

Yayın Geliş Tarihi: 27.10.2021
Yayına Kabul Tarihi: 05.04.2022
Online Yayın Tarihi: 30.12.2022
DOI: 10.18613/deudfd.1015260
Araştırma Makalesi

Dokuz Eylül Üniversitesi
Denizcilik Fakültesi Dergisi
Cilt:14 Sayı:2 Yıl:2022 Sayfa:190-205
E-ISSN: 2458-9942
(Research Article)

VERİYE DAYALI YÖNTEMLER YARDIMI İLE KİMYASAL TANKERDE YAKIT TÜKETİMİ TAHMİNİ

Tayfun UYANIK¹

ÖZ

Ticari gemilerde yakıt tüketimi denizcilik işletmelerinde en önemli gider kalemini oluşturmaktadır. Aynı zamanda enerji verimliliği ile de yakından alakalı olan bu konu denizcilik sektörü açısından son derece önem arz etmektedir. Uluslararası Denizcilik Örgütü kuralları gereği denizcilik sektöründe emisyon azaltma konusunun gündemdeki yerini koruduğu da göz önünde bulundurulduğunda gemilerde yakıt tüketimi ve ortaya çıkan emisyonlar denizcilik otoriteleri tarafından ciddi olarak takip edilmektedir. Bu çalışmada bir kimyasal tanker gemisinin yakıt tüketiminin gerçek sefer verilerinden hareketle veriye dayalı yöntemler yardımıyla modellenip tahmin edilmesi amaçlanmıştır. Öncelikle gemiden alınan sefer verileri işlenip algoritmaların üzerinde çalışabileceği hale getirilmiştir. Algoritmalar veri seti üzerinde çalıştırılmış ve yakıt tüketimi tahmin başarımları incelenmiştir. İlk aşamada bazı algoritmaların başarısı yetersiz bulunmuştur. Tahmin başarımları yetersiz bulunan algoritmaların parametreleri ayarlanarak tahmin işlemi tekrar edilmiştir. Son olarak hata metrikleri kullanılarak algoritmaların yaptığı tahminler birbiriyle karşılaştırılmıştır. Sonuçlar incelendiğinde Çok Katmanlı Derin Sinir Ağı yönteminin kimyasal tanker yakıt tüketimi tahmini problemi kapsamında ele alınan diğer yöntemlerden daha başarılı olduğu tespit edilmiştir.

Anahtar Kelimeler: Kimyasal Tanker, Enerji Verimliliği, Yakıt Tüketimi Tahmini, Veriye Dayalı Yöntemler

¹ Araş. Gör., İstanbul Teknik Üniversitesi, Denizcilik Fakültesi, İstanbul, Türkiye, uyanikt@itu.edu.tr, ORCID No: 0000-0003-2371-8894

FUEL CONSUMPTION PREDICTION IN CHEMICAL TANKER WITH DATA-DRIVEN METHODS

ABSTRACT

Fuel consumption in commercial ships constitutes the most important expense item in maritime enterprises. This issue, which is also closely related to energy efficiency, is extremely important for the maritime industry. Considering that the issue of emission reduction remains on the agenda in the maritime sector as per the International Maritime Organization rules, fuel consumption and the emissions on ships are followed seriously by the maritime authorities. In this study, it is aimed to model and estimate the fuel consumption of a chemical tanker ship with the help of data-based methods based on real voyage data. First of all, the voyage data taken from the ship is processed and the algorithms can work on it. Algorithms were run on the data set and fuel consumption estimation performances were examined. At the first stage, the success of some algorithms was found to be insufficient. The estimation process was repeated by adjusting the parameters of the algorithms with insufficient estimation performance. Finally, the predictions made by the algorithms were compared with each other using error metrics. When the results are examined, it has been determined that the Multi-Layer Deep Neural Network method is more successful than the other methods discussed for the chemical tanker fuel consumption estimation problem.

Keywords: Chemical Tanker, Energy Efficiency, Fuel Consumption Estimation, Data-Driven Methods

1. GİRİŞ

Ticari yük taşımacılığında denizcilik sektörü son yıllarda önemini giderek arttıran bir sektördür. Deniz ticareti üzerindeki yükün artması sebebiyle küresel denizcilik filosuna her yıl çok sayıda yeni gemi dahil edilmiş ve bu da denizcilik sektörü kaynaklı doğaya salınan zehirli gazların miktarında artışa neden olmuştur. Uluslararası Denizcilik Örgütü (IMO) yayınladığı kural ve yönetmeliklerle denizcilik sektörü kaynaklı emisyonların azaltılması ve gemilerde enerji verimliliğinin artırılması konularında denizcilik şirketlerini yeni arayışlara yöneltmiştir (Chen vd. 2019). Şirketler enerji verimliliğini artırma ve emisyonları kontrol edebilme konularında sistemlerin tamamen değiştirilmesi yerine fayda maliyet oranı bakımından etkin yöntemleri ele almışlardır. Gemilerde enerji verimliliğini artırma konusunda ilk adım enerji verimliliği konusunda mevcut durumun analiz edilip belirlenmesidir. Verimlilik artışı yapılacak alanlar böylelikle daha kolay belirlenebilir (Tien-Anh, 2021).

Günümüz teknolojisinin denizcilik sektörüne uygulanması sonucunda gemilerden veri elde etmek kolaylaşmıştır. Bu sayede bir

geminin harcadığı yakıt, gittiği rota, ana makinede elde edilen güç ve geminin hızı gibi pek çok farklı değişken hakkında bilgi sahibi olunabilmektedir. Bu verilerden hareketle geminin enerji verimliliği ve doğaya saldığı emisyonlar hesaplanabilmektedir. Gemilerden veri elde edilmesinin yaygınlaşması sayesinde veriye dayalı yöntemlerin denizcilik alanındaki uygulamaları da son yıllarda artış trendine girmiştir. Meteorolojik veriler ve gemi sefer verilerinin yardımıyla kaza riski tahminin yapıldığı bir çalışmada aşırı hava koşullarının gemi kazalarına ve gemi kazalarının da deniz kirliliğine yol açtığı belirlenmiştir. Gemi kazası riskinin azaltılabilmesi adına incelenen bölgeden alınan gemi sefer trafik verisi ve meteorolojik verilerden hareketle bir makine öğrenmesi tahmin modeli oluşturulmuştur (Rawson vd. 2021). Denizcilik faaliyetlerinden kaynaklanan emisyonların incelendiği bir çalışmada turistik yerlerde denizcilik faaliyetleri nedeniyle oluşan kirliliğin endişeye yol açtığından bahsedilmiştir. Bu etkinin incelenmesi için öncelikle klasik yaklaşımlar incelenmiş ve tahmin yeteneklerinin belli durumlarda kısıtlı olduğundan bahsedilmiştir. Bu nedenle çalışmada veriye dayalı yöntemler tercih edilmiş ve klasik yöntemlerden daha başarılı sonuçlar elde edilmiştir (Fabregat vd. 2021). Gemilerde bakım konusu emniyetli seyiri etkilediği gibi enerji verimliliğini de etkilemektedir. Planlı bakım çalışmalarının yapıldığı bir gemide arızalanma riski daha az olacaktır. Gemilerde bakım faaliyetlerinin makine öğrenmesi algoritmaları yardımıyla planlandığı bir çalışmada ana makine sensörlerinden alınan veri setinden faydalanılmıştır. Kurulan modeller sayesinde ana makine egzoz sıcaklığı ve süpürme hava basıncı tahmin edilmiştir. Tahmin modelleri %96 doğrulukla bu iki değişken tahmin edilip gerçek değerlerle karşılaştırıldığında anormal değerlerin arıza durumlarına ait olduğu gözlemlenmiştir (Cheliotis vd. 2020). Gemilerde emisyonlara neden olan en önemli etmenin yakıt tüketimi olduğu belirtilen bir çalışmada bir dökme yük gemisinin yakıt tüketimi tahmini için geminin iki yıllık sefer verileri kullanılmıştır. Gemi ana makinesinin yakıt tüketimi tahmininde Yapay Sinir Ağı yöntemi başarılı sonuçlar vermiştir (Tien-Anh, 2021). Limandaki gemilerin enerji verimliliğini arttırmak için makine öğrenmesi yöntemlerinden yararlanılan bir çalışmada gemi ve limandan iki ayrı veri seti bir araya getirilmiştir. Bu veri seti sayesinde enerji tahmin modeli geliştirilmiştir. Veriler incelendiğinde gemilerin limandaki enerji tüketimini en çok etkileyen özellikler belirlenmiştir. Bu özellikler optimize edildiğinde geminin limanda enerji tüketiminin azaldığı tespit edilmiştir (Peng vd. 2020). Gemi enerji optimizasyonunda gidilen rotanın da önemi büyüktür. Bu kapsamda incelenen bir çalışmada belirli bir hatta sürekli olarak sefer yapan bir gemi için yakıt tüketimi tahmini için veriye dayalı yöntemlerden faydalanılmıştır. Çalışma sonucunda çeşitli sefer verilerinden ve

meteorolojik verilerden hareketle kurulan yakıt tüketimi tahmini modelinde %95'lik bir başarı sağlanmıştır (Bui-Duy ve Vu-Thi-Minh, 2021). Yakıt tüketimi tahmininde gemi hızı ve trim gibi değişkenlerin önemi büyüktür.

Veri setinde bu tipte değişkenlerin kullanıldığı bir çalışmada kurulan tahmin modelinde ilk aşamada istenilen başarı sağlanamamıştır. Tahmin başarısının artırılması için kullanılan makine öğrenmesi algoritmalarının parametreleri optimize edilmiştir. Optimize edilen algoritmalarla modeller güncellenip tahmin işlemi tekrar edildiğinde modellerin başarısının yükseldiği tespit edilmiştir (Zhou vd. 2021). Gemi ana makinesinin harcadığı yakıtın tahmin edilmesi için bir çalışmada dinamik veriler kullanılmıştır. Bu veriler ile kurulan tahmin modelinde ise makine öğrenmesi yöntemlerinden yararlanılmıştır (Ahlgren vd. 2019). Ticari gemilerde işletme maliyetlerinin önemli bir kısmını yakıt tüketimi oluşturmaktadır. Geminin yakıt tüketiminin bu yüzden doğru şekilde tahmin edilmesi gerekmektedir. Yakıt tüketimi tahmininin veriye dayalı yöntemlerle yapıldığı bir çalışmada geminin öğlen raporu ve sensör verilerinden yararlanılmıştır. Yapılan çalışma sonucunda incelenen geminin yakıt tüketimi doğru bir şekilde tahmin edilebilmiştir (Gkerekos vd. 2019).

Çalışmada yakıt tüketimi modeli için veri kaynağı elde edilirken kimyasal tanker olarak kullanılan 183 metre uzunluğunda 32,2 metre genişliğinde 50.000 DWT'lik CPP taşınma üzerine inşa edilmiş MR sınıfı özel bir gemi seçilmiştir. Bu çalışmada bir kimyasal tanker gemisinin Aralık 2017 - Ağustos 2019 tarihleri arasındaki 1.047 örneklik sefer verisinden hareketle veriye dayalı yöntemler yardımıyla yakıt tüketimi tahmininin yapılması ve kullanılan yöntemlerin birbiriyle karşılaştırılması amaçlanmıştır. Çalışma kapsamında rüzgar, dalga, deniz durumu gibi dış değişkenler altında oluşmuş olan ana makine değerleri üzerinden veri seti elde edilmiştir. Veriler geminin seferde karşılaşılabileceği çoğudurumu içeren yaklaşık 20 aylık bir zaman dilimini kapsamaktadır. Veri seti öncelikle eksik verilerin bulunduğu örneklerden ayıklanarak temizlenmiştir. Elde edilen 1.000 örneklik tam veri seti algoritmaların üzerinde çalışabileceği hale getirilmiştir. Daha sonra veri seti incelenmiş ve birbiri ile korelasyon içeren veriler korelasyon matrisi aracılığıyla belirlenmiştir. Veri setinin bir kısmı (%80) yöntemlere öğretilmiş ve böylece tahmin modelleri oluşturulmuştur. Kalan kısım ise tahmin modellerinin başarısının birbirleriyle karşılaştırılabilmesi adına saklanmıştır. Algoritmaların yaptıkları tahminler veri setinin algoritmalara öğretilmeyen kısmı ile karşılaştırılmış ve aradaki fark hata metrikleri ile

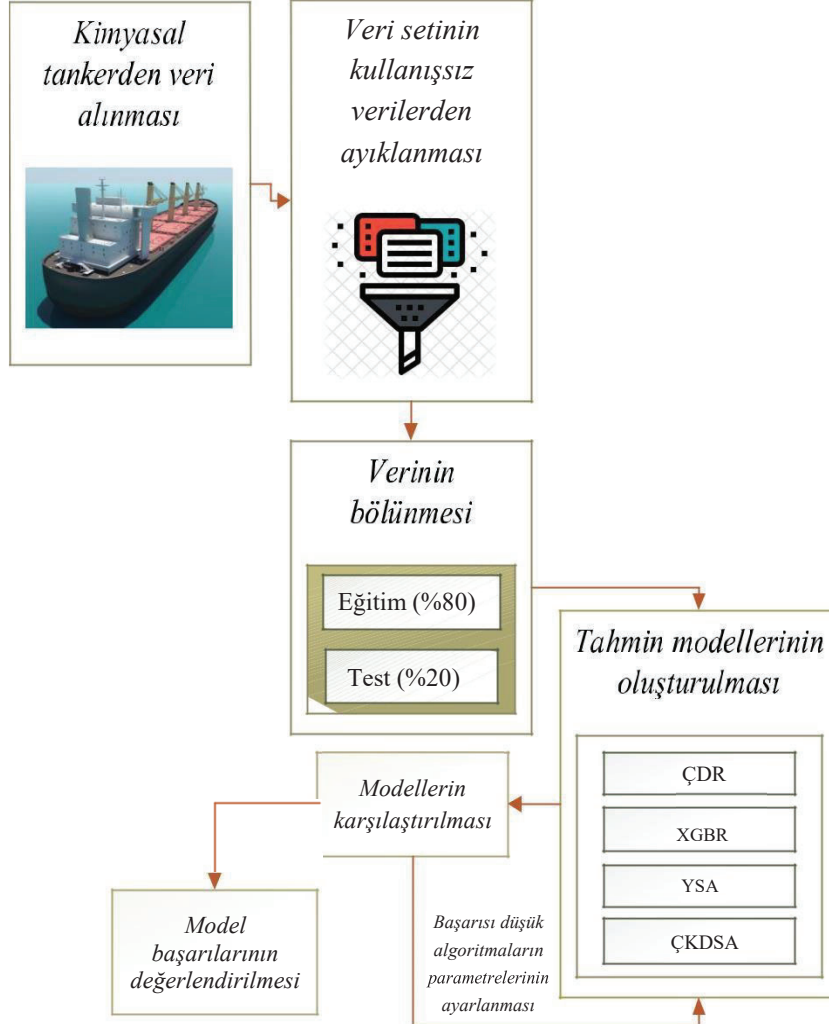
ifade edilmiştir. Bu çalışmada kimyasal tanker yakıt tüketimi tahmininde Çoklu Doğrusal Regresyon (ÇDR) (Thiangchanta ve Chaichana, 2020), XGradient Boost Regresyon (XGBR) (Shehadeh vd. 2021), Yapay Sinir Ağı (YSA) (Choi ve Kim, 2021) ve literatürde yer alan ilgili çalışmalardan farklı olarak Çok Katmanlı Derin Sinir Ağı (ÇKDSA) (Sun vd. 2018; Desai ve Shah, 2021) yöntemleri, hata metriği olarak da R^2 (Belirleme Katsayısı) (Ueki, 2021), Ortalama Kare Hatası (OKH) (Lopez ve Mancini, 2019), Ortalama Mutlak Hata (OMH) (Paredes vd. 2018) ve Kök Ortalama Kare Hatası (KOKH) (Schubert vd. 2017) yöntemleri kullanılmıştır. Çalışma sonucunda Çok Katmanlı Derin Sinir Ağı algoritmasının ele alınan diğer algoritmalarından daha başarılı olduğu gözlemlenmiştir.

Çalışmanın bundan sonraki bölümleri şu şekilde oluşturulmuştur. Materyal ve yöntemler bölümünde çalışmanın metodolojisi açıklanmış, kullanılan veriye dayalı yöntemler tanıtılmış ve hata metrikleri açıklanmıştır. Çalışmanın üçüncü bölümü olan yakıt tüketimi tahmini benzetim sonuçları kısmında kullanılan yöntemler ile kurulan modeller sonrasında yapılan tahmin sonuçları ele alınmıştır. Çalışmanın son bölümünde ise elde edilen benzetim sonuçları değerlendirilmiştir.

2. MATERYAL VE YÖNTEMLER

2.1. Kullanılan Yöntem

Bu çalışmada gemilerden kaynaklı emisyonların ve gemi enerji verimliliği konusunun temelini oluşturan, son yıllarda üzerinde çokça çalışılan bir konu olan gemi yakıt tüketimi veriye dayalı yöntemler yardımıyla tahmin edilmiştir. Çalışma için öncelikle bir kimyasal tanker gemisinden 1.047 örneklik sefer verisi alınmıştır. Bu veriler incelenmiş ve aralarında eksik bilgilerin olduğu kısımlar veri setinden atılmıştır. Veri seti bu işlem sonunda 1.000 örneğe düşürülmüştür. Elde edilen 1.000 örneklik veri setinin %80'lik kısmı Python programlama dili Spyder ara yüzü ile veriye dayalı yöntemlere öğretilmiş ve yakıt tüketimi tahmin modelleri oluşturulmuştur. Oluşturulan bu modellerin başarısını değerlendirebilmek için ise kalan veriler saklanmış ve algoritmalarla öğretilmemiştir. Algoritmalarla kalan verilerdeki yakıt tüketimini tahmin etmeleri hedef çıktı olarak verilmiştir. Kurulan modellerden bazılarının yaptıkları tahminlerin başarıları ilk aşamada yetersiz görülmüştür ve algoritma parametreleri ayarlanarak işlem tekrar edilmiştir. Son olarak hatametriklere kullanılarak en başarılı algoritmanın belirlenmesi işlemi yapılmıştır. Yapılan bu işlemler Şekil 1'de gösterilmiştir.




Şekil 1: Çalışmada İzlenen Akış Şeması

2.2. Veri Setinin Tanıtılması

Bu çalışmada 183 metre uzunluğunda ve 32,2 metre genişliğinde özel yapım birkimyasal tanker gemisinin ana makinesinde kullanılan HFO türündeki yakıt tüketimi tahmini veriye dayalı yöntemler kullanılarak yapılmıştır. Tahmin modellerinde kullanılan 1047 satırlık veri setinin özeti Tablo 1’de verilmiştir. Veri seti içinde yer alan değişkenler arasındaki ilişkiyi incelemek için korelasyon matrisi oluşturulmuştur. Oluşturulan korelasyon matrisi Şekil 2’de gösterilmiştir.

Tablo 1: Veri Setinin Özeti

	Ortalama	Std. Sapma	Minimum	Maksimum
Ana mak. dönüş hızı (d/dk)	79,46	16,24	0,1	98,113
Dizel jen. günlük çalışma saati	1,45	1,03	0,1	4,5
Ana mak. günlük çalışma saati	13,09	9,86	0,5	24
Ana mak. gücü (kW)	4.169,86	1.559,25	285,14	6.968,16
Ana mak. günlük yakıt tüketimi (t)	9,95	8,44	0,04	28,68
...



Şekil 2: Korelasyon Matrisi

2.3. Kullanılan Veriye Dayalı Yöntemler

2.3.1. Çoklu Doğrusal Regresyon

Klasik makine öğrenmesi algoritmalarından olan Çoklu Doğrusal Regresyon yönteminde bulunacak hedef değişkeni sistemde yer alan bağımsız değişkenlerin belli katsayılarla çarpılarak toplanması sonucu elde edilir (Olsen vd. 2020). Bu algoritmada kullanılan denklem aşağıda verilmiştir.

$$x_1a_1 + x_2a_2 + \dots + x_na_n = y \quad (1)$$


Bu denklemde x değişkenleri bağımsız değişkenleri ifade ederken, a değişkeni katsayıları ifade eder. Denklemin çözülmesi sonucu bulunan y değişkeni ise bağımlı değişkeni ifade eder (Aline vd. 2021).

2.3.2. XGradient Boost Regresyon

Ekstrem Gradient Boosting algoritması son yıllarda hesaplama hızınınyüksek olması nedeniyle kullanım sıklığı artan yüksek performanslı gözetimli makine öğrenme yöntemlerindedir. Bu algoritma sınıflandırma problemleri için kullanılabilmesinin yanı sıra regresyon problemlerinde de işlevseldir (Chen vd. 2021).

2.3.3. Yapay Sinir Ağı


Yapay sinir ağı insan sinir sisteminin tipik bir örneği taklit edilerek oluşturulmuş bir algoritmadır. Bu algoritmada girişler nörona yani giriş katmanına gelir. Algoritmada girişler arasında ilişki kurup bir hesaplama yapan bölüm ise gizli katman olarak isimlendirilmektedir. Sonuç ise çıkış katmanında oluşturulmaktadır. Tipik bir yapay sinir ağı yapısı Şekil 3'te gösterilmiştir. Bu yapay sinir ağı modeli incelendiğinde x değişkenlerinin giriş değişkenleri, w harfinin ise ağırlıkları temsil ettiği görülecektir (Chen vd. 2008).



Şekil 3: Tipik Bir Yapay Sinir Ağı Modeli

2.3.4. Çok Katmanlı Derin Sinir Ağı

Çok katmanlı derin sinir ağı yapay sinir ağının gelişmiş bir yapısıdır. Bu yapıda Yapay sinir ağı modelinden farklı olarak gizli katmanlar fazladır. Bunun dışında her katmanda yine bir ağırlık ve aktivasyon fonksiyonu yer alır. Derin sinir ağında bu sayede ağ parametreleri üzerinde daha fazla işlem yapılabilir ve daha başarılı modeller kurulabilir. Tipik bir çok katmanlı derin sinir ağı Şekil 4'te görülmektedir. Şekil incelendiğinde giriş katmanında yer alan x değerleri modeli oluşturan temel girdiler olan giriş değişkenlerini, w değerleri ise ağırlıkları temsil etmektedir (Sahu vd. 2021).



Şekil 4: Tipik Bir ÇKDSA Modeli

2.4. Hata metrikleri

Hata metrikleri, veriye dayalı yöntemler ile ilgili çalışmalarda yapılan tahminlerin gerçek değere ne kadar yakın olduğunun sayısallaştırılmış ifadesidir. Bu çalışmada algoritmaların yaptığı tahminlerin başarısının farklı yöntemlerle de ele alınabilmesi adına dört farklı hata metriği kullanılmıştır.

2.4.1. Belirleme Katsayısı (R^2)

Belirleme katsayısı oluşturulan modelin hedef değişkenini tahmin etme başarısının bir ölçüsüdür. Bir tahmin modeline ilişkin R^2 değeri 0-1 aralığında sayısal değer alır. Bu değer sıfıra ne kadar yakınsarsa model o kadar başarısız, 1'e yakınsadığı oranda ise model başarılıdır denilebilir (Ueki, 2021). Kurulan modelde tahmin başarısının belirleme katsayısı ile bulunması aşamasında öncelikle $e_i = y_i - t_i$ değeri bulunur. Burada e_i hata değerini, bu ifadedeki y_i değeri gerçek değeri, t_i değeri ise tahmin edilen değeri ifade eder. Gerçek değerlerin ortalaması ' y_s ' ile gösterilmek üzere farkların karelerinin ortalaması (A) Denklem 2'deki gibi ifade edilir. Denklem 3'te ise gerçek değer ile ortalama değer arasındaki farkın ortalaması (B) ifade edilmiştir. Bu iki denklemden belirleme katsayısının hesaplanması ise Denklem 4'te gösterilmiştir (Ueki, 2021).

$$A = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (2)$$

$$B = \frac{1}{n} \sum_{i=1}^n (y_i - y_s)^2 \quad (3)$$

$$R^2 = 1 - \frac{A}{B} \quad (4)$$

2.4.2. Ortalama Kare Hatası

Ortalama kare hatası hata metriklerinden en sık tercih edilenlerdendir. Bu yöntemle tahminlerin kalitesi ölçülürken gerçek değer ve yapılan tahmin arasındaki farkların karelerinin ortalaması alınır. Ortalama kare hatası Denklem 5'te ifade edilmiştir. Bu denklemde y_i ifadesi gerçek değeri, t_i ifadesi ise tahmin edilen değeri gösterir (Salman vd. 2017).

$$OKH = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \quad (5)$$

2.4.3. Ortalama Mutlak Hata

Ortalama mutlak hata yönteminde tahminlerin başarısı bulunurken gerçek değer ve tahmin aşamasında bulunan değer arasındaki farkın mutlak değeri alınır. Tüm bulunan değerlerin ortalaması ortalama mutlak hata değerini verecektir (Paredes vd. 2018). Ortalama mutlak hata değerinin bulunması Denklem 6'da gösterilmiştir. Bu denklemde y_i ifadesi gerçek değeri, t_i ifadesi ise tahmin edilen değeri gösterir.

$$OMH = \frac{1}{n} \sum_{i=1}^n |y_i - t_i| \quad (6)$$

2.4.4. Kök Ortalama Kare Hatası

Belirli bir veri setinde kurulan algoritmaların tahmin başarısını karşılaştırabilmek için sıklıkla kullanılan hata metriklerinden biridir. Bu yöntemde hata değerinin elde edilmesi Denklem 7'de gösterilmiştir. Bu denklemde y_i değeri gerçek değeri gösterirken, t_i değeri tahmin edilen değeri göstermektedir.

$$KOKH = \left\{ \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \right\}^{1/2} \quad (7)$$

3. YAKIT TÜKETİMİ TAHMİNİ BENZETİM SONUÇLARI

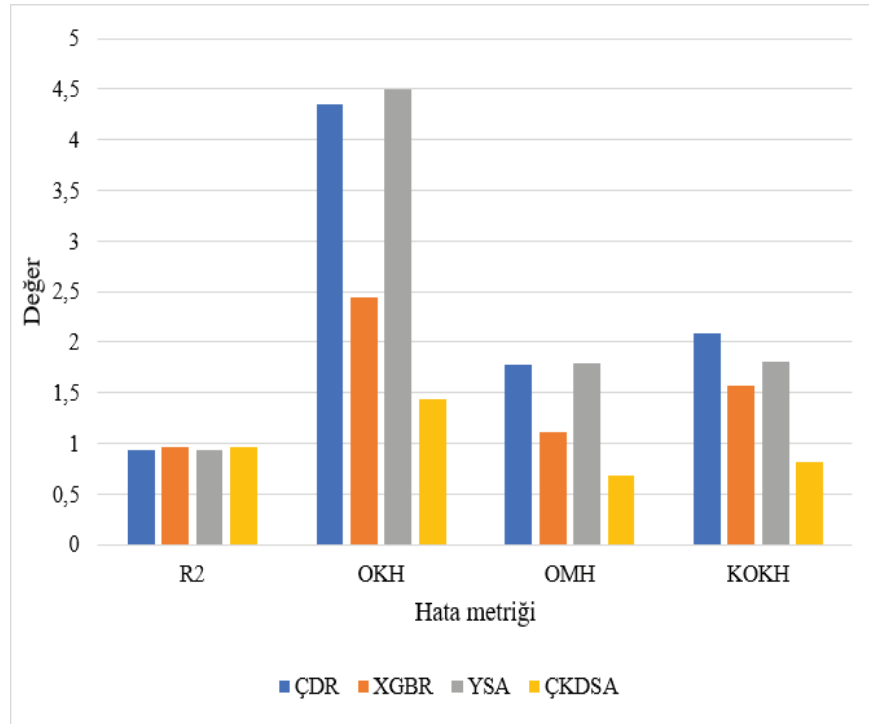
Kimyasal tanker gemisinde yakıt tüketimi tahmini için öncelikle veri setinin %80'lik kısmı eğitim verisi olarak algoritmalara öğretilmiş, kalan kısım ise yöntemlerin başarısının değerlendirilmesi için saklanmıştır. Algoritmalar ilk kez çalıştırıldığında Yapay Sinir Ağı ve Çok Katmanlı Derin Sinir Ağı yöntemlerinin başarısının çalışma kapsamında ele alınan diğer yöntemlerden daha düşük olduğu gözlemlenmiştir. Bu yöntemlerin parametreleri ayarlanarak tahmin işlemi tekrar gerçekleştirilmiştir. Algoritmaların parametreleri Tablo 2'de verilmiştir. Yöntemlerin başarıları ise hata metrikleri ile değerlendirilmiştir. Oluşturulan hata metriği tablosu Tablo 3'te gösterilmiştir. Farklı hata metriklerinin kullanılmasının avantajı bu noktada ortaya çıkmıştır. Belli bir hata metriğinde birbirine çok yakın başarı sağlayan algoritmaların başarısı arasındaki fark diğer bir hata metriğinde görülmektedir. Bu bulgunun somutlaştırılması Şekil 5'te görülmektedir.

Tablo 2: Ayarlanan Parametreler


Model	Parametre
Çoklu Doğrusal Regresyon	-
XGradient Boost Regresyon	-
Yapay Sinir Ağı	<i>çözücü='lbfgs', alfa='0,00001', maks_iterasyon=15000, aktivasyon_fonk='relu', gizli_katman_boyutu=9, güç_t=0,7, doğrulama_fraksiyonu=0,3, batch_boyutu=110</i>
Çok Katmanlı Derin Sinir Ağı	<i>Epoch_sayısı='1500', optimize_edici='adam', aktivasyon_fonksiyonu='relu'</i>

Tablo 3: Hata Metrikleri

	ÇDR	XGBR	YSA	ÇKDSA
R²	0,94	0,97	0,94	0,97
OKH	4,3463	2,4418	4,4986	1,4423
OMH	1,78	1,1047	1,7873	0,687
KOKH	2,0847	1,5626	1,8035	0,814

**Şekil 5:** Hata Metrikleri Karşılaştırması

Algoritmaların yaptıkları tahminlerin gerçek değerlerle ve birbirleriyle karşılaştırılması işlemi Şekil 6 ile somutlaştırılmıştır. Bu şekilde test verisinden rastgele seçilen 20 örnek için gerçek değerler ve algoritmalar tarafından tahmin edilen yakıt tüketimi değerleri görülmektedir.



Şekil 6: Rastgele seçilen 20 örnek için yöntemlerin karşılaştırılması

4. SONUÇLAR

Bir kimyasal tanker gemisinde gerçek sefer verileri kullanılarak veriye dayalı yöntemlerle yakıt tüketimi tahmini yapılan bu çalışmada tahmin işlemi için Çoklu Doğrusal Regresyon, XGradient Boost Regresyon, Yapay Sinir Ağı ve Çok Katmanlı Derin Sinir Ağı kullanılmıştır. Tahmin sonuçları incelendiğinde ve hata metriği tablosu analiz edildiğinde Çok Katmanlı Derin Sinir Ağı yönteminin çalışma kapsamında incelenen

veriye dayalı diğer yöntemlerden ele alınan problem özelinde gerçek yakıt tüketimi değerlerini tahmin etme konusunda hem çok katmanlı ve gelişmiş bir yapıda olması, hem de epoch sayısının 1.500 gibi yüksek bir değerde olmasının nedeniyle daha başarılı olduğu söylenebilir. Buna ek olarak klasik yapay sinir ağı yönteminin 15.000 iterasyona rağmen yapısının çok katmanlı derinsinir açısından daha ilkel olması nedeniyle istenen performans değerlerini yakalayamadığı tespit edilmiştir.

Çalışma sonucunda veriye dayalı yöntemler sayesinde bir kimyasal tanker gemisinde seferde çeşitli durumlarda harcanan yakıtın tahmin edilebileceği sonucuna varılabilir. Ayrıca Uluslararası Denizcilik Örgütü ve diğer denizcilik otoriteleri tarafından denizcilik şirketlerinden istenen emisyonların azaltılması, verimlilik artışı sağlanması ve yakıt tüketiminin düşürülmesi gibi konularda çalışmada ele alınan çıkış değişkeni olan yakıt tüketimini etkileyen giriş değişkenlerinde yapılacak bir optimizasyon sayesinde gemide sefer sırasında harcanan yakıt miktarı azaltılabilir ve böylece gemi enerji verimliliği artırılmış olacaktır.

KAYNAKLAR

Ahlgren F., Mondejar M.E. ve Thern M. (2019). Predicting dynamic fuel oil consumption on ships with automated machine learning. *Energy Procedia*, 158, 6126-6131.

Aline F.S., Nicolau A.C., André D.S.B., José E.S., Amauri G., Noé C. ve Bismarck L.S. (2021). Multiple linear regression approach to predict tensile properties of Sn-Ag-Cu (SAC) alloys. *Materials Letters*, 304, 130587.

Bui-Duy L. ve Vu-Thi-Minh N. (2021). Utilization of a deep learning-based fuel consumption model in choosing a liner shipping route for container ships in Asia. *The Asian Journal of Shipping and Logistics*, 37 (1), 1-11.

Cheliotis M., Lazakis I. ve Theotokatos G. (2020). Machine learning and data-driven fault detection for ship systems operations. *Ocean Engineering*, 216, 107968.

Chen C., Ruiz M.T., Delefortrie G., Mei T., Vantorre M. ve Lataire E. (2019). Parameter estimation for a ship's roll response model in shallow water using an intelligent machine learning method. *Ocean Engineering*, 191, 106479.

Chen C.H., Wu J.C. ve Chen J.C. (2008). Prediction of flutter derivatives by artificial neural networks. *Journal of Wind Engineering and Industrial Aerodynamics*, 96, 10–11, 1925-1937.

Chen L, Gao X. ve Li X. (2021). Using the motor power and XGBoost to diagnose working states of a sucker rod pump. *Journal of Petroleum Science and Engineering*, 199, 108329.

Choi S. ve Kim Y.J. (2021). Artificial neural network models for airport capacity prediction. *Journal of Air Transport Management*, 97, 102146.

Desai M. ve Shah M. (2021). An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN). *Clinical eHealth*, 4, 1-11.

Fabregat A., Vázquez L. ve Vernet A. (2021). Using machine learning to estimate the impact of ports and cruise ship traffic on urban air quality: The case of Barcelona. *Environmental Modelling & Software*, 139, 104995.

Gkerekos C., Lazakis I. ve Theotokatos G. (2019). Machine learning models for predicting ship main engine fuel oil consumption: A comparative study. *Ocean Engineering*, 188, 106282.

López J.E.F. ve Mancini C. (2019). Optimum thresholding using mean and conditional mean squared error. *Journal of Econometrics*, 208, 1, 179-210, 0304-4076.

Olsen A.A., McLaughlin J.E. ve Harpe S.E. (2020). Using multiple linear regression in pharmacy education scholarship. *Currents in Pharmacy Teaching and Learning*, 12 (10), 1258-1268.

Paredes L.F., Mallor F., Romeo M.G. ve León T. (2018). Dynamic mean absolute error as new measure for assessing forecasting errors. *Energy Conversion and Management*, 162, 176-188.

Peng Y., Liu H., Li X., Huang J. ve Wang W. (2020). Machine learning method for energy consumption prediction of ships in port considering green ports. *Journal of Cleaner Production*, 264, 121564.

Rawson A., Brito M., Sabeur Z. ve Tran-Thanh L. (2021). A machine learning approach for monitoring ship safety in extreme weather events. *Safety Science*, 141, 105336.

Sahu P., Raghavan S. ve Chandrasekaran K. (2021). Ensemble deep neural network based quality of service prediction for cloud service recommendation. *Neurocomputing*, 465, 476-489.

Salman M.S., Kukrer O. ve Hocanin A. (2017). Recursive inverse algorithm: Mean-square-error analysis. *Digital Signal Processing*, 66, 10-17.

Schubert A.L., Hagemann D., Voss A. ve Bergmann K. (2017). Evaluating the model fit of diffusion models with the root mean square error of approximation. *Journal of Mathematical Psychology*, 77, 29-45.

Shehadeh A., Alshboul O., Mamlook R.E.A ve Hamedat O. (2021). Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM, and XGBoost regression. *Automation in Construction*. 129, 103827.

Sun W., Su F. ve Wang L. (2018). Improving deep neural networks with multi-layer maxout networks and a novel initialization method. *Neurocomputing*, 278, 34-40.

Thiangchanta S. ve Chaichana C. (2020). The multiple linear regression models of heat load for air-conditioned room. *Energy Reports*, 6 (9), 972-977.

Tien-Anh, T. (2021). Comparative analysis on the fuel consumption prediction model for bulk carriers from ship launching to current states based on sea trial data and machine learning technique. *Journal of Ocean Engineering and Science*, 6 (4), 317-339.

Ueki M. (2021). Testing conditional mean through regression model sequence using Yanai's generalized coefficient of determination. *Computational Statistics & Data Analysis*, 158, 107168.

Zhou T., Hu Q., Hu Z. ve Zhen R. (2021). An adaptive hyper parameter tuning model for ship fuel consumption prediction under complex maritime environments. *Journal of Ocean Engineering and Science*, In Press, Journal Pre-proof.