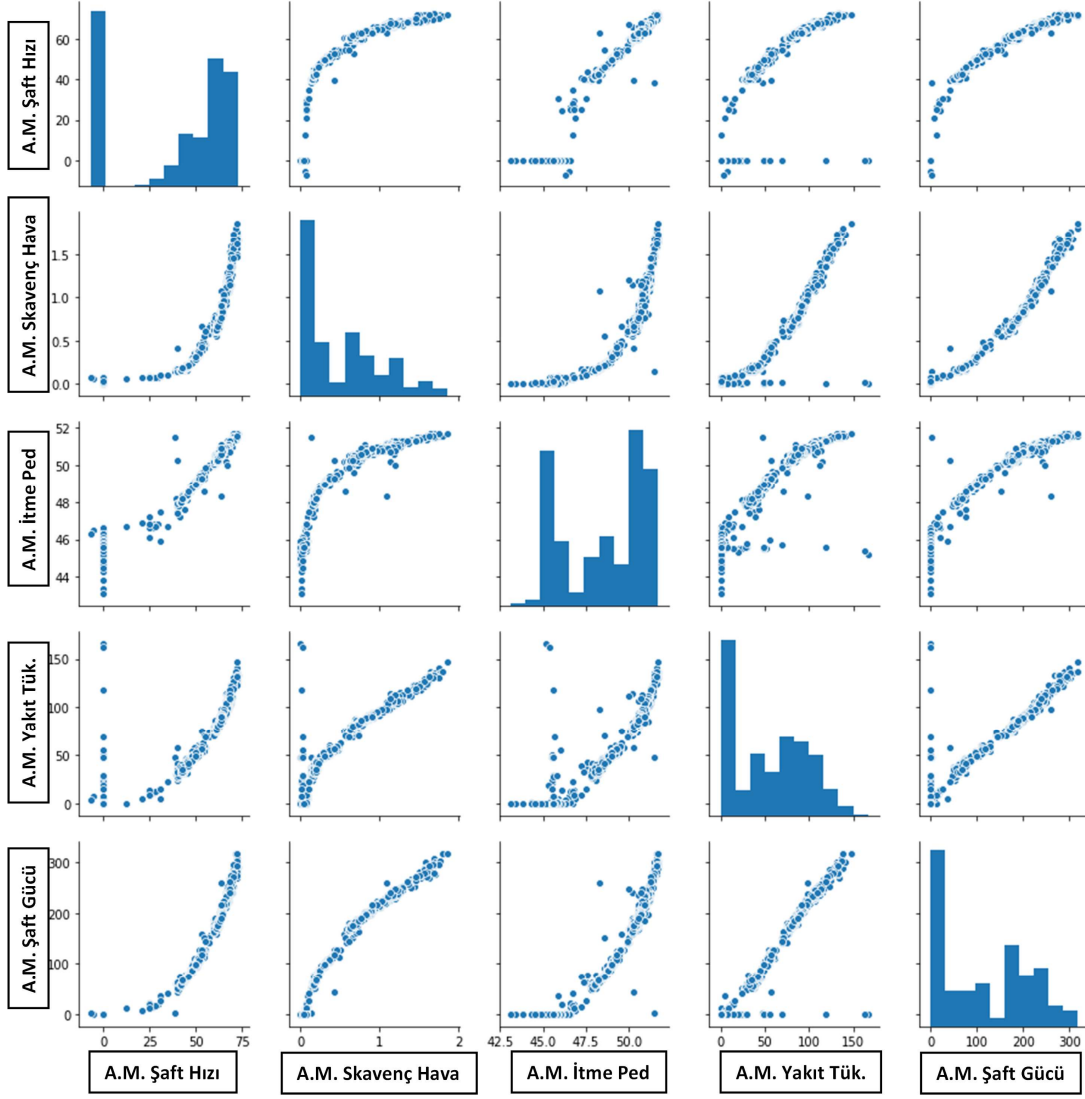
Herhangi iki deęiřken arasındaki iliřki ve deęiřkenler arasındaki iliřkiyi analiz etmek ve g¼stermek iin bir y¼ntem olan korelasyon analizi kullanılarak belirlenmiřtir (Goossens, 2019). Bu alıřmada Pearson Korelasyon Katsayısı kullanılmıřtır

(Coraddu vd., 2017). Katsayı pozitif olduğunda iyi bir korelasyon vardır; ancak, işaret negatif olduğunda ters bir korelasyon olduğundan bahsedilebilir. İki değişken arasında bir ilişki olduğunda, bu değişkenlerin ikili grafiğinde doğrusal bir şekil ortaya çıkacaktır. Korelasyon yoksa, bu iki değişkenin çift grafiği doğrusal bir şekle sahip olmayacaktır. Pearson Korelasyon Analizi Şekil 3.3'te gösterilmiştir.



Şekil 3.3: Pearson Korelasyon Analizi sonucu.

Ana makine shaft hızı (d/dk), ana makine süpürme havası sıcaklığı, ana makine itme pedi sıcaklığı ve ana makine yakıt tüketimi verilerinin güçlü bir korelasyona sahip olduğu gözlemlenebilir. Şekil 3.4'teki ikili grafik, bu değişkenler arasındaki ilişkinin daha ayrıntılı bir incelemesini sağlamaktadır.



Şekil 3.4: Değişkenlerin ikili grafikler ile gösterimi

İkili grafikte gösterildiği gibi, şaft hızı yaklaşık 35 d/dk olana kadar güç değişmemiştir. Bu değerden sonra güç ile mil devri arasında önemli bir bağlantı olduğu sonucuna varılabilir. Ana makine süpürme havası sıcaklığı ve ana makine yakıt tüketim istatistikleri güç ile bir korelasyon oluşturmuştur denilebilir.

Bu çalışmada, TensorFlow 2.0 ortamında Python 3.7.7 ve Spyder 4.1.5 ara yüzü kullanılarak ana makine şaft gücü ve yakıt tüketimi tahmin edilmiştir. Veriye dayalı metodolojileri kullanan araştırmalarda veri seti, eğitim ve test verilerine bölünür. Veri toplamanın boyutuna bağlı olarak, eğitim ve test veri kümeleri arasındaki oran değişebilir. Çünkü bu oran bu alandaki araştırmalara göre değişkenlik göstermektedir (Anguita vd., 2012; Coraddu vd., 2017; Frías-Paredes vd., 2018). Literatürle uyumlu olması açısından bu çalışmada da bu oranın kullanılmasına karar verilmiştir.

Bilgisayar, makine öğrenimi yöntemlerini kullanarak şaft gücünün hesaplanması için veri setini (700 gün) rastgele seçmiştir ve bunu iki kısma ayırmıştır: eğitim (2/3) ve test verileri (1/3). Bilgisayara eğitim verisi olarak 467 günlük sefer verisi öğretilmiştir ve modeller geminin şaft gücü ve yakıt tüketimi değişkenlerini 233 günlük sefer verisi (test verisi) içinde değerlendirmiştir. Algoritma başarılarını karşılaştırmak için üç alternatif hata ölçümü yaklaşımı kullanılmıştır.

Tahmin işlemi sonucunda kullanılan algoritmaların başarısını karşılaştırabilmek ve sayıllaştırmak için hata metrikleri kullanılmıştır. Algoritmalarından bazıları, hata metrik değerlerine (RMSE, MAE ve R^2) göre, tahmin aşamasının başlangıcında tatmin edici sonuçlar üretememiştir. Başarısız olan algoritmaların parametreleri, tahmin süreci için 'Grid Search' yaklaşımı kullanılarak ayarlanmıştır. Aşırı uyum (overfitting) durumunun irdelenmesi ve sonuçların doğrulanması için K-Katlamalı Çapraz Doğrulama yöntemi uygulanmıştır. Veri setinin bir kısmı test verisi, bir kısmı doğrulama verisi ve kalan üç kısım ise eğitim verisi olarak kullanılmıştır. Bu prosedür, veri setindeki tüm veriler işlenene kadar (5 yineleme) tekrarlanmıştır. Tüm iterasyonlarda bulunan ortalama MAE hata metriği değerlerinin ortalaması alınmış ve 5. iterasyon tamamlandığında ortalama doğrulama puanı belirlenmiştir.

Çizelge 3.2: Ayarlanan parametre değerlerinin algoritma bazında gösterilmesi

Yöntem	Ayarlanan Parametre
MLR	Yok
Ridge	alpha=0.1, solver='lsqr', tol=0.00001
Lasso	alpha=0.4
Ç. Ridge	None
XGradyan A.	loss="ls", alpha=0.3
Elastik Ağ	alpha=0.1
Bayes	None
YSA	solver='lbfgs', alpha='0,00001', max_iteration=15000, activation='relu', hidden_layer_size=9, power_t=0,7, validation_fraction=0,3, batch_size=110
DSA	Epoch='1500', optimizer='adam', activation='relu', hidden_layer count=17

Çizelge 3.3 ve Çizelge 3.4 çapraz doğrulama bulgularını gösterirken, Çizelge 3.5 ve Çizelge 3.6 birincil bulgular için hata metriği değerlerini ortaya koymaktadır. Çizelge 3.7 ve Çizelge 3.8 vaka çalışmaları için nihai bulguları göstermektedir. Güç tahmini ve yakıt tüketimi sonucunda MAE, R^2 ve RMSE hata metrikleri ortaya çıkmıştır.

Çizelge 3.3: Güç üretimi için k-katlamalı çapraz doğrulama işlemi sonuçları.

Yöntem	Doğrulama Skoru (MAE)					
	Iter. 1	Iter. 2	Iter. 3	Iter. 4	Iter. 5	Mean
MLR	0.012862	0.012559	0.012618	0.012797	0.012841	0.012735
Ridge	0.510485	0.495327	0.483942	0.495371	0.453798	0.487785
Lasso	0.231584	0.214795	0.241357	0.214186	0.221935	0.224771
Ç. Ridge	0.012689	0.013487	0.016741	0.013523	0.014652	0.014218
XG. Arttırma	0.084215	0.043156	0.076897	0.032481	0.064215	0.060193
Elastik Ağ	0.135145	0.127468	0.141544	0.134523	0.126524	0.133041
Bayes	0.001847	0.001429	0.001421	0.001627	0.001712	0.001607
YSA	0.173515	0.194257	0.161526	0.178426	0.145795	0.170703

Çizelge 3.4: Yakıt tüketimi için k-katlamalı çapraz doğrulama işlemi sonuçları.

Yöntem	Doğrulama Skoru (MAE)					
	Iter. 1	Iter. 2	Iter. 3	Iter. 4	Iter. 5	Mean
MLR	0.003076	0.003255	0.003261	0.003279	0.003214	0.003217
Ridge	0.248713	0.255327	0.243942	0.255371	0.253798	0.251113
Lasso	0.561487	0.574795	0.541357	0.564186	0.551935	0.558752
Ç. Ridge	0.002894	0.003487	0.002741	0.003523	0.002652	0.003059
XG. Arttırma	0.001678	0.001556	0.001897	0.001481	0.001215	0.001565
Elastik Ağ	0.544513	0.537468	0.541544	0.534523	0.526524	0,536914
Bayes	0.003811	0.003429	0.003421	0.003627	0.003711	0.003599
YSA	0.001947	0.001894	0.001875	0.001952	0.001971	0.001927

Çizelge 3.5: Güç tahmini simülasyon sonuçları (Öncül bulgular).

Yöntem	RMSE	MAE	R2
ÇDR	0.000003	0.000996	0.999999
Ridge	1.237432	1.512512	0.659222
Lasso	1.264545	1.127521	0.775724
Ç. Ridge	0.855976	0.925191	0.999993
XGradyan Arttırma	0.009053	0.095750	0.993211
Elastik Ağ	1.203749	1.097155	0.647199
Bayes	0.000002	0.000991	0.999999
YSA	0.801357	0.892518	0.703928
DSA	0.684111	0.827112	0.724955

Çizelge 3.6: Yakıt tüketimi tahmini için simülasyon sonuçları (Öncül bulgular).

Yöntem	RMSE	MAE	R ²
ÇDR	0.000208	0.001375	0.999999
Ridge	0.177651	0.421492	0.992594
Lasso	2.452164	1.314547	0.894411
Ç. Ridge	0.000216	0.001471	0.999999
XGradyan Arttırma	1.591357	1.101458	0.903437
Elastik Ağ	3.947521	0.924571	0.795421
Bayes	0.000299	0.001743	0.999998
YSA	0.091456	0.051465	0.887452
DSA	0.021364	0.031451	0.895415


Çizelge 3.7: Güç tahmini için nihai simülasyon sonuçları.

Yöntem	RMSE	MAE	R ²
ÇDR	0.000003	0.000996	0.999999
Ridge	0.500782	0.517583	0.999965
Lasso	0.299883	0.260465	0.999971
Ç. Ridge	0.000621	0.013221	0.999993
XGradyan Arttırma	0.129474	0.114669	0.999871
Elastik Ağ	0.082140	0.154781	0.999991
Bayes	0.000002	0.000991	0.999999
YSA	0.001547	0.001621	0.999992
DSA	0.000001	0.000987	0.999999


Çizelge 3.8: Yakıt tüketimi tahmini için nihai simülasyon sonuçları.

Yöntem	RMSE	MAE	R ²
ÇDR	0.000208	0.001375	0.999999
Ridge	0.001875	0.002494	0.999999
Lasso	1.850958	0.536233	0.999905
Ç. Ridge	0.000216	0.001471	0.999999
XGradyan Arttırma	0.000274	0.001459	0.999771
Elastik Ağ	2.384741	0.524532	0.998768
Bayes	0.000299	0.001743	0.999998
YSA	0.003248	0.001745	0.999981
DSA	0.000368	0.001674	0.999999

Şekil 3.5 ve Şekil 3.6'da 233 günlük test verisinden 30 günlük veri rastgele seçilmiş ve makine öğrenimi algoritmalarının tahmin başarısını değerlendirmek için algoritmalar tarafından üretilen tahminler karşılaştırılmıştır. Şekil 3.5 ve 3.6 sırasıyla, tahmini ve gerçek güç, yakıt tüketimi ve tahmini yakıt tüketimi değerlerine ilişkin karşılaştırma grafiklerini göstermektedir.



Şekil 3.5: Gerçek güç verileri ile tahmini değerlerin karşılaştırılması.

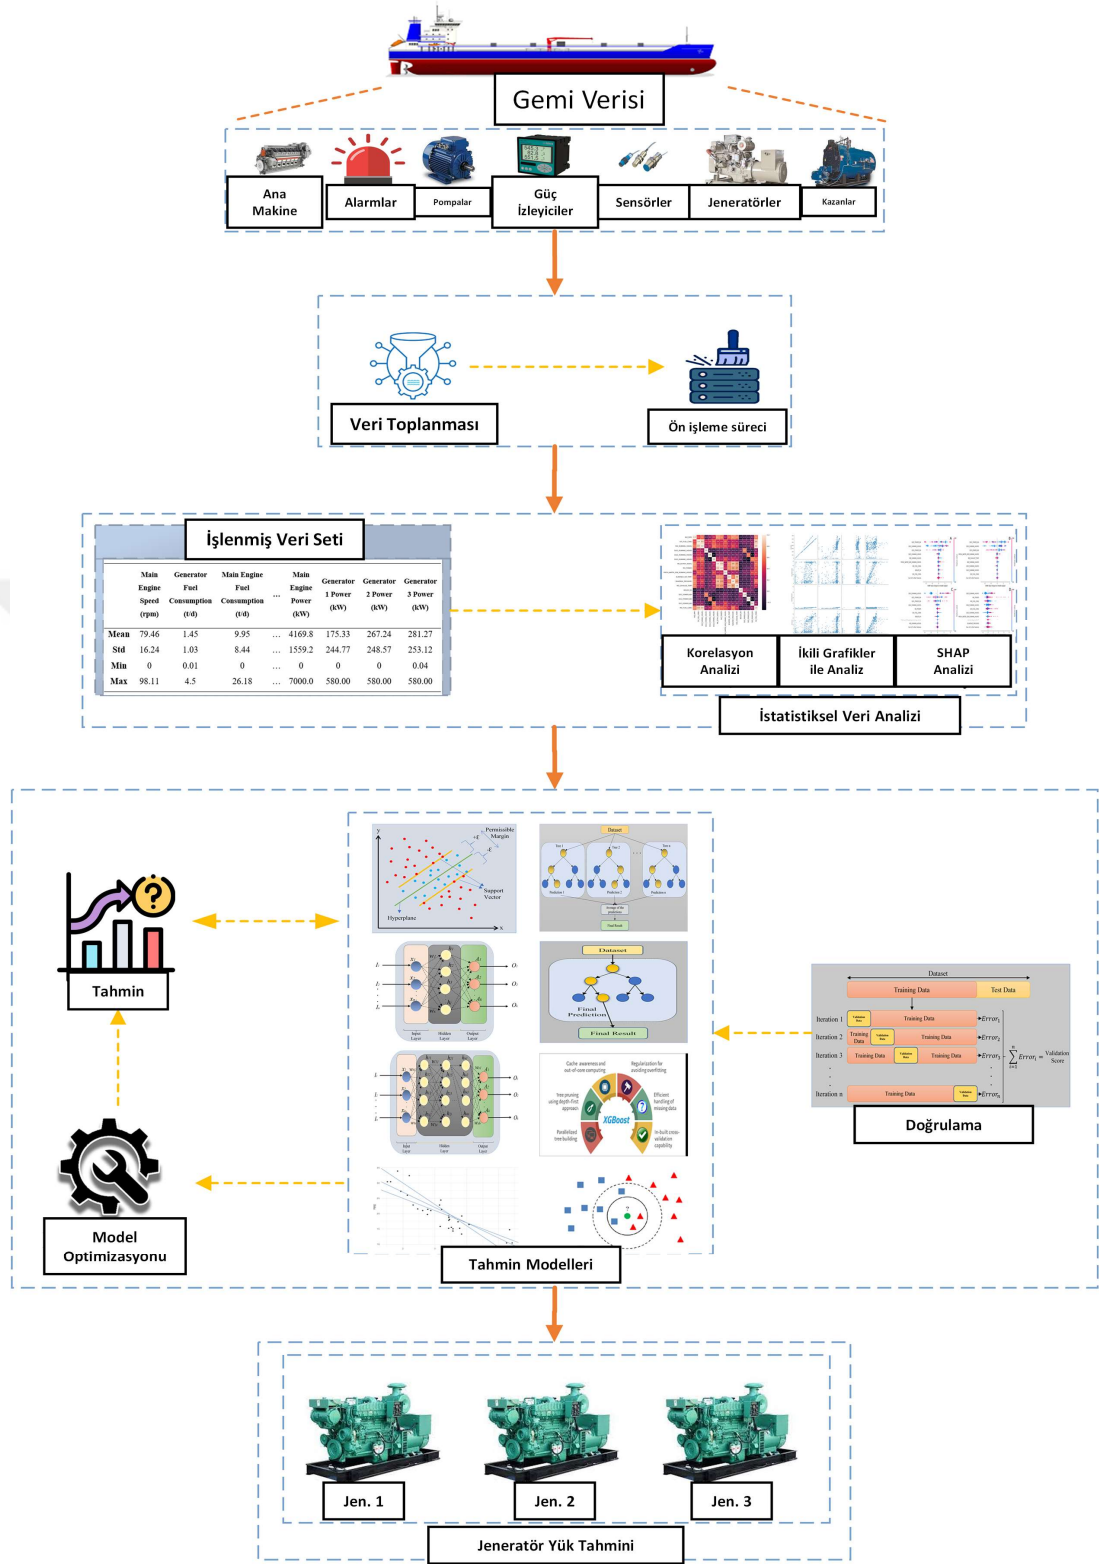


Şekil 3.6: Gerçek yakıt tüketimi verileri ile tahmini değerlerin karşılaştırılması.

Çalışmada elde edilen sonuçlar, dördüncü bölümünde ayrıntılarıyla ele alınmıştır.

3.2 Kimyasal Tanker Gemisinde Jeneratör Yükleri Tahmini Uygulaması

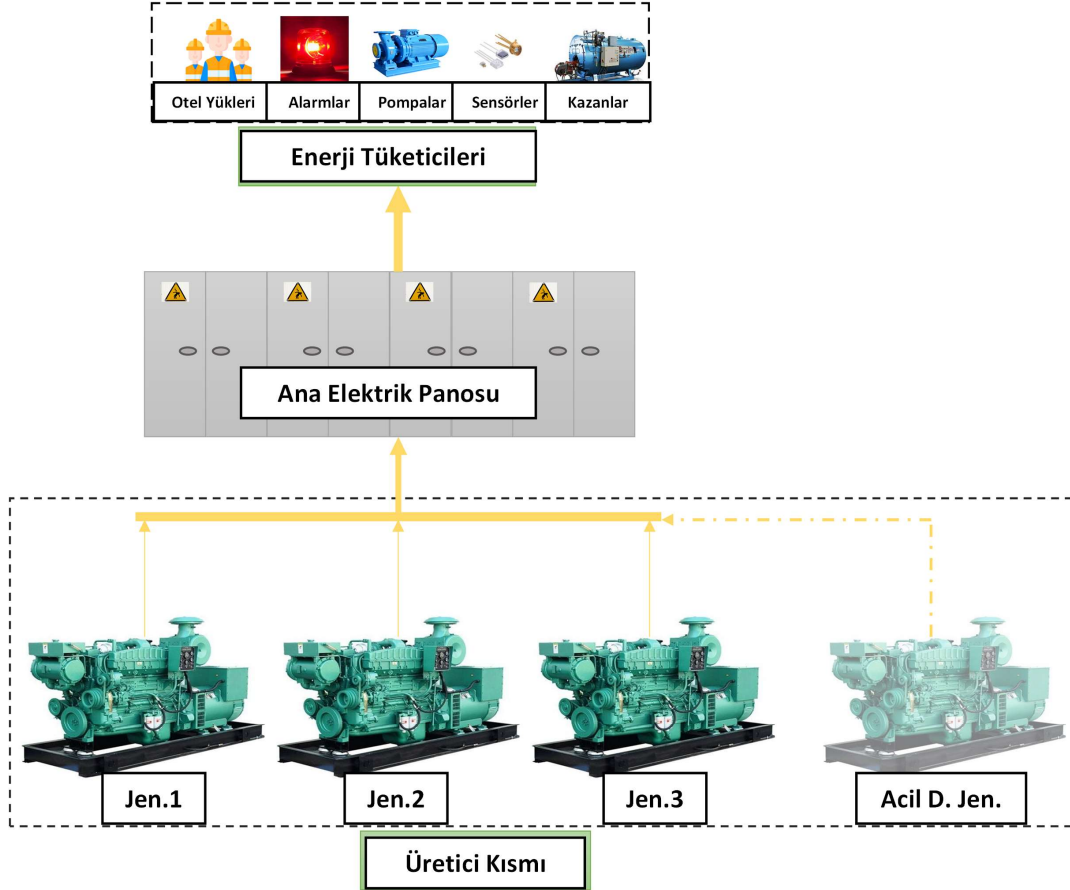
Gemi dizel jeneratör gücünü tahmin etmek için bu çalışmada kullanılan algoritmalar arasında destek vektör makineleri, çoklu doğrusal regresyon, yapay sinir ağı, derin sinir ağı, k-en yakın komşular, rastgele orman, ekstrem gradyan artırma ve karar ağacı yer almaktadır. 2017 yılında inşa edilen ticari bir kimyasal tanker gemisinden yaklaşık 1000 günlük sefer veri seti elde edilmiştir. Daha sonra veri seti, veri ön işleme teknikleri kullanılarak eksik örneklerden arındırılarak işlenmiş ve daha sonra algoritmaların çalışabileceği bir formata dönüştürülmüştür. Bu veri seti, gemideki çeşitli sensörlerden ana makine, yardımcı makineler ve dizel jeneratörler hakkında veriler içermektedir. Veri setindeki korelasyonları incelemek için Pearson Korelasyonu, yüksek korelasyona sahip veriler arasındaki ilişkileri açıklamak için ise çift grafikler kullanılmıştır. Veri setinde yüksek korelasyona sahip değişkenler ile dizel jeneratörlerdeki toplam yük arasındaki korelasyon, ayrı bir ikili grafikte gösterilmiştir. Simülasyon sonuçları hata metrikleri ortalama mutlak hata (MAE), ortalama karesel hatanın kökü (RMSE) ve ortalama mutlak yüzde hatası (MAPE) ile sayısallaştırıldı. Simülasyonlar sonucunda, gemi dizel jeneratörlerinin sefer sırasındaki yükleri, veriye dayalı algoritmalar ile başarılı bir şekilde tahmin edilmiştir. Ayrıca, sistemdeki toplam yükü tahmin etmek için ayrı bir simülasyon başarıyla gerçekleştirilmiştir. Sonuçları doğrulamak için K-Katlamalı Çapraz Doğrulama yöntemi kullanılmıştır. Yukarıda özetlenen çalışmanın metodolojisi Şekil 3.7'de görselleştirilmiştir.



Şekil 3.7: Çalışmada izlenen yöntemin anlatılması

Bu mikro şebekede enerji tüketicileri otel yükleri, alarmlar, pompalar, sensörler, kazanlar vb. olup, üretici tarafı ise dizel jeneratörler olarak tasarlanmıştır. Bu kimyasal tankerde, tüketicilere elektrik enerjisi üretmek için üç adet dizel jeneratör

kullanılmakta olup, acil durum yükleri ve jeneratörlerin arızalanması durumunda kullanılmak üzere bir adet acil durum jeneratörü devrededir. Bahsedilen mikro şebekenin genel yapısı Şekil 3.8'de gösterilmiştir.



Şekil 3.8: İncelenen geminin elektrik mikro şebekesi planı.

Bu aşamadan sonra incelenen ticari gemi için veri elde etme çalışması yapılmıştır. Veri toplama, veriye dayalı çalışmalarda temel süreçtir (Schäfers vd., 2019). Sağlam ve temiz bir veri seti, çalışmada hedeflenen sonuçlara ulaşılmasını da kolaylaştırabilir (Ellingsen ve Aasland, 2019). Bu çalışmada ilk olarak 1461 günlük bir sefer veri seti bu inceleme için toplanmıştır. Daha sonra bu veri setinin boş hücre içeren değerleri elenerek bu çalışmada kullanılacak 1000 günlük işlenmiş veri seti elde edilmiştir. Geminin özellikleri ve veri setinin özetçe istatistiksel bilgileri sırasıyla Çizelge 3.9 ve Çizelge 3.10'da verilmiştir. Bu çalışmada kullanılan veri setinin özellikleri şu şekildedir;

- Ana makine devir hızı (devir/dakika).
- Dizel jeneratör yakıt tüketimi (t/gün), güç (kW).

- Ana makine çalışma saatleri (saat/gün).
- Dizel jeneratör çalışma saatleri (saat/gün).
- Ana makine çıkışı maksimum güç (%).
- Ana makine gücü (kW), yakıt tüketimi (t/gün).
- Temiz su jeneratörü çalışma saatleri (saat/gün).
- Temizleme havası sıcaklığı (°C) ve temizleme basıncı (bar).
- Ana makine egzoz sıcaklığı (°C).
- Kazan çalışma saatleri (saat/gün).

Çizelge 3.9: Gemi özellikleri.


Birim	Özellik
Gemi Tipi	Petrol/Kimyasal Tanker
Gros Tonaj	29590 t
Deadweight Tonaj	49990 t
Uzunluk/Genişlik	183/32.3 m
Yıl	2017
Ortalama/En Yüksek Hız	13.4/17.3 knots
Ana Makine Gücü	7000 kW
Jeneratör Gücü/Sayısı	580 kW/3
Draft	8 m

Çizelge 3.10: Veri setinin istatistiksel özeti.

	Ana mak. devir hızı (d/dk)	Jen. Yakıt Tük. (t/gün)	Ana Mak. Yak. Tük. (t/d)	...	Ana Mak. Güç (kW)	Jen. 1 Güç (kW)	Jen. 2 Güç (kW)	Jen. 3 Güç (kW)
Ort.	79.46	1.45	9.95	...	4169.8	175.3	267.2	281.2
Std.	16.24	1.03	8.44	...	1559.2	244.7	248.5	253.1
Min.	0	0.01	0	...	0	0	0	0.04
Mak.	98.11	4.5	26.18	...	7000.0	580.0	580.0	580.0

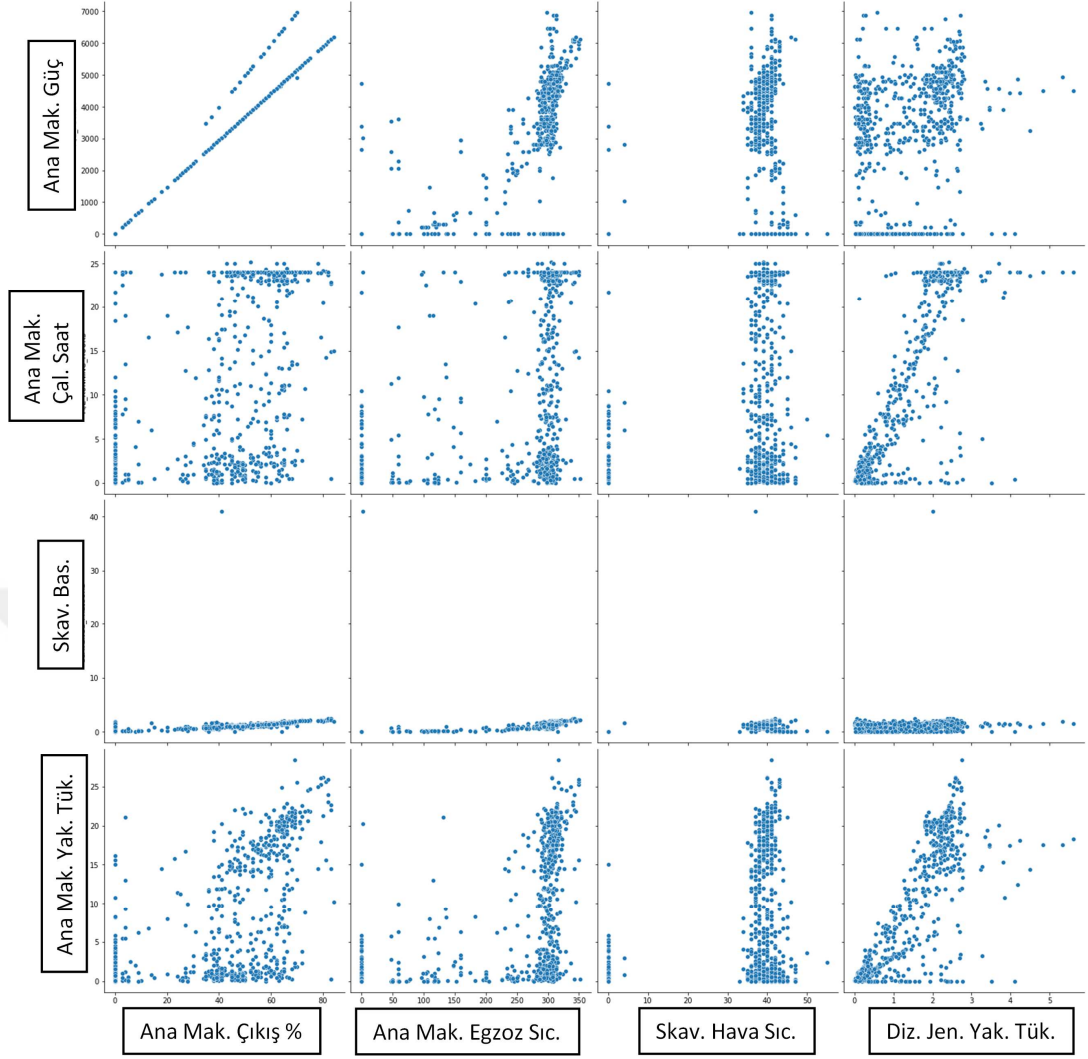
Veriye dayalı çalışmalarda korelasyon analizi, veriler arasındaki ilişkiyi açıklar ve değişkenlerin önem derecesini de belirler. Bu çalışmada veri setindeki iki değişken arasındaki ilişkiyi belirlemek için Pearson Korelasyon Katsayısı (r) kullanılmıştır. Korelasyon katsayısı -1 ile +1 arasında değerler alır. Şekil 3.9, veri setinin Pearson Korelasyon matrisini göstermektedir. Burada korelasyon katsayısının önündeki "+" işareti iki değişken arasında pozitif korelasyonu, "-" işareti ise iki değişken arasında negatif korelasyonu göstermektedir. Örneğin, bu veri setinde, dizel jeneratörlerin yakıt

tüketimi ile ana makine yakıt tüketimi değerleri arasında güçlü bir korelasyon (0,9) bulunurken, dizel jeneratör 1 çalışma saati ve tahliye havası sıcaklık değeri korelasyon değeri 0'dır.

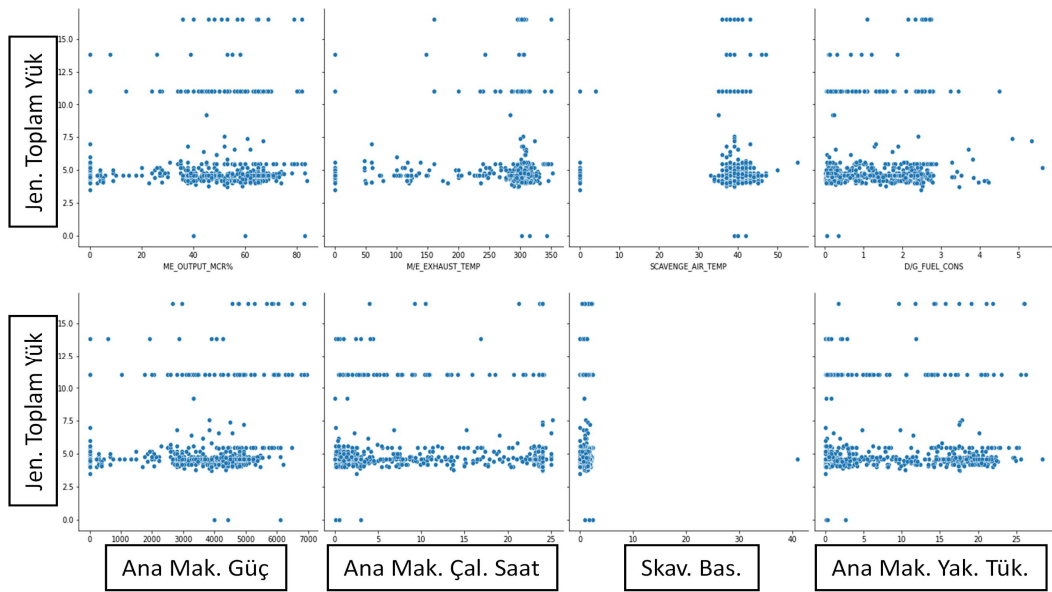


Şekil 3.9: Veri setinin Pearson korelasyon matrisi.

Çift grafik yöntemi, veri setindeki değişkenler arasındaki ilişkinin daha ayrıntılı incelenmesine olanak sağlayabilir. Bu çalışmada yüksek korelasyon katsayısına sahip değişkenlerin ikili grafikleri Şekil 3.10'da gösterilmektedir. Bu değişkenler ile jeneratörlerin toplam yükü arasındaki ilişki de Şekil 3.11'de gösterilmektedir. Ana makine ve güç değişkenleri tüm değerler için güçlü korelasyon gösterirken, diğer değişkenler böyle bir doğrusal grafik oluşturamamıştır. Şekil 3.11 incelendiğinde dizel jeneratörün toplam yükünün süpürme basıncı değişkeni ile belirli bir aralıkta korelasyon gösterdiği görülmektedir.




Şekil 3.10: Yüksek korelasyon katsayısına sahip değişkenlerin ikili grafikleri.



Şekil 3.11: Değişkenler ile jeneratörlerin toplam yükü arasındaki ikili ilişkiler.

SHAP değerleri (SHapley Additive exPlanations), oyun teorisine dayanan ve veri kümesindeki çıktı değişkeni üzerinde girdilerin önemini bulmaya olanak sağlayan bir yöntemdir (Futagami vd., 2021; D. Wang vd., 2022). Keşfedilen SHAP değerleri, Şekil 3.12'de gösterilen bu tahmin modelinde girdilerin sistemin çıktısına yönelik önemini ölçmek içindir. Şekil 3.12.A, dizel jeneratör 1 gücünü tahmin ederken girdi değişkenlerinin çıktı üzerindeki etkisini göstermektedir. Şekil 3.12.B ve Şekil 3.12.C, giriş değişkenlerinin sırasıyla jeneratör 2 ve 3 için çıkışı nasıl etkilediğini göstermektedir. Bu arada, Şekil 3.12.D, jeneratörlerin toplam yükünü tahmin etmek için kullanılan modelde girdi değişkenlerinin çıkış üzerindeki etkisini göstermektedir. DG1 güç tahmin işlemi için (Şekil 3.12.A), veri setindeki diğer özelliklerden DG2 gücü, DG1 çalışma saati ve DG3 gücünün daha önemli olduğu söylenebilir. Şekil 3.12.B'den DG1 gücü, DG2 çalışma saatleri ve DG3 güç değerlerinin DG2 güç tahmin aşaması için daha önemli özellikler olduğu söylenebilir. DG3 güç tahmini için DG3 çalışma saatleri, DG2 gücü ve DG1 güç değerleri diğer özelliklerden daha önemlidir (Şekil 3.12.C) ve önemli değerler Şekil 3.12.D'de toplam yük tahmini durumu için sunulmuştur.



Şekil 3.12: Giriş değişkenlerinin çıkış değişkeni üzerindeki etkisi.

Gerçek değerlere yakın jeneratör yük tahmini çıkış değerlerine ulaşmak önerilen eğitim modelinin temel amacıdır. En düşük hatayı üreten bir tahmin modeli, yüksek tahmin doğruluğu gösterir ve yeni veri seti üzerinde güvenilir sonuçlar üretebilir. Veriye dayalı yaklaşımların tahmin hedefini karşılayabilecek tahmin modelini bulmak için bu çalışmada DVM, ÇDR, YSA, DSA, KEK, RO, XGB ve Karar Ağacı olmak üzere sekiz farklı algoritma kullanılmıştır. Kimyasal tankerin jeneratör yükü için en iyi tahmin modelini sağlayan tüm algoritmaların karşılaştırmalı sonuçları ve her tahmin modelinin performansının analizinden elde edilen bulgular aşağıda ele alınmıştır.

Bu çalışmada, gemi dizel jeneratör güç tahmini için simülasyonlarda Python programlama dili sürüm 3.7.7'deki TensorFlow ortamı kullanıldı. Bilgisayar donanımında Intel Core i7-9750H 2.60GHz işlemci, 32 GB RAM ve NVIDIA GeForce RTX 2070 grafik kartı kullanıldı. Simülasyonun ilk aşamasında bazı algoritmalar istenilen tahmin skorlarını üretmediği için kurulan modellerin parametreleri düzenlenmiştir. Hiperparametre ayarı, tahmin modeli için optimize edilmiş değerleri sağlamak için avantaj oluşturmaktadır. Bu işlem, tahmin doğruluğunu mümkün olan en üst düzeye çıkaracaktır ve tahmine dayalı modelin davranışını kontrol etmede önemli bir adımdır. Hiperparametre ayarlama adımı olmadan, tahmin modeli simülasyonu sırasında daha fazla hata yapacaktır. Çizelge 3.11, bu işlem sonucunda elde edilen model parametrelerini göstermektedir.

Çizelge 3.11: Ayarlanan model parametreleri

Model	Parametre
DVM	None
ÇDR	None
YSA	solver='lbfgs',alpha=0.00001,max_iter=10000,activation='tanh', hidden_layer_sizes=(5000,), power_t=0.7,validation_fraction=0.3, batch_size=250
DSA	input_dim=16, hidden_layer_count=17, input_layer_activation_function='relu', hidden_layer_activation_function='linear', output_layer_activation_function='linear', optimizer='Adam', epochs=1500
KEK	n_neighbors=3,weights="distance",algorithm="kd_tree", p=20
RO	n_estimators=350,max_depth=150
XGB	None
K.Ağacı	None

Bu çalışmada tahmin algoritmalarının performansı MAE, RMSE, MAPE gibi çeşitli hata ölçütleri ile değerlendirildi. İlk senaryoda, tahmin modelleri DJ1 (dizel jeneratör 1), DJ2 ve DJ3'ün güçlerinin ayrı ayrı bulunması için uygulanmıştır. Çizelge 3.12, her jeneratörde güç tahmini için sekiz tahmin algoritmasının sonuçlarını karşılaştırmaktadır. Karar Ağacı (Dtree) algoritmasının bu özel vaka çalışması için kullanılan diğer algoritmalarından daha verimli olduğunu görülmektedir. DJ1 güç tahmini için 0.2364 MAE, 0.2455 RMSE ve 17.493 MAPE değerlerine ulaşılmıştır. DJ2 güç tahmin skorları değerlendirildiğinde Karar Ağacı algoritmasının 0,1306 MAE, 0,2069 RMSE ve 5,1139 MAPE değerlerine ulaştığı görülmektedir. DJ3 güç tahmini için Karar Ağacı algoritması 0,1532 MAE, 0,2182 RMSE ve 7,7481 MAPE değerlerine ulaşmıştır. Karar Ağacı algoritması, tipik bir model tabanlı öğrenme yöntemidir. Bu yöntemin diğer algoritmalarından farkı, girdi değişkenleri ile çıktı değişkeni arasındaki ilişkinin modellenmesidir. Bu nedenle hem lineer hem de lineer olmayan sistemlerde başarılı sonuçlar elde edebilmektedir(C. Liu vd., 2022). Öte yandan, XGB, RO ve DSA algoritmaları Karar Ağacı'ndan biraz daha yüksek hata ölçümü ile iyi bir performans göstermiştir. Bu arada, DVM tekniği en yüksek hata oranıyla bu problem özelinde en kötü performansa sahiptir. Bunun nedeni, belirli bir hata derecesine izin veren hiperdüzlemler arasındaki marjla işlemleri gerçekleştirme doğası olabilir.

Jeneratör bazında yükün bilinmesi, denizcilik şirketlerine arızaları öngörmeye, enerji verimliliğini artırmada ve bakım-tutum çalışmalarını yürütmede yardımcı olabilir (Brito vd., 2022). Jeneratör yükü bilindiğinde, yakıt tüketimi hesaplanabilir. Bu sayede yakıt tüketimi optimize edilebilmekte ve enerji verimliliği açısından adımlar atılabilmektedir (Yiğit, 2022). Yakıt tüketiminin bilinmesi, tüketimin normalden farklı olduğu durumlarda, yani enerji verimliliği değiştiğinde, jeneratör sistemindeki bir arızanın veya hatanın tespit edilmesini de sağlayabilir. Bu, taşımacılık şirketlerine öngörücü bakım faaliyetleri açısından yardımcı olabilir.

Çizelge 3.12: Jeneratör bazında algoritmaların tahmin performansları

	MAE			RMSE			MAPE		
	DJ1	DJ2	DJ3	DJ1	DJ2	DJ3	DJ1	DJ2	DJ3
DVM	1.6736	1.9411	1.6893	6.3752	4.8703	7.5162	30.865	33.814	36.241
ÇDR	1.1652	1.3124	1.1804	2.6701	3.1117	2.4007	29.597	28.877	31.195
YSA	0.9589	1.0027	0.9324	1.9204	2.1717	1.8913	34.265	24.977	29.988
DSA	0.5783	0.4025	0.5308	1.8067	1.4948	1.8733	31.714	36.591	33.773
KEK	1.4294	1.5561	1.2901	4.4118	4.4908	4.0399	34.652	32.794	35.763
RO	0.3413	0.2252	0.2892	0.4733	0.2662	0.4714	31.879	8.1517	9.9462
XGB	0.2817	0.1424	0.2926	0.4212	0.2431	0.5093	29.547	6.1015	11.184
K.Ağ.	0.2364	0.1306	0.1532	0.2455	0.2069	0.2182	17.493	5.1139	7.7481

İkinci senaryoda, kimyasal tanker gemisinin tüm jeneratörleri dikkate alınarak toplam jeneratörü gücü tahmin modeli geliştirilmiştir. Çizelge 3.13, sekiz tahmin modelinden toplam yük tahmini için simülasyon sonuçlarını göstermektedir. Modellerin aşırı öğrenme (overfitting) durumu olup olmadığını belirlemek için 5 yinelemeli çapraz doğrulama prosedürü kullanıldı. Bu süreçte eğitim veri seti her biri 200 örnek olacak şekilde beş bölüme ayrılmıştır; bu parçalardan biri doğrulama veri seti olarak belirlenmiş, diğer dördü ise model eğitiminde eğitim verisi olarak kullanılmıştır. Çapraz doğrulama işlemi beş iterasyon boyunca devam ettirilmiş ve performans değerleri Ortalama Mutlak Hata metriği ile Çizelge 3.14'te verilmiştir.

Bu durumda Derin Sinir Ağı (DNN) algoritması, 1.0866 (MAE), 2.6049 (RMSE) ve 14.728 MAPE hata performansı ile diğer tüm algoritmalarından daha iyi performans göstermiştir. İlk simülasyon çalışmasında elde edilen bulgular ışığında, jeneratör güç tahmini senaryosu için model tabanlı algoritmaların veri setinin formatı nedeniyle daha avantajlı olduğu ortaya çıkmıştır. Ayrıca simülasyon sürecinde kullanılan diğer algoritmalar arasında aşamalı öğrenme metodolojisini kullanan XGBoost algoritmasının öne çıktığı söylenebilir. Jeneratörlerin toplam yükünün tahmini olan simülasyon çalışmasının ikinci bölümünde, zor ve karmaşık sistemlerde daha verimli çalışan DSA algoritmasının diğer algoritmalara göre daha başarılı tahmin skorları elde ettiği ortaya çıkmıştır. YSA'dan farklı olarak, Derin Sinir Ağı'nda birden fazla gizli katman vardır. Bu, algoritmanın daha karmaşık problemlerde daha etkili davranmasını sağlar. Ayrıca DSA algoritması lineer olmayan sistemlerde de başarılı bir yöntemdir. Bu aşamada sistemin girdi sayısının azaltılması ÇDR, YSA, KEK, RO, XGB ve Karar Ağacı algoritmaları ile kurulan modellerin başarısını önemli ölçüde azaltmıştır. Ancak DSA ve DVM algoritmaları bu süreçte puanlarını yükseltmiştir. DSA ve DVM algoritmaları karşılaştırıldığında, ikinci simülasyonda DSA algoritmasının başarısının

önemli ölçüde arttığı tespit edilmiştir. DVM algoritmasının başarısının da arttığı ancak bu artışın tatmin edici düzeyde olmadığı görülmektedir.

Çizelge 3.13: Toplam güç tahmini simülasyon sonuçları

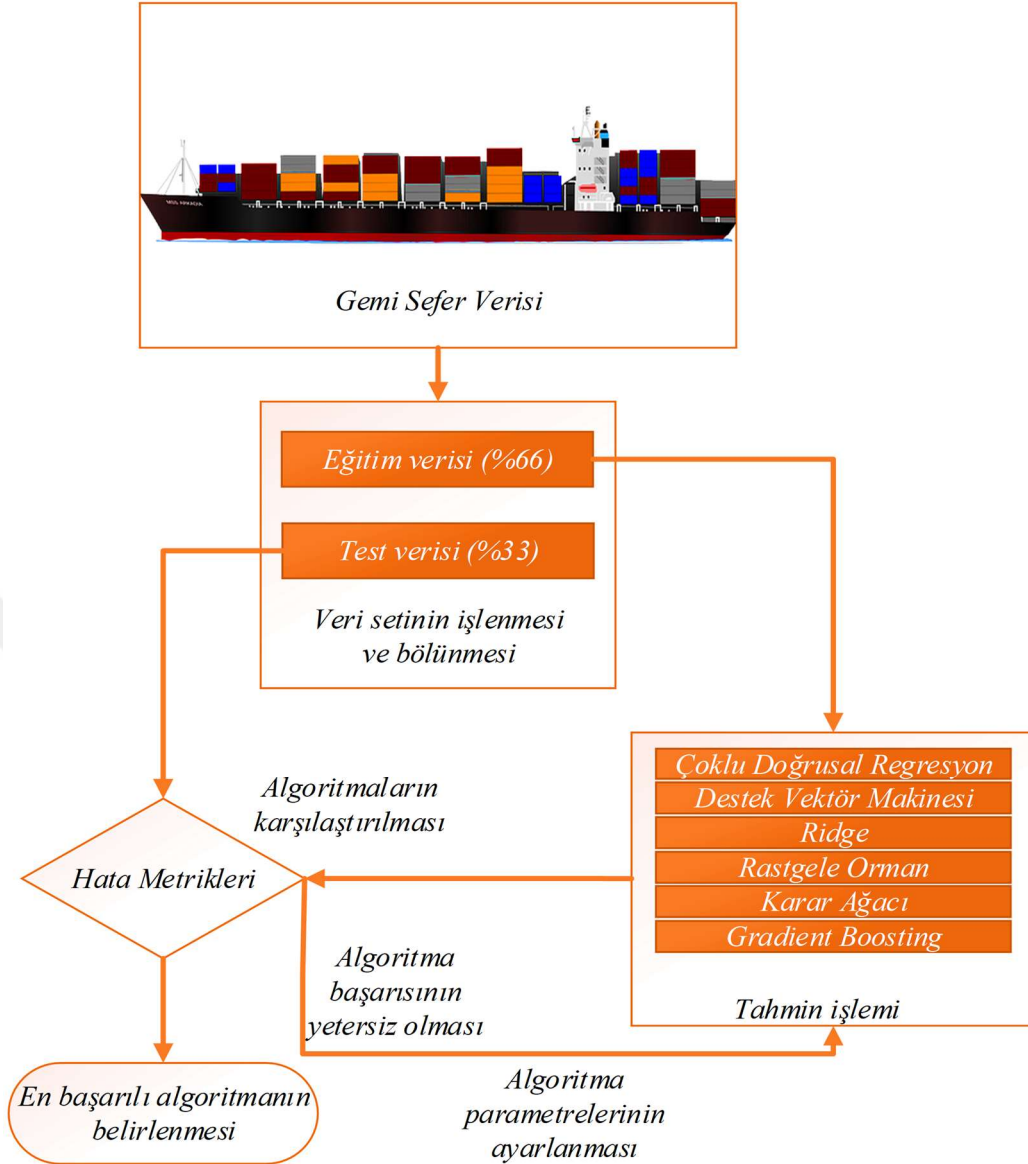
	Toplam Güç Tahmini		
	MAE	RMSE	MAPE
DVM	1.3520	8.3232	15.966
ÇDR	1.5283	5.6608	23.302
YSA	1.6575	6.1073	25.048
DSA	1.0866	2.6049	14.728
KEK	1.8220	9.6310	27.184
RO	1.3146	4.9486	14.513
XGB	1.4152	5.7916	16.805
K.Ağacı	1.4452	9.0413	19.748

Çizelge 3.14: Çapraz doğrulama işlemi simülasyon sonuçları

	Model							
	DVM	ÇDR	YSA	DSA	KEK	RO	XGB	K.Ağacı
İter. 1	1.4235	1.5813	1.7434	1.1517	1.9589	1.4257	1.4789	1.4925
İter. 2	1.4387	1.5975	1.6928	1.2146	1.9827	1.3952	1.4912	1.5014
İter. 3	1.4291	1.6124	1.7126	1.1738	1.9186	1.3573	1.4671	1.4874
İter. 4	1.4413	1.5731	1.6891	1.1513	1.8917	1.3841	1.4397	1.4731
İter. 5	1.4275	1.5629	1.6973	1.1725	1.9226	1.3619	1.4515	1.4667
Ort.	1.4320	1.5854	1.7070	1.1727	1.9349	1.3848	1.4656	1.4842

3.3 Konteyner Gemisinde Şaft Jeneratörü Gücü Tahmini Uygulaması

Bu vaka çalışmasında ticari bir gemide şaft jeneratörü elektriksel gücünün makine öğrenmesi yöntemleri ile tahmin edilmesi üzerine modeller oluşturulmuştur. Çalışma kapsamında bir konteyner gemisinden 750 günlük sefer verisi alınmıştır. Veri seti alınıp işlendikten sonra makine öğrenmesi algoritmalarının üzerinde çalışabileceği hale getirilmiştir. Bu noktada veri seti eğitim ve test verisi olarak iki kısma ayrılmış, eğitim verileri algoritmalarla öğretilerek tahmin modelleri geliştirilmiştir. Test verileri ise algoritma başarılarının tespitinde kullanılmak üzere saklanmıştır. Çalışma kapsamında şaft jeneratörü elektriksel gücü tahmini başarısını ölçebilmek adına hata metrikleri kullanılmıştır. Bu sayede algoritmaların tahmin başarıları sayısal olarak ifade edilebilmiş ve birbirleriyle karşılaştırılabilmiştir. Çalışma kapsamında yapılan işlemler Şekil 3.13'te gösterilmiştir.



Şekil 3.13: Çalışmanın metodolojisi.

Çalışmada ticari amaçla kullanılan 318 metre uzunluğa 42 metre genişliğe ve 8,4 metre drafta sahip bir konteyner gemisinin 750 günlük sefer verisi üzerinde makine öğrenmesi algoritmaları çalıştırılmıştır. Bu veri gemide yer alan çeşitli sensörlerden elde edilmiştir. Veri setinde 24 farklı değişken mevcuttur. Bu değişkenler silindir sıcaklıkları, ana makina ceket soğutma suyu sıcaklık değerleri, yakıt giriş sıcaklığı, yakıt giriş debisi, ana makina gücü, yakıt tüketimi ve şaft jeneratörü gücü gibi değerlerdir. Kullanılan veri setinin istatistiksel özeti Çizelge 3.15’te verilmiştir.

Çizelge 3.15: Veri setinin istatistiksel özeti

	Adet	Ortalama değer	En k. Değer	En b. Değer	Standart Sapma
Günlük yakıt tüketimi (t)	750	48,73	17,3	151,7	35,71
Ana makine gücü (kW)	750	10970,6	2781,4	30872	8365,2
Ceket soğutma suyu sıcaklığı (°C)	750	89,5	85,1	94,12	9,5
Ana mak. yakıt giriş sıcaklığı (°C)	750	67,8	63,9	71,74	6,51
Şaft jeneratörü gücü (kW)	750	814,76	95	1740	1317,45
...


Konteyner gemisi şaft jeneratörü elektriksel güç tahmini için öncelikle veri seti işlenip makine öğrenmesi algoritmaları için uygun hale getirilmiştir. Daha sonra bilgisayar tarafından eğitim ve test verisi olarak veri seti iki kısma ayrılmıştır. İlk kısım olan 500 satırlık eğitim verisi bölümü algoritmalara tahmin modeli oluşturulabilmesi amacıyla öğretilmiştir. Kalan 250 satırlık test verisi ise algoritmalar tarafından eğitim verisi ile kurulan modellerin başarısının incelenebilmesi adına saklanmıştır. Çalışmanın bir sonraki aşamasında algoritmalar tarafından şaft jeneratörü gücü tahmini yapılmıştır. Tahmin çalışmasının ilk safhasında bazı algoritmalar tatmin edici seviyede bir başarı sağlayamamıştır. Bu nedenle algoritmaların parametreleri optimize edilerek tahmin işlemi tekrarlanmıştır. Çalışmada elde edilen hata metrikleri Çizelge 3.16’da verilmiştir. Çalışmanın ilk safhasında optimize edilen algoritma parametreleri ise Çizelge 3.17’de görülmektedir. Algoritmaların yaptığı tahminlerin 30 günlük bir karşılaştırılması ise Şekil 3.14’te yer almaktadır.

Çizelge 3.16: Hata metrikleri

	ÇDR	DVM	R	KA	RO	GB
OMH	0,0338	0,3141	0,1889	0,2873	0,282	0,3248
KOKH	0,0973	0,4101	0,3293	0,3541	0,347	0,3944

Çizelge 3.17: Algoritma parametreleri

Algoritma	Parametre değeri
Çoklu doğrusal regresyon	pozitif=Doğru
Destek vektör makinesi	çekirdek='doğrusal'
Ridge	çözücü='svd', alpha = 0.4
Karar Ağacı	maksimum derinlik = 27
Rastgele orman	tahmin edici sayısı=76, minimum örnek bölümü = 12
Gradient Boosting	kayıp='ls'



Şekil 3.14: Algoritma tahminlerinin gerçek güç değeri ile karşılaştırılması



4. SONUÇLAR VE TARTIŞMA

Gemideki elektrik şebekesi enerjinin %15-20'sini tüketmektedir. Bu çalışmada yapılan uygulamalar ile IMO emisyon kurallarının sağlanmasına katkıda bulunulması, gemi enerji verimliliğinin artırılması ve gemi operasyonlarının iyileştirilmesi amaçlanmıştır.

Bu tez çalışmasında irdelenen problemlerde problem bazında başarılı ve başarısız algoritmalar ayrı ayrı irdelenmiştir.

Yapılan çalışmaların bir sonraki aşaması gemi elektriksel enerji verimliliğinin artırılması yönünde bir enerji yönetim modeli geliştirilmesidir. Gemideki jeneratörlerin yükünün tahmini uygulaması sayesinde jeneratörlerin üreteceği optimum yük bilinebilecek, bu sayede geliştirilecek dinamik yük tahmini yönetimi modeli sayesinde jeneratörlerin operasyonlar esnasında çökmemesi ve böyle durumlarda operasyonların durması, aksaması, gemide kullanılan ekipmanda hasarlar oluşması, seferin aksaması gibi maddi durumlar dışında personelin iş güvenliği açısından yaşayacağı sıkıntılı durumların da önüne geçilebilecektir. Şaft jeneratörünün gücünün bilinmesi sayesinde seyirdeki elektriksel güç optimizasyonu yapılabilir. Bu durumda fazladan güç üretilmesi yerine dinamik bir güç üretimi modeli sayesinde enerji verimliliğinin artmasına katkıda bulunulabilir. Bu çalışmalar yardımıyla ve alternatif enerji kaynakları sayesinde geliştirilecek hibrit bir enerji yönetim modeli sayesinde gemideki elektriksel enerji verimliliği çok daha yüksek oranda artırılabilir. Bu sayede denizcilik sektörünün sürdürülebilirliği artacak, denizcilik kaynaklı çevre kirliliğinin azalması sağlanabilecektir. Yapılan üç adet vaka çalışması ayrıntılı olarak irdelenecek olursa;

4.1 Konteyner Gemisindeki Elektriksel Gücün Tahmini Uygulaması

Denizcilik sektöründe, rüzgar hızı, dalga yüksekliği, rüzgar yönü, gemi tespiti, dalga yönü, gemi hızı, gemi yakıt tüketimi gibi alanlarda veri odaklı algoritma teknikleri kullanılmıştır. gemi elektrik güç tahmini çalışmasında, konteyner gemisinin ana motor

gücü ve yakıt tüketimini tahmin etmede 9 farklı veri odaklı algoritma etkili olmuştur. Bu çalışmada öncelikle literatürde sıklıkla kullanıldığı belirlenen yöntemler incelenmiş, daha sonra klasik algoritmalar dışında çalışmanın özgünlüğünü artıracakları düşünülen yöntemler eklenmiş ve son olarak DNN algoritması, bu özel vaka çalışması için incelendi. Bu yöntemler aynı zamanda araştırmanın özgünlüğünü zenginleştirmiş ve artırmıştır. Bu çalışmada gerçek sefer verileri kullanılmış ve enerji verimliliği hesaplamalarında gerekli olan ana makine gücü ve yakıt tüketimi değişkenlerinin karmaşık formüller yerine gerçek veri seti kullanılarak belirlenmesi için uygulanabilir bir yaklaşım önerilmiştir. Güç tahmini için simülasyonlar, Derin Sinir Ağı tekniğinin diğer sistemlerden daha iyi performans gösterdiğini ortaya çıkarmıştır. Çoklu Doğrusal Regresyon yaklaşımı ise yakıt tüketimi durumunda daha iyi performans göstermiştir. Bu bulgular, veriye dayalı yöntemlerin gemilerdeki ana makine shaft gücünü ve yakıt tüketimini doğru bir şekilde tahmin edebildiğini gösterdi.

İlgili çizelgeler karşılaştırıldığında, algoritmaların ilk simülasyonlarda tatmin edici sonuçlar vermediği açıktır. Güç tahmini ile ilgili simülasyonlar için Ridge algoritmasının ilk simülasyonlarda 1.237432 RMSE, 1.512512 MAE ve 0.659222 R^2 değerlerine ulaşırken, parametre optimizasyonu sayesinde algoritmanın 0.500782 RMSE, 0.517583 MAE ve 0.999965 R^2 hata metriği değerlerine ulaştığı söylenebilir. Lasso modeli incelendiğinde ilk simülasyonlar sonucunda 1.264545 RMSE, 1.127521 MAE, 0.775724 R^2 elde edilebilirken, parametre optimizasyonu sonrasında bu değerler 0.299883 RMSE, 0.260465 MAE, 0.999971 R^2 olarak güncellenmiştir. İlk simülasyonlarda XGradient Boosting modelinde 0.009053 RMSE, 0.095750 MAE, 0.993211 R^2 olan hata metriği değerleri 0.129474 RMSE, 0.114669 MAE, 0.999871 R^2 'ye ulaştı. Elastic Net yöntemi için bir karşılaştırma yapılırsa; 1.203749 RMSE, 1.097155 MAE, 0.647199 R^2 değerlerinin 0.082140 RMSE, 0.154781 MAE, 0.999991 R^2 'ye ulaştığı söylenebilir. YSA algoritmasının optimizasyon öncesi ve sonrası performans değerleri karşılaştırıldığında 0.801357 RMSE, 0.892518 MAE ve 0.703928 R^2 değerlerinin 0.001547 RMSE, 0.001621 MAE ve 0.999992 R^2 olarak güncellendiği görülmektedir. DNN algoritmasının benzetim sonuçları karşılaştırıldığında 0.684111 RMSE, 0.827112 MAE, 0.724955 R^2 hata metrik değerlerinin 0.000001 RMSE, 0.000987 MAE, 0.999999 R^2 'ye ulaştığı söylenebilir. Benzer şekilde, yakıt tüketimi tahmini simülasyon sonuçları incelendiğinde,

algoritmaların parametre ayarlama işleminden sonra daha başarılı sonuçlar verdiği söylenebilir.

Çalışma sınırlılıklar açısından değerlendirildiğinde, denizcilik sektörü koşulları nedeniyle veri setleri gerçek zamanlı olarak elde edilememekte ve çok sayıda örneklemeden oluşmamaktadır. Veriye dayalı algoritmalar ile veri kümesi çok daha fazla sayıda örnek içeriyorsa, daha güçlü modeller oluşturulabilir. Ayrıca mevcut denizcilik teknolojisi ile kıtalararası sefer yapan ticari gemilerden anlık veri elde etmenin zorluğu da önümüzdeki yıllarda çözülmesi gereken bir sorun olarak öne çıkıyor. Bu sorun da çözüldüğünde denizcilikte gerçek zamanlı uygulamaların kullanımı yaygınlaştırılabilir. Bu sayede veriye dayalı yaklaşımlarla gerçek zamanlı güç ve yakıt tüketimi tahmini ve optimizasyon çalışmaları yapılabilir.

Konteyner gemileri, yılda 200-250 gün aktif seferlerde sefer yapar ve ticari ömürleri bakım şartlarına göre değişmekle birlikte normalde 30 ile 40 yıl arasındadır. Bu çalışma için toplanan veri seti, geminin ticari ömrünün yaklaşık %10'unu temsil etmektedir. Veri ede etme ile ilgili teknolojilerin kullanımı yaygınlaştıkça veri setlerinin sayısı ve açıklayıcılığı daha da artacaktır ve bu da denizcilik sektörü açısından umut vericidir. Veri seti, geminin tahrik gücünün ve yakıt tüketiminin, geminin gerçek sefer koşullarına dayalı olarak tahmin edildiği çeşitli durumları içermektedir ve bu değişkenlerin, geminin bu aşırı koşullarda karşılaşmalarına dayanarak bile hesaplanabileceği kanıtlanmıştır. Gelecekteki çalışmalarda geliştirilen modelin güvenilirliğini ve anlaşılabilirliğini artırmak için gemilerin sayısı ve türleri genişletilecektir. Ayrıca, gemide kullanılan jeneratörlerde yük tahmini için veriye dayalı metodolojiler uygulanarak, geminin elektrik yükü doğru bir şekilde incelenebilir ve jeneratörlerdeki arızalar önceden önlenir.

4.2 Kimyasal Tanker Gemisinde Jeneratör Yükleri Tahmini Uygulaması

Jeneratörler, bir gemide ana makineden sonra en büyük ikinci yakıt tüketicisidir enerji verimliliğinin artırılması adına önemli bir bileşen haline gelmektedir. Jeneratörlerin elektrik yükü doğru bir şekilde tahmin edilemez ve planlanamazsa ani yükler altında da elektriksel arızalar meydana gelebilir. Bu sorun, geminin operasyonlarını durdurmaya zorlayabilir ve geminin ağır hasar görmesine ve iş kazalarına neden olabilir. Bu çalışmada, bir ticari geminin jeneratörlerindeki yükü tahmin etmek için

veriye dayalı algoritmalar kullanılmıştır. Simülasyon sonuçları, Karar Ağacı modelinin 0.2364, 0.1306 ve 0.1532 MAE puanları, 0.2455, 0.2069 ve 0.2182 RMSE puanları, 17.493, 5.1139 ve 7.7481 MAPE puanları (dizel jeneratörler: sırasıyla DG1, DG2 ve DG3) ile jeneratör yükü tahmini için en başarılı yöntem olduğunu göstermiştir. Derin Sinir Ağı modeli ise 1.0866 MAE, 2.6049 RMSE ve 14.728 MAPE skorları ile toplam yük tahmin durumu için en başarılı yöntem olmuştur. Modellerin aşırı uyum durumuna (overfitting) sahip olup olmadığını belirlemek için kullanılan 5-Katlamalı Çapraz Doğrulama prosedürü, aşırı uyum durumu olmadığını ortaya çıkarmıştır.

Elde edilen sonuçlardan veriye dayalı algoritmaların gemi jeneratörlerindeki elektrik yükünü tahmin etmede yararlı olabileceği sonucuna varılabilir. Bu çalışmada geliştirilen tahmin modellerinin gelecekte gemi mikro şebeke kontrolüne enjekte edilmesi ile gemi elektrik şebekesinde yaşanan ani yüklerden kaynaklanan problemlerin önüne geçilebilir. Bu, elektrik arızalarına karşı önlem alınmasını, olası arızaların önlenmesini, olası ek bakım maliyetlerinin azaltılmasını ve enerji verimliliğinin artırılmasını mümkün kılacaktır.

4.3 Konteyner Gemisinde Şaft Jeneratörü Gücü Tahmini Uygulaması

Yapılan bu çalışmada, konteyner gemisinde şaft jeneratörünün güç tahmini veriye dayalı yöntemler yardımıyla gerçekleştirilmiştir. Şaft jeneratörü gemilerin genelde seyir sırasında gerekli olan elektriksel gücü karşılamak adına ana makineden bağlantı elemanları aracılığıyla alınan mekanik gücün bir jeneratör vasıtasıyla elektriksel güce çevrilmesi sayesinde seyir sırasında enerji verimliliğine katkıda bulunan bir bileşendir. Buradaki güç aynı zamanda sefer sırasında kullanılan operasyonel güçtür. Bir diğer deyişle, yapılan çalışma sonucunda gemide sefer sırasındaki gerekli olan operasyonel güç tahmin edilmiştir.

Tahmin işlemi sonucunda Çoklu Doğrusal Regresyon yönteminin tahmin sonuçlarından görüleceği üzere bu veri seti özelinde şaft jeneratörü elektriksel gücünü tahmin etmede ele alınan diğer makine öğrenmesi algoritmalarından daha başarılı olduğu ortaya çıkmıştır.

Yapılan tahminler gemilerde şaft jeneratörünün elektriksel gücünün tahmininde makine öğrenmesi algoritmalarının işlevsel olabileceğini göstermiştir. Ayrıca makine öğrenmesi yöntemleri ile kurulan tahmin modeli sayesinde elektriksel yükün önceden

tahmin edilebileceđi, bu sayede gemide sefer esnasında ani bir yüklenme için oluşabilecek elektriksel çökmelere karşı önlem alınabileceđi ve elektriksel yük davranışının tahmin edilebilmesi sayesinde fazladan güç üretmek yerine yapılacak bir güç üretimi optimizasyonu sayesinde elektriksel güç üretmek için harcanan yakıt miktarından tasarruf edilebileceđi ve sürdürülebilir bir denizcilik için ve Uluslararası Denizcilik Örgütü tarafından konulan emisyon kurallarını sağlamaya yönelik olumlu bir adım atılabileceđi bulguları elde edilmiştir.





KAYNAKLAR

- Ahlgren, F., Mondejar, M. E., Thern, M.** (2019). "Predicting dynamic fuel oil consumption on ships with automated machine learning". *Energy Procedia*, 158, 6126–6131.
- Ahmadabadi, A. A., Jafari, H., Shoorian, S., Moradi, Z.** (2023). "The application of artificial neural network in material identification by multi-energy photon attenuation technique". *Nuclear Inst. and Methods in Physics Research, A*, 1051(January), 168203.
- Aksoy, N., Genc, I.** (2023). "Predictive models development using gradient boosting based methods for solar power plants". *Journal of Computational Science*, 67(November 2022), 101958.
- Alonso, J. M., Alvarruiz, F., Desantes, J. M., Hernández, L., Hernández, V., Moltó, G.** (2007). "Combining neural networks and genetic algorithms to predict and reduce diesel engine emissions". *IEEE Transactions on Evolutionary Computation*, 11(1), 46–55.
- Alzahrani, A., Ferdowsi, M., Shamsi, P., Dagli, C. H.** (2017). "Modeling and Simulation of Microgrid". *Procedia Computer Science*, 114, 392–400.
- Anguita, D., Ghio, A., Oneto, L., Ridella, S.** (2012). "In-sample and out-of-sample model selection and error estimation for support vector machines". *IEEE Transactions on Neural Networks and Learning Systems*, 23(9), 1390–1406.
- Assaf, A. G., Tsionas, M., Tasiopoulos, A.** (2019). "Diagnosing and correcting the effects of multicollinearity: Bayesian implications of ridge regression". *Tourism Management*, 71(October 2018), 1–8.
- Babarinde, T. O., Madyira, D. M.** (2022). "Dataset and ANFIS model prediction of the performance of graphene nano-LPG in domestic refrigerator system". *Data in Brief*, 44, 108548.
- Baldwin, S. A., Larson, M. J.** (2017). "An introduction to using Bayesian linear regression with clinical data". *Behaviour Research and Therapy*, 98, 58–75.
- Bao, J., Li, Y., Zheng, G., Zhang, P.** (2021). "Exploring into contributing factors to young seafarer turnover: Empirical evidence from China". *Journal of Navigation*, 74(4), 914–930.
- Bazari, Z., Longva, T.** (2011). "Assessment of IMO Mandated Energy Efficiency Measures for International Shipping". Lloyd's Register, (MEPC 63/INF.2 (Annex)).

- Brito, L. C., Susto, G. A., Brito, J. N., Duarte, M. A. V.** (2022). "An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery". *Mechanical Systems and Signal Processing*, 163(March 2021), 108105.
- C. Saunders, A. Gammerman, V. V.** (1998). "Ridge Regression Learning Algorithm in Dual Variables". In: Proceedings of the Fifteenth International Conference on Machine Learning (ss. 515–521). Morgan Kaufmann Publishers Inc.
- Ćalasan, M., Abdel Aleem, S. H. E., Zobaa, A. F.** (2020). "On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function". *Energy Conversion and Management*, 210(January), 112716.
- Caravaggi, P., Leardini, A., Giacomozzi, C.** (2016). "Multiple linear regression approach for the analysis of the relationships between joints mobility and regional pressure-based parameters in the normal-arched foot". *Journal of Biomechanics*, 49(14), 3485–3491.
- Chen, Z., Hu, J., Qiu, X., Jiang, W.** (2022). "Kernel ridge regression-based TV regularization for motion correction of dynamic MRI". *Signal Processing*, 197, 108559.
- Cheng, C. L., Shalabh, Garg, G.** (2014). "Coefficient of determination for multiple measurement error models". *Journal of Multivariate Analysis*, 126, 137–152.
- Cheng, X., Shen, X., Wang, X., Liang, K.** (2023). "A deep neural network-based method for solving obstacle problems". *Nonlinear Analysis: Real World Applications*, 72, 103864.
- Cheng, Y., Zhang, W.** (2018). "Concise deep reinforcement learning obstacle avoidance for underactuated unmanned marine vessels". *Neurocomputing*, 272, 63–73.
- Choi, B., Lee, J. H., Kim, D. H.** (2008). "Solving local minima problem with large number of hidden nodes on two-layered feed-forward artificial neural networks". *Neurocomputing*, 71(16–18), 3640–3643.
- Coelho, V. N., Coelho, I. M., Coelho, B. N., Reis, A. J. R., Enayatifar, R., Souza, M. J. F., Guimarães, F. G.** (2016). "A self-adaptive evolutionary fuzzy model for load forecasting problems on smart grid environment". *Applied Energy*, 169, 567–584.
- Coraddu, A., Oneto, L., Baldi, F., Anguita, D.** (2017). "Vessels fuel consumption forecast and trim optimisation: A data analytics perspective". *Ocean Engineering*, 130(September 2015), 351–370.
- Das, L., Sivaram, A., Venkatasubramanian, V.** (2020). "Hidden representations in deep neural networks: Part 2. Regression problems". *Computers and Chemical Engineering*, 139, 106895.
- Davoudi, F., Freeman, S. A., Mosher, G. A.** (2019). "Evaluating machine learning performance in predicting injury severity in agribusiness industries". *Safety Science*, 117(July 2018), 257–262.

- de Myttenaere, A., Golden, B., Le Grand, B., Rossi, F.** (2016). "Mean Absolute Percentage Error for regression models". *Neurocomputing*, 192, 38–48.
- Dehghani, A. A., Movahedi, N., Ghorbani, K., Eslamian, S.** (2023). "Decision tree algorithms". *Handbook of Hydroinformatics* (ss. 171–187). Elsevier.
- Deo, R. C., Ahmed, A. A. M., Casillas-Pérez, D., Pourmousavi, S. A., Segal, G., Yu, Y., Salcedo-Sanz, S.** (2023). "Cloud cover bias correction in numerical weather models for solar energy monitoring and forecasting systems with kernel ridge regression". *Renewable Energy*, 203(December 2022), 113–130.
- Dong, J., Chen, Y., Yao, B., Zhang, X., Zeng, N.** (2022). "A neural network boosting regression model based on XGBoost". *Applied Soft Computing*, 125, 109067.
- El, S., Kharbach, J., Hammouch, Z., Rezzouk, A., Ouazzani, M.** (2023). "State of charge estimation of an electric vehicle's battery using Deep Neural Networks: Simulation and experimental results". *Journal of Energy Storage*, 62(February), 106904.
- Elidolu, G., Uyanık, T., Karabiyık, P., Arslanoğlu, Y.** (2020). "Hull cleaning effects on CO₂ emissions: estimation with machine learning methods". 5th International Mediterranean Science and Engineering Congress (IMSEC 2020), (October), 200–208.
- Ellingsen, O., Aasland, K. E.** (2019). "Digitalizing the maritime industry: A case study of technology acquisition and enabling advanced manufacturing technology". *Journal of Engineering and Technology Management - JET-M*, 54(October 2018), 12–27.
- Feng, Y., Duives, D., Daamen, W., Hoogendoorn, S.** (2020). "Data collection methods for studying pedestrian behaviour: A systematic review". *Building and Environment*, 187(July 2020), 107329.
- Forrester, P. J., Zhang, J.** (2020). "Parametrising correlation matrices". *Journal of Multivariate Analysis*, 178, 104619.
- Frías-Paredes, L., Mallor, F., Gastón-Romeo, M., León, T.** (2018). "Dynamic mean absolute error as new measure for assessing forecasting errors". *Energy Conversion and Management*, 162(December 2017), 176–188.
- Friedman, J. H.** (2001). "Greedy function approximation: A gradient boosting machine.". *The Annals of Statistics*, 29(5), 1189–1232.
- Futagami, K., Fukazawa, Y., Kapoor, N., Kito, T.** (2021). "ScienceDirect Pairwise acquisition prediction with SHAP value interpretation". *The Journal of Finance and Data Science*, 7, 22–44.
- Gao, Y., Zheng, B., Chen, G., Lee, W. C., Lee, K. C. K., Li, Q.** (2009). "Visible reverse k-nearest neighbor query processing in spatial databases". *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1314–1327.
- Ghenai, C., Ahmad, F. F., Rejeb, O., Bettayeb, M.** (2022). "Artificial neural networks for power output forecasting from bifacial solar PV system with enhanced building roof surface Albedo". *Journal of Building Engineering*, 56(June), 104799.

- Giri, S., Kang, Y., MacDonald, K., Tippet, M., Qiu, Z., Lathrop, R. G., Obropta, C. C.** (2023). "Revealing the sources of arsenic in private well water using Random Forest Classification and Regression". *Science of the Total Environment*, 857(October 2022), 159360.
- Gkerekos, C., Lazakis, I., Theotokatos, G.** (2019). "Machine learning models for predicting ship main engine Fuel Oil Consumption: A comparative study". *Ocean Engineering*, 188(January), 106282.
- Glavic, M.** (2019). "(Deep) Reinforcement learning for electric power system control and related problems: A short review and perspectives". *Annual Reviews in Control*, 48, 22–35.
- Goossens, W. R. A.** (2019). "Review of the empirical correlations for the drag coefficient of rigid spheres". *Powder Technology*, 352, 350–359.
- Gu, X., Han, Y., Yu, J.** (2020). "A novel lane-changing decision model for autonomous vehicles based on deep autoencoder network and XGBoost". *IEEE Access*, 8, 9846–9863.
- Gupta, R., Pierdzioch, C., Salisu, A. A.** (2022). "Oil-price uncertainty and the U.K. unemployment rate: A forecasting experiment with random forests using 150 years of data". *Resources Policy*, 77(December 2021), 102662.
- Haque, M., Shaheed, M. N., Choi, S.** (2018). "Deep Learning Based Micro-Grid Fault Detection and Classification in Future Smart Vehicle". 2018 IEEE Transportation and Electrification Conference and Expo, California, ITEC 2018, 201–206.
- Hirsch, C., Neumann, M., Schmidt, V.** (2023). "Asymptotic properties of one-layer artificial neural networks with sparse connectivity". *Statistics and Probability Letters*, 193, 109698.
- Howlader, A. M., Patel, D., Gammariello, R.** (2023). "Data-driven approach for instantaneous vehicle emission predicting using integrated deep neural network". *Transportation Research Part D: Transport and Environment*, 116(January), 103654.
- Jadhav, D. A.** (2021). "An enhanced and secured predictive model of Ada-Boost and Random-Forest techniques in HCV detections". *Materials Today: Proceedings*, 51, 186–195.
- Jain, N., Jana, P. K.** (2023). "LRF: A logically randomized forest algorithm for classification and regression problems". *Expert Systems with Applications*, 213(September 2021), 119225.
- Jia, J., Dong, H.** (2018). "Research on ship power plant simulation system based on LabVIEW and MATLAB mixed programming". Proceedings of the 2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2017, 2018-Janua, 72–75.
- Jiang, B., Ma, X., Lu, Y., Li, Y., Feng, L., Shi, Z.** (2019). "Ship detection in spaceborne infrared images based on Convolutional Neural Networks and synthetic targets". *Infrared Physics and Technology*, 97(December 2018), 229–234.

- Jiang, C. X., Jing, Z. X., Cui, X. R., Ji, T. Y., Wu, Q. H.** (2018). "Multiple agents and reinforcement learning for modelling charging loads of electric taxis ☆", *Applied Energy* 222(April), 158–168.
- Joseph, R. V., Mohanty, A., Tyagi, S., Mishra, S., Satapathy, S. K., Mohanty, S. N.** (2022). "A hybrid deep learning framework with CNN and Bi-directional LSTM for store item demand forecasting". *Computers and Electrical Engineering*, 103(July), 108358.
- Kaneko, H.** (2023). "Local interpretation of nonlinear regression model with k-nearest neighbors". *Digital Chemical Engineering*, 6(December 2022), 100078.
- Karunasingha, D. S. K.** (2022). "Root mean square error or mean absolute error? Use their ratio as well". *Information Sciences*, 585, 609–629.
- Khan, S., Paul, D., Momtahan, P., Aloqaily, M.** (2018). "Artificial intelligence framework for smart city microgrids: State of the art, challenges, and opportunities". 2018 3rd International Conference on Fog and Mobile Edge Computing, FMEC 2018, 283–288.
- Khanmohammadi, S., Tutun, S., Kucuk, Y.** (2016). "A New Multilevel Input Layer Artificial Neural Network for Predicting Flight Delays at JFK Airport". *Procedia Computer Science*, 95, 237–244.
- Kim, D., Lee, S., Lee, J.** (2020). "Data-driven prediction of vessel propulsion power using support vector regression with onboard measurement and ocean data". *Sensors* (Switzerland), 20(6).
- Kim, J.-H., Park, Y.-J., Yi, C.-Y., Lee, D.-E.** (2023). "Stochastic flame locating method hybridizing Kalman filter and deep neural network for rapid fire response at construction sites". *Journal of Building Engineering*, 66(November 2022), 105967.
- Kim, K. S., Roh, M. II.** 2020. "Iso 15016:2015-based method for estimating the fuel oil consumption of a ship". *Journal of Marine Science and Engineering*, 8(10), 1–18.
- Kim, S., Kim, H.** (2016). "A new metric of absolute percentage error for intermittent demand forecasts". *International Journal of Forecasting*, 32(3), 669–679.
- Leifsson, L. T., Sævarsdóttir, H., Sigurdsson, S. T., Vésteinsson, A.** (2008). "Grey-box modeling of an ocean vessel for operational optimization". *Simulation Modelling Practice and Theory*, 16(8), 923–932.
- Li, D., Gu, M., Liu, S., Sun, X., Gong, L., Qian, K.** (2022). "Continual learning classification method with the weighted k-nearest neighbor rule for time-varying data space based on the artificial immune system". *Knowledge-Based Systems*, 240, 108145.
- Ling, H., Qian, C., Kang, W., Liang, C., Chen, H.** (2019). "Combination of Support Vector Machine and K-Fold cross validation to predict compressive strength of concrete in marine environment". *Construction and Building Materials*, 206, 355–363.

- Liu, C., Lin, B., Lai, J., Miao, D.** (2022). "An improved decision tree algorithm based on variable precision neighborhood similarity". *Information Sciences*, 615, 152–166.
- Liu, M., Zhou, Q., Wang, X., Yu, C., Kang, M.** (2020). "Voyage performance evaluation based on a digital twin model". *IOP Conference Series: Materials Science and Engineering*, 929(1).
- Liu, X., Tao, W., Pan, Z.** (2022). "A convergence analysis of Nesterov's accelerated gradient method in training deep linear neural networks". *Information Sciences*, 612, 898–925.
- Liu, Y., Li, Y., Huang, Y., Zhang, J., Ding, J., Zeng, Q., ... Lu, G.** (2022). "Prediction of Catheter-Associated Urinary Tract Infections Among Neurosurgical Intensive Care Patients: A Decision Tree Analysis". *World Neurosurgery*, 170, 123–132.
- Liu, Z., Gao, J., Xu, L., Jia, P., Pan, D., Xue, W.** (2022). "Electromagnetic Fusion Underwater Positioning Technology Based on ElasticNet Regression Method". *In* 2022 IEEE 10th International Conference on Information, Communication and Networks (ICICN) (ss. 121–126). IEEE.
- Lloyd, R., Rebow, M.** (2018). "Data Driven Prediction Model (DDPM) for Server Inlet Temperature Prediction in Raised-floor Data Centers". *Proceedings of the 17th InterSociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems, ITherm 2018*, 716–725.
- Loce, R. P., Dougherty, E. R.** (1995). "Mean-absolute-error representation and optimization of computational-morphological filters". *Graphical Models and Image Processing*.
- Luíza da Costa, N., Dias de Lima, M., Barbosa, R.** (2021). "Evaluation of feature selection methods based on artificial neural network weights". *Expert Systems with Applications*, 168(March 2020).
- Lundby, E. T. B., Rasheed, A., Gravdahl, J. T., Halvorsen, I. J.** (2023). "Sparse deep neural networks for modeling aluminum electrolysis dynamics". *Applied Soft Computing*, 134, 109989.
- Magalhães, D., Lima, R. H. R., Pozo, A.** (2023). "Creating deep neural networks for text classification tasks using grammar genetic programming". *Applied Soft Computing*, 135, 110009.
- Mayr, A., Weigelt, M., Masuch, M., Meiners, M., Hüttel, F., Franke, J.** (2018). "Application Scenarios of Artificial Intelligence in Electric Drives Production". *Procedia Manufacturing*, 24, 40–47.
- McKenzie, J.** (2011). "Mean absolute percentage error and bias in economic forecasting". *Economics Letters*, 113(3), 259–262.
- Melkumova, L. E., Shatskikh, S. Y.** (2017). "Comparing Ridge and LASSO estimators for data analysis". *Procedia Engineering*, 201, 746–755.
- Mell, L., Rey, V., Schoefs, F.** (2023). "Support vectors machines for the estimation of probability of failure: Multifidelity classifiers built from a posteriori discretization error estimators". *Structural Safety*, 102(October 2022), 102321.

- Mumcu, Y. K., Kayar, M., Bulur, Ö. C.** (2022). "An application of Artificial Neural Network solution in the apparel industry for Job distribution to subcontractors". *Advances in Engineering Software*, 174(August).
- Nakai, T., Nishimoto, S.** (2023). "Artificial neural network modelling of the neural population code underlying mathematical operations". *NeuroImage*, 270(February), 119980.
- Nethra Betgeri, S., Reddy Vadyala, S., Matthews, J. C., Madadi, M., Vladeanu, G.** (2023). "Wastewater pipe condition rating model using K- Nearest Neighbors". *Tunnelling and Underground Space Technology*, 132(December 2022), 104921.
- Nhat-duc, H., Van-duc, T.** (2023). "Automation in Construction Comparison of histogram-based gradient boosting classification machine, random Forest, and deep convolutional neural network for pavement raveling severity classification". *Automation in Construction*, 148(June 2022), 104767.
- Nhat-Duc, H., Van-Duc, T.** (2023). "Comparison of histogram-based gradient boosting classification machine, random Forest, and deep convolutional neural network for pavement raveling severity classification". *Automation in Construction*, 148(November 2022), 104767.
- Ogunbo, J. N., Alagbe, O. A., Oladapo, M. I., Shin, C.** (2020). "N-hidden layer artificial neural network architecture computer code: geophysical application example". *Heliyon*, 6(6), e04108.
- Pagoropoulos, A., Møller, A. H., McAloone, T. C.** (2017). "Applying Multi-Class Support Vector Machines for performance assessment of shipping operations: The case of tanker vessels". *Ocean Engineering*, 140(May), 1–6.
- Patonai, Z., Kicsiny, R., Géczi, G.** (2022). "Multiple linear regression based model for the indoor temperature of mobile containers". *Heliyon*, 8(12).
- Petersen, J. P., Jacobsen, D. J., Winther, O.** (2012). "Statistical modelling for ship propulsion efficiency". *Journal of Marine Science and Technology*, 17(1), 30–39.
- Prousalidis, J. M., Xanthopoulos, E., Voutzoulidis, K.** (2009). "Reactive power sharing in ship energy systems with shaft generators". Proceedings of the Institute of Marine Engineering, *Science and Technology Part A: Journal of Marine Engineering and Technology*, 4177(13), 21–38.
- Quondam-Antonio, S., Riganti-Fulginei, F., Laudani, A., Lozito, G. M., Scorretti, R.** (2023). "Deep neural networks for the efficient simulation of macro-scale hysteresis processes with generic excitation waveforms". *Engineering Applications of Artificial Intelligence*, 121(March 2022), 105940.
- Rajasekaran, S., Suresh, D., Vijayalakshmi Pai, G. A.** (2002). "Sequential learning artificial fuzzy neural networks (SLAFNN) with single hidden layer". *Neurocomputing*, 42(1–4), 287–310.
- Ren, L., Zhang, P.** (2018). "Generalized Microgrid Power Flow". *IEEE Transactions on Smart Grid*, 9(4), 3911–3913.

- Rožić, N., Chiaraluce, F., Radić, J.** (2011). "Analysis of the correlation coefficient between component noise squared norms for OFDM systems". *IEEE Signal Processing Letters*, 18(5), 311–314.
- Sanjika Devi, R. V., Bindu, K. R., Kurup, D. G.** (2022). "Behavioral modeling and digital predistortion of RF power amplifiers based on time-delay kernel ridge regression". *AEU - International Journal of Electronics and Communications*, 152(December 2021), 154239.
- Sathe, A. M., Upadhye, N. S., Wylomańska, A.** (2023). "Forecasting of symmetric α -stable autoregressive models by time series approach supported by artificial neural networks". *Journal of Computational and Applied Mathematics*, 425, 115051.
- Saud, S., Jamil, B., Upadhyay, Y., Irshad, K.** (2020). "Performance improvement of empirical models for estimation of global solar radiation in India: A k-fold cross-validation approach". *Sustainable Energy Technologies and Assessments*, 40(June), 100768.
- Schäfers, P., Mütze, A., Nyhuis, P.** (2019). "Integrated Concept for Acquisition and Utilization of Production Feedback Data to Support Production Planning and Control in the Age of Digitalization". *Procedia Manufacturing*, 31, 225–231.
- Seal, H. L.** (1967). "Studies in the history of probability and statistics. XV. The historical development of the Gauss linear model.". *Biometrika*, 54(1), 1–24.
- Silionis, N. E., Anyfantis, K. N.** (2023). "Data-driven probabilistic quantification and assessment of the prediction error model in damage detection applications". *Probabilistic Engineering Mechanics*, 71(December 2022), 103412.
- Singh Kushwah, J., Kumar, A., Patel, S., Soni, R., Gawande, A., Gupta, S.** (2022). "Comparative study of regressor and classifier with decision tree using modern tools". *Materials Today: Proceedings*, 56, 3571–3576.
- Sinha, K., Uddin, Z., Kawsar, H. I., Islam, S., Deen, M. J., Howlader, M. M. R.** (2023). "Analyzing chronic disease biomarkers using electrochemical sensors and artificial neural networks". *Trends in Analytical Chemistry*, 158, 116861.
- Smola, A. J., Schölkopf, B.** (2004), "A tutorial on support vector regression". *Statistics and Computing*. 14, pages199–222 2004.
- Sobolewski, R. A., Tchakorom, M., Couturier, R.** (2023). "Gradient boosting-based approach for short- and medium-term wind turbine output power prediction". *Renewable Energy*, 203(November 2022), 142–160.
- Srinivasan, S., Deepalakshmi, P.** (2023). "ENetRM: ElasticNet Regression Model based malicious cyber-attacks prediction in real-time server". *Measurement: Sensors*, 25(November 2022), 100654.
- Thanki, R.** (2023). "A deep neural network and machine learning approach for retinal fundus image classification". *Healthcare Analytics*, 3(December 2022), 100140.

- Trucco, P., Cagno, E., Ruggeri, F., Grande, O.** (2008). "A Bayesian Belief Network modelling of organisational factors in risk analysis: A case study in maritime transportation". *Reliability Engineering and System Safety*, 93(6), 845–856.
- Tso, G. K. F., Yau, K. K. W.** (2007). "Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks". *Energy*, 32(9), 1761–1768.
- Uyanık, T.** (2021). "Ticari gemilerde operasyonel elektriksel gücün tahmininde makine öğrenmesi yaklaşımı: şaft jeneratörü güç tahmini uygulaması". *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, (September 2021), 0–3.
- Uyanık, T., Arslanoglu, Y., Kalenderli, O.** (2019). "Ship Fuel Consumption Prediction with Machine Learning". 4th International Mediterranean Science and Engineering Congress, (April), 1–7.
- Uyanık, T., Karatuğ, Ç., Arslanoğlu, Y.** (2020). "Machine learning approach to ship fuel consumption: A case of container vessel". *Transportation Research Part D: Transport and Environment*, 84.
- Vettor, R., Guedes Soares, C.** (2022). "Reflecting the uncertainties of ensemble weather forecasts on the predictions of ship fuel consumption". *Ocean Engineering*, 250, 111009.
- Wang, D., Thun, S., Lindberg, U., Jiang, L., Trygg, J., Tysklind, M.** (2022). "Towards better process management in wastewater treatment plants: Process analytics based on SHAP values for tree-based machine learning methods", 301(June 2021). *Journal of Environmental Management* 301, 113941
- Wang, H., Lei, Z., Zhang, X., Zhou, B., Peng, J.** (2019). "A review of deep learning for renewable energy forecasting". *Energy Conversion and Management*, 198(July), 111799.
- Wang, R., Wang, L., Zhang, J., He, M., Xu, J.** (2022). "XGBoost Machine Learning Algorithm Performed Better Than Regression Models in Predicting Mortality of Moderate-to-Severe Traumatic Brain Injury". *World Neurosurgery*, 163, e617–e622.
- Wang, S., Chen, H.** (2019). "A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network". *Applied Energy*, 235(March 2018), 1126–1140.
- Wang, T., Liu, J., Zeng, F.** (2018). "Application of QFD and FMEA in ship power plant design". Proceedings - 2017 10th International Symposium on Computational Intelligence and Design, ISCID 2017, 2, 467–470.
- Wang, X., Wang, X., Ma, B., Li, Q., Wang, C., Shi, Y.** (2023). "High-performance reversible data hiding based on ridge regression prediction algorithm". *Signal Processing*, 204, 0–11.
- Wang, Y., Pang, W., Jiao, Z.** (2023). "An adaptive mutual K-nearest neighbors clustering algorithm based on maximizing mutual information". *Pattern Recognition*, 137.

- Wen, L., Zhou, K., Yang, S., Lu, X.** (2019). "Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting". *Energy*, 171, 1053–1065.
- Wu, X. H., Lu, Y. Y., Zhao, P. W.** (2022). "Multi-task learning on nuclear masses and separation energies with the kernel ridge regression". *Physics Letters, Section B: Nuclear, Elementary Particle and High-Energy Physics*, 834.
- Wu, Y., Tan, H., Peng, J., Zhang, H., He, H.** (2019). "Deep reinforcement learning of energy management with continuous control strategy and traffic information for a series-parallel plug-in hybrid electric bus". *Applied Energy*, 247(March), 454–466.
- Wun, L. M., Pearn, W. L.** (1991). "Assessing the statistical characteristics of the mean absolute error or forecasting". *International Journal of Forecasting*, 7(3), 335–337.
- Xie, X., Wu, T., Zhu, M., Jiang, G., Xu, Y., Wang, X., Pu, L.** (2021). "Comparison of random forest and multiple linear regression models for estimation of soil extracellular enzyme activities in agricultural reclaimed coastal saline land". *Ecological Indicators*, 120(August 2020), 106925.
- Yan, H., Peng, Y., Shang, W., Kong, D.** (2023). "Open-circuit fault diagnosis in voltage source inverter for motor drive by using deep neural network". *Engineering Applications of Artificial Intelligence*, 120(August 2022), 105866.
- Yao, G., Hu, X., Wang, G.** (2022). "A novel ensemble feature selection method by integrating multiple ranking information combined with an SVM ensemble model for enterprise credit risk prediction in the supply chain". *Expert Systems with Applications*, 200(March), 117002.
- Yating Feng, Pengxiang Zhang, Miao Yang, Quian Li, A. Z.** (2019). "Short Term Load Forecasting of Offshore Oil Field Microgrids". *Energy Procedia*, 158, 2448–2455.
- Yiğit, K.** (2022). "Evaluation of energy efficiency potentials from generator operations on vessels". *Energy*, 257, 15, October, 124687
- Yildirim, H., Revan Özkale, M.** (2019). "The performance of ELM based ridge regression via the regularization parameters". *Expert Systems with Applications*, 134, 225–233.
- Yin, L., Gao, Q., Zhao, L., Wang, T.** (2019). "Expandable deep learning for real-time economic generation dispatch and control of three-state energies based future smart grids". *Energy*, 191, 116561.
- Yuan, Z., Niu, M. Q., Ma, H., Gao, T., Zang, J., Zhang, Y., Chen, L. Q.** (2023). "Predicting mechanical behaviors of rubber materials with artificial neural networks". *International Journal of Mechanical Sciences*, 249(February), 108265.
- Zheng, M., Zhang, J., Wang, J., Yang, S., Han, J., Hassan, T.** (2022). "Reconstruction of 0.05° all-sky daily maximum air temperature across Eurasia for 2003–2018 with multi-source satellite data and machine learning models". *Atmospheric Research*, 279(9), 106398.

- Zheng, Y., Ge, Y., Muhsen, S., Wang, S., Elkamchouchi, D. H., Ali, E., Ali, H. E.** (2023). "Advances in Engineering Software New ridge regression, artificial neural networks and support vector machine for wind speed prediction". *Advances in Engineering Software*, 179(December 2022), 103426.
- Zhu, J., Zou, H., Rosset, S., Hastie, T.** (2009). "Multi-class AdaBoost *". *Statistics and Its Interface (C. 2)*. 2 349–360
- Zhu, W., Peng, Y.** (2020). "Elastic net regularized kernel non-negative matrix factorization algorithm for clustering guided image representation". *Applied Soft Computing Journal*, 97, 106774.
- Zou, H., Hastie, T.** (2005). "Regularization and variable selection via the elastic net". *Journal of the Royal Statistical Society. Series B: Statistical Methodology*, 67(2), 301–320.





ÖZGEÇMİŞ

Ad-Soyad : Tayfun UYANIK

ÖĞRENİM DURUMU:

- **Lisans** :2013, Pamukkale Üniversitesi, Müh. Fakültesi, Elk.-Ele. Müh. Bölümü
- **Yüksek Lisans** :2017, Süleyman Demirel Üniversitesi, Elk.-Ele. Müh. Anabilim Dalı, Elk.-Ele. Müh.Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2015-Halen İstanbul Teknik Üniversitesi Denizcilik Fakültesi'nde Araştırma Görevlisi
- 2022-2023 yılları arasında Aalborg Üniversitesi Enerji Bölümü'nde Prof. Dr. Josep M. Guerrero danışmanlığında misafir araştırmacı olarak çalıştı.

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Uyanık, T.**, Yalman, Y., Kalenderli, Ö., Arslanoğlu, Y., Terriche, Y., Su, C. L., & Guerrero, J. M. 2022. Data-Driven Approach for Estimating Power and Fuel Consumption of Ship: A Case of Container Vessel. *Mathematics*, 10(22), 4167.
- **Uyanık, T.** 2021.Ticari gemilerde operasyonel elektriksel gücün tahmininde makine öğrenmesi yaklaşımı: şaft jeneratörü güç tahmini uygulaması. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 4(2), 165-174.
- **Uyanık, T.**, Karatug, Ç., Arslanoglu, Y. 2020. Ship Electrical Power Estimation with Machine Learning. 9th. International Conference on Advanced Technologies (ICAT20).

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

Dergi Makaleleri:

- **Uyanık, T.** 2022. Veriye Dayalı Yöntemler Yardımı İle Kimyasal Tankerde Yakıt Tüketimi Tahmini. *Dokuz Eylül Üniversitesi Denizcilik Fakültesi Dergisi*, 14(2), 190-205.
- Atak, Ü., **Uyanık, T.**, & Arslanoğlu, Y. 2022. An MDCM approach for risk assessment at the polar regions: analysing the antarctic route ice navigation risk parameters. *Australian Journal of Maritime & Ocean Affairs*, 1-19.
- Yalman, Y., **Uyanık, T.**, Atlı, İ., Tan, A., Bayındır, K. Ç., Karal, Ö., Golestan, S. & Guerrero, J. M. 2022. Prediction of Voltage Sag Relative Location with Data-Driven Algorithms in Distribution Grid. *Energies*, 15(18), 6641.
- Ceylan, B. O., Karatuğ, Ç., Ejder, E., **Uyanık, T.**, & Arslanoğlu, Y. 2022. Risk assessment of sea chest fouling on the ship machinery systems by using both FMEA method and ERS process. *Australian Journal of Maritime & Ocean Affairs*, 1-20.
- Yalman, Y., **Uyanık, T.**, Tan, A., Bayındır, K. Ç., Terriche, Y., Su, C. L., & Guerrero, J. M. 2022. Implementation of Voltage Sag Relative Location and Fault Type Identification Algorithm Using Real-Time Distribution System Data. *Mathematics*, 10(19), 3537.
- Bakar, N. N. A., Bazmohammadi, N., Çimen, H., **Uyanık, T.**, Vasquez, J. C., & Guerrero, J. M. 2022. Data-driven ship berthing forecasting for cold ironing in maritime transportation. *Applied Energy*, 326, 119947.
- **Uyanık, T.**, Ejder, E., Arslanoğlu, Y., Yalman, Y., Terriche, Y., Su, C. L., & Guerrero, J. M. 2022. Thermoelectric generators as an alternative energy source in shipboard microgrids. *Energies*, 15(12), 4248.
- **Uyanık, T.**, Karatuğ, Ç., & Arslanoğlu, Y. 2021. Machine learning based visibility estimation to ensure safer navigation in strait of Istanbul. *Applied Ocean Research*, 112, 102693.
- **Uyanık, T.**, Karatuğ, Ç., & Arslanoğlu, Y. 2020. Machine learning approach to ship fuel consumption: A case of container vessel. *Transportation Research Part D: Transport and Environment*, 84, 102389.
- Arslanoglu, B., Elidolu, G., & **Uyanık, T.** 2023. Application Of Machine Learning Methods For Prediction Of Seafarer Safety Perception. *International Journal of Maritime Engineering*, 164(A3), 269-282.

Bildiriler:

- **Uyanık, T.** Arslanoglu, Y., Kalenderli, Ö. 2019. Ship Fuel Consumption Prediction with Machine Learning. 4th International Mediterranean Science and Engineering Congress (IMSEC 2019)
- Elidolu, G., **Uyanık, T.**, Arslanoglu, Y. 2019. Estimation of safe work behavior of seafarers using Artificial Neural Network. 4th International Mediterranean Science and Engineering Congress (IMSEC 2019)
- **Uyanık, T.** Arslanoğlu, Y., Kalenderli, Ö. 2018. Investigation of the Ship Lightning Protection Systems. 7th International Conference on Advanced Technologies (ICAT18)

- **Uyanık, T.** Arslanoğlu, Y., Kalenderli, Ö. 2018. Energy Optimization By Determining PID Coefficients By Genetic Algorithm in Marine Dual Fuel Engine. Tayfun Uyanık, Yasin Arslanoğlu, Özcan Kalenderli. 7th International Conference on Advanced Technologies (ICAT18)
- Usluer, H.B., **Uyanık, T.** Arslanoğlu, Y. 2018. Low Cost Sensor System Design for Lagrangian Drifter. 4th International Conference on Environmental Science and Technology (ICOEST2018)
- Usluer, H.B., **Uyanık, T.** Arslanoğlu, Y. 2018. A Sensor Application for Oceanographic Drifter. 4th International Conference on Environmental Science and Technology (ICOEST2018).
- **Uyanık, T.** Kartal, Ş.E., Arslanoğlu, Y. 2017. Ship Fuel Consumption And Emission Amount Modelling and Minimization with Fuzzy Logic. Tayfun Uyanık, , Yasin Arslanoğlu. International Conference & Workshop Energy For Tomorrow (REMOO-2017).
- Arslanoğlu, Y., **Uyanık, T.**, Kalenderli, Ö. 2017. Analysis of Electromagnetic Field Levels in Ships. International Conference & Workshop Energy For Tomorrow (REMOO-2017).
- **Uyanık, T.**, Bingöl. O. 2017. Genetic Algorithm with Ship Steering System PID Coefficients Optimization. 4th International Conference on Pure and Applied Sciences: Renewable Energy (ICPAS2017).
- **Uyanık, T.** Arslanoğlu, Y., Usluer, H.B. 2017. Oceanographic Measurements in Istanbul Strait with New Type Buoy: Design and Performance at Sea. 4th International Conference on Pure and Applied Sciences: Renewable Energy (ICPAS2017).
- Elidolu, G., **Uyanık, T.**, Arslanoğlu, Y. 2020. Seafarer personnel selection with Fuzzy AHP. 5th International Mediterranean Science and Engineering Congress (IMSEC 2020).
- Elidolu, G., **Uyanık, T.**, Karabıyık, P., Arslanoğlu, Y. 2020. Hull cleaning effects on CO2 emissions estimation with machine learning methods. 5th International Mediterranean Science and Engineering Congress (IMSEC 2020).
- Karatuğ, Ç., **Uyanık, T.**, Arslanoglu, Y. 2020. Data Driven Approach for Estimation of Marine Vessel's Fuel Oil Consumption. 9th. International9th International Conference on Advanced Technologies (ICAT20).
- **Uyanık, T.**, Yılmaz, O., Arslanoglu, Y. 2020. A Machine Learning Approach for Solar Power Plant Electrical Power Estimation., Yasin Arslanoğlu. 5. International Anatolian Energy Symposium (AES2020).
- Yılmaz, O., **Uyanık, T.**, Arslanoglu, Y. 2020. Ship Energy Efficiency Analysing Approaches: A Case Study. 5. International Anatolian Energy Symposium (AES2020).