

## Araştırma Makalesi

# Ticari gemilerde operasyonel elektriksel gücün tahmininde makine öğrenmesi yaklaşımı: şaft jeneratörü güç tahmini uygulaması

Tayfun Uyanık

Gemi Makineleri İşletme Mühendisliği Bölümü, Denizcilik Fakültesi, İstanbul Teknik Üniversitesi,  
Tuzla, İstanbul, Türkiye

\*Correspondence: [uyanikt@itu.edu.tr](mailto:uyanikt@itu.edu.tr)

DOI:10.51513/jitsa.993058

**Özet:** Son yıllarda uluslararası denizcilik ve çevre otoritelerince denizcilik sektöründeki emisyonların azaltılması için son derece radikal kararlar alınmaktadır. Şirketler yürürlüğe konulan kuralları uygulamak için fayda-maliyet oranı bakımından etkin yaklaşımlarla enerji verimliliğini arttırmayı amaçlamaktadır. Bu kapsamda gemi enerji verimliliğinin ve emisyonların belirlenmesi için literatürde çeşitli yaklaşımlar oluşturulmuştur. Özellikle son beş yılda makine öğrenmesi yöntemlerinin farklı alanlarda uygulamalarının başarılı sonuçlar vermesi üzerine bu yöntemler denizcilik sektöründe emisyonların belirlenebilmesi adına da kullanılmaya başlanmıştır. Gemide yakıt tüketimi emisyonun büyük bir bölümünü oluşturmaktadır. Bu konuda literatürde çok sayıda çalışma mevcuttur. Bu çalışmada ise gemilerde genellikle seyir sırasında birden fazla sayıda jeneratörün çalıştırılması yerine operasyonel iş ve işlemler için kullanılan şaft jeneratörünün gücü makine öğrenmesi uygulamaları vasıtasıyla tespit edilmiştir. Çalışmada bir konteyner gemisinden alınan 750 günlük veri seti kullanılmıştır. Alınan veri seti makine öğrenmesi yöntemleri için uygun hale getirilmiştir. Bu aşamada veri seti eğitim ve test verisi olarak bilgisayar tarafından rastgele seçilerek iki kısma ayrılmıştır. Eğitim verisi ile algoritmalar eğitilmiş, test verisi ise algoritmalara öğretilmemiş ve tahmin işlemi sırasında algoritma başarılarının ölçülebilmesi adına saklanmıştır. Yapılan tahminler sonucunda Çoklu Doğrusal Regresyon algoritmasının şaft jeneratörünün elektriksel gücünün tahmini işleminde çalışmada incelenen diğer algoritmalarından daha başarılı sonuçlar verdiği tespit edilmiştir.

**Anahtar Kelimeler:** Gemi kaynaklı emisyonlar, enerji verimliliği, makine öğrenmesi, şaft jeneratörü

## Machine learning approach to estimating operational electrical power on trade vessels: an application for shaft generator power prediction

**Abstract:** In recent years, extremely radical decisions have been taken by international maritime and environmental authorities to reduce emissions in the maritime sector. Companies aim to increase energy efficiency with effective approaches in terms of cost-benefit ratio to implement the rules that have been put into effect. In this context, various approaches have been developed in the literature to determine ship energy efficiency and emissions. Especially in the last five years, applications of machine learning methods in different fields have yielded successful results, and these methods have started to be used to determine emissions in the maritime sector. Fuel consumption onboard accounts for a large part of emissions. There are many studies in the literature on this subject. In this study, the power of the shaft generator is generally used for operational work and operations instead of running more than one generator during the cruise, has been determined through machine learning applications. A data set for 750 days from a container ship was used in the study. The received data set has been made suitable for machine learning methods. At this stage, the data set was randomly selected by the computer as training and test data and divided into two parts. Algorithms were trained with the training data, while the test data was not taught to the algorithms and stored to measure the success of the algorithms during the estimation process. As a result of the estimations, it has been determined that the Multiple Linear Regression algorithm gives more successful results than the other algorithms examined in the study in the estimation of the electrical power of the shaft generator.

**Key words:** Vessel based emissions, energy efficiency, machine learning, shaft generator.

## 1. Giriş

Denizcilik sektörü dünya ticaretinde hayati öneme sahiptir ve gündün güne önemi artmaktadır (Chengpeng ve ark., 2021). Özellikle son 10 yılda sektörde oluşan talebin karşılanabilmesi adına deniz ticareti üzerindeki yoğunluk giderek artmaktadır (Jin ve ark., 2019). Bu yoğunluğun neden olduğu emisyonların azaltılması adına Uluslararası Denizcilik Örgütü (IMO) tarafından çeşitli kurallar gündeme getirilmiştir (Bilgili, 2021; Harilaos ve ark., 2021; Paula, 2021). Sektörde yer alan denizcilik şirketleri bu kuralların getirdiği yükümlülükleri yerine getirebilmek adına çeşitli araştırma ve geliştirme çalışmalarına yönelmiştir (Alexey, 2014). Bu çalışmalarda akla gelen ilk yaklaşım mevcut sistemlerin yenilenmesi olsa da yenileme işlemi maliyet bakımından önemli bir handikap da barındırmaktadır (Saim ve Yercan, 2021). Bu yüzden denizcilik şirketleri var olan sistemlerin verimliliğinin belirlenmesi ve bu sistemlerin daha verimli kullanılması yolu ile IMO'nun emisyon kurallarını sağlamayı amaç edinmişlerdir (Andrew ve ark., 2020). Gemi enerji verimliliğinin artırılması için öncelikle verimlilik durumu tespit edilmeli, analiz edilebilecek seviyede veri elde edilmeli ve sistem geliştirmeleri bunun üzerine bina edilmelidir. Gelişen teknolojinin son yıllarda denizcilik sektörü üzerinde uygulamalarının artması ve gemilerden veri elde edilmesinin kolaylaşması sayesinde gemilerden sefer verileri elde edilmeye başlanmıştır (Pavlos ve Nikos, 2021). Bu veriler sefer rotası kapsamında karşılaşılan meteorolojik veriler, çeşitli dış faktörler, makine sensörlerinden alınan bilgiler, geminin iç dinamikleri ile ilgili bilgiler gibi çeşitli tipte verileri içerebilmektedir. Bu verilerin elde edilmesinde yaşanan gelişmelerden hareketle geminin enerji verimliliğinin bulunmasında önemli mesafe kat edilmiştir denilebilir (Chi ve ark. 2019). Gemi ve liman enerji verimliliğini arttırmayı hedefleyen bir çalışmada makine öğrenmesi yöntemlerinden faydalanılmış, gemiden ve geminin yanışığı limandan 15 farklı veri alınarak ve bu veriler analiz edilerek gemi ve liman enerji verimliliğinin artırılması hedeflenmiştir. Analiz sonucunda en önemli veriler belirlenerek enerji verimliliğinin bu verilerden hareketle artırılması çalışması

yapılmıştır (Peng ve ark., 2020). Gemilerde enerji verimliliği uygulamalarında sefer verileri sıklıkla kullanılmaktadır. Bu kapsamda hazırlanan bir çalışmada bir dökme yük gemisinin iki yıllık sefer verisi analiz edilmiştir. Veri seti yardımıyla yapay sinir ağı eğitilmiş ve tahmin işlemi yapılmıştır. Benzetim sonuçları veriye dayalı yöntemlerin klasik yöntemlere göre başarı anlamında daha üstün olduğunu ortaya koymuştur (Tran, 2021). Gemilerin operasyonel verimliliklerinin artırılması için veri toplama sistemlerinden faydalanılmasını öneren bir çalışmada veri setindeki verilerin birbiri ile ilişkisinden faydalanılarak ana makine çalışma modu için bir karar destek modeli geliştirilmiştir (Khanh ve Perera., 2021). Makine öğrenmesi yöntemlerinin gerçek gemi verileri üzerine uygulanarak dinamik yakıt tüketiminin tahmin edilmesini amaçlayan bir çalışmada kurulan modeller sayesinde enerji verimliliği optimizasyonu yapılabilmektedir (Ahlgren ve ark., 2019). İki farklı gemide yakıt tüketimi tahminini amaçlayan bir çalışmada veri seti olarak öğlen raporları ve makine sensörlerinden alınan veriler kullanılmıştır. Ana makine sensör sisteminin veri toplamada önemli bir avantaj sunduğu, veri toplamak için harcanan süreyi azalttığı tespit edilmiştir. Kullanılan makine öğrenmesi modelleriyle de gemilerin yakıt tüketimi başarılı bir şekilde tahmin edilebilmiştir (Gkerekos ve ark., 2019). Ticari gemiler için yakıt tüketimi seferde oluşabilecek giderlerin en önemlisidir. Son yıllarda yapılan çalışmalarda elde edilen bulgular ticari gemilerin sefer boyunca gün bazında tükettiği yakıtın tespiti, emisyonlar, enerji verimliliği hesaplanması, harcanan yakıt miktarı ve gidilen yol arasındaki ilişkilerin bilinmesi gibi konularda önemli mesafe alındığını ortaya çıkarmıştır (Andrea ve ark., 2019; Yuanqiao ve ark. 2020). Gemilerde ana enerji kaynağı olan yakıtın tüketilmesi esnasında verimli ve doğru davranışlar ticari gemilerin sürdürülebilirliğini arttırmaktadır. Bu kapsamda enerji verimliliğinin artırılması adına seyir durumunda iken operasyonel işlerde 2 veya 3 jeneratör çalıştırılması yerine gemide ana makinede üretilmiş enerjinin şaft vasıtasıyla bir jeneratöre verilmesi yöntemi son yıllarda tercih edilir hale gelmiştir (Jan, 2014). Gemide jeneratörlerin toplam yakıtın yaklaşık %10-15'lik bir bölümünü harcadığı literatürde

incelen çalışmalar vasıtasıyla bilinmektedir (Aris ve ark., 2017). Bu miktar kayda değer bir orandır. Sefer sırasında harcanan yakıt sayesinde şaft jeneratörü vasıtasıyla üretilen elektriksel enerjinin tahmini ve verimli kullanılması sayesinde gemide enerji verimliliği artırılabilir.

Bu çalışmada son yıllarda çok farklı alanlara uygulanıp başarılı sonuçlar elde edilen ve böylelikle uygulama alanı yaygınlaşan makine öğrenmesi yöntemleri ile ticari bir gemide 750 günlük gerçek sefer verilerinden hareketle gemide kullanılan şaft jeneratörü tarafından üretilen elektriksel güç tahmin edilmiştir. Veri seti eğitim (%66) ve test verisi (%33) olarak bilgisayar tarafından rastgele seçilerek iki kısma ayrılmıştır. Eğitim verisi olarak seçilen kısım ile makine öğrenmesi yöntemlerine öğretilerek tahmin modelleri geliştirilmesi sağlanmıştır. Bu modeller ile yapılan tahminlerin doğruluğunun tespit edilebilmesi adına test verileri kullanılmıştır. Bu veriler algoritmalara öğretilmemiş ve saklanmıştır. Makine öğrenmesi yöntemlerinin kullanılması için Python programlama dilinin Spyder 3.0 ara yüzü kullanılmıştır. Bu ara yüz sayesinde Çoklu Doğrusal Regresyon (Aline ve ark., 2021), Ridge (Dai ve ark., 2020), Destek Vektör Makinesi (Kanka ve Samuel, 2021), Rastgele Orman (Zhen ve ark., 2021), Karar Ağacı (Tariku ve ark., 2020) ve Gradient Boosting (Nitin ve ark., 2021) isimli makine öğrenmesi yöntemleri kullanılarak bir konteyner gemisi için şaft jeneratörünün elektriksel gücü tahmin edilmiştir. Tahminlerin karşılaştırılabilmesi adına Ortalama Mutlak Hata (Laura ve ark., 2018) ve Kök Ortalama Kare Hata (Martin ve ark., 2020) isimli hata metrikleri kullanılmıştır. Benzetim çalışmasında yapılan tahminler başlangıçta istenen başarıyı sağlayamamıştır. Bu nedenle başarısı düşük algoritmaların parametreleri ayarlanarak tahmin başarısı artırılmıştır. Çalışma sonucunda Çoklu


Doğrusal Regresyon algoritmasının gemi şaft jeneratörünün elektriksel gücünün tahmin edilmesinde diğer yöntemlerden daha başarılı olduğu ortaya çıkmıştır. Çalışma sonunda elde edilen bulgulardan hareketle gemilerde şaft jeneratörünün elektriksel güç tahmininin makine öğrenmesi algoritmaları ile başarılı bir şekilde tahmin edilebileceği sonucuna da varılabilir. Bu sayede ilerleyen yıllarda bu bağlamda enerji verimliliği modelleri kurulabilir ve gemi enerji verimliliğinin artırılmasına katkı da sunulabilir.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir; ikinci bölüm materyal ve metod üzerine kurgulanmıştır, üçüncü bölümde yapılan tahmin çalışması ve elde edilen sonuçlar yer almıştır. Çalışmanın dördüncü ve son bölümünde ise benzetim çalışmasında elde edilen bulgular değerlendirilmiştir.

## 2. Materyal ve Yöntemler

### 2.1. Çalışmada izlenen yöntem

Bu çalışma ticari bir gemide şaft jeneratörü elektriksel gücünün makine öğrenmesi yöntemleri ile tahmin edilmesi üzerine 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 algoritmalara 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 birbirileriyle karşılaştırılabilmiştir. Çalışma kapsamında yapılan işlemler Şekil 1’de gösterilmiştir.



**Şekil 1.** Çalışmanın metodolojisi.

## 2.2. Veri setinin özeti

Çalışmada ticari amaçla kullanılan 318 metre uzunluğa 42 metre genişliğe ve 8,4 metre draфта 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 silindirik 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 tablo 1’de verilmiştir.

**Tablo 1.** Veri setinin istatistiksel özeti

	Adet	Ortalama değer	En küçük değer	En büyük 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 makine yakıt giriş sıcaklığı (°C)	750	67,8	63,9	71,74	6,51
Şaft jeneratörü gücü (kW)	750	814,76	95	1740	1317,45
...	...	...	...	...	...

### 2.3. Makine öğrenmesi algoritmaları


#### a) Çoklu doğrusal regresyon

Makine öğrenmesi algoritmalarının en bilinen yöntemlerinden olan çoklu doğrusal regresyon (ÇDR) algoritmasında bağımsız değişkenlerin belirli katsayılarla çarpılarak toplanması sonucunda bağımlı değişken elde edilir. Bu algoritmaya ilişkin denklem aşağıda verilmiştir. Denklem 1’de  $w$  değerleri sabitleri,  $x$  değerleri bağımsız değişkenleri ifade ederken  $y$  değeri ise bağımlı değişkeni göstermektedir (Aline ve ark., 2021).

$$w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n = y \quad (1)$$

#### b) Destek vektör makinesi

Destek vektör makinesi (DVM) denetimli makine öğrenmesi yöntemlerinden biridir (Kanka ve Samuel, 2021). Bu algoritmada amaç yapılan tahminlerin önceden belirlenen aralık içinde olmasını sağlamaktır. Bu aralığa destek vektörü de denmektedir. Bu algoritma Şekil 2’de gösterilmiştir. Şekil incelendiğinde  $\epsilon$  değerleri hata için izin verilen aralığı ifade etmektedir. Grafikte belirlenen destek vektörleri mavi renkte uzun çizgiler olarak gösterilmiş, kabul edilebilir hata oranına sahip tahminler mavi noktalarla belirtilmiştir. Destek vektörlerinin dışında kalan başarısız tahmin değerleri ise kırmızı noktalarla gösterilmiştir.



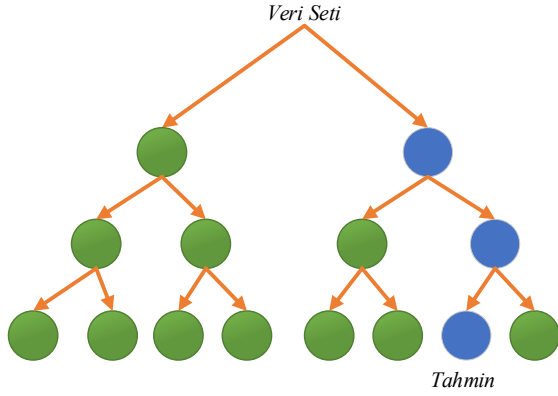
Şekil 2. Destek vektör makinesi.

#### c) Ridge yöntemi

Ridge (R) yöntemi katsayı tahmininde kullanılan bir yöntemdir. Bu yöntemde tahmin edicilerin yaptığı tahminlerin hata değerinin sifira yaklaştığı modeller üretilmeye çalışılır. Kurgusu bakımından doğrusal regresyon algoritmasına benzer ancak katsayılar en küçük kareler yöntemi yerine ceza değeri uygulanarak belirlenmeye çalışılır (Dai ve ark., 2020).

#### d) Karar ağacı algoritması

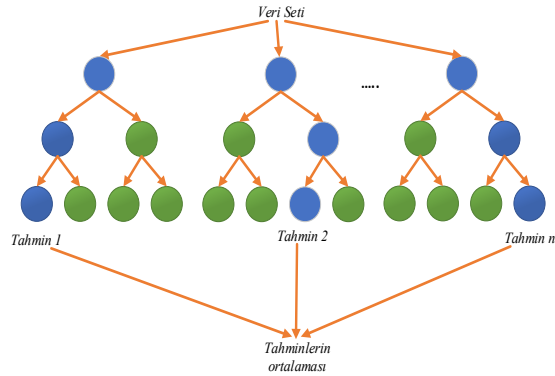
Karar ağaçları (KA), hem regresyon hem de sınıflandırma modelleri üzerine kullanılan bir algoritmadır. Karar ağaçları, özellik ve hedefe göre değişen karar düğümleri ve yaprak düğümlerden oluşmaktadır. Bu yöntem insan düşünme yöntemine benzerliği ile diğer algoritmalarından ayrılmaktadır. Şekil 3’te karar ağacı yöntemi gösterilmiştir.



Şekil 3. Karar ağacı yöntemi

### e) Rastgele orman algoritması

Rastgele orman (RO) yönteminde çok sayıda karar ağaçlarının oluşturduğu bir yapı düşünülmelidir. Bu yapı üzerinde farklı ağaçların tahminleri bir araya getirilir ve ortalaması alınarak nihai tahmin değerine ulaşılır (Zhen ve ark., 2021). Bu yapı Şekil 4'te gösterilmiştir.



Şekil 4. Rastgele orman algoritması

### f) Gradient boosting algoritması

Gradient boosting (GB) yöntemi regresyon ve sınıflandırma konularında sıklıkla kullanılan bir yöntemdir. Bu yöntemde yapılan tahmin değeri için kullanılan parametre ağırlıkları her tahmin için değiştirilmek yerine bir önceki yapılan tahminlerdeki hata ile karşılaştırarak sonuca gidilmeye çalışılır (Nitin ve ark., 2021).

## 2.4. Hata metrikleri

### a) Ortalama mutlak hata

Bu hata metriği bulunurken her indis için gerçek değer ile tahmin edilen değer arasındaki farkın mutlak değeri bulunur. Bulunan bu değerlerin

ortalaması ortalama mutlak hata (OMH) değerini verir. Denklem 2'de ortalama mutlak hatanın bulunması gösterilmiştir.

$$OMH = \frac{1}{n} \sum_{i=1}^n |g_i - t_i| \quad (2)$$

Bu denklemde i değeri indis numarasını, g değeri gerçek değerleri ifade ederken t değeri ise tahmin edilen değerleri ifade eder.

### b) Kök ortalama kare hata

Makine öğrenmesi modellerinin başarısı incelenirken sıklıkla kullanılan yöntemlerden biridir. Bu yöntemde tahmin edilen değerler ile gerçek değerler arasındaki farkların kareleri alınır ve toplanır. Bu toplamın karekökü alınır. Son olarak ortalaması bulunarak kök ortalama kare hata (KOKH) değeri bulunmuş olur. Bu işlem Denklem 3'te gösterilmiştir.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (g_i - t_i)^2} \quad (3)$$

Bu denklemde i değeri indis numarasını ifade ederken g değeri gerçek değerleri ifade eder. Denklemde t değeri ise tahmin edilen değerleri ifade eder.

## 3. Şaft Jeneratörü Elektriksel Güç Tahmini Benzetim Sonuçları

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 algoritmalar tahmin modeli oluşturulabilmesi amacıyla öğretilmiştir. Kalan 250 satırlık test verisi ise algoritmalar tarafından eğitim verisi ile kurulan modellerin başarısının incelenmesi adına saklanmıştır. Çalışmanın bir sonraki aşamasında algoritmalar tarafından şaft jeneratörü gücü tahmini yapılmıştır. Tahmin çalışmasının ilk safhasında bazı algoritmalar tahmin edici seviyede bir başarı sağlayamamıştır. Bu nedenle algoritmaların parametreleri optimize edilerek tahmin işlemi tekrarlanmıştır. Çalışmada elde edilen hata metrikleri Tablo 2'de verilmiştir. Çalışmanın ilk safhasında optimize edilen algoritma parametreleri ise Tablo 3'te görülmektedir. Algoritmaların yaptığı

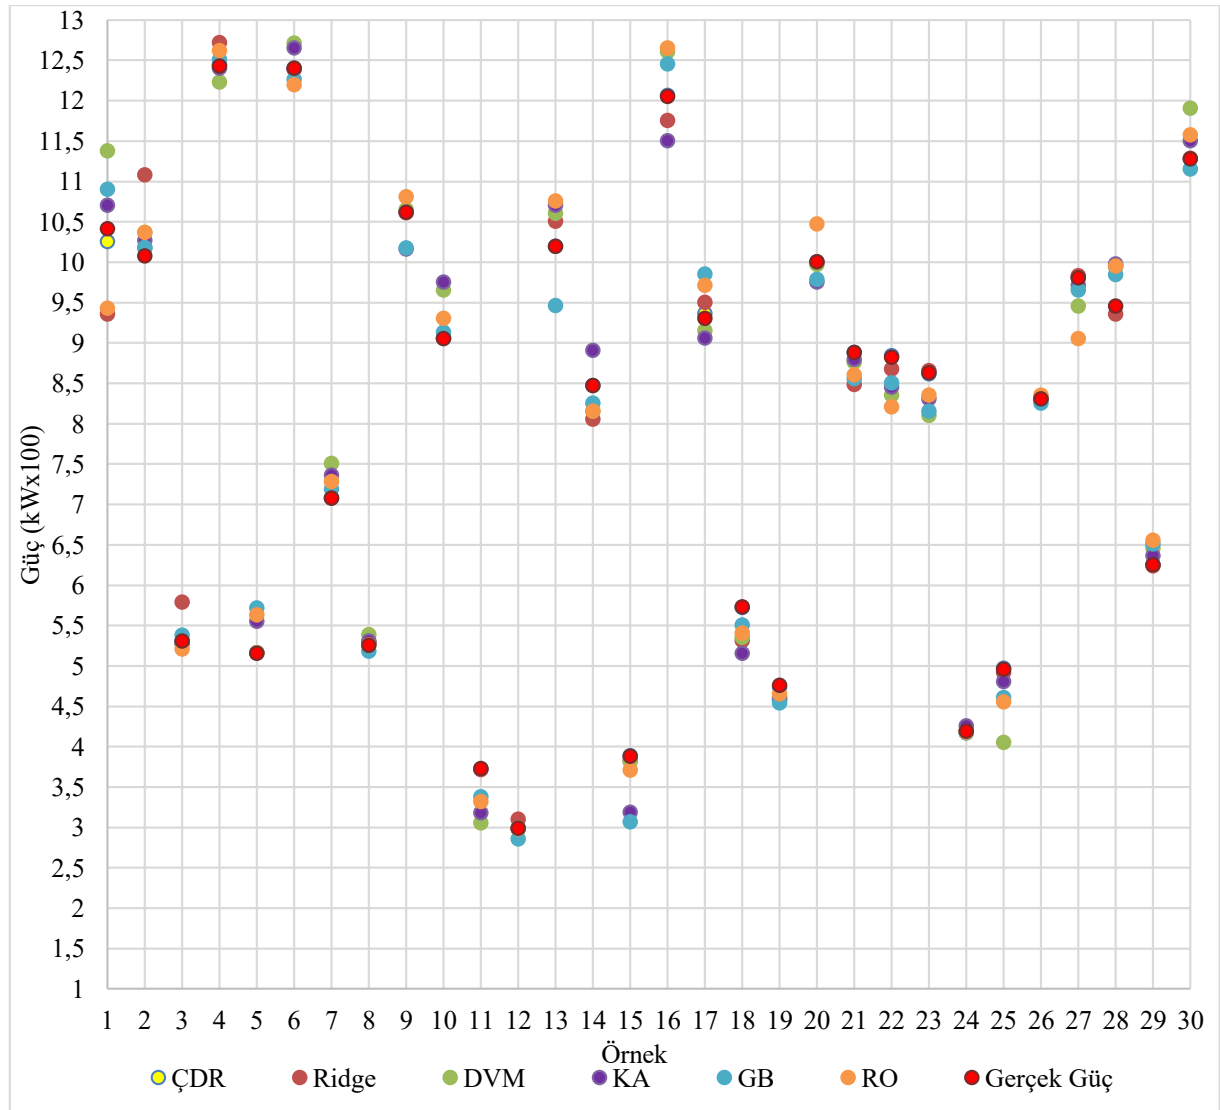
tahminlerin 30 günlük bir karşılaştırılması ise Şekil 5'te yer almıştır.

**Tablo 2.** 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

**Tablo 3.** 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 5.** Algoritma tahminlerinin karşılaştırılması

#### 4. Sonuçlar ve öneriler

Bu çalışmada ticari amaçla kullanılan bir konteyner gemisinde sefer sırasında ihtiyaç duyulan elektriksel güç ihtiyacının şaft jeneratörü ile karşılandığı bu sistemde geminin operasyonel güç ihtiyacının makine öğrenmesi algoritmaları ile tahmini yapılmıştır. 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 edilebileceği, bu sayede gemide sefer esnasında ani bir yüklenme için oluşabilecek elektriksel çökmelere karşı önlem alınabileceği 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 edilebileceği ve sürdürülebilir bir denizcilik için ve Uluslararası Denizcilik Örgütü tarafından konulan emisyon kurallarını sağlamaya yönelik olumlu bir adım atılabileceği bulguları elde edilmiştir.

#### Destek ve Teşekkür Beyanı

Teşekkür edilecek bir kurum ya da kuruluş bulunmamaktadır.

#### Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kişi ya da kurum ile çıkar çatışması bulunmamaktadır.

#### Referanslar

**Ahlgren F., Mondejar M.E., Thern M.** (2019). Predicting Dynamic Fuel Oil Consumption on Ships with Automated Machine Learning, *Energy Procedia*, 158, 6126-6131, 1876-6102, doi: 10.1016/j.egypro.2019.01.499.

**Alexey V. P.** (2014). Innovation and design of cruise ships, *Pacific Science Review*, 16, 4, 280-282, 1229-5450, doi: 10.1016/j.pscr.2015.02.001.

**Aline F. S., Nicolau A. C., André D. S. B., José E. S., Amauri G., Noé C., Bismarck L. S.** (2021). Multiple linear regression approach to predict tensile properties of Sn-Ag-Cu (SAC) alloys, *Materials Letters*, 304, 130587, 0167-577X, doi: 10.1016/j.matlet.2021.130587.

**Andrea C., Luca O., Francesco B., Francesca C., Mehmet A., Stefano S.** (2019). Data-driven ship digital twin for estimating the speed loss caused by the marine fouling, *Ocean Engineering*, 186, 106063, 0029-8018, doi: 10.1016/j.oceaneng.2019.05.045.

**Andrew C. T., Irina H., Vasco S. R., Joseph S.** (2020). Maritime container shipping: Does coopetition improve cost and environmental efficiencies?. *Transportation Research Part D: Transport and Environment*, 87, 102507, 1361-9209, doi: 10.1016/j.trd.2020.102507.

**Aris P., Anders H. M., Tim C. M.** (2017). Applying Multi-Class Support Vector Machines for performance assessment of shipping operations: The case of tanker vessels, *Ocean Engineering*, 140, 1-6, 0029-8018, doi: 10.1016/j.oceaneng.2017.05.001.

**Bilgili L.** (2021). Life cycle comparison of marine fuels for IMO 2020 Sulphur Cap. *Science of The Total Environment*, Volume 774, 145719, 0048-9697, doi: 10.1016/j.scitotenv.2021.145719.

**Chengpeng W., Yinxiang Z., Di Z., Tsz L. Y.** (2021). Identifying important ports in maritime container shipping networks along the Maritime Silk Road. *Ocean & Coastal Management*, 211, 105738, 0964-5691, doi: 10.1016/j.ocecoaman.2021.105738.

**Chi Z., Di Z., Mingyang Z., Wengang M.** (2019). Data-driven ship energy efficiency analysis and optimization model for route planning in ice-covered Arctic waters, *Ocean Engineering*, 186, 106071, 0029-8018, doi: 10.1016/j.oceaneng.2019.05.053.

**Dai X., Chen H., Seyed A. B., Masoud S., Mohammad A.** (2019). Statistical estimation the thermal conductivity of MWCNTs-SiO<sub>2</sub>/Water-EG nanofluid using the ridge regression method, *Physica A: Statistical Mechanics and its Applications*, 537, 122782, 0378-4371, doi: 10.1016/j.physa.2019.122782.



- Gkerekos C., Lazakis I., Theotokatos G.** (2019). Machine learning models for predicting ship main engine Fuel Oil Consumption: A comparative study, *Ocean Engineering*, 188, 106282, 0029-8018, doi: 10.1016/j.oceaneng.2019.106282
- Harilaos N. P., Thalys Z., Sotiria L.** (2021). A comparative evaluation of market based measures for shipping decarbonization. *Maritime Transport Research*, 2, 100019, 2666-822X, doi: 10.1016/j.martra.2021.100019.
- Jan K.** (2014). Ship's Propulsion Neural Controller Main Engine-Pitch Propeller-Shaft Generator, *IFAC Proceedings Volumes*, 47, 1, 905-912, 1474-6670, 9783902823601, doi: 10.3182/20140313-3-IN-3024.00067.
- Jin S. P., Young-Joon S., Min-Ho H.** (2019). The role of maritime, land, and air transportation in economic growth: Panel evidence from OECD and non-OECD countries. *Research in Transportation Economics*, 78, 100765, 0739-8859, doi: 10.1016/j.retrec.2019.100765.
- Kanka G., Samuel G. L.** (2021). Support vector machine regression for predicting dimensional features of die-sinking electrical discharge machined components, *Procedia CIRP*, 99, 508-513, 2212-8271, doi: 10.1016/j.procir.2021.03.109.
- Khanh Q. B., Perera L.P.** (2021). Advanced data analytics for ship performance monitoring under localized operational conditions, *Ocean Engineering*, 235, 109392, 0029-8018, doi: 10.1016/j.oceaneng.2021.109392.
- Laura F. P., Fermin M., Martín G. R., Teresa L.** (2018). Dynamic mean absolute error as new measure for assessing forecasting errors, *Energy Conversion and Management*, 162, 176-188, 0196-8904, doi: 10.1016/j.enconman.2018.02.030.
- Martin Ć., Shady H. E. A. A., Ahmed F. Z.** (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, 112716, 0196-8904, doi: 10.1016/j.enconman.2020.112716.
- Nitin D., Babita S., Chalak H.D.** (2021). Gradient boosting-based regression modelling for estimating the time period of the irregular precast concrete structural system with cross bracing, *Journal of King Saud University-Engineering Sciences*, 1018-3639, doi: 10.1016/j.jksues.2021.08.004.
- Pavlos K., Nikos T.** (2021), Data-driven modelling of ship propulsion and the effect of data pre-processing on the prediction of ship fuel consumption and speed loss. *Ocean Engineering*, 222, 108616, 0029-8018, doi: 10.1016/j.oceaneng.2021.108616.
- Paula S. Á.** (2021). From maritime salvage to IMO 2020 strategy: Two actions to protect the environment, *Marine Pollution Bulletin*, 170, 112590, 0025-326X, doi: 10.1016/j.marpolbul.2021.112590.
- Peng Y., Huakun L., Xiangda L., Jian H., Wenyuan W.** (2020). Machine learning method for energy consumption prediction of ships in port considering green ports, *Journal of Cleaner Production*, 264, 121564, 0959-6526, doi: 10.1016/j.jclepro.2020.121564.
- Saim T.K., Yercan F.** (2021). Comparative Cost-Effectiveness Analysis of Arctic and International Shipping Routes: A Fuzzy Analytic Hierarchy Process, *Transport Policy*, 0967-070X, doi: 10.1016/j.tranpol.2021.08.015.
- Tariku S. T., Gang X., Zhishuai L., Hao T., Zhen S., Bin H., Heruye M. M.** (2021). Traffic Congestion Prediction using Decision Tree, Logistic Regression and Neural Networks, *IFAC-Papers On Line*, 53, 5, 512-517, 2405-8963, doi: 10.1016/j.ifacol.2021.04.138.
- Tran T.A.** (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*, 2468-0133, doi: 10.1016/j.joes.2021.02.005.
- Yuanqiao W., Zhongyi S., Chunhui Z., Changshi X., Qianqian C., Dong H., Yimeng Z.** (2020). Automatic ship route design between two ports: A data-driven method, *Applied*

*Ocean Research*, 96, 102049, 0141-1187, doi:  
10.1016/j.apor.2019.102049.

**Zhen G., Bin Y., Mengyan H., Wensi W., Yu J., Fang Z.** (2021). A novel hybrid method for

flight departure delay prediction using Random Forest Regression and Maximal Information Coefficient, *Aerospace Science and Technology*, 116, 106822, 1270-9638, doi:  
10.1016/j.ast.2021.106822.