

## Genetik Algoritmalar ile Deniz Taşımacılığında Hız Optimizasyonu

Tarik TAŞPINAR<sup>1</sup>, Zeynep ORMAN<sup>\*2</sup>

<sup>1,2</sup>İstanbul Üniversitesi-Cerrahpaşa, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, 34320, Türkiye

Araştırma Makalesi, Geliş Tarihi: 11.02.2023, Kabul Tarihi: 26.02.2023

### Özet

Gemicilik sektöründe yakıt tüketimini ve dolayısıyla sera gazı emisyonunu azaltmaya yönelik bazı düzenlemeler yapılmaktadır. Bunların başında seyir hızlarının düşürülmesi gelmektedir. Bu çalışmada, zaman kısıtlatmalı genetik algoritmalar (GA) kullanılarak hız optimizasyonu çalışması yapılmıştır. Böylece gemi yolculuklarında en az yakıt tüketimi veren hız profilleri araştırılmıştır. Ham veri seti üzerinde çeşitli veri bilimi teknikleri uygulanarak eksik veya hatalı verilerin düzeltilmesi ve yerel anormallik faktör algoritması kullanılarak anormalliklerin temizlenmesi sağlanmıştır. Daha sonra, korelasyon analizi ile regresyon değişkenleri arasındaki ilişkiler belirlenmiştir. Bu bölümün sonunda da en az yakıt tüketimiyle sonuçlanan optimum gemi hızının araştırılması için ön işlemden geçirilmiş veriler kullanılarak yakıt tüketimi tahmin modeli ortaya çıkarılmıştır. Regresyon tahmin modeli için bir dizi makine öğrenmesi teknikleri kullanılmıştır. Bunlar; lineer regresyon (LR), K-En Yakın Komşuluk algoritması (KNN), Destek Vektörleri (SVR), Rastgele Orman (RF), ADABOOST, Gradyan Artırmalar (GRB ve XGB) ve topluluk yöntemleridir. Ayrıca, tüm modeller için hiper parametre optimizasyonu yapılmıştır. Genetik algoritmada popülasyon bireyleri hız profilleri olup, ilklendirilmeleri için hız profillerinde rastgele modifikasyonlar denenmiştir. Sonuçta, genetik algoritmada farklı büyüklükteki mutasyon, çaprazlama, seçme, popülasyon sayısı, yolculuk gecikmesi ve hız limitleri kullanılarak minimum yakıt tüketimi ile sonuçlanan hız profilleri araştırılmıştır.

**Anahtar Kelimeler:** Gemi hız optimizasyonu, yakıt tüketimi, genetik algoritma, makine öğrenmesi, regresyon modelleri.

## Voyage Speed Optimization Using Genetic Algorithm

### Abstract

Decreasing the fuel consumption and thus greenhouse gas emissions of vessels have emerged as a critical topic for both ship operators and policymakers in recent years. The speed of vessels has long been recognized to have the highest impact on fuel consumption. For this purposes, linear and non-linear methods such as KNN, support vectors, random forest, gradient boosting, ada boost, xgboost and ensemble models accuracy results are compared for better fuel consumption predictions in speed optimization using genetic algorithms. Furthermore, hyperparameters are researched for all models. The local outlier factor algorithm is used to eliminate outliers in prediction features. The overfitting problem is observed after hyperparameter tuning in boosting and tree-based regression prediction methods. The early stopping technique is applied for overfitted models. The aim of this study is to develop a speed optimization model using a time-constrained genetic algorithm (GA). The speed profiles are used as individuals in genetic algorithm and randomly initialization of speed profiles has been investigated. Also, various mutation, crossover, selection, population size, time of arrivals and speed limits have been tried to find a speed profile that results in minimum fuel consumption.

**Keywords:** Ship speed optimization, fuel consumption, genetic algorithm, machine learning, regression methods.

\*Sorumlu yazar ormanz@iuc.edu.tr, <sup>2</sup>tarikaspinar@gmail.com

## 1. GİRİŞ

Deniz taşımacılığı sektöründe, hız kısıtlamaları ile ilgili yeni düzenlemeler tartışma konusu olmaktadır. Uluslararası Denizcilik Örgütü (International Maritime Organization - IMO) tarafından, yakıt tüketimini ve seyir maliyetlerini azaltmak amacıyla gemilerin tasarlanırken belirlenen ve optimum seyir hızları için hız limitleri önerilmektedir. Bunun gerekçesi ise şimdiye kadar genel bir kural olarak bilinen; seyir hızı %10 azalır, ilgili motor gücü ve sefer için gerekli toplam enerji sırasıyla %27 ve %19 azalmakta olduğudur (Faber vd., 2012).

Gemi operasyonel verilerini kullanan literatürdeki son çalışmalar, hız azalsa bile yakıt tüketiminin artabileceğini göstermiştir. Ayrıca, çalışmalar aynı zamanda her yolculuk için optimum bir hız profiline olduğunu ve optimum hızdan sapmaların daha fazla yakıt tüketimine neden olabileceğini göstermektedir (förstudie initierad av Lighthouse). Çünkü, hava şartları, rüzgar yönü, dalga büyüklüğü, limanlardaki trafik, bunker fiyatları ve daha birçok parametre anlık olarak değişerek nakliye gecikmelere neden olmaktadır. Hava şartları kötü olsa bile, rüzgar yönünün avantajı veya limanlardaki trafikte beklemenin maliyeti nedeniyle yolculuğun belirli bir döneminde hız yükseltmek avantajlı olabilirken, yine hava şartları nedeniyle tersi de geçerli olabilmektedir. Bu yüzden bir yolculuk boyunca sabit hız veya hız limiti uygulamak yerine, enerji verimliliğini artırma amacıyla kurulan yapay zekalı karar destek sistemleri sayesinde değişken hızların bulunduğu bir hız profili ortaya çıkabilmektedir. Bu nedenle, bu çalışmada, gemi operatörü tarafından müsaade edilen gecikmeler için minimum yakıt tüketimine yol açan optimum gemi hızı profilleri araştırılmıştır. Sonuç olarak, ham gemi verileri için ilk veri ön işleme aşamasından sonra, bir yakıt tüketim tahmin modeli geliştirilmiştir. Sonrasında en iyi sonucu veren tahmin fonksiyonu, genetik algoritmada amaç fonksiyonu olarak kullanılmıştır.

## 2. LİTERATÜR ARAŞTIRMASI

Gemi ulaşımında enerji verimliliği çalışmaları literatürde yaygın olarak bulunmaktadır. University College London (UCL) Enerji Enstitüsü (2013) (Kim vd., 2021) Otomatik Tanımlama Sistemi-OTS (Automatic Identification System - AIS) uydu verilerini kullanarak farklı filoların operasyonel verimliliğinin bir değerlendirmesini yayınlamıştır. AIS veri sonuçları, gemilerin ortalama hızında yapılan %10-15 oranındaki bir azaltmanın, toplu filolar için yakıt verimliliğini

yaklaşık %10 ve konteyner filoları için %30'a kadar artırabileceğini göstermiştir.

Ancak, zamanla tam tersi bir görüş de ortaya çıkmıştır. Karl ve diğerleri (2020) (förstudie initierad av Lighthouse), İsveç ticaretindeki gemiler için hız azaltmanın sonuçlarını araştırmıştır. Araştırma sonuçları, yakıt tüketiminin düşük hızlarda da artabileceğini göstermiştir. Ayrıca, en önemli bulgulardan biri, her yük seviyesi için optimum hıza göre değişebilen minimum yakıt tüketimidir. Hızı bu optimum noktadan yukarı veya aşağı yönde değiştirmek, daha fazla yakıt tüketimine neden olabilmektedir.

Aslında, daha önceleri baskın görüş, gemi hızının kübik bir fonksiyonu ile, tarihsel verilerin kullanılmadığı zamanlarda, gemilerin yakıt tüketiminin açıklanabildiği varsayıyordu (Andrea vd., 2017). Böylece, gemilerin sabit olan tasarım hızları seyir için de optimum hız haline gelmişti. Optimum nokta etrafında hızın esneklik potansiyelini göstermek için Adland ve diğerleri petrol tankerlerinin öğlen raporlarını (noon reports) dikkate almıştır. Çalışma sonuçları ise, hız azaltma değerlendirmelerinin yakıt tüketimi verimliliğini olduğundan daha yüksek tahmin ettiğini göstermiştir. Çünkü, hız esnekliği için kübik yöntemlerin kullanılması, regresyon modellerinden daha fazla yakıt tasarrufuyla sonuçlanmıştır. Ayrıca, ilgili çalışmada doğrusal olmayan bir regresyon modeli önerilmiş olsa bile tahminler için global optimum bulma yeteneğine sahip olmadığı iddia edilmiştir. Lineer regresyon modelinin yakıt tüketimi tahmin doğruluğu ise Aframax ve Suezmax tankerleri için %80 civarındaydı. Ancak, beş gizli katmana sahip sinir ağları daha yüksek doğrulukta sonuçlar vermiştir.

Daha yüksek doğruluk ve daha düşük hata oranlarına sahip yakıt tüketimi tahmini, optimizasyon çalışmaları için bir ön koşuldur. Kim ve diğerleri (Kim vd., 2021) geminin ana motor hızı, yere göre hızı, rüzgar hızı, dümen açısı, trim, ıslak yüzey alanı ve deplasman parametreleri ile ANN veya çoklu doğrusal regresyon (MLR) modellerini yakıt tüketimini tahmin etmek için kullanmıştır. Bu çalışmanın sonucunda ANN ve MLR modelleri sırasıyla %99 ve %87 doğruluk sonuçlarıyla çıktı vermiştir.

Gemilerde yakıt tüketimini etkileyen çok sayıda parametre bulunmaktadır. Ancak, bazı değişkenlerin modelde sadece gürültü etkisi vardır ve sonuca anlamlı bir etkisi de bulunmaz. Ayrıca, bazı parametreler aşırı öğrenmeye veya kötü algoritma performansına neden

olabilir. Bu nedenle, parametre seçimi, makine öğrenmesi modellerinde ele alınması gereken önemli bir konudur. Bu konuda Corradu ve arkadaşları (Andrea vd., 2017) hesaplamalı olarak düşük performans gösteren rastgele orman yöntemini (random forest method) kullanmıştır. Karar ağaçlarını seçmek için ise kaba kuvvet yöntemini (brute force method) kullanmıştır. Sonunda, kaba kuvvet yöntemleri daha iyi doğruluk sonuçları vermiştir. Daha kesin olarak, pervane adımı ve gemi hızı parametrelerinin yakıt tüketimi tahmininde daha fazla etkisi görülmüştür. Ayrıca, gemi taslağı ve şaft gücü, yakıt tüketimi tahmini için en önemli parametreler arasında bulunurken, rüzgar hızı ve yönü parametreleri ise ciddi bir etkiye sahip olmamıştır.

Parametrik modellerin öznitelik seçimini abartılı tahmin edebilmesi nedeniyle aşırı öğrenmeyi önlemek için parametrik olmayan modeller kullanılabilir. Gkerkos ve arkadaşları (Christos vd., 2019), en iyi model performansını bulmak için bir grup parametrik ve parametrik olmayan makine öğrenmesi modellerini birlikte test etmişlerdir. Ridge and Lasso regresyon, Destek Vektörleri (SVR) ve ANN parametrik modeller olarak kullanılmıştır. Ayrıca, Karar Ağacı Regresörü (DTR), Ekstra Ağaç Regresörü (ETR), K-En Yakın Komşular (KNN) ve Rastgele Orman Regresörü (RFR) parametrik olmayan modeller olarak ele alınmıştır. Çalışmanın varsayımı ise, başlangıçta parametre varsayımları olmadan çalıştırıldığı için, parametrik olmayan modellerin daha yüksek performans göstereceğidir. Sonuçta en iyi doğruluk sonuçları, randomize ETR'lerden elde edilmiştir.

Yang, Chen (Yang vd., 2020), bir petrol tankerinin hız optimizasyonu için bir genetik algoritma kullanmıştır. Öncelikle tüm rota birkaç etaba ayrılmıştır. Bu etaplar hız, rüzgar, dalgalar ve okyanus akıntıları dikkate alınarak değiştirilmiştir. Genetik optimizasyon kısıtlamaları için maksimum ve minimum seyir hızları ve beklenen varış süreleri uygulanmıştır. Ayrıca, yakıt tüketimi, minimum tutulacak bir amaç fonksiyonu olarak ele alınmıştır. Sonunda, her segment için doğru hızın seçilmesiyle birlikte yapılan çalışma %2,2 daha az yakıt tüketimi ile sonuçlanmıştır.

Deniz taşımacılığında beklenen varış zamanı pek çok beklenmedik olayla değişebilir. Lineer taşımacılıkta limanlarda yaşanan bekleme ve gecikmeler ekstra maliyete neden olabilmektedir. Aydın ve Lee (Aydın vd., 2017) değişken tahmini varış tarihi (Estimated time of arrival - ETA) gecikmeleri ve bunker fiyatlarını kullanarak optimum seyir hızını araştırmıştır. Dinamik programlama, belirsiz liman sürelerini göz önünde

bulundurarak seyir hızını belirlemek için kullanılmıştır. Çünkü, gemi kaptanı seyahat sırasında bir sonraki liman sıklıkliğini ve yakıt ikmal fiyatlarını anlık kontrol ederek gemi hızını arttırmayı ya da düşürmeyi tercih edebilirler. Ayrıca, alternatif olarak, dinamik programlamada rüzgar hızı, dalga yüksekliği vb. rastgele niceliklerin beklenen değerleri kullanılarak deterministik bir yöntem de uygulanmıştır. Sonuçta, ortalama seyir hızları en deterministik modelde dinamik programlama modeline göre daha yüksek hesaplanmıştır. Ayrıca gecikme cezası arttıkça deterministik modelin performansı düşmüştür.

Tahmini varış zamanı ve yakıt tüketimi birbiriyle ters orantılıdır. ETA'nın kısaltılması daha fazla yakıt tüketimine neden olabilmektedir veya bunun tersi de geçerlidir. Helong, Xiao (Helong vd., 2021), iki farklı amaç fonksiyonu ile genetik algoritma kullanarak yolculuk optimizasyon modeli geliştirmiştir. Bunlar, yakıt tüketimi minimizasyonu ve varış dakikliğidir. Zorlu deniz koşullarında rotaları sezgisel olarak planlayarak ve aynı ETA'ları koruyarak yakıt tüketiminde %3,4'e varan tasarruf sağlanmıştır. Ayrıca, bu çalışma, genetik algoritma popülasyonlarında genetik çeşitliliği artırmanın, amaç fonksiyonunun başarısını yani yakıt tüketimi tasarrufunu artırdığını göstermiştir.

### 3. ANALİZ METODU

Bu çalışmada sırasıyla veri analizi, regresyon ve genetik algoritma ile yakıt tüketimi optimizasyonu yapılmıştır.

#### 3.1 Veri Analizi


Yakıt tüketimi ile ana motorlar veya pervane hatvesi arasındaki korelasyon yüzde yüz olmasa da sonuç olarak yakıt sadece ana motorlar tarafından tüketilmektedir. Bu nedenle, diğer parametrelerin tahmin gücünü kaybetmemek için ana motorlar veya pervane hatvesi değişkenleri bu çalışmanın dışında tutulmuştur. Seçilen tüm parametreler Tablo 1'de listelenmiştir.

**Tablo 1** Regresyon analizi için seçilen parametreler

Id	Parametre	Boyut
1	Yere Göre Hız	knots
2	Yakıt Tüketimi	kg/h
3	Balast	ton
4	Dizel Yakıt	ton
5	Omurga Derinliği	m
6	Navlun	ton
7	Su	ton
8	Meyil Açısı	deg
9	Seyir Yönü	deg

10	Trim	m
11	Pupa Rüzgarı	m/s
12	Rüzgar Hızı	m/s
13	Rüzgar Yönü	deg

Orijinal örnekleme hızı (1 saniye), tüm veri kümesine uygulanan 30 saniyelik alt örnekleme işlemi ile değiştirilmiştir. Şekil 1’de veri kümesinde bulunan tüm değişkenlerin 1 günlük grafikleri gösterilmektedir. Rüzgar hızı, yere göre hız ile yakıt tüketimi arasındaki korelasyonlar gözle görülebilmektedir. Ancak diğer değişkenler için (örneğin balast yükü) bunu söylemek zordur.

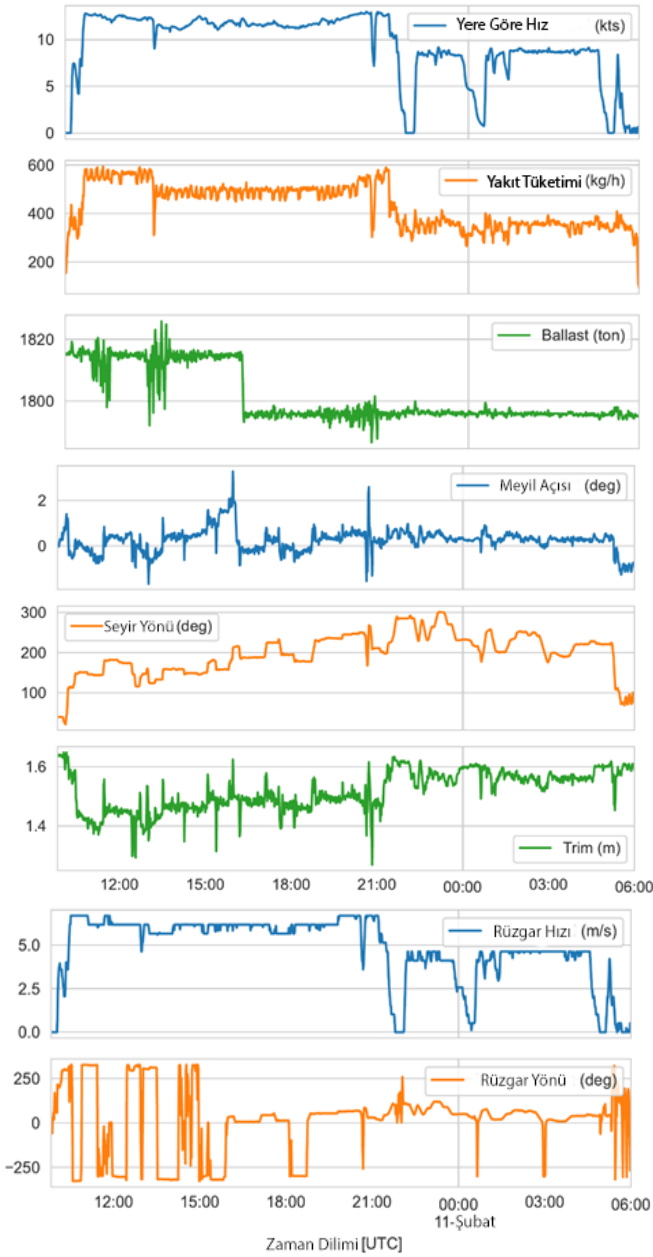


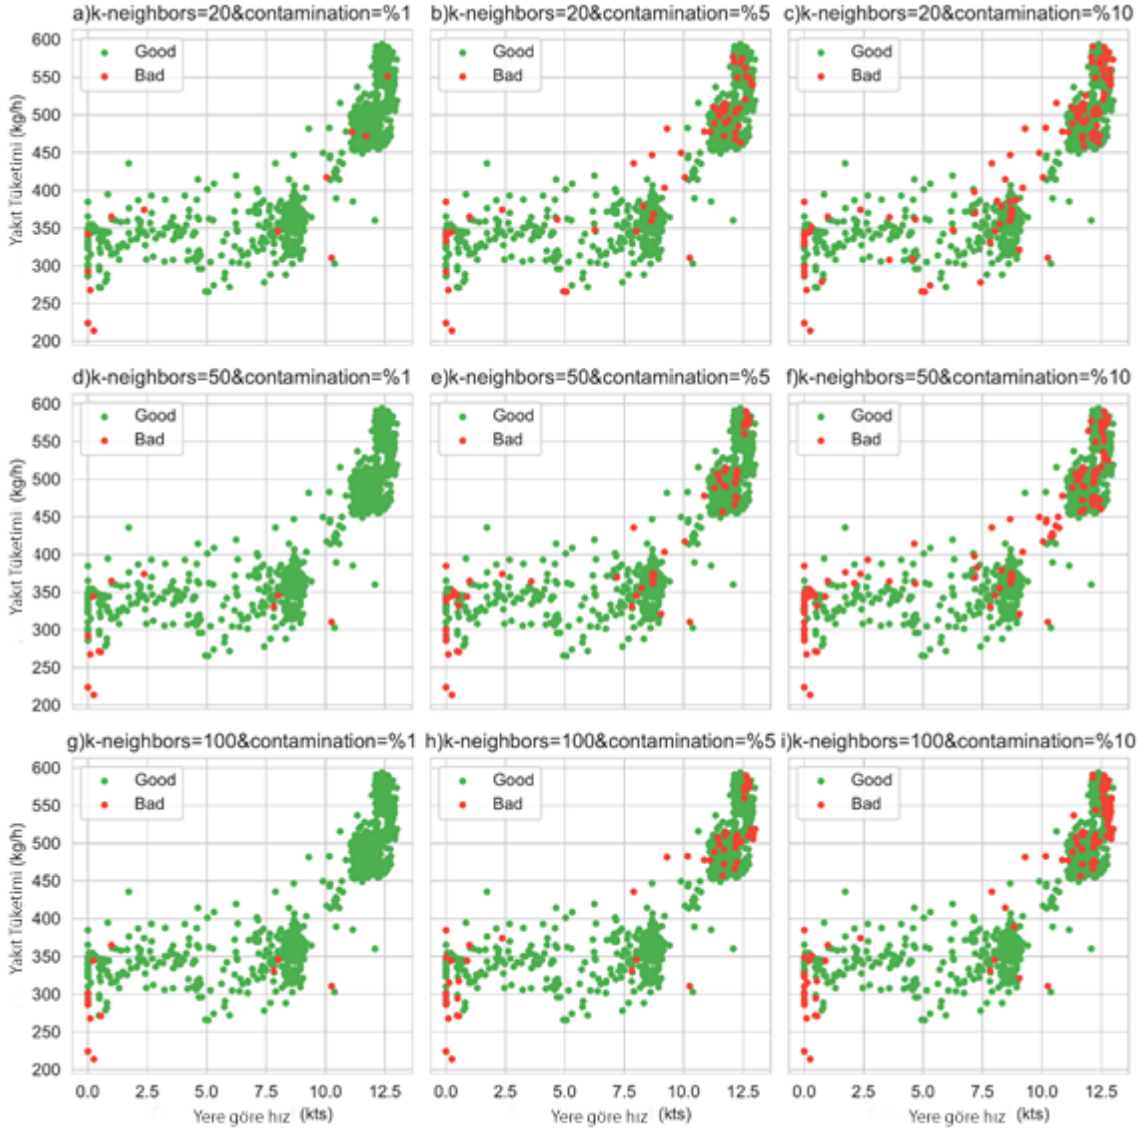
Şekil 1. Gemi parametrelerinin 1 günlük grafiği

### 3.1.1 Aykırı Değer Faktörü

Yerel Aykırı Değer Faktörü (Local Outlier Factor - LOF) algoritması, bir aykırı olma derecesi tanımlayarak aykırı değerleri bulur. Kısaca, LOF algoritması, noktanın komşularıyla karşılaştırmak için bir yoğunluk fonksiyonu kullanır. LOF algoritmasının temel varsayımı, aykırı değerlerin yoğunluğunun, aykırı olmayanlara göre komşuların yoğunluğundan çok daha farklı olduğu için, yoğunluk k-en yakın komşulara ve bunların k-mesafesine bağlıdır. Bu amaçla, 20, 50 ve 100 komşu sayısı (k-komşu) ile tahmini kontaminasyon oranlarının yüzde 1, 5 ve 10'u sırasıyla ve diğer tüm değişkenler sabit tutulmak koşuluyla yinelemeli olarak birlikte uygulanmıştır. Son olarak, LOF yönteminin sonuçları Şekil 2’de dağılım grafikleri olarak gösterilmektedir. Kırmızı renkli noktalar aykırı değerleri göstermektedir.

Ham veri kümesinden daha fazla veri ve dolayısıyla da istatistiksel özellik kaybını önlemek için kirlilik oranı %5 seçilerek en fazla %5’lik veri kaybı yapılmıştır. Ayrıca artan kirlilik oranının, birçok aykırı değerlerin yanlış çıkmasına neden olduğu Şekil 2’de görülmektedir. Öte yandan, sıfır hız bölgelerinde bulunan birçok aykırı değer ile artan k-komşuluk sonuçları hız azaltımı optimizasyonunda kullanılamayacağı için analizden çıkartılması uygundur. Bu nedenle, k-komşuluk ve kirlilik parametreleri sırasıyla 100 ve 5 olarak seçilmiştir, bu seçim Şekil 12’deki alt grafikte (h) görülebilir.



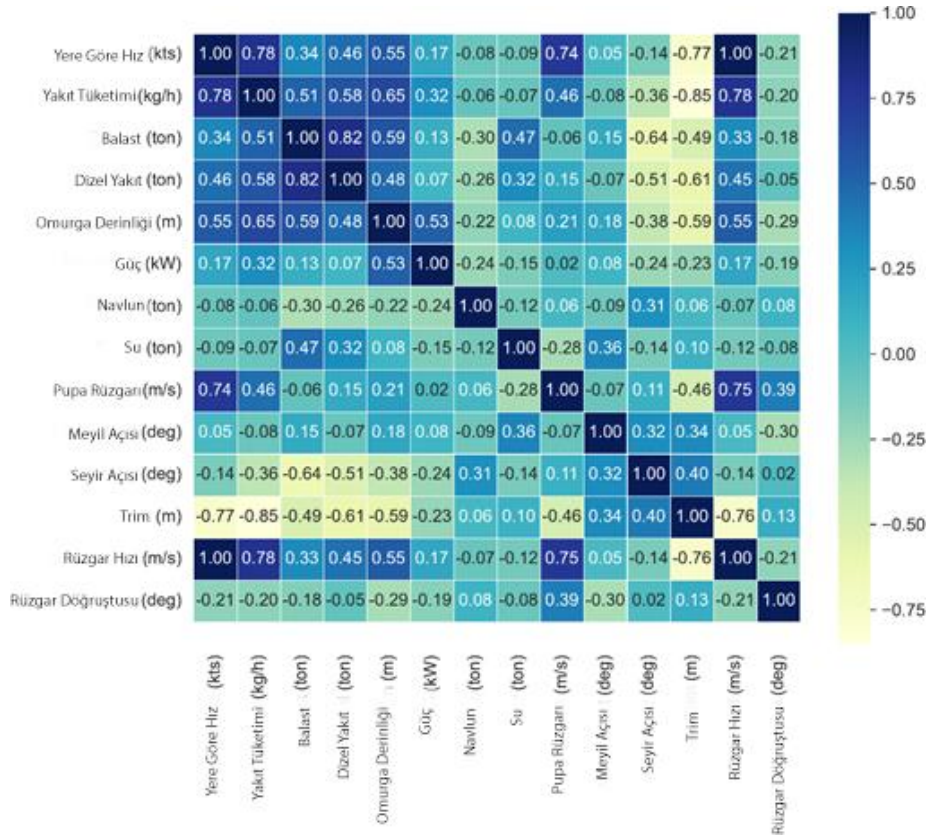


Şekil 2. LOF methodu ile aykırı değer sonuçları (farklı k-komşuluk and kirlilik oranlarında)

### 3.1.2 Öznitelik Seçimi

Yakıt tüketimini tahmin etmek için tüm özniteliklerin kullanılması fazla gürültüye ve uzun hesaplama süresine neden olabilir. Ayrıca, regresyon parametrelerinin bağımsız değişkenleri arasındaki mevcut doğrusal bağımlılık, regresyon katsayılarını yanlış önemde tahmin ederek regresyonun yanlış tahminde bulunmasına neden olabilir (Aldous, 2016). Şekil 3'te ilk bakışta geminin yere göre hızı ile rüzgar hızının korelasyon katsayısının 1 olduğu dikkat çekmektedir. Dolayısıyla bu değişkenler arasında bir doğrusal bağlantı mevcuttur. Ancak, bu tezde yere göre hız, hız optimizasyonu için bir kontrol parametresi olarak kullanılacaktır. Bu nedenle onun yerine rüzgar hızı parametresi regresyon analizinden çıkarılmıştır.





Şekil 3. Pearson korelasyon matrisi

### 3.2 Regresyon Modellemesi

Doğrusal regresyon sonuçları yeterli doğruluk ve RMSE değerleri göstermeyebilirler. Böylece, doğrusal regresyon modelleri kullanan yakıt tüketimi tahminleri, mevcut veri kümesine bağlı olarak güvenilir ve uygulanabilir olmayabilir. Bu sebeple, özellikler üzerinde normal dağılım varsayımları yapmak yerine, daha doğru tahmin sonuçları için parametrik olmayan yöntemler kullanılabilir. Bu çalışmada Destek Vektörleri, KNN, Rastgele Orman, AdaBoost ve Gradyan Arttırma regresyon modelleri uygulanmaktadır. Ayrıca, hiperparametrelerini ayarlamak için Grid Arama, Rastgele Arama ve Bayesyen Arama yöntemleri kullanılmıştır.

#### 3.2.1 Hiperparametre Optimizasyonu

Grid Arama (Grid Search - GS), tüm girdi uzayını araştıran ve aynı zamanda n olası değer  $O(nk)$  ile k hiperparametre uzayının kartezyen çarpımının hesaplama karmaşıklığına sahip bir kaba kuvvet yöntemidir. Bu nedenle, GS ile daha fazla olası parametre değeri aramak, hesaplama maliyetini üssel kuvvetle artırır. Ancak bu çalışmada KNN, SVR, ADA ve GBR modeller için GS kullanılmıştır.

GS'den farklı olarak, Rastgele Arama (Random Search - RS), tüm girdi uzayını aramaz. Ancak, kullanıcı tarafından tanımlanan yineleme sayısı kadar yalnızca rastgele seçilen değerleri kullanır. Yinelemeli sayıları artırmak, model için daha iyi sonuçlar verir; ancak, hesaplama maliyetleri de artar. Bu çalışmada RS, RF, XGB ve GBR modelleri için kullanılmıştır.

Hem GS hem de RS yöntemlerinin ana dezavantajı, önceki değerlendirme sonuçlarını hatırlamadan değerlendirmedir (Karthé, 2016). Ancak Bayes yöntemleri, sonraki giriş değerleri için hiperparametrelerin geçmiş değerlendirme sonuçlarını kullanır. Bu çalışmada hiperparametre optimizasyonu gerçekleştirmek için Bayes Optimizasyon tekniklerinden biri olan Python HyperOpt kütüphanesi kullanılmıştır. Bu çalışmada kullanılan hiperparametre değer arama aralıkları ve atanan ayarlayıcı tarafından bulunan optimal değerler Tablo 2'de listelenmiştir.

**Tablo 2** Hiperparametreler ve optimizasyonun koşma süreleri

Model	Hiper-parametreler	Aralık	Değer	Süre
LR	Hiçbiri			<1
SVR	Hiçbiri			<1
	Tuner: GridSearchCV			<120

C	[0.1,1,10,100,1000]	1000
gamma	[1,0.1,0.01,0.001,0.0001]	0.1
kernel	['rbf','poly','sigmoid','linear']	rbf
degree	[1,2,3]	1
KNN	Hiçbiri	<1
	Tuner: GridSearchCV	<1
n_neighbours	[5,7,9,11,13,15,20,30,50]	5
weights	['uniform','distance']	distance
metric	['minkowski','euclidean','manhattan']	Manhattan
ADA	Hiçbiri	<1
	Tuner: GridSearchCV	<1
n_estimators	[2,3,4,5,7,8,9,10,20,50,100,300]	50
learning_rate	[0.97,0.98,0.99,1,1.01,1.02,1.06]	1.06
XGB	Hiçbiri	<1
	Tuner: RandomizedSearchCV(iteration:200)	<2
min_child_weight	[1,3,5,7,10,15]	10
gamma	[0.1,0.5,1,1.5,2,5,8,15]	1
subsample	[0.2,0.6,0.8,1.0,1.5]	0.8
colsample_bytree	[0.2,0.6,0.8,1.0,1.5]	1
max_depth	[3,4,5,7,10,15]	15
reg_alpha	[50,70,100,120,150]	50
n_estimators	[100,180,300,1000,1500]	180
RF	Hiçbiri	<1
	Tuner: RandomizedSearchCV(iteration:200)	<2
n_estimators	[5,20,50,100,300,450,500]	300
max_features	['auto','sqrt']	auto
max_depth	np.linspace(10,120,num=24)	10
min_samples_split	[2,4,6,8,10]	2
min_samples_leaf	[1,2,3,4,5]	2
	Tuner: HyperOpt	<15
n_estimators	uniform(100,1000)	469
max_depth	uniform(5,120)	16
min_samples_leaf	uniform(1,5)	2
min_samples_split	uniform(2,10)	4
max_features	['auto','sqrt','log2',None]	2
GBR	Hiçbiri	<1
	Tuner: GridSearchCV	<5
n_estimators	sample(200,1100,step:50)	1050
max_features	['auto','sqrt']	auto

max_depth	sample(4,16,step:2)	12
min_samples_split	sample(2,20,step:1)	2
min_samples_leaf	sample(5,61,step:5)	5
	Tuner: RandomizedSearchCV(iteration:200)	<5
n_estimators	rand(low:100,high:1200)	460
max_features	rand(low:5,high:20)	8
max_depth	rand(low:2,high:30)	9
min_samples_split	rand(low:2,high:100)	55
min_samples_leaf	rand(low:2,high:25)	22
learning_rate	rand(low:0,high:1)	0.0425
subsample	rand(low:0,high:1)	0.823

### 3.3. Genetik Algoritmalar İle Gemi Hız Optimizasyonu

Hız optimizasyonu, ton-mil başına minimum yakıt tüketimiyle sonuçlanan en iyi hız profilini bulmak için değerlendirilir. Çünkü Gemi Enerji Verimliliği Yönetim Planına (Ship Energy Efficiency Management Plan - SEEMP) göre, gemi hızının, optimum hızın altında olması daha yüksek yakıt tüketimine neden olabilir (IMO, 2016; Psaraftis, 2019). Ancak optimum hız en düşük hız demek değildir ve ayrıca yolculuk sırasında sabit de değildir (Arslan vd., 2014; IMO, 2016). Bunker fiyatları, liman varış zamanları, gecikmeler, hava ve deniz çevresel değişkenleri, piyasa değerleri vb. değişkenler gerçek hayatta rastgele değişebilen özellikler içermektedir. Bu nedenle, gemilerin hız ve yakıt tüketimi optimizasyonunu çözmek için var olan deterministik yaklaşımlar, bu rastgele değişkenlerin önceden bilindiklerini varsayarak rastgele olayları göz ardı ederler (Aydın vd., 2017). Bazı yönlerden, literatürdeki birçok çalışma, hava ve deniz koşulları veya motor parametreleri gibi yakıt tüketimini etkileyen bazı değişkenler için stokastik bir terim kullanır. Ancak, bunlar da yakıt tüketimini etkileyen bu rastgele faktörlerin normal bir dağılım izlediğini varsaymışlardır (Aydın vd., 2017). Yakıt tüketimini etkileyen daha birçok faktörün olduğunu varsayarsak, optimizasyon problemleri için sadece olasılıksal dağılımları kullanmak etkili çözümler üretmeyecektir. Bu nedenle, optimizasyon problemlerinde rastgele değişkenlerin kullanılması esastır. Bu çalışmada, minimum yakıt tüketimini elde etmek amacıyla optimum hız profillerini

aramak için genetik optimizasyon algoritmaları kullanılmıştır. Evrimsel bir algoritmanın seçilmesinin ana nedeni, yerel bir optimal noktada yakınsama yapmaktan kaçınmak ve global optimal noktayı bulmak amaçlanmıştır.

Ayrıca, bir önceki bölümde yapılan regresyon analizi sonuçları, yakıt tüketiminin diğer parametrelere göre gemi hızına daha çok bağlı olduğunu göstermiştir. Bu nedenle hız optimizasyonunun diğer faktörlere göre daha fazla yakıt tasarrufu sağlayabileceği kolayca söylenebilir.

Bu çalışmada, ETA gecikmesi, maksimum seyir hızı ve hız ivmesi parametreleri (gemi gövde stresini azaltmak için) hız optimizasyon kısıtlamaları olarak belirlenmiştir. Ayrıca yakıt tasarrufunu desteklemek için limandan ayrılırken hızın aniden aşırı derecede artırılmasına izin verilmiştir (IMO, 2016).

### 3.3.1 Önerilen Genetik Algoritma Modeli

Bu bölümde, iki liman arasındaki tek bir rota için bir hız optimizasyonu matematiksel modeli geliştirilmiştir. Modelin notasyonları Tablo 3'te verilmiştir.

**Tablo 3** Hız optimizasyon modelinin matematiksel terimleri

Parametre	Açıklama
$ETA$	The ETA (hedef port için) (h)
$d$	Seyir mesafesi (mile)
$d^{new}$	Değiştirilmiş hızın seyir mesafesi (mile)
$t$	Yolculuk süresi (h)
$T^R$	Seçilen kalan hız için ek süre (h)
$V^R$	Kalan hız (mile/h)
$F_{total}$	Toplan yakıt tüketimi (normal hız için) (kg)
$F^R$	Kalan hız için yakıt tüketim oranı (kg/h)
$V^{new}$	Değiştirilmiş hız profili

Denklem 1, değiştirilmiş hız profilinin ulaşabileceği mesafeyi ifade eder:

$$d^{new} = \sum_{i=0}^n V_i^{new} \times t \quad (1)$$

Değiştirilen hız profilinin mesafesi ile normal mesafe arasındaki fark, gemi işletmecisi tarafından seçilen kalan hız ile kapatılacaktır. Yeni hız profilinin kalan yolculuğu tamamlaması için gereken ekstra süre Denklem 2'de gösterilmektedir.

$$T^R = (d - d^{new}) / V^R \quad (2)$$

Denklem 3'te gösterilen toplam yakıt tüketimi amaç fonksiyonu, toplam yolculuk mesafesinin sonuna kadar geminin tüm seyir hızlarındaki tahmin edilen yakıt tüketimlerinin toplamıdır.

$$\min \sum F_{total} + T^R \times F^R \quad (3)$$

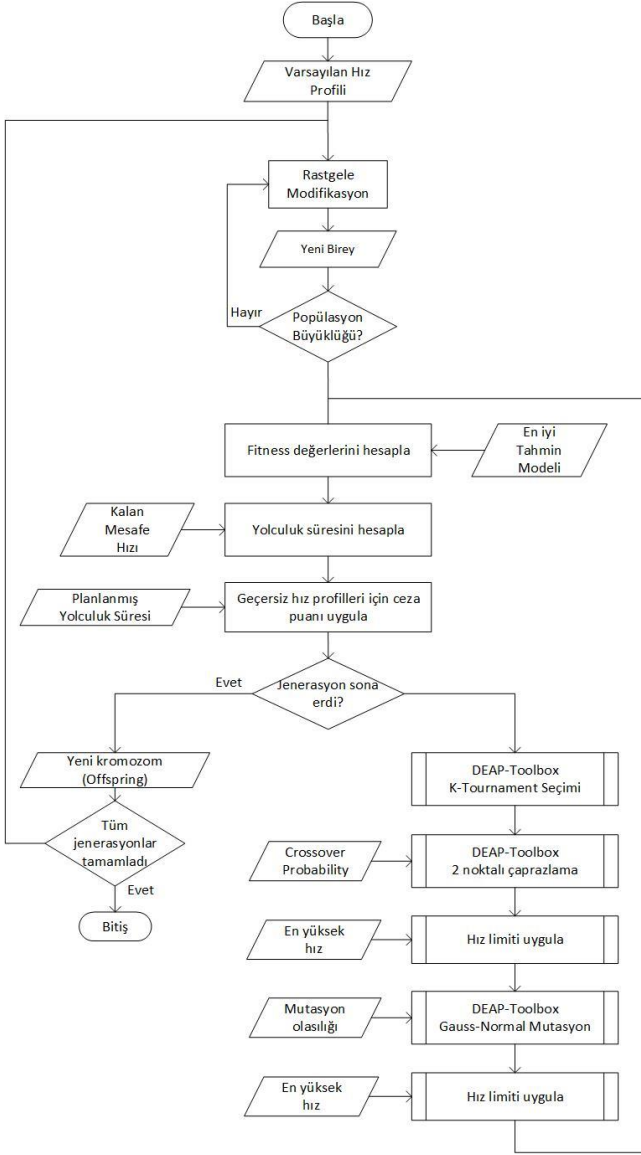
Denklem 3'teki amaç fonksiyonu, genetik optimizasyon algoritmasında bireylerin uygunluk değerlerini hesaplamak için kullanılır. GA'nın temel amacı, minimum uygunluk değerli bireyleri bulmaktır. Bu nedenle denklem 4 ve 5'te bulunan kısıtlamalarla hız profili, gemi varış süresinin ETA'dan uzun olmamasını ve izin verilen maksimum hız limiti ise, bunun üzerinde aşırı hız olmamasını sağlar.

$$t + T^R < ETA \quad (4)$$

$$V^{new} = \begin{cases} V^{new}, & \text{if } V^{new} < V^{top} \\ V^{top}, & \text{diğer} \end{cases} \quad (5)$$

Önerilen hız optimizasyon yönteminin iş akış modeli Şekil 4'te gösterilmiştir.

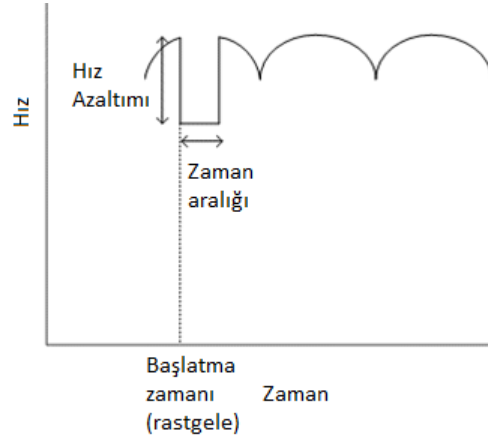




Şekil 4. Hız optimizasyon probleminin akış şeması

Bu çalışmada gemi hız profilleri, GA'nın bireyleri olarak önerilmiştir. Ayrıca, her birey bir yakıt tüketim puanı ile değerlendirilir. Genetik algoritmaların başlatılması, hız optimizasyonunda yakınsama ve dayanıklılık sorunlarına neden olabilir (Helong vd., 2021). Bu çalışmada, bu sorunların üstesinden gelmek için bireyler arasında üst düzey bir genetik çeşitlilik oluşturulması amaçlanmıştır. Bu nedenlerle, yeni bireyler için farklı iklendirilmiş hız profilleri oluşturmak üzere hız profilinde değişiklikler yapılmıştır. Orijinal hız profilinin rastgele seçilen bir bölümünde rastgele bir değişiklik yapılarak rastgele seçilen miktarda hız azaltma ve zaman aralığı değişikliği uygulanmıştır. Rastgele hız azaltmaları, yakıt tüketiminin hız değişkenine olan esnekliği olarak kabul edilebilir. Benzer şekilde, sabit azaltmalar sabit esneklik olarak kabul edilebilir (Roar vd., 2020). Optimum hız etrafındaki esnekliğin bulunması, bu çalışmada bir araştırma hedefidir. Bu rastgele yaklaşım ise, GA'da

seçim, çaprazlama ve mutasyon aşamalarından önce bireyler arasında iyi bir genetik çeşitlilik oluşturmaktadır.



Şekil 5. Bireyleri iklendirmek için rastgele hız değişimi

### 3.3.2 Genetik Algoritma Parametreleri

Bu tezde, her üretim döngüsünde rastgele veya manuel yaklaşımla N sayıda yeni birey iklendirilir. Fitness, yakıt tüketimini en aza indirmeyi amaçlayan bir fonksiyon tanımıdır. Rastgele hız azaltmaları, çaprazlama ve mutasyonlar, yolculuk için gecikme süresine neden olabilir. GA'da ilk olarak kalan mesafedeki hız dahil edilerek yeni toplam yolculuk süresi hesaplanır. Ve GA tarafından toplam yolculuk süresinin aşılmasına neden olan hız profillerine bir ceza puanı verilir. Bir popülasyonda değerlendirilen tüm bireyler, uygunluk değerlerine göre artan düzende sıralanır. Çünkü bu çalışmada uygunluk fonksiyonunun amacı yakıt tüketimini en aza indirmektir.

Bir nesildeki ilk adım, yavru seçimidir. Bu çalışmada 3 turnuva büyüklüğünde ve k(1) süreli K-Turnuva seçim yöntemi kullanılmıştır. Çaprazlama adımı için her seferinde en iyi iki birey seçilir. En iyi bireyler, çapraz olasılık oranlarına göre eşleştirilir ve çiftleştirilir (De Andrade, 2014). Bu çalışmada iki noktalı çaprazlama kullanılmıştır. Ayrıca, çaprazlama oranları ampirik olarak yüzde 20 ila 90 arasında araştırılmıştır. Yine de, %80 (Chaal, 2018) ve %75 (Changnan vd., 2017) çaprazlama oranları literatürde yaygın olarak kullanılan değerlerdir.

Mutasyon, genetik değişkenliği artırmak için bir başka önemli adımdır. Mümkün olduğu kadar uzun süre en iyi sonuçları aramaya devam etmek için mutasyonlar gereklidir. Aksi takdirde, optimizasyon yanlış bir şekilde yerel bir minimum veya maksimum noktayı global olarak kabul eder. Bireylerde rastgele seçilen değerler, sıfır

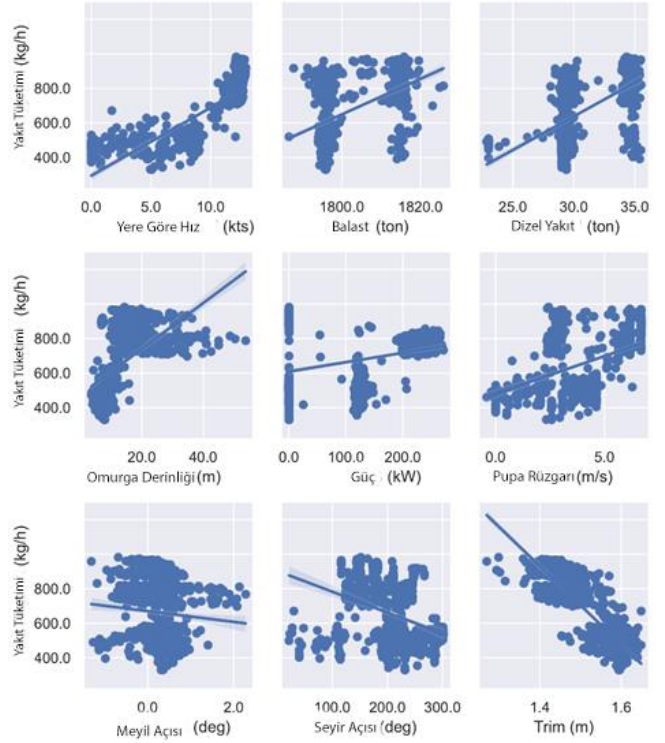
ortalama ve bir standart sapma ile tanımlanan gauss-normal dağılım aralığında mutasyona uğrar. Toplam nesil sayısı genetik optimizasyonun yaygın kullanımından öğrenilen şekilde yaklaşık 99 olarak tanımlanmıştır.

Gecikme süresini belirlemek için ise öncelikle ETA ve kalan mesafe hızı tanımlanmalıdır. Daha sonra regresyon analizinden seçilen en iyi yakıt tüketimi tahmin modeli tarafından, değiştirilmiş ve kalan mesafedeki hızlar için karşılık gelen yakıt tüketimi eğrisi yaratılır. Sonuçta toplam yakıt tüketimi bir bireyin fitness skoru olup genetik algoritma tarafından bu değer minimize edilmesi hedeflenir. Bu nedenle, görece yüksek fitness skoruna sahip bireyler popülasyonlar içerisinde daha düşük oranda seçilme şansına sahip olduğu için gelecek jenerasyonlara aktarılma olasılığı da düşüktür.

## 4. ANALİZ

### 4.1 Regresyon Analizi

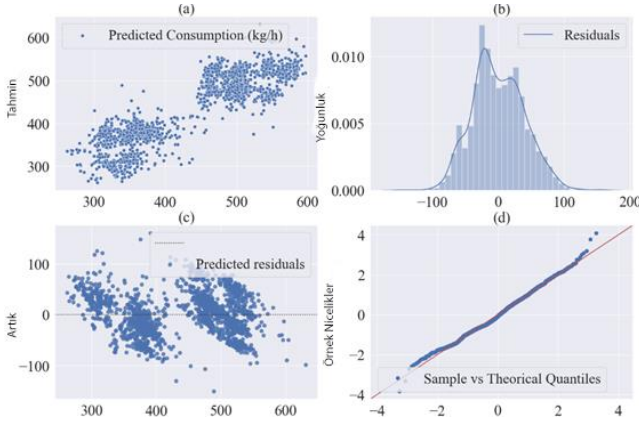
Şekil 6'da tüm regresyon değişkenlerine ait dağılım grafikleri görülmektedir. Y eksenini bağımsız değişken olup yakıt tüketimini temsil eder. Ayrıca, en uygun doğrunun eğimleri diğer bağımsız değişkenlere bağımlı değildir (Robert, 2022). Dolayısıyla, yere göre hız ve trim değişkenlerinin bağımlı değişkenle daha doğrusal olarak ilişkilendirme eğiliminde olduğu Şekil 3'teki korelasyon tablosu kullanılarak iddia edilebilir. Ancak diğer değişkenler için aynı şeyi söylemek zordur. Şekil 3'teki korelasyon matrisine bakıldığında su, yük ve meyil açısı değişkenlerinin korelasyon katsayılarının sırasıyla -0.04, -0.07 ve -0.08 olup değerler sıfıra çok yakın olduğundan bu parametrelerin yakıt tüketimi tahmininde beklenen herhangi bir toplanabilirliği yoktur (Robert, 2022).



**Şekil 6.** Seçilen özelliklerin yakıt tüketimine karşı dağılım grafikleri, en uygun doğrusal regresyon çizgileri dahil

Şekil 14'teki korelasyon matrisinde koyu renkli hücelere karşılık gelen yüksek oranda ilişkili değişkenlerin varlığı, yüksek RMSE hatalarına neden olur. Dolayısıyla tahmin doğruluğu azaldığından güven aralığı da daralır (Karthe, 2016). Balast ile dizel yakıt arasındaki ve yere göre hız ile trim arasındaki korelasyonlar yüksektir. Ancak trim, bu çalışmada yakıt tüketimi üzerindeki etkiyi araştırmak için bir başka önemli değişkendir olduğundan analizde tutulmuştur.

Hataların varyansı uydurulan değerlere göre artar veya azalır, güven aralıklarının daha küçük bir aralığa girmesine neden olacaktır. Bu sorun, değişen varyans olarak bilinir ve regresyonda yalnızca küçük bir veri alt kümesine çok fazla önem verilmesi ile sonuçlanır (Robert, 2022). Şekil 7(c)'de, normalleştirilmiş artık değerlerin sıfır eksenini boyunca dağılımının artış veya azalma eğiliminde olmadığı görülmektedir. Yine, dağılım hataları normal dağılırsa, RMSE hata hesaplaması onu daha fazla azaltmakta başarısız olabilir ve güven aralıkları çok dar veya çok geniş olacaktır (Robert, 2022). Şekil 7(b)'den artıklar arasında bir korelasyon olmadığı görülmektedir.



**Şekil 7.** Doğrusal regresyonun tahmini ve artıkları (a) Tahmine karşı gözlemlenen, (b) Artıkların normal dağılımı, (c) Normalleştirilmiş artıklara karşı tahminler, (d) Örnek niceliklerin eğilim çizgisi

Değerlendirme sürecinde kullanılan eğitim ve test veri kümesi performans ölçütleri sırasıyla Tablo 9 ve 10'da verilmiştir. Doğrusal regresyon modelinin R2 değerleri %80 civarındadır, bu nedenle model, literatürdeki çalışmalara kıyasla yakıt tüketimini daha zayıf bir şekilde açıklamaktadır (Kee vd., 2018; Uyanık vd., 2020). Ek olarak, Şekil 8'de, LR'nin eğitim doğruluk puanları artan eğitim verisi boyutuyla oldukça düşük bir değere yakınsamaktadır. Bu nedenle, daha fazla eğitim verisi eklemenin doğrusal regresyona fayda sağlamadığı söylenebilir.

Ayrıca SVR modelinin R2 ve RMSE skorları, LR modelinden daha düşüktür (bkz. Tablo 3). Üstelik, SVR literatürdeki çalışmalara kıyasla yakıt tüketimini zayıf bir şekilde açıklamaktadır (Christos vd., 2019; Hu vd., 2021). Bunun yanında, KNN'nin performans ölçütleri, LR ve SVR modellerinden daha iyi sonuç vermiştir. Ayrıca bu çalışmadaki KNN modeli yakıt tüketimini literatüre göre daha iyi açıklamaktadır (Christos vd., 2019). Ayrıca SVR ve KNN modelleri, yeni eğitim verileri ekleyerek doğruluk değerlerini artırmaktadır (bkz. Şekil 8) ve doğruluk puanları, yeni veriler ekleyerek birbirine yakınlaşır, yeni verilerle iyi uyum sağlarlar. Öte yandan, KNN ve SVR'nin hiperparametre optimizasyonu sonucunda, öğrenme eğrilerinin doğruluk puanları hala yüksek olup aralarında bir fark bulunmaktadır. Bu nedenle, KNN ve SVR için aşırı öğrenme yaşanmış olabilir. Özellikle daha az eğitim verisi için, SVR'nin eğitim doğruluk puanı, doğrulama değerinden çok daha yüksektir. Ve yeni eğitim verileri eklemek, genellemeyi artıracaktır.

Eğitim ve test veri kümeleri için VR ve SR topluluk modellerinin doğrulukları birbirine yakındır. Test veri kümesi için VR eğitim doğruluğu (%94,55), SR'den

(%93,53) biraz daha yüksektir. Ancak VR ve SR topluluk modellerinde, eğitim ve test puanları arasında hala bir fark olması, aşırı öğrenme sorununu göstermektedir.

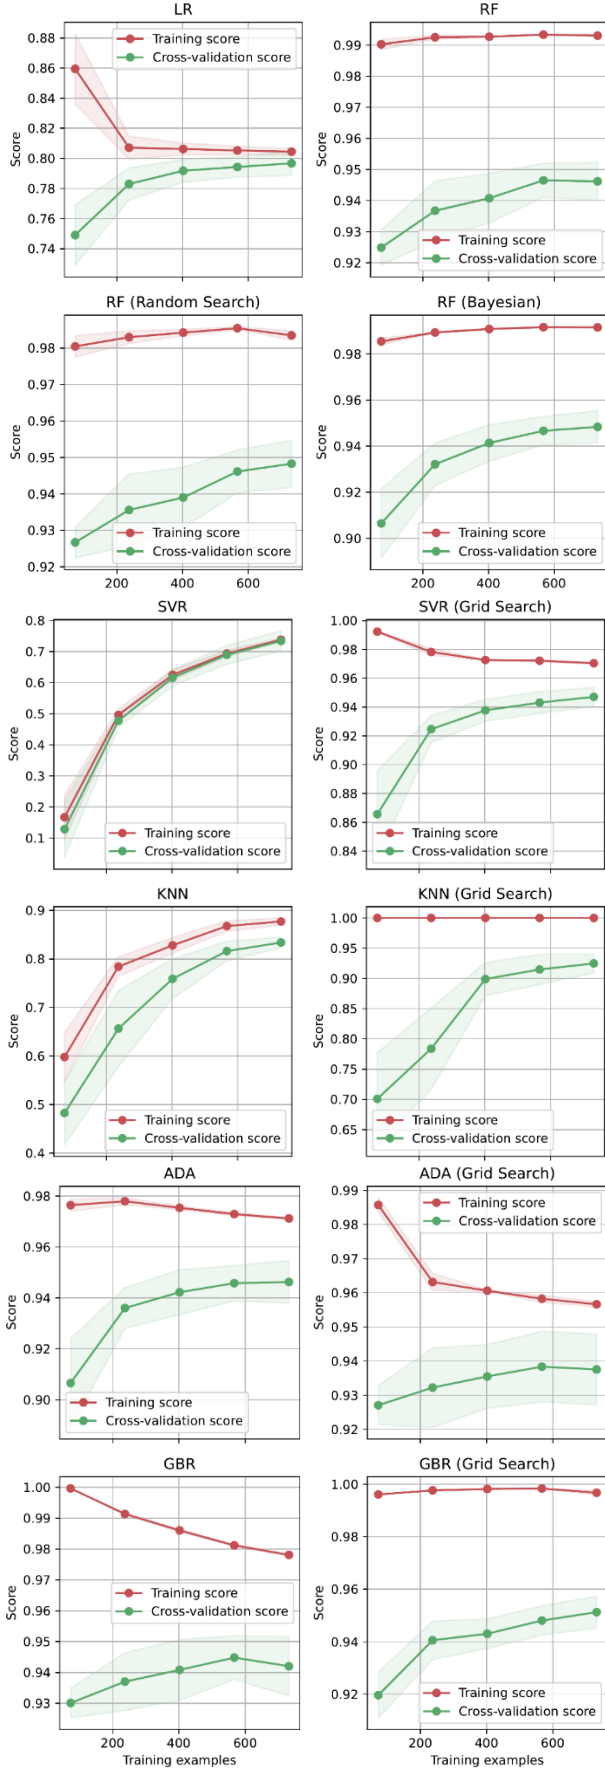
Sonuç olarak, RF hiperparametreleri, rastgele arama optimizasyonu ile ayarladıktan sonra eğitim doğruluk değerini %98,07'den %98,39'a yükseltmiştir (bkz. Tablo 3). Ayrıca, test doğruluğu da %94,48'den %94,63'e yükselmiştir ve sonuçta da RF için aşırı öğrenme yaşanmamış olduğu varsayılabilir (bkz. Tablo 4). Bu nedenle, bir sonraki bölümde hız optimizasyonu değerlendirmesi için RF seçilmiştir.

**Tablo 3** Eğitim veri kümesinin performans sonuçları

Model	RMSE	R2 Score (%)
SVR	41.37	77.23
LR	38.41	80.38
KNN	28.31	89.34
Tuned ADA (Grid Search)	18.53	95.43
Tuned SVR (Grid Search)	15.11	96.96
ADABOOST	15.02	97.00
GBR	13.54	97.56
<b>RF</b>	<b>12.04</b>	<b>98.07</b>
SR	11.06	98.37
<b>Tuned RF (Random Search)</b>	<b>11.00</b>	<b>98.39</b>
XGBR	9.85	98.71
VR	7.87	99.18
<b>Tuned RF (Bayesian)</b>	<b>7.84</b>	<b>99.18</b>
Tuned GBR (Grid Search)	5.09	99.66
Tuned GBR (Random Search)	2.01	99.95
Tuned XGB (Random Search)	1.70	99.96
Tuned KNN (Grid Search)	0.01	99.99

**Tablo 4** Test veri kümesinin performans sonuçları

Model	RMSE	R2 Score (%)
SVR	41.81	75.33
LR	39.63	77.83
KNN	29.50	87.72
Tuned KNN (Grid Search)	25.57	90.78
Tuned SVR (Grid Search)	24.86	91.28
Tuned ADA (Grid Search)	23.44	92.25
SR	21.41	93.53
<b>Tuned RF (Bayesian)</b>	<b>21.07</b>	<b>93.73</b>
Tuned XGB (Random Search)	20.78	93.90
Tuned GBR (Random Search)	20.75	93.93
ADABOOST	20.62	94.00
GBR	20.44	94.10
<b>RF</b>	<b>19.77</b>	<b>94.48</b>
VR	19.66	94.55
XGBR	19.61	94.57
Tuned GBR (Grid Search)	19.58	94.59
<b>Tuned RF (Random Search)</b>	<b>19.52</b>	<b>94.63</b>



Şekil 8. Regresyon modellerinin öğrenme eğrileri

## 4.2 Genetik Algoritma ile Yakıt Tüketimi Optimizasyonu

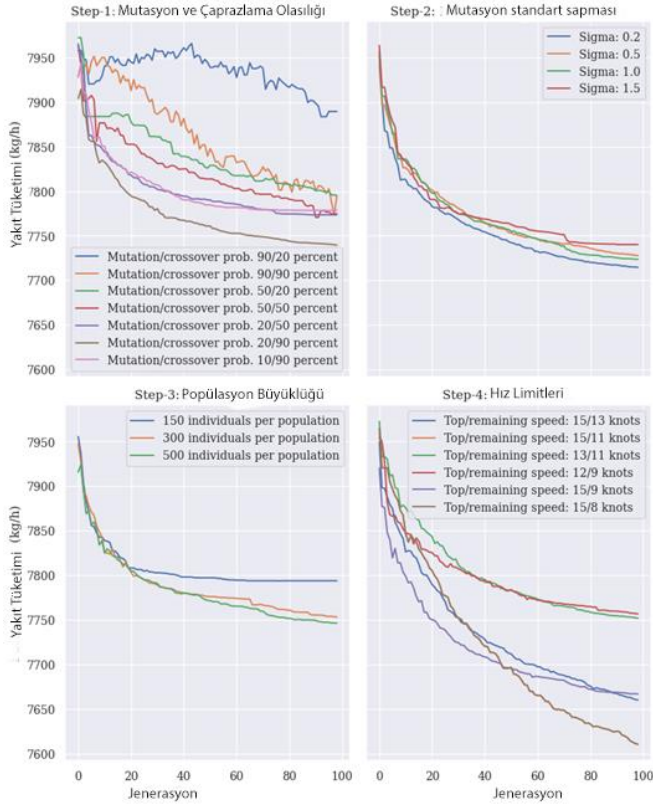
Bireylerin ya da hız profillerinin rastgele iklenmesinde GA parametre ayarı manuel olarak dört adımda uygulanmıştır. Tablo 5'te, her adım için tüm kontrol ve sabit parametreler listelenmiştir. İlk adımda, mutasyon ve çaprazlama olasılık kontrol parametreleri değiştirilir ve GA, olasılıkların %10'u ile %90'ı arasında 7 farklı kombinasyon için tekrar tekrar çalışır. İkinci adımda, mutasyon ve çaprazlama olasılıklarının en iyi parametreleri kullanılır ve mutasyon standart sapma (sigma) kontrol parametreleri dört kez 0,2'den 1,5'e kadar artırılmıştır. Üçüncü adımda ise popülasyonun birey sayıları 150, 300 ve 500 olmak üzere üç kez değiştirilmiştir. Son olarak hız limiti ve kalan hız parametreleri altı farklı kombinasyonda değiştirilmiştir.

**Tablo 5** Rastgele iklenirilen GA'da kontrol parametreleri ve sabitler

Adım	Mutas-yon olasılığı	Çapraz-lama olasılığı	Sigma	Popü-lasyon birey sayısı	Hız limiti (mile/h)	Kalan mesafe hızı (mile/h)
1	Kontrol param.	Kontrol param.	1.5	300	13	13
2	20%	90%	Kontrol param.	300	13	13
3	20%	90%	1	Kontrol param.	13	13
4	<b>20%</b>	<b>90%</b>	<b>1</b>	<b>500</b>	Kontrol param.	Kontrol param.

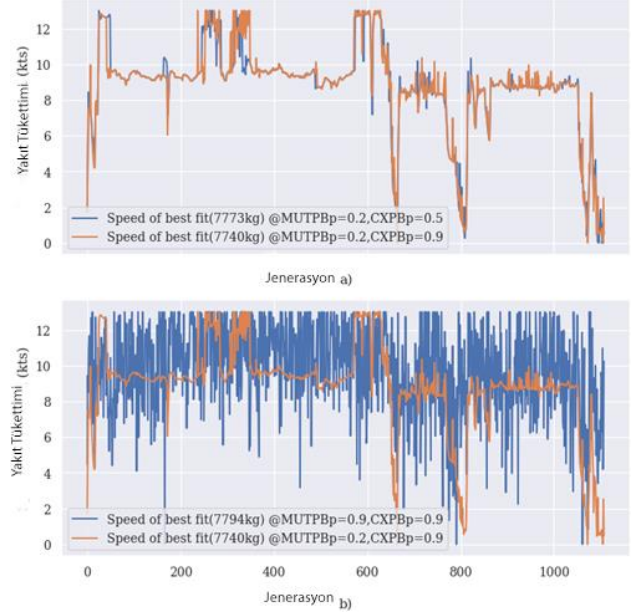
Bu çalışmada GA, kontrol parametreleri değiştirildikten sonra tekrar tekrar çalıştırılmıştır. GA simülasyonlarının minimizasyon veya uygunluk değerlerinin amaç fonksiyonu, yakıt tüketimi değişkenidir. Parametre uyarlama simülasyonları dört adımda tamamlanmıştır. Sonuçlar Şekil 9'da sunulmuştur.





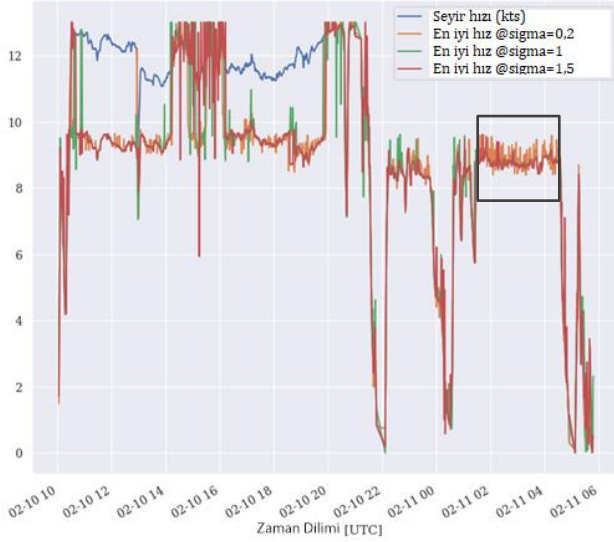
**Şekil 9.** Rastgele iklendirme yönteminde parametre en iyilenmesi

Mutasyon ve çaprazlama olasılığı: Şekil 9 adım-1'e bakarak düşük mutasyon oranlarının, yüksek çaprazlama oranları ile birlikte daha iyi performans gösterdiği söylenebilir. Ayrıca, mutasyon oranının artmasının kararsız hız profillerine neden olduğu Şekil 10b'de görülmektedir. Aksine, daha yüksek bir çaprazlama oranı, küresel bir minimum nokta arayışı sırasında hız profilini sabit tutmaktadır. Ayrıca, çaprazlama operatörü hız profilinin her yerine eşit olasılıklı davranır (bkz. Şekil 10a).



**Şekil 10.** Rastgele yaklaşım adım-1'de en iyi hız profilleri, a) çaprazlama ve b) mutasyonlar

Mutasyon standart sapması (sigma): Sonuçları önemli ölçüde etkilemese de, yüksek gemi hızı yayılımı (sigmanın tersi) daha yüksek performans göstermiştir. Şekil 11'de farklı sigma değerlerine sahip popülasyonların en uygun bireylerinin hız profilleri ile gerçek yolculuk hız profilleri birlikte gösterilmektedir. Genetik algortmada sigma değerlerinin artırılması, hız değerlerinin daha yüksek oranda değiştirilerek daha fazla yakıt tasarrufu sağlanmasına yol açtığı görülmektedir. Ayrıca, Şekil 11'de görülen pencerede, sigma değerleri arttığında genetik algortma, hızdaki küçük değişiklikler yaparak yakıt tüketimi tasarrufu için bir çözüm aramaktan vazgeçmektedir. Bu sebeple genetik algortma için, yerel bir minimum noktaya yığılmayı aşarak, global minimum noktayı aramaya devam etmekte olduğu söylenebilir.



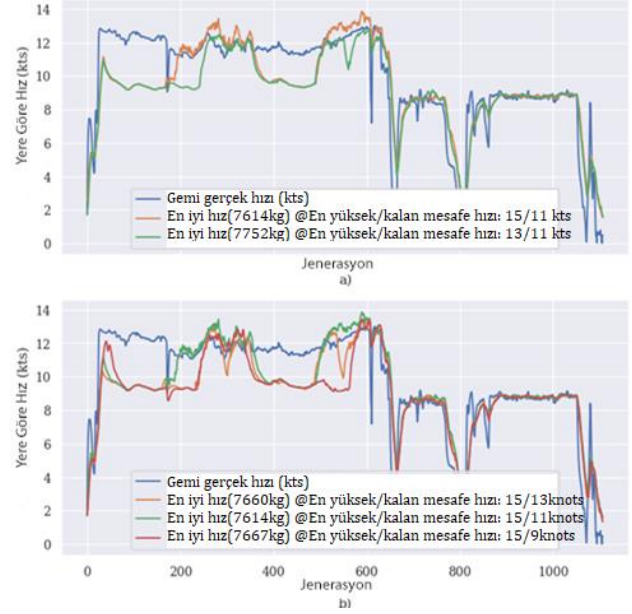
**Şekil 11.** Rastgele yaklaşım adım-2'de en uygun hız profilleri ve mutasyon standart sapmaları

Ayrıca, en iyi bireylere ait hız sinyalleri, pratik kullanım için çok fazla gürültüye sahiptir. Bu nedenle, yüksek frekanslı sinyalleri ortadan kaldırmak için bir alçak geçiren filtre gereklidir. Python Pandas kütüphanesindeki üstel ağırlıklı hareketli ortalama filtresi, Şekil 12'de görüldüğü gibi 0,1 gibi çok düşük bir yumuşatma faktörü ( $\alpha$ ) ile uygulanmıştır.

Şekil 9'a bakıldığında, bir popülasyondaki birey sayısını artırmak bu çalışmada her zaman daha iyi GA performansı göstermektedir. Ayrıca, 500 adet birey sayısı en verimli sonuçları göstermiştir.

Şekil 9'da görüldüğü gibi, yüksek hız sınırı ve düşük kalan mesafe hızları belirlemek daha fazla yakıt tasarrufu ile sonuçlanmıştır.

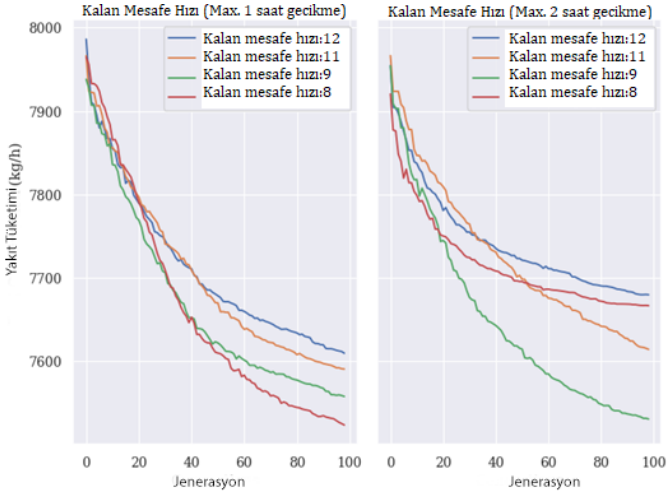
Hız profilinde aşağı ve yukarı yönlü (maksimum hıza kadar) rastgele değişiklikler yapmak, değiştirilen hız profilinin katedeceği mesafeyi değiştirir. Genetik algoritmanın değerlendirme adımı sonunda hız profilindeki net toplam hız düşüşü nedeniyle kalan mesafe ortaya çıkabilir. Kalan mesafelerin hızı ile azami hız sınırı birbirini etkiler. Kalan mesafe hızları sabitten üst hız sınırının düşürülmesi daha az yakıt tasarrufu sağlamaktadır (bkz. Şekil 12a). Ancak bu durumun tersi de geçerli değildir (bkz. Şekil 12b). Örneğin, azami hız limiti 15 knot olarak sabitlenirken, 15 veya 9 knot olan kalan mesafe hızları, 11 knot'tan daha fazla yakıt tüketimine neden olmuştur. Kısaca, en yüksek hız limiti, GA'da kalan mesafe hızı ile doğrusal olmayan bir şekilde ilişkilidir. Ancak, en iyi kombinasyonu bulmak için başka bir optimizasyon rutini gereklidir.



**Şekil 12.** Rastgele yaklaşım adım-4'e en uygun hız profilleri, a) değişen hız limiti ve b) kalan mesafe için seyir hızı

Gerçek hayatta teknik, hava durumu veya yönetimsel sebeplerden ötürü limana varış zamanının gecikmesi çok yaygındır. Buna bağlı olarak, yolculuk hızları da gecikme cezalarından kaçınmak için artabilir. Ayrıca, hava koşulları dışında, denizde yapılan yakıt alım fiyatlarındaki ani değişimler, liman tıkanıklığı nedeniyle bekleme maliyetleri vb. sebepler gemi operatörlerine maddi zarar vermektedir (Aydın vd., 2017). Ancak limana varış saatlerinin esnek olması bir miktar yakıt tüketimi verimliliği sağlayabilir. Bu amaç doğrultusunda, bu çalışmada genetik algoritma rutinine bir ve iki saatlik izin verilebilir ETA gecikmeleri tanımlanmıştır. GA ile sadece 15 knot azami hız limiti altında bulunan 1 ve 2 saatlik gecikmeler simüle edilmiştir. Öbür taraftan, yakıt tüketimi üzerindeki etkilerini araştırmak için farklı miktarlarda kalan hız değerleri denenmiştir. Sonuçta, kalan hızın azaltılması ile GA yakıt tasarrufunu ETA'nın yalnızca 1 saatlik gecikme koşulları için her zaman arttırmıştır (bkz. Şekil 13). Ancak 2 saatlik gecikme şartlarında aynı şeyi söylemek mümkün değildir. GA kalan mesafe hızını azaltarak minimum yakıt tüketim noktasını aramaktadır. Ancak, minimum yakıt tüketimi sadece kalan mesafedeki en düşük hız için oluşmamaktadır (bkz. Tablo 6). Bu nedenle, minimum yakıt tüketimi için kalan mesafe hızı, üst hız limiti ve ETA'nın her defasında optimum kombinasyonları başka bir optimizasyon rutiniyle araştırılmalıdır.





**Şekil 13.** ETA gecikmesi 1 saat (sol) ve 2 saat (sağ) için yakıt tüketimi sonuçları

**Tablo 6.** Rastgele ikklendirilmede 1 ve 2 saatlik gecikmeler için yakıt tüketimi tasarrufları

Kalan Mesafe Hızı	1 Saat Gecikmede	2 Saat Gecikmede
12	% 4,78	% 4,18
11	% 5,12	% 4,88
9	% 5,52	<b>% 5,90</b>
8	<b>% 6,00</b>	% 4,22

## 5. SONUÇLAR VE TARTIŞMALAR

Bu çalışma, gemiler için hız optimizasyonu yoluyla yakıt tüketimi verimliliği potansiyelini keşfetmeyi amaçlamıştır. Yakıt tüketimi tahmini için doğrusal ve doğrusal olmayan makine öğrenimi regresyon modellerini analiz eden bu tez, gemilerin çeşitli çevresel, operasyonel ve seyir veri günlüklerini kullanarak yakıt tüketiminin nasıl tahmin edilebileceğini göstermiştir. Ham verilere veri ön işleme teknikleri uygulanarak, veri kayıtlarının çoğunda eksik değerler ve yakıt tüketimi ile ilgisiz kayıtlar olduğu gözlemlenmiştir. Bu nedenle, verileri regresyon modellemesine hazırlamak için öznitelik silme ve veri atama teknikleri uygulanmıştır. Öte yandan, orijinal veri kümesinin örnekleme oranı bir saniye olduğu için yüksek hesaplama maliyetleri ve uzun çalışma süreleri oluşabileceği öngörülerek 24 saatlik veri kümesi için örnekleme oranı 30 saniyeye düşürülmüştür. LR, SVR ve KNN yakıt tüketimi modelleri, sırasıyla %90'ın altında en düşük eğitim veri kümesi doğruluğuyla sonuçlanmıştır. Ancak, gradyan artırmaya dayalı tahmin modelleri en yüksek doğrulukları göstermiştir, bununla birlikte yüksek oranda aşırı öğrenme içermektedirler. Bu çalışma ayrıca, gemilerin hız optimizasyonda kullanılan genetik algoritmalarda rastgele modifikasyonlar ile oluşturulmuş hız profillerinin daha fazla yakıt tüketimi ile sonuçlandığını göstermiştir.

Ayrıca, GA'daki yüksek çaprazlama oranları ve popülasyon boyutları, hız limitleri ve düşük mutasyon oranları yakıt tüketimi tasarrufunda daha iyi sonuçlar vermiştir. Ek olarak, bu çalışmanın sonuçlarına bakarak, gemi seyir hız profili dikkate alınmadan hız limitlerinin belirlenmesinin, GA ile daha yüksek yakıt tüketimine neden olabileceği söylenebilir.

GA ile hız optimizasyonu, rastgele seçim kullanan çoklu parametre optimizasyonu ile daha verimli olabilir. Örneğin bu tez kapsamında yer almayan liman gecikmeleri, hava durumu tahminleri, dalga koşulları, bunker, operasyonel emirler vb. yakıt tüketimini etkileyen parametreler GA amaç fonksiyonunda kullanıldığında daha gerçekçi sonuçlar elde edilebilir.

## KAYNAKLAR

- Aldous, L. G. (2016). *Ship operational efficiency: performance models and uncertainty analysis* UCL (University College London)].
- Andrea, C., Luca, O., Francesco, B., & Davide, A. (2017). Vessels fuel consumption forecast and trim optimisation: A data analytics perspective. *Ocean Engineering*, 130, 351-370. <https://doi.org/https://doi.org/10.1016/j.oceaneng.2016.11.058>
- Arslan, O., Besikci, E., & Olcer, A. (2014). Improving energy efficiency of ships through optimisation of ship operations. *No. FY2014-3 IAMU*.
- Aydin, N., Lee, H., & Mansouri, S. A. (2017). Speed optimization and bunkering in liner shipping in the presence of uncertain service times and time windows at ports. *European Journal of Operational Research*, 259(1), 143-154. <https://doi.org/10.1016/j.ejor.2016.10.002>
- Chaal, M. (2018). *Ship operational performance modelling for voyage optimization through fuel consumption minimization* World Maritime University]. Malmö, Sweden.
- Changnan, W., Man, L., Songlin, Y., & Shasha, G. (2017, 2017/09). Optimization Analysis of USV Based on Genetic Algorithm. Proceedings of the 2017 5th International Conference on Mechatronics, Materials, Chemistry and Computer Engineering (ICMMCCE 2017).
- Christos, G., Iraklis, L., & Gerasimos, T. (2019). Machine learning models for predicting ship main engine Fuel Oil Consumption: A comparative study. *Ocean Engineering*, 188, 106282.

<https://doi.org/https://doi.org/10.1016/j.oceaneng.2019.106282>

De Andrade, L. C. O. (2014). Genetic Algorithms Application In Line Simplification.

Faber, J., Nelissen, D., Hon, G., Wang, H., & Tsimplis, M. (2012). Regulated Slow Steaming in Maritime Transport. An assessment of options, costs and benefits.

förstudie initierad av Lighthouse, E. Consequences of speed reductions for ships.

Helong, W., Xiao, L., & Wengang, M. (2021). Voyage optimization combining genetic algorithm and dynamic programming for fuel/emissions reduction. *Transportation Research Part D: Transport and Environment*, 90, 102670. <https://doi.org/10.1016/j.trd.2020.102670>

Hu, Z., Zhou, T., Osman, M. T., Li, X., Jin, Y., & Zhen, R. (2021). A Novel Hybrid Fuel Consumption Prediction Model for Ocean-Going Container Ships Based on Sensor Data. *Journal of Marine Science and Engineering*, 9(4), 449. <https://www.mdpi.com/2077-1312/9/4/449>

IMO. (2016). Guidelines for the development of a Ship Energy Efficiency Management Plan (SEEMP). In *RESOLUTION MEPC.282(70)*.

Karthe. (2016, 1/23/2022). Going Deeper into Regression Analysis with Assumptions, Plots & Solutions.

Kee, K. K., Boung Yew, S. L., & Renco, K.-H. (2018). *Prediction of Ship Fuel Consumption and Speed Curve by Using Statistical Method*.

Kim, Y.-R., Jung, M., & Park, J.-B. (2021). Development of a Fuel Consumption Prediction Model Based on Machine Learning Using Ship In-Service Data. *Journal of Marine Science and Engineering*, 9(2), 137. <https://www.mdpi.com/2077-1312/9/2/137>

Psaraftis, H. (2019). Speed Optimization vs Speed Reduction: the Choice between Speed Limits and a Bunker Levy. *Sustainability*, 11, 2249. <https://doi.org/10.3390/su11082249>

Roar, A., Pierre, C., & Francois-Charles, W. (2020). Optimal ship speed and the cubic law revisited: Empirical evidence from an oil tanker fleet. *Transportation Research Part E: Logistics and Transportation Review*, 140, 101972. <https://doi.org/10.1016/j.tre.2020.101972>

Robert, N. (2022). *Regression diagnostics: Testing the assumptions of linear regression*. Retrieved 1/23/2022 from <https://people.duke.edu/~rnau/testing.htm>

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. <https://doi.org/10.1016/j.trd.2020.102389>

Yang, L., Chen, G., Zhao, J., & Rytter, N. G. M. (2020). Ship Speed Optimization Considering Ocean Currents to Enhance Environmental Sustainability in Maritime Shipping. *Sustainability*, 12(9), 3649. <https://www.mdpi.com/2071-1050/12/9/3649>