



Comparative analysis of metaheuristic optimization algorithms for natural gas demand forecast with meteorological parameters

Zehra Bilici¹ , Durmuş Özdemir^{2*}

¹Department of Software Engineering, Faculty of Technology, Afyon Kocatepe University, 03200, Afyonkarahisar, Türkiye

²Department of Computer Engineering, Faculty of Engineering, Kütahya Dumlupınar University, 43100, Kütahya, Türkiye

Highlights:

- Natural gas demand forecasting according to meteorological input parameters
- Energy estimation with metaheuristic algorithms
- Turkey's monthly natural gas consumption forecast

Keywords:

- Natural gas demand forecast
- Forecast according to meteorological parameters
- Metaheuristic algorithms

Article Info:

Research Article

Received: 25.10.2021

Accepted: 19.05.2022

DOI:

10.17341/gazimmfd.1014788

Correspondence:

Author: Durmuş Özdemir
e-mail:
durmus.ozdemir@dpu.edu.tr
phone: +90 274 443 42 53

Graphical/Tabular Abstract

Natural gas demand forecasting is critical, especially for decision-makers and the industrial sector. This study presents Turkey's monthly natural gas demand forecasting model according to meteorological parameters. Figure A shows the general structure of our suggested models and processes for natural gas demand forecasting.

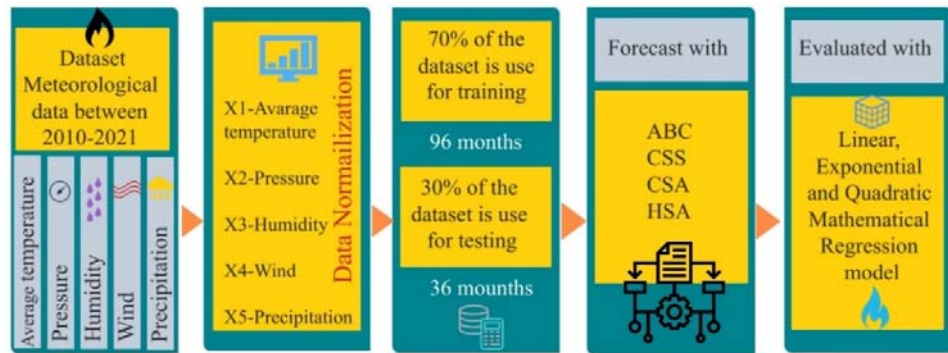


Figure A. Block diagram of Natural Gas Demand Forecast with Meteorological Parameters

Purpose:

This study aims to present Turkey's monthly natural gas demand forecast model according to meteorological parameters with metaheuristic optimization algorithms.

Theory and Methods:

Meteorological data such as monthly average temperature, pressure, humidity, wind, precipitation were used as input parameters to estimate Turkey's natural gas demand. 2010-2017 data were used as training data and 2018-2020 data were used as test data. Four different metaheuristic algorithms (Artificial Bee Colony Algorithm (ABC), Charged System Search Algorithm (CSS), Crow Search Algorithm (CSA), and Harmony Search Algorithm (HSA)) and three different mathematical models (linear, exponential, quadratic) was used. Results were compared according to six different error metrics (AE, MAE, R^2 , MAPE, RMS, MARNE).

Results:

Natural gas demand estimation results from the models we propose based on meteorological parameters are as follows. In the linear model, the CSA algorithm gave the best result for the training dataset, while the ABC algorithm produced the best result for the test dataset. In the exponential model, while the algorithm that gave the best result in the training dataset was the HSA algorithm, the algorithm that gave the best result for the test dataset was the CSA algorithm. In the Quadratic model, while CSS produces a nominal error value for the training dataset, the CSA algorithm gives the best results in the test dataset. In general, the CSA algorithm gave the best result for the test data among the three mathematical models.

Conclusion:

As a result, four different metaheuristic algorithms have been successfully applied with three different models for Turkey's natural gas consumption estimation. Policymakers can use the results of the models presented in this study as a guide for future natural gas energy plans in Turkey. The proposed model can be extended by applying datasets from different countries and with different input parameters



Meteorolojik parametreler ile doğal gaz talep tahmini için metasezgisel optimizasyon algoritmalarının karşılaştırmalı analizi

Zehra Bilici¹ , Durmuş Özdemir^{2*}

¹Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, 03200, Afyonkarahisar, Türkiye

²Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, Türkiye

Ö N E Ç İ K A N L A R

- Meteorolojik girdi parametrelerine göre doğal gaz talep tahmini
- Metasezgisel algoritmalar ile enerji tahmini
- Türkiye'nin aylık doğal gaz tüketim tahmini

Makale Bilgileri

Araştırma Makalesi

Geliş: 25.10.2021

Kabul: 19.05.2022

DOI:

10.17341/gazimmfd.1014788

Anahtar Kelimeler:

Doğal gaz talep tahmini,
meteorolojik parametrelere
göre tahmin,
metasezgisel algoritmalar

ÖZ

Doğal gaz talep tahmini, özellikle enerji tüketimi yüksek ülke ekonomilerinin karar vericileri ve sanayi sektörü için büyük önem taşımaktadır. Bu çalışma, meteorolojik parametrelere göre Türkiye'nin aylık doğal gaz talep tahmin modelini sunmayı amaçlamaktadır. Çalışmada Yapay Arı Kolonisi Algoritması (ABC), Yüklü Sistem Arama Algoritması (CSS), Karga Arama Algoritması (CSA) ve Harmoni Arama Algoritması (HSA) ile oluşturulan modeller karşılaştırılmıştır. Araştırmada doğrusal (lineer), üstel (exponential) ve ikinci dereceden (quadratic) olmak üzere üç matematiksel model geliştirilmiş ve modellerin performansları altı farklı global hata ölçütleri ile değerlendirilmiştir. Çalışmada meteorolojik verilerden ortalama sıcaklık, basınç, nem, rüzgar ve yağış girdi parametreleri olarak kullanılmıştır. 2010-2017 yılları arasındaki veriler eğitim verileri, 2018-2020 yılları arasındaki veriler ise test verisi olarak uygulanmıştır. Doğal gaz talep tahmini eğitim veri kümesini en başarılı tahmin eden model CSS algoritmasının ikinci dereceden modeliyken, test verilerinde ise CSA algoritmasının ikinci dereceden modelidir. Her üç modelde de en başarılı tahmini yapan model CSA ikinci dereceden model olurken, CSS üstel modeli en başarısız tahmin değeri üreten model olmuştur.

Comparative analysis of metaheuristic optimization algorithms for natural gas demand forecast with meteorological parameters

H I G H L I G H T S

- Natural gas demand forecasting according to meteorological input parameters
- Energy estimation with metaheuristic algorithms
- Turkey's monthly natural gas consumption forecast

Article Info

Research Article

Received: 25.10.2021

Accepted: 19.05.2022

DOI:

10.17341/gazimmfd.1014788

Keywords:

Natural gas demand forecast,
forecast according to
meteorological parameters,
metaheuristic algorithms

ABSTRACT

Natural gas demand forecasting is critical, especially for the decision makers of countries with high energy consumption and the industrial sector. This study presents Turkey's monthly natural gas demand forecasting model according to meteorological parameters. In the study, models created with the Artificial Bee Colony Algorithm (ABC), Loaded System Search Algorithm (CSS), Crow Search Algorithm (CSA), and Harmony Search Algorithm (HSA) were compared. Linear, exponential, and quadratic mathematical models were developed in the research. The models' performances were evaluated with six different global error criteria. We used the input parameters such as average temperature, pressure, humidity, wind, and precipitation from meteorological data. The data between 2010-2017 was applied as training data, and the data between 2018-2020 was applied as test data. While the model that successfully predicts the natural gas demand forecast training dataset is the quadratic model of the CSS algorithm, it is the quadratic model of the CSA algorithm in the test data. In all three models, the model that made the most successful prediction was CSA, the quadratic model, while the CSS exponential model was the model that produced the most unsuccessful predictive value.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : zbilici@aku.edu.tr, *durmus.ozdemir@dpu.edu.tr / Tel: +90 274 443 42 53

1. Giriş (Introduction)

Enerji ve elektrik üretiminin birincil kaynakları petrol, doğal gaz ve kömür gibi fosil enerji kaynaklarıdır [1]. Doğal gaz, enerji üretimi için dünyada kullanılan başlıca kaynaklardandır. Düşük karbonlu olması sebebiyle çevre dostu ve en temiz fosil yakıt olan doğal gaz; kömür, petrol gibi kirletici yakıtlardan daha fazla tercih edilmektedir [2]. 2018 verilerine göre doğal gaz, dünya çapındaki tüm enerji tüketiminin yaklaşık olarak %24'ünü karşılamaktadır [3]. Başta ısınma olmak üzere, elektrik üretimi, sanayi, mutfak ve ulaşımda kullanılan doğal gazın tüketimi her geçen gün enerjiye duyulan ihtiyacın artmasıyla beraber yükselmektedir. Doğal gaz, maliyet etkinliği, atık madde salınımının düşük olması, yüksek yanma verimi, kolay depolama ve hatta bazı sektörler için depolama alanına ihtiyaç duymama gibi çok önemli avantajlara sahiptir [4]. Doğal gaz bir ülkenin ekonomik kalkınma hızında, sunduğu avantajlardan dolayı önemli bir role sahiptir [5].

Türkiye, Asya ve Avrupa'yı birbirine bağlayan konumu sebebiyle doğal gaz ve petrol gibi enerji kaynaklarının kıtalararası (Orta Doğu'dan Avrupa'ya, Asya'dan Avrupa'ya) boru hatlarıyla ulaştırılmasında önemli bir jeopolitik rol oynamaktadır [6]. Bu sebeple Türkiye, petrol ve doğal gaz üreten ülkeler için önemli bir pazar ve geçiş ülkesidir. Özellikle Türk Akım ve Mavi Akım doğal gaz boru hattı anlaşmalarıyla doğal gaz dağıtım merkezi üssü haline gelen Türkiye'nin önemi her geçen gün artmaktadır [7, 8]. Türkiye İstatistik Kurumu (TÜİK) 2019 yılı verilerine göre enerji kaynaklarına göre elektrik enerjisi üretimi ve payları; kömür (%37,1), sıvı yakıtlar (%0,1), doğal gaz (%18,9), hidrolik (%29,2), yenilenebilir enerji ve atıklar (%14,7) olarak verilmiştir [9]. 2018 yılında birincil enerji kaynaklarına göre dünya enerji tüketimi şu şekildedir; petrol (%2,9), kömür (%38), nükleer (%10,1), hidro (%16,2), rüzgar (%4,8), güneş (%2,1), biyoyakıtlar ve atıklar (%2,4) ve diğer (%0,5) [10]. Türkiye, sürekli artan enerji talebi ve sınırlı enerji kaynakları sebebiyle enerji ihtiyacının yaklaşık dörtte üçünü ithal etmekte ve enerji ihtiyacının büyüme hızına paralel olarak artması öngörülmektedir [11]. Türkiye doğal gaz ihtiyacının neredeyse tamamına (%99,09) ithalat yoluyla karşılayıp yalnızca ihtiyacının %0,91'ini üretmiştir [12]. 2020 yılında Türkiye'de tüketilen 47,7 milyar m³ doğal gazın yaklaşık %32,3'ü konutlarda tüketilmiştir [13]. Ayrıca Türkiye 2020 yılında dünyadaki en fazla doğal gaz tüketiminin gerçekleştiği ülkeler arasında yedinci olmuştur. Türkiye, 2020 yılının EPDK (Enerji Piyasası Düzenleme Kurumu) sonuçlarına göre doğal gaz ithalatı sırasıyla %33,59 Rusya, %24 Azerbaycan, %11,58 Cezayir, %11,06 İran, %2,82 Nijerya ve %16,95 diğer ülkelerden karşılamıştır [12]. Özellikle enerji ihtiyacını ithalat yolu ile karşılayan ülkeler için doğal gaz talep tahminini doğru şekilde yapmak, geleceğe yönelik talep, arz, iletim, dağıtım ve fiyatlandırmanın planlanması açısından önem arz etmektedir.

Enerji ihtiyacının büyük çoğunluğunu doğal gazdan karşılayan ülkelerin enerji yatırımlarını etkin bir şekilde yönetebilmeleri için doğru talep tahminleri önemlidir [14, 15]. Talep tahminlerindeki hataların minimum düzeyde olması ile ithal edilecek olan enerji kaynakları için yapılacak erken anlaşmalar sayesinde enerji kaynağının satın alım maliyeti düşmektedir. Bu sebeple karar vericiler için doğru talep tahmini çok önemlidir [16]. Enerji üretim maliyetlerinin yüksek olmasından dolayı, enerji üretimi ve tüketimi arasında dengeli bir plan olmalıdır. Bir ülkenin doğal gaz talep tahmininin gereğinden az olması doğal gaz krizlerine ve tüketiciye yüksek satış fiyatları ile sunulmasına, fazla olması ise ekonomide zarara neden olabilmektedir. Türkiye'de Devlet Planlama Teşkilatı (DPT) ve Enerji ve Tabii Kaynaklar Bakanlığı (ETKB), büyüme hedefleri doğrultusunda enerji ve doğal gaz talep projeksiyonları hazırlamaktadır (ETKB, 2019). Ancak ETKB tahminleri genel olarak

incelendiğinde gerçek enerji talebinin üzerinde tahminler gerçekleştirilmektedir. Tüm bu sebeplerden dolayı literatürde doğal gaz tahmini üzerine birçok çalışma olduğu görülmektedir. Doğal gaz talep tahmini doğru bulmak için birçok farklı algoritma, yöntem ve veri kümesi kullanılarak tahmin modeli oluşturulmuştur.

Karadede vd., Panapakidis vd., Wu vd., Su vd. [17-20], çalışmalarında doğal gaz talep tahmini için genetik algoritma (GA) kullanmışlardır. GA ile birlikte Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS), Yapay Sinir Ağları (YSA), Parçacık Sürü Optimizasyonu (PSO), Regresyon Analizi, Grey Teori Modeli gibi algoritmalar kullanılarak yıllık, saatlik tahminlerde bulunmuşlardır. Doğal gaz tüketim tahmini için giriş değerleri olarak nüfus, Gayri Safi Yurtiçi Hasıla (GSYİH), sıcaklık ve doğal gaz fiyatı girdi parametrelerini kullanılmıştır. Hata metriği olarak Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE) ve Karelerinin Ortalamasının Karekökü (RMS) ölçütlerini kullanmışlardır. Bianco vd. [21] ve Oliver vd. [22], çalışmalarında regresyon analizi yaparak yıllık doğal gaz tüketimini tahmin etmişlerdir. Doğal gaz talep tahmini için girdi parametreleri olarak GSYİH, doğal gaz fiyatı ve sıcaklık değerlerini kullanmışlardır. Hata metriği olarak MAPE'yi kullanmışlardır. Doğal gaz talep tahmini için en çok kullanılan yöntemlerden bir diğeri ise Yapay Sinir Ağlarıdır. Taşpınar vd., Szoplik, Beyca vd., Potonic vd. [23-26], YSA kullanarak saatlik, günlük ya da yıllık olarak doğal gaz talep tahmininde bulunmuşlardır. YSA ile üstel ve doğrusal matematiksel modeller oluşturmuşlardır. Ayrıca Destek Vektör Makinesi (SVR), Otoregresif Hareketli Ortalamalar Modeli (ARMA) ve Birleştirilmiş Otoregresif Hareketli Ortalama Modeli (ARIMA) gibi algoritmaları tekil, hibrit veya çoklu olarak kullanmışlardır [27, 28]. Girdi parametresi olarak başta sıcaklık, zaman, nüfus, basınç, nem ve doğal gaz fiyatı verilerini kullanmışlardır. Hata metriği olarak genellikle RMS ve MAPE kullanılmıştır.

Rui vd. [29] doğal gaz talep tahmini için genetik algoritmalara dayalı bir yöntem önermiştir. 1994-2006 yılları arasındaki doğal gaz tüketim verileri kullanılarak 2010-2015 yılları arasındaki tüketim tahmin edilmiştir. Wu vd. [30], Çin'in doğal gaz tüketimi ve üretiminin tahmini Markov zinciri ile iyileştirilmiş Grey tahmin modeliyle gerçekleştirilmiştir. Grey tahmin modelinin daha güvenilir ve daha yüksek tahmin doğruluğu olduğunu göstermişlerdir. Wan vd. [31], Çin'in Chongqing şehri için Grey-Markov modelini kullanarak doğal gaz talep tahmininde bulunmuşlardır. 2001-2010 yılları arasındaki doğal gaz tüketim verileri kullanılarak, 2011-2015 yıllarındaki doğal gaz tüketimi tahmin edilmiştir. Rahman vd. [32] Bangladeş'in 2011-2040 yılları arasındaki uzun vadeli enerji talep tahmini için GSYİH, petrol fiyatı, nüfus artışı ve elektrik tüketimi verilerini girdi parametreleri olarak kullanmış ve üstel matematiksel model gerçekleştirmiştir. Brown vd. [33] doğruluk oranı yüksek kısa vadeli doğal gaz talep tahmin modelleri oluşturmak için uzun vadeli doğal gaz talep eğrisinden faydalanan yeni bir eğilim algoritması sunmuşlardır. Tahmin doğruluğu, eğilimi giderilmiş uzun vadeli sinyaller kullanıldığında azaldığını belirtmişlerdir. Khani vd. [34] gün öncesi doğal gaz talebi tahminine uygulamalı, çevrimiçi olarak kalibre edilmiş yeni bir zaman serisi tabanlı model önermektedir. Tahmin modelini oluşturmak için çift aşamalı bir süreç geliştirilmiştir. İlk aşama, doğal gaz talebinin sıcaklıktan bağımsız ve sıcaklığa bağlı bileşenlerinin analizini içerir. Sonraki aşama, ortam sıcaklığı ile ilgili doğal gaz talebi özelliklerinden yararlanılarak gerçekleştirilir. Qiao vd. [35] Volterra uyarlanabilir filtre ile yeni bir hibrit tahmin modeli ve kısa vadeli doğal gaz tüketimini tahmin etmek için geliştirilmiş bir Balina Optimizasyon Algoritması (WOA: Whale Optimization Algorithm) önermeyi amaçlamaktadır. Liu vd. [36] planlama, maliyetleri düşürme ve verimliliği artırarak için ayrık kesirli zaman güç terimi ile grey model tabanlı doğal gaz talep tahmin modeli

önermişlerdir. Ayrıca doğal gaz talebinin SARIMA, Gri Bernoulli, Nöro-Bulanık Gauss yöntemleri kullanılarak tahmin edildiği çalışmalarda bulunmaktadır [37-39].

Literatüre göre doğal gaz talep tahmini genellikle tekil veya hibrit olarak YSA, GA, ARIMA, Regresyon analizi, ANFIS, bulanık mantık ve sürü zekası algoritmaları gibi farklı metodlar ile hesaplanmıştır. Ayrıca, Gri Kurt Algoritması (GWA: Grey Wolf Algorithm), Karınca Kolonisi Optimizasyonu (ACO: Ant Colony Optimization) ve PSO gibi metasezgisel algoritmaların, doğal gaz talep tahmininde tek başına kullanıldığı görülmüştür [19], [35]. Yapmış olduğumuz çalışmanın literatürdeki çalışmalardan farkı ve alana katkısı aşağıda maddeler halinde özetlenmiştir.

- Literatürdeki çalışmaların genel olarak bir şehri veya bir bölgeyi kapsadığı belirlenmiştir. Bu çalışmada ise Türkiye'nin tamamının (ülke bazlı) doğal gaz talep tahminini üzerine çalışılmıştır.
- Araştırmalarda genellikle tekil girdi parametrelerinin kullanıldığı görülmüş, çalışmamızda ise basınç, nem, rüzgar, yağış ve sıcaklık gibi birden çok girdi parametresi dahil edilerek tahmin çalışmaları yürütülmüştür.
- Doğal gaz talep tahmini için metasezgisel algoritma yöntemlerinin tekil olarak tercih edildiği görülmüştür. Bu çalışmada ise doğal gaz talep tahmini için tek bir model veya algoritma kullanmak yerine ABC, CSS, CSA ve HSA olmak üzere dört farklı metasezgisel algoritmaları kullanılmış ve bu dört algoritmanın ayrı ayrı performansları kapsamlı bir şekilde karşılaştırılmıştır.
- Çalışmamızda doğrusal, üstel ve ikinci dereceden olmak üzere üç matematiksel modeli dört metasezgisel algoritma için yinelenmiştir ve sonuçları analiz edilmiştir.

Bu çalışmada doğal gaz talep tahmini için, girdi parametresi olarak bir ülkenin tamamına ait 132 aylık sıcaklık, rüzgar, nem, basınç ve yağış

verileri kullanılmıştır. 2010-2017 yılları arasındaki veriler eğitim verileri, 2018-2020 yılları arasındaki veriler ise test verisi olarak uygulanmıştır. Tahmin verileri için oluşturulan modellerin istatistiksel olarak değerlendirilmesi için altı farklı hata metriği bir arada kullanılarak analiz edilmiştir. Araştırmamızda bir ülkenin tamamına yönelik doğal gaz tüketim tahmin modellemesi gerçekleştirmek ve kullanılan metasezgisel algoritmaların performanslarını gerçek dünya problemi olan doğal gaz tüketim tahmini üzerinde belirlemek amaçlanmıştır.

2. Metodoloji (Methodology)

2.1. Veri Kümesi (Dataset)

Türkiye'nin doğal gaz talebini tahmin etmek için aylık ortalama sıcaklık, basınç, nem, rüzgar, yağış gibi meteorolojik veriler girdi parametreleri olarak kullanılmıştır. Çalışmada kullanılan meteorolojik veriler Devlet Meteoroloji İşleri Genel Müdürlüğü'nün (MGM) ile yapılan resmi yazışmalarından, doğal gaz tüketim verileri ise jodidata.org'dan kamuya açık veriler olarak elde edilmiştir. Çalışmamızda kullandığımız veri kümesi çok uzun olduğu için örnek olarak seçilen veriler Tablo 2'de sunulmuştur. Veri kümesinin tamamı kaggle veri paylaşım platformu üzerinden paylaşılmıştır. Modelde kullanılan veriler iki gruba ayrılmıştır. Eğitim sürecinde 2010-2017 (96 ay) verileri, test verisi olarak 2018-2020 (36 ay) verileri kullanılmıştır.

2.2. Veri Kümesi Normalleştirme (Data Set Normalization)

Çalışmada kullanılan nem, ortalama sıcaklık (OS), yağış, basınç, rüzgar verilerinin değerleri geniş değer aralıklarına sahip olduğu için, girdi parametreleri olarak kullanılmak üzere ortalama sıcaklık (Eş. 1), nem (Eş. 2), yağış (Eş. 3), basınç (Eş. 4) ve rüzgar (Eş. 5) verileri ilgili formüller ile normalize edilmiştir.

Tablo 1. Doğal gaz tüketim tahmini çalışmaları (Studies on natural gas consumption forecasting)

Referans	Model	Tahmin süresi	Tahmin bölgesi
[40]	ANFIS	Günlük	İran
[41]	YSA, Bulanık mantık, Regresyon	Günlük	Batı Pensilvanya
[25]	YSA, SVR	Aylık	İstanbul (Türkiye)
[42]	Fuzzy	Haftalık	Polonya'nın bir bölgesi
[43]	GA	Yıllık	İran
[38]	Grey Bernoulli Model, MFO	Yıllık	Kuzey Amerika
[24]	ANN	Yıllık /Günlük	Szczecin (Polonya)
[44]	GA-YSA	Günlük	Yasouj (İran)
[45]	GA	Günlük	Şanghay (Çin)
[46]	GWO	Yıllık	Chongqing (Çin)
Bu çalışmada	(ABC), (CSS), (CSA) ve (HSA)	Aylık	Tüm Türkiye

Tablo 2. Veri kümesinden bazı örnek veriler (Some sample data from the dataset)

Yıl	Ay	Ortalama Sıcaklık (°C)	Basınç (hPa)	Nem (%)	Rüzgar (m÷sn)	Yağış (mm=kg÷m²)	Doğal gaz Tüketimi (MScM)
2010	1	4,86819	940,784	76,84304	1,87838	2,88559	3985
2010	2	6,94513	936,5603	73,40168	1,95222	2,79971	3286
2010	3	9,14407	941,02576	65,35619	2,00645	1,67283	3441
2010	4	12,44667	940,33032	64,17954	1,87869	1,73443	2930
2010	5	17,77129	937,66213	58,17681	1,78828	1,21473	2566
...
...
2020	7	25,75067	936,23719	51,33666	2,02262	0,44139	2801
2020	8	24,94154	935,2753	47,35114	1,94166	0,36651	2833
2020	9	23,7636179	937,5707724	50,6569512	1,6964183	0,3917316	3311
2020	10	18,2800157	940,4997234	49,3441797	1,182716	0,8399916	3572
2020	11	9,2195033	943,4654397	68,0886354	1,4266888	1,4647414	5413
2020	12	6,67637	942,0131786	73,62641	1,3709321	1,3466584	6341

$$OS = \frac{OS - OS_{min}}{OS_{max} - OS_{min}} = \frac{OS - 0.127}{27.289 - 0.127} \quad (1)$$

$$Nem = \frac{nem - nem_{min}}{nem_{max} - nem_{min}} = \frac{nem - 45.632}{80.775 - 45.632} \quad (2)$$

$$Yağış = \frac{yağış - yağış_{min}}{yağış_{max} - yağış_{min}} = \frac{yağış - 0}{4.378 - 0} \quad (3)$$

$$Basınç = \frac{basınç - basınç_{min}}{basınç_{max} - basınç_{min}} = \frac{basınç - 932.187}{947.491 - 932.187} \quad (4)$$

$$Rüzgar = \frac{rüzgar - rüzgar_{min}}{rüzgar_{max} - rüzgar_{min}} = \frac{rüzgar - 1.137}{2.304 - 1.137} \quad (5)$$

2.3. Çalışmada Karşılaştırılan Metasezgisel Algoritmalar (Metaheuristics Algorithms Compared in the Study)

Metasezgisel algoritmalar problemin en iyi (optimum) çözümünü garanti etmezler ancak hızlı çözüm elde edilmesini sağlarlar. Örneğin bazı algoritmalar yerel optimumda takılı kalıp (stuck in local optima) en iyi değeri bulamadan kendisini tamamladığı için, global çözümün bulunmasında algoritmaların kıyaslanması oldukça önem arz etmektedir [47]. Araştırmamızda Yapay Arı Kolonisi Algoritması (ABC: Artificial Bee Colony), Yüklü Sistem Arama Algoritması (CSS: Charged System Search), Karga Arama Algoritması (CSA: Crow Search Algorithm) ve Harmoni Arama Algoritması (HSA: Harmony Search Algorithm) kullanılmıştır. Doğrusal (linear), üstel (exponential) ve ikinci dereceden (quadratic) matematiksel modelleri oluşturularak performanslarına göre karşılaştırılmıştır.

2.2.1. Yapay arı kolonisi algoritması (ABC) (Artificial bee colony algorithm)

Karaboğa [48] tarafından önerilen Yapay Arı Kolonisi algoritması, popülasyon tabanlı sayısal optimizasyon algoritmasıdır. Arı sürülerinin yiyecek arama davranışlarının basitleştirilmiş matematiksel modellerine dayanmaktadır. ABC algoritmasında, problemin herhangi bir rastgele çözümü bir nektar kaynağına karşılık gelir. Her nektar kaynağına atanmış bir işçi arı vardır. İstihdam edilen arıların sayısı, toplam besin kaynağı sayısına (yani popülasyon

değerinin büyüklüğüne) eşittir. Nektarı tükenmiş bir nektar kaynağından çalıştırılan arı, yeniden gözcü arıya dönüşür. Bir nektar kaynağındaki nektar miktarı, ilgili nektar kaynağının amaç fonksiyon değeri ile ifade edilir. Bu nedenle, ABC algoritması, maksimum miktarda nektar içeren nektar kaynağını bulmayı hedefler [48]. Genel anlamda algoritmanın yapısı Tablo 3'te gösterilmiştir.

2.2.2. Yüklü sistem arama algoritması (CSS) (Charged system search algorithm)

Kaveh ve Talatahahari [50] tarafından önerilen Yüklü Sistem Arama Algoritması, Coulomb kanunu ve Newton'un hareket kanunundan esinlenilerek geliştirilmiştir. Algoritmada popülasyondaki bireyler yüklü parçacık (CP: Charged Particles) olarak adlandırılır. Yüklü parçacıklar yükleri oranında ve aralarındaki mesafenin tersi bir oranda birbirlerine bir kuvvet (resultant force) uygularlar. Daha sonra yüklü parçacıklar üzerindeki bu kuvvet aracılığı ile yeni konumuna hareket ettirilir [50]. Genel anlamda algoritmanın yapısı Tablo 4'te gösterilmiştir.

2.2.3. Karga arama algoritması (CSA) (Crow search algorithm)

CSA, kargaların (crows) birbirleriyle nasıl iletişim kurduğuna dayanmaktadır. Kargaların etkileşimi, birbirlerinin uçuşlarını izlemesi ve izledikleri kargaların yiyeceklerini nerede sakladıklarını gözlemesidir. Ardından yuvanın sahibi olan karganın yuvayı terk ettikten sonra izleyici karganın gelip yiyecekleri çalmasından esinlenilmiş bir algoritmadır. Bu yaklaşım optimizasyon yöntemi adı altında ilk kez Askarzadeh aracılığıyla 2016 senesinde sunulmuştur [52]. CSA, özellik seçimi, kesirli optimizasyon ve doğrusal olmayan optimizasyon problemleri gibi bazı gerçek dünya problemlerine uygulanır. Algoritmanın genel yapısı Tablo 5'te gösterilmiştir.

2.2.4. Harmoni arama algoritması (HSA) (Harmony search algorithm)

Lee and Geem (2004) tarafından geliştirilen HS algoritması, bir orkestradaki müzisyenlerin çaldıkları notalar ile harmonik açıdan en iyi melodinin elde edilmesi prensibine dayanmaktadır [54], [55]. Kesikli ve sürekli değişkenleri kullanabilirken yerel arama yeteneği zayıftır. Genel anlamda algoritmanın yapısı Tablo 6'da gösterilmiştir.

Tablo 3. ABC algoritması sözde kodu (Pseudo-code of ABC algorithm) [49]

1: Başla
2: Başlangıç parametrelerinin belirlenmesi
3: l_i ve u_i , X_{ij} parametresinin alt ve üst sınırdır
4: ϵ : [0,1) aralığındaki rastgele sayıdır,
5: SN: besin kaynağı konumu sayısı,
6: D: Optimizasyon parametrelerinin sayısı
7: $X_{ij} = l_i + \epsilon(u_i - l_i)$ fomülünü kullanarak, $X_{ij}, \{i = 1, 2, \dots, SN, j = 1, 2, \dots, D\}$ çözümlerin rastgele popülasyon değerlerini başlat ve popülasyonun uygunluk değerini bul;
8: While not T
9: T sonlandırma kriteridir.
10: ∂_{ij} , [-1, 1] arasında rastgele sayı
11: $V_{ij} = X_{ij} - \partial_{ij}(X_{ij} - X_{kj})$, $k \in \{1, 2, \dots, SN\}$ denklemini kullanarak işçi arılar için yeni çözümler V_{ij} üret;
12: İşçi arılar için greedy (açgözlü) seçim sürecini uygula;
13: $F(X_i)$, X_i^* de bulunan besin kaynağının nektar miktarı
14: $P_i = F(X_i) / \sum_{k=1}^{SN} F(X_k)$ ile X_{ij} çözümleri için P_{ij} olasılık değerlerini hesaplanır;
15: P_{ij} 'ye bağlı olarak seçilen X_{ij} çözümlerinden gözcü arılar için yeni çözümler V_{ij} üret ve uygunluk değerlerini hesapla;
16: Gözcü arılar için greedy (açgözlü) seçim sürecini uygula;
17: Kâşif arı için rastgele üretilmiş daha iyi bir çözüm X_{ij} var ise, $X_{ij} = l_i + \epsilon(u_i - l_i)$ kullanarak eski çözümü belirle ve değiştir;
18: En iyi çözüme (best solution) ulaşıldığında hafıza al;
19: end while
20: end

Tablo 4. CSS algoritması sözde kodu (Pseudo-code of CSS algorithm) [51]

1: Rastgele bir dizi yüklü parçacık (CP) başlat
2: Bu parçacıkların başlangıç hızlarını sıfır olarak al.
3: while iteration <max iteration do
4: for her parçacık
5: Yükün büyüklüğünü hesapla aşağıdaki formüle göre hesapla; $q(i) = \frac{\text{fit}(i) - \text{fitworst}}{\text{fitbest} - \text{fitworst}}$, $i = 1, 2, \dots, N$
6: fit(i), CP için amaç fonksiyonu tarafından elde edilen uygunluk değerini temsil eder.
7: fitworst ve fitbest, tüm CP'lerin en iyi ve en kötü uygunluk değeridir.
8: Bileşik kuvveti aşağıdaki formüle göre hesapla;
9: $F_j = q_j \sum_{i, i \neq j} \left(\frac{q_i}{a^3} r_{ij} \cdot i_1 + \frac{q_i}{i_j^2} r_{ij} \cdot i_2 \right) ar_{ij} P_{ij} (X_i - X_j) = \pi r^2$, $\begin{cases} j = 1, 2, \dots, N \\ i_1 = 1, i_2 = 0 \leftrightarrow r_{ij} < a \\ i_1 = 0, i_2 = 1 \leftrightarrow r_{ij} \geq a \end{cases}$
10: F_j: CP'ye etki eden bileşke kuvvettir.
11: r_{ij}: (ith ve jth CP arasındaki Öklid mesafesidir)
12: X_i ve X_j: ith ve jth CP'lerinin konumudur.
13: N: toplam CP sayısıdır.
14: İki yüklü parçacık arasındaki r_{ij} ayırma mesafesi hesapla; $r_{ij} = \frac{\|X_i - X_j\|}{\|(X_i + X_j) / 2 - \|\| + \epsilon}$
15: X_i ve X_j: CP'lerin konumlarıdır, X_{best}: mevcut en iyi CP
16: ε, tekilliklerden kaçınmak için küçük bir pozitif sayıdır,
17: P_{ij}: her bir CP'yi diğerine doğru hareket ettirme olasılığıdır
18: $P_{ij} = \begin{cases} 0 & \frac{\text{fit}(i) - \text{fitbest}}{\text{fit}(j) - \text{fit}(i)} > \text{rand} \vee \text{fit}(j) > \text{fit}(i) \\ 1 & \text{diğer} \end{cases}$
19: rand: (0,1) aralığında eşit olarak dağılmış rastgele bir sayıdır. a: yarıçap
20: a = 0.01 X max({u_i - l_i | i = 1, 2, ..., n_v})
21: l_i ve u_i karar parametresinin alt ve üst sınırdır.
22: Yeni konumu ve hızı hesapla;
 $X_{j, \text{new}} = \text{rand}_{j1} \cdot k_a \cdot F_j + \text{rand}_{j2} \cdot k_v \cdot V_{j, \text{old}} + X_{j, \text{old}}$, $V_{j, \text{new}} = X_{j, \text{new}} - X_{j, \text{old}}$
23: r_{j1} ve r_{j2}: (0,1) arasında rastgele vektörlerdir, k_a ve k_v: sabit sayılardır
24: end for
25: end while

Tablo 5. CSA algoritması sözde kodu (Pseudo-code of CSS algorithm) [53]

1: Arama uzayındaki N Karga sürüsünün konumunu rastgele başlat;
2: Kargaların konumunu değerlendir;
3: Her karganın hafızasını sıfırla;
4: while iter < Maxiter
5: Maxiter : prosedür içindeki en yüksek yineleme
6: for i=1 : N
7: N: sürünün tüm kargaları
8: Kargalardan birini rastgele seçin;
9: Farkındalık olasılığını tanımla
10: x_i^{iter} : i karganın iterasyondaki konumu
11: if r_i ≥ AP_j^{iter} AP_j^{iter}: yinelemede j kargasının farkında olma olasılığıdır
12: x_i^{iter+1} = x_i^{iter} + r_i · fl_i^{iter} · (m_j^{iter} - x_i^{iter}) m_i : en iyi besin kaynağı
13: r_i : [0,1] aralığında rastgele bir sayıdır,
14: fl_i^{iter} : yinelemede karga i'nin uçuş uzunluğudur.
15: else
16: x_i^{iter+1} arama uzayında rastgele konumu
17: end if
18: end for
19: Yeni pozisyonların uygulanabilirliğini kontrol et.
20: Kargaların yeni konumunu değerlendir.
21: Kargaların hafızasını güncelle.
22: end while

2.3. Matematiksel Regresyon Modelleri ve Deneysel Sonuçlar
(Mathematical Regression Models and Experimental Results)

Türkiye'nin doğal gaz talebini tahmin etmek için üç farklı matematiksel model (doğrusal, üstel and ikinci dereceden fonsiyon) geliştirilmiştir. Doğrusal matematiksel modelin genel denklemi Eş. 6'da üstel matematiksel modelin genel denklemi Eş. 7'de ve ikinci dereceden matematiksel modelin genel denklemi Eş. 8'de verilmiştir. Modellerde kullanılan değişken değerleri Z_1 ortalama sıcaklık, Z_2 basınç, Z_3 nem, Z_4 , rüzgar, Z_5 ise yağış değerini temsil etmektedir. Oluşturulan modellerde algoritmalar tarafından bulunan optimum w_1, w_2, \dots, w_N ağırlık değerleri Tablo 8, Tablo 9 ve Tablo 10'da sırasıyla sunulmuştur.

- Doğrusal model

$$E_{lineer} = w_1 + w_2Z_1 + \dots + w_{N+1}Z_N \quad (6)$$

- Üstel model

$$E_{üstel} = w_1 + w_2e^{(Z_1W_3)} + \dots + w_{2N}e^{(Z_NW_{2N+1})} \quad (7)$$

- İkinci dereceden model

$$E_{ikincidereceden} = w_1 + \sum_{i=1}^n w_{i+1}Z_i + \sum_{i=2}^n \sum_{j=i}^n w_k Z_i Z_j \quad k = n + 1, n + 2, \dots, N \quad (8)$$

ABC, CSS, CSA ve HSA algoritmaları ile Türkiye için 2010-2020 yılları arasındaki aylık doğal gaz talep tahminin doğrusal (Tablo 8), üstel (Tablo 9) ve ikinci dereceden (Tablo 10) matematiksel model formüllerinin bulunan ağırlık değerleri verilmiştir. Uygulanan modellerde algoritmalarda iterasyon sayısı 1000, popülasyon sayıları 40 olarak belirlenip veriler 250 kez test edilerek en iyi sonuçlar elde edilmiştir. Algoritmalar MATLAB programı üzerinde kodlanmış ve Intel i7 ve 2.60 GHz işlemcili ve 8 GB belleğe sahip bir bilgisayarda çalıştırılmıştır. Algoritmalar için kullanılan diğer parametre değerleri ise Tablo 7'de verilmiştir.

Ağırlık değerleri, parametrelerin etki büyüklüklerini belirlemektedir. Etki büyüklüklerine göre ağırlık değerleri kodladığımız optimizasyon algoritmaları (ABC, CSA, CSS ve HSA) ile bulunmuştur. Doğrusal, üstel ve ikinci dereceden matematiksel modeller için algoritmalar ayrı ayrı çalıştırıldı ve tüm ağırlıklar, uygunluk fonksiyonunu kullanan optimizasyon algoritmalarımız tarafından doğrudan hesaplandı. Algoritmalar, eğitim veri seti ile verilen giriş değerlerine göre parametrenin önemini belirten ağırlık değerlerini belirlemektedir. Bu nedenle eğitim veri seti ile öğrenilen ağırlık değerlerinin doğruluğu test veri seti üzerinde test edilmiştir.

Tablo 6. HSA algoritması sözde-kodu (Pseudo-code of HSA algorithm) [59]

1: Başla
2: Harmony belleği dikkate alma oranı (HMCR: Harmony Memory Considering rate)
3: Ton ayarlama oranı (PAR: Pitch Adjusting Rate), Armoni hafıza boyutu (HMS: Harmony Memory Size)
4: Maksimum iterasyon sayısı (Maxiter), Başlangıç popülasyonu (HM)
5: min: minimum görünür değer, max: maximum görünür değer
6: Rastgele harmonilerle Harmony belleği oluşturun
7: while (t < Maxiter)
8: while (i <= değişken sayısı)
9: if(rand < HMCR),
10: i değişkeni için HM'den bir değer seç;
11: if(rand < PAR),
12: Belirli bir miktar ekleyerek değeri ayarla;
13: $X_{new}^i = X_{new}^i \mp r_3 \cdot BW$ (Distance Bandwidth):sınırlar arasındaki mesafe
14: end if
15: else
16: Rastgele değer seç;
17: $X_{new}^i = l_i + r_3 \cdot (u_i - l_i)$
18: l_i ve u_i : karar değişkeni için alt ve üst sınırdır. r_3 : [0,1] arasında rastgele bir sayıdır.
19: end while
20: if (fitness(X_{new}) ≤ worst(fitness(HM))) then
21: HM'i güncelle Daha iyiyse Yeni Harmony'i (çözümü) kabul edin
22: end if
23: end while
24: Mevcut en iyi çözümü bulun
25: end

Tablo 7. Algoritmalarda kullanılan parametreler (Parameters used in algorithms)

Algoritma	Parametre Değerleri	İterasyon Sayısı	Popülasyon Sayısı
ABC	$F(X_i) = 0.2$	1000	40
CSS	$k_a = 0.9, rand_{j1} = 0.1, k_v = 0.9;$ $rand_{j2} = 0.1, a = 0.01, \epsilon = 1e-6$	1000	40
CSA	$AP_j^{iter} = 0.1, fl_i^{iter} = 2$	1000	40
HSA	Hmcr = 0.9 Par = 0.1 Bw = 0.01	1000	40

* $F(X_i)$ besin kaynağının nektar miktarıdır, k_a ve k_v : sabit sayılardır, $rand$: (0,1) aralığında eşit olarak dağılmış rastgele bir sayıdır, a : yarıçap, ϵ : tekilliklerden kaçınmak için küçük bir pozitif sayıdır, AP_j^{iter} : yinelemede j kargasının farkında olma olasılığıdır, fl_i^{iter} : yinelemede karga i'nin uçuş uzunluğudur, Hmcr: Harmony belleği dikkate alma oranıdır, Par: ton ayarlama oranıdır, Bw: sınırlar arasındaki mesafedir.

Tablo 8. ABC, CSS, CSA ve HSA algoritmalarının doğrusal model için ağırlık değerleri
(Weight values of ABC, CSS, CSA and HSA algorithms for linear model)

	ABC	CSS	CSA	HSA
w ₁	0,752622	0,856460	0,834541	0,829069
w ₂	-0,640869	-0,631750	-0,617991	-0,609613
w ₃	0,084392	0,006486	0,015842	0,013385
w ₄	-0,130524	-0,135004	-0,120559	-0,108868
w ₅	0,001810	-0,097259	-0,088688	-0,091117
w ₆	0,008434	-0,052747	-0,054318	-0,059025

Tablo 9. ABC, CSS, CSA ve HSA algoritmalarının üstel model için ağırlık değerleri
(Weight values of ABC, CSS, CSA, and HSA for the exponential model)

	ABC	CSS	CSA	HSA
w ₁	0,50082	0,114813	0,128224	-0,037036
w ₂	0,761851	0,689611	0,757548	0,837320
w ₃	0,252464	0,132073	0,003356	0,168482
w ₄	0,186818	0,193956	0,342818	0,379955
w ₅	0,982495	0,987649	0,653571	0,900770
w ₆	-0,089992	-0,135156	-0,2699310	-0,198164
w ₇	-2,572130	-2,769725	-2,549061	-2,210353
w ₈	-15,000000	-14,323153	0,778528	-13,721768
w ₉	-4,646044	-7,937008	-3,341060	-2,653542
w ₁₀	-7,321292	-7,323356	-4,445338	-6,089423
w ₁₁	-9,562759	-10,912434	-1,093100	-2,189995

3. Performans Analizi ve İstatistiksel Bulgular (Performance Analysis and Statistical Findings)

Modellerin performansı mutlak hata (AE) (Eş. 9), ortalama mutlak hata (MAE) (Eş. 10), mutlak varyans oranı (R²) (Eş. 11), ortalama mutlak yüzde hata (MAPE) (Eş. 12), ortalama karekök hatası (RMS) (Eş. 13) ve ortalama mutlak aralık normalize hatası (MARNE) (Eş. 14) hata ölçütleri ile analiz edildi. Literatürde metasezgisel algoritmalar ile optimizasyon çalışmalarında yaygın olarak kullanılan hata ölçütleri seçilmiştir. AE, MAE, MAPE, RMS ve MARNE hata ölçütleri için daha küçük olan değer daha başarılı olurken, R² hata metriğinin 1'e en yakın değeri daha başarılıdır. E_{obs} ve E_{pre} sırasıyla tahmin edilen ve gözlenen değerlerdir. Ayrıca n, eğitim, test ve doğrulama için kullanılan veri noktalarının sayısıdır. MAE, tüm AE değerlerinin toplamına karşılık gelmektedir. MAPE, özellikle tahmin problemlerinde yaygın olarak kullanılır. Tahmin kabiliyetini belirleyen MAPE ölçütleri, MAPE %10'dan azsa çok iyi, MAPE %10 ila %20 arasındaysa iyi, MAPE %20 ila %50 arasındaysa kabul edilebilir ve MAPE 50'den büyükse yanlış olarak tanımlanır [56].

$$AE = \sum_{i=1}^n |E_{obs} - E_{pre}| \quad (9)$$

Tablo 10. ABC, CSS, CSA ve HSA algoritmalarının ikinci dereceden model için ağırlık değerleri
(Weight values of ABC, CSS, CSA and HSA algorithms for quadratic model)

	ABC	CSS	CSA	HSA		ABC	CSS	CSA	HSA
w ₁	0,631802	0,676480	0,673571	0,520659	w ₁₂	-0,037705	-0,362511	-0,232885	-0,311581
w ₂	-0,294529	-0,271849	-0,592360	-0,479650	w ₁₃	1,000000	0,863457	0,333398	0,070581
w ₃	0,607272	-0,110999	0,113138	0,385642	w ₁₄	1,000000	0,288518	0,107965	0,212332
w ₄	0,700086	0,490030	0,332512	0,635090	w ₁₅	-0,561329	-0,077265	-0,052928	0,347462
w ₅	-0,368352	-0,706886	0,153733	-0,273807	w ₁₆	-0,666440	-0,366328	-0,319028	-0,221078
w ₆	0,015452	0,830104	0,108638	0,080081	w ₁₇	-1,000000	-0,665729	-1,000000	-0,747989
w ₇	0,661918	0,492122	0,238278	0,224181	w ₁₈	0,561329	0,690787	0,068747	-0,089911
w ₈	-0,496875	-0,367765	-0,407441	-0,706516	w ₁₉	0,295631	0,786444	-0,020799	-0,036177
w ₉	-0,338478	-0,659859	-0,315118	-0,438674	w ₂₀	0,113899	-0,145455	-0,034339	0,414475
w ₁₀	-0,631135	-0,594744	-0,110637	0,419170	w ₂₁	-0,063294	0,188212	-0,258809	0,085278
w ₁₁	-0,207051	-0,509941	-0,61716	-0,285791					

$$MAE = \frac{1}{n} \sum_{i=1}^n AE \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n AE^2}{\sum_{i=1}^n (E_{obs} - E_{obs})^2} \quad (11)$$

$$MAPE = \frac{1}{n-1} \sum_{i=2}^n \left| \frac{E_{obs} - E_{pre}}{E_{obs}} \right| \quad (12)$$

$$RMS = \left(\frac{\sum_{i=1}^n AE^2}{n} \right)^{0.5} \quad (13)$$

$$MARNE = \frac{1}{n} \sum_{i=1}^n \frac{AE}{\max(E_{obs})} \quad (14)$$

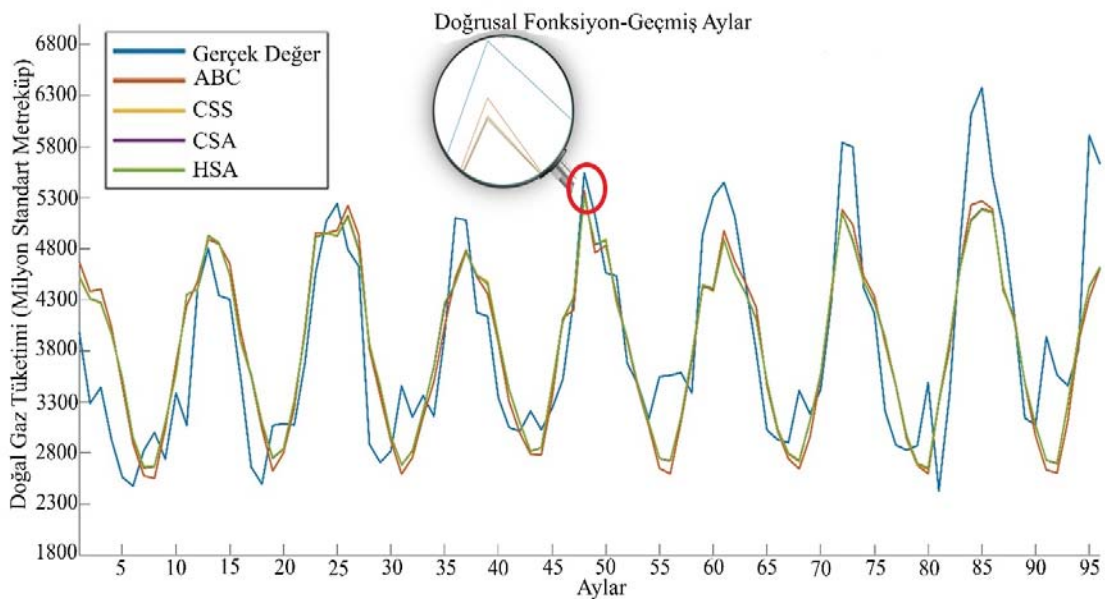
Eğitim ve test veri kümeleri için ABC, CSS, CSA ve HSA algoritmalarından elde edilen hata ölçütleri (AE, MAE, R², MAPE, RMS, MARNE) üç matematiksel model (doğrusal, üstel, ikinci dereceden) için Tablo 11'de verilmiştir. Eğitim ve test veri kümelerinde doğrusal, üstel, ikinci dereceden matematiksel modellere göre grup içi en başarılı sonucu elde edilen algoritma yani minimum hata değerlerine sahip algoritma koyu siyah olarak gösterilmiştir. Örneğin test veri kümesinde AE hata metriği için doğrusal matematiksel model kullanıldığında, 4 farklı algoritma içinden en iyi sonucu ABC algoritması vermiştir ve koyu siyah renk ile gösterilmiştir. Doğrusal ve Üstel modellerde üretilen değerlerin koyu siyah renk ile sunulmasının nedeni, bu modellerde üretilen sonuç değerleri kendi gruplarında en iyi değerleri temsil etmesidir. İkinci dereceden modelin ürettiği sonuçlar doğrusal ve üstel modele göre gerek eğitim gerekse test verilerinde daha başarılı olduğu için kırmızı (eğitim veri kümesi en iyi sonuç) ve mavi (test veri kümesi en iyi sonuç) renkte gösterilmektedir. Doğrusal matematiksel modelde eğitim veri kümesi için tüm hata ölçütlerinde en iyi sonucu veren algoritma CSA-L (CSA algoritmasının ikinci dereceden matematiksel modeli) algoritmasıdır. Test veri kümesi için ise en iyi sonucu veren (en az hata değerine sahip) algoritma tüm hata ölçütleri için ABC-L (ABC algoritmasının doğrusal matematiksel modeli) algoritmasıdır. Üstel (exponential) matematiksel modelde eğitim veri kümesi için en iyi sonucu veren algoritma incelenen tüm hata ölçütlerine göre HSA-E (HSA algoritmasının üstel matematiksel modeli) algoritmasıdır. Test veri kümesi için ise en iyi sonucu veren algoritma tüm hata ölçütleri için CSA-E (CSA algoritmasının üstel matematiksel modeli) algoritmasıdır. İkinci dereceden (quadratic) matematiksel modelde eğitim veri kümesi için en az hata değeri üreten algoritma incelenen tüm hata ölçütlerine göre CSS-Q (CSS algoritmasının ikinci dereceden matematiksel modeli) algoritmasıdır. Test veri kümesinde ise en iyi sonucu veren algoritma tüm hata ölçütlerine göre CSA-Q (CSA algoritmasının ikinci dereceden matematiksel modeli) algoritmasıdır. Genel anlamda üç matematiksel model (doğrusal, üstel, ikinci dereceden) içerisinde en iyi sonuçları veren model CSS-Q ve CSA-Q olduğu görülmüştür.

Doğrusal modeller için eğitim veri kümesine göre ABC-L en başarısız sonucu üretmiştir. Test veri kümesine göre ise hata ölçütlerine göre en başarısız sonucu veren algoritma CSS-L (CSS algoritmasının doğrusal matematiksel modeli)'dir. Üstel modeller için eğitim veri kümesinde en başarısız sonucu üreten model CSS-E (CSS algoritmasının üstel matematiksel modeli) iken test veri kümesine göre AE, MAE ve MARNE hata ölçütlerine bakıldığında ABC-E (ABC algoritmasının üstel matematiksel modeli), R^2 , MAPE ve RMS hata ölçütleri incelendiğinde ise CSS-E en başarısız sonucu üretmektedir. İkinci dereceden modeller için eğitim veri kümesinde ve test veri kümesinde ABC-Q (ABC algoritmasının ikinci dereceden matematiksel modeli) en başarısız sonucu üretmiştir.

Eğitim veri kümesi için dört farklı optimizasyon algoritmasından doğrusal modele göre elde edilen sonuçlar Şekil 1'de görselleştirilmiştir. Şekil 1'de eğitim veri kümesi (ilk 96 ay) verileri geçmiş ay olarak adlandırılmış, test veri kümesi (son 36 ay) verileri ise gelecek aylar olarak adlandırılmıştır. Türkiye'nin aylık gerçek doğal gaz tüketim değeri mavi renkle grafik üzerinde gösterilmiştir. Grafikte kırmızı renk ABC-L modelini, Sarı renk CSS-L modelini, Mor renk CSA-L modelini ve Yeşil renk ise HSA-L modelini temsil etmektedir. Dört algoritma için doğrusal matematiksel modelin sonuçlarından ABC algoritması belirgin iken diğer algoritmaların birbirine çok yakın olduğu Şekil 1'de görülmektedir. Şekil 1 ve Şekil 2, algoritma sonuçları birbirine çok yakın olduğu için algoritmalar

Tablo 11. Modellerin hata değerleri (Error values of models)

Hata ölçütleri	Algoritma	Doğrusal		Üstel		İkinci Dereceden	
		Eğitim	Test	Eğitim	Test	Eğitim	Test
AE	ABC	8,950083	4,911940	6,324500	6,074182	6,256513	5,041788
	CSS	8,853118	5,101672	6,500581	6,041177	5,688817	4,916201
	CSA	8,850709	5,090764	6,323502	5,455607	6,076513	4,240483
	HSA	8,856237	5,092325	6,216202	5,863182	5,929116	4,493282
MAE	ABC	0,093230	0,136443	0,065880	0,168727	0,065172	0,140050
	CSS	0,092200	0,141713	0,067714	0,167810	0,059259	0,136561
	CSA	0,092195	0,141410	0,065870	0,151545	0,063297	0,117791
	HSA	0,092252	0,141453	0,064752	0,162866	0,061762	0,124813
R^2	ABC	0,657876	0,600050	0,816377	0,232360	0,820203	0,650202
	CSS	0,664682	0,581409	0,815089	0,216473	0,857941	0,653946
	CSA	0,664751	0,582335	0,821763	0,506201	0,848705	0,737633
	HSA	0,664708	0,583115	0,827009	0,306746	0,851444	0,718962
MAPE	ABC	12,396507	17,631412	8,445379	21,723182	8,371919	18,459882
	CSS	12,189080	18,023081	8,778613	21,732824	7,582606	17,710914
	CSA	12,185862	17,981872	8,552008	19,492062	8,280654	15,240119
	HSA	12,195266	18,001378	8,391852	21,035600	8,013314	16,196766
RMS	ABC	57,654548	145,713634	42,238181	201,872107	41,795870	136,271924
	CSS	57,078175	149,070759	42,386127	203,950389	37,151521	135,540663
	CSA	57,072308	148,905845	41,614095	161,909626	38,340131	118,019024
	HSA	57,075994	148,766664	40,997115	191,841969	37,991513	122,146274
MARNE	ABC	7,104494	9,774944	5,020330	12,087850	4,966363	10,033347
	CSS	7,027524	10,152518	5,160102	12,022169	4,515731	9,783425
	CSA	7,025612	10,130811	5,019538	10,856862	4,823480	8,438720
	HSA	7,030000	10,133918	4,934364	11,667951	4,706478	8,941799




Şekil 1. Eğitim verisinin doğrusal modele göre sonuçları (Results of the training data according to the linear model)

arasındaki farkı daha net hale getirmek için grafiği büyütülerek gösterilmiştir. Test veri kümesi için dört farklı optimizasyon algoritmasından doğrusal modele göre elde edilen sonuçlar Şekil 2’de verilmiştir. Şekil 2 incelendiğinde algoritmaların ürettiği doğal gaz talep tahmin sonuçları genel olarak gerçek tüketim değerleri ile benzer hareketler göstermiştir. Ancak, 4800 MScM’nin üzerindeki doğal gaz tüketim tahminlerinde, algoritmalar gerçek tüketim değerlerinin altında değerler üretmiştir. Doğrusal test modelinde en doğru sonuç veren algoritma ABC algoritmasıdır.

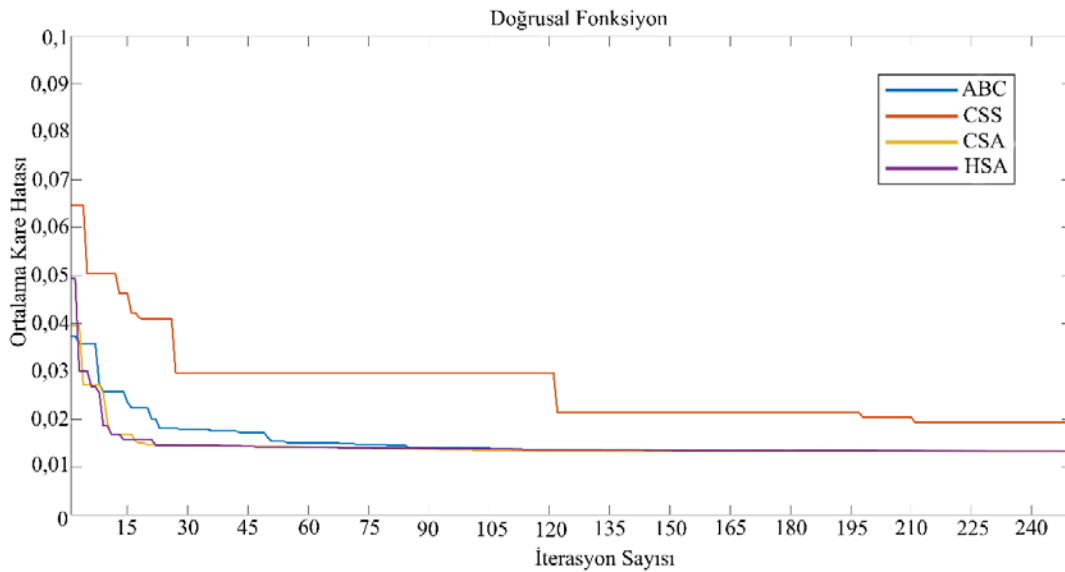
Doğrusal matematiksel model için maliyet fonksiyonu (cost function) grafiği Şekil 3’de sunulmuştur. CSS-L algoritması başlanıçta diğer algoritmalara göre daha geç yakınsamıştır. ABC algoritmasının 80. iterasyonda MSE (Ortalama Kare Hatası) oranı, CSA algoritmasının 20. iterasyonda MSE oranı sabitlenmiştir. ABC ve CSS algoritmaları ise 80. iterasyonda MSE oranlarının en optimum sonuca ulaştığı ve sonrasında sabit kaldığı görülmektedir. Algoritmaların öğrenme iterasyonları birbirinden oldukça farklıdır.

Eğitim veri kümesi için dört farklı optimizasyon algoritmasından üstel modele göre elde edilen sonuçlar Şekil 4’de verilmiştir. Dört algoritma için üstel matematiksel modelin sonuçlarının, doğrusal modele göre daha belirgin şekilde ayrıştığını söyleyebiliriz fakat değerler yine birbirine oldukça yakındır.


Test veri kümesi için dört farklı optimizasyon algoritmasından üstel modele göre elde edilen sonuçlar Şekil 5’te verilmiştir. Dört algoritma için üstel matematiksel modelin sonuçlarının, doğrusal modele göre belirgin şekilde ayrıştığını fakat sonuçların birbirine yakın olduğunu söyleyebiliriz. Ancak, 2800 MScM’nin altındaki doğal gaz tüketim tahminlerinde, algoritmalar gerçek tüketim değerlerinden daha düşük tahminler üretmiştir. Ayrıca 12. ve 14. aylar arasında ise 5000 MScM’nin üstünde kalan tüketim değeri tahminini algoritmalar daha düşük tahmin etmiştir. Üstel matematiksel model için maliyet fonksiyonu (cost function) grafiği Şekil 6’da sunulmuştur. CSS-L algoritması başlanıçta diğer algoritmalara göre daha geç yakınsamıştır.



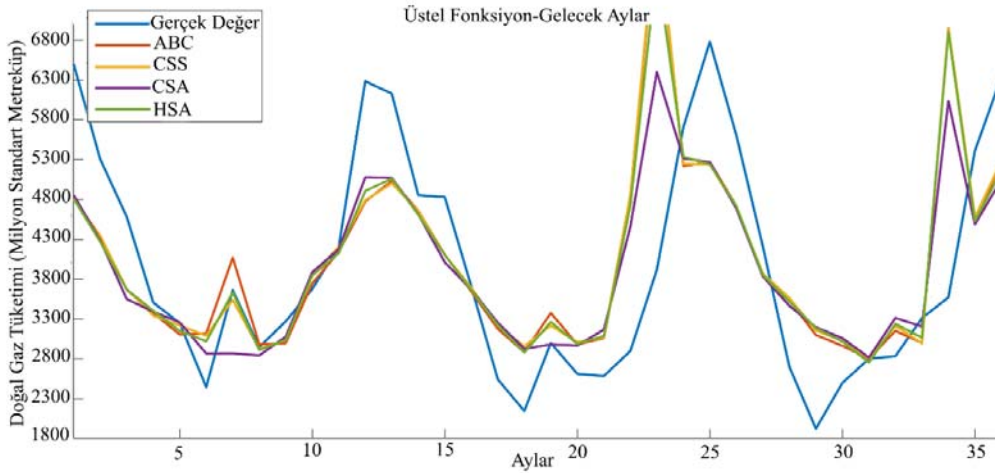
Şekil 2. Test verisinin doğrusal modele göre sonuçları (Results of test data by linear model)




Şekil 3. Doğrusal matematiksel modelin maliyet fonksiyonu grafiği (Cost function graph of linear mathematical model)




Şekil 4. Eğitim verisinin üstel modele göre sonuçları (Results of training data by exponential model)



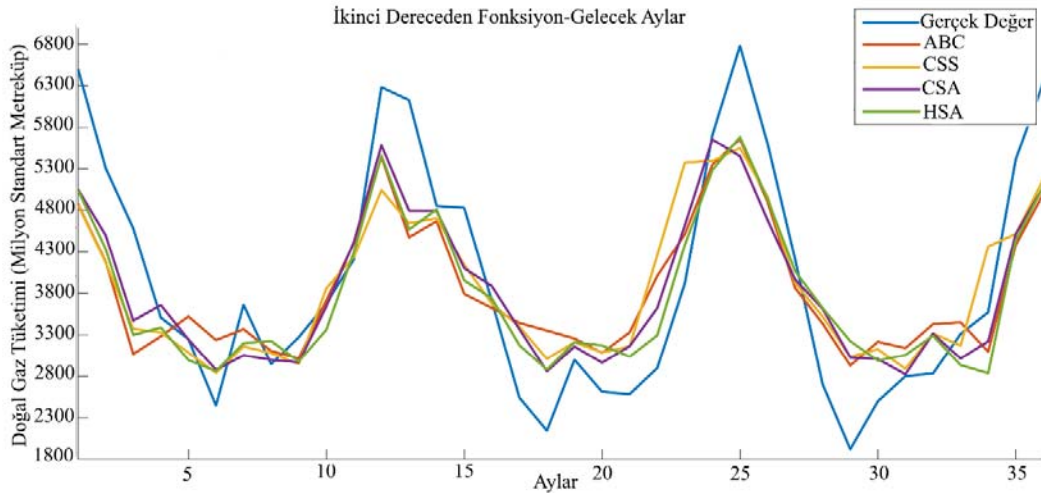
Şekil 5. Test verisinin üstel modele göre sonuçları (Results of test data by exponential model)



Şekil 6. Üstel matematiksel modelin maliyet fonksiyonu grafiği (Cost function graph of exponential mathematical model)



Şekil 7. Eğitim verisinin ikinci dereceden modele göre sonuçları (Results of training data by quadratic model)



Şekil 8. Test verisinin ikinci dereceden modele göre sonuçları (Results of test data by quadratic model)

HSA algoritmasınının 45. İterasyonda MSE oranı sabitlenmiştir, CSA algoritmasınının 80. iterasyonda, ABC algoritmasınının 980. İterasyona kadar değiştiği sonucuna ulaşılmıştır. Algoritmaların öğrenme iterasyonları birbirinden oldukça farklıdır.

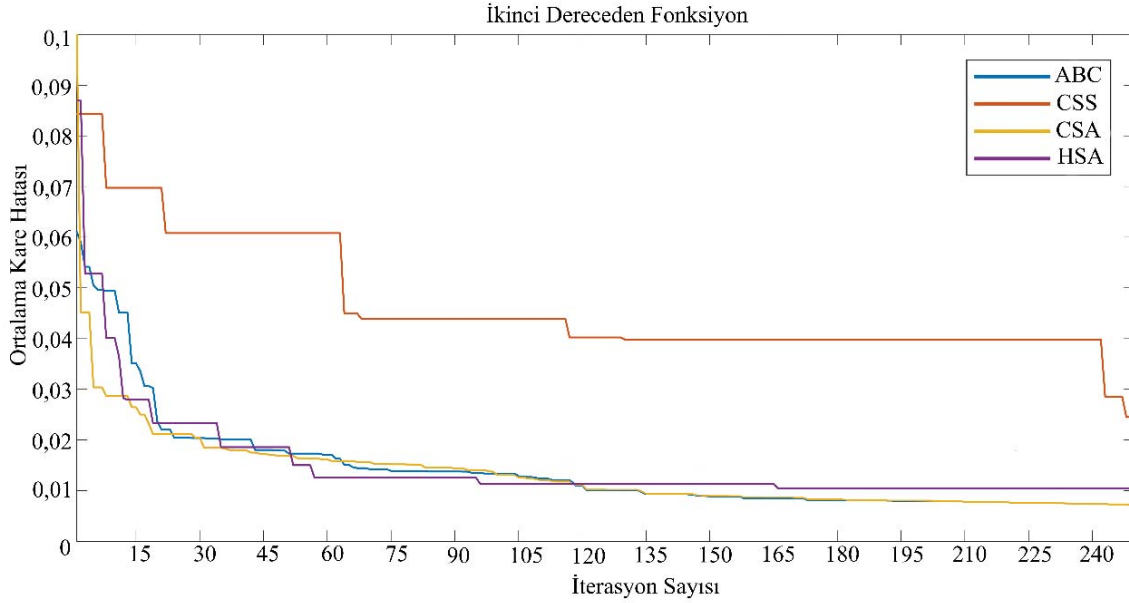
Eğitim veri kümesi için dört farklı optimizasyon algoritmasından ikinci dereceden matematiksel modele göre elde edilen sonuçlar Şekil 7'de verilmiştir. Dört algoritma için genel olarak ikinci dereceden matematiksel modelin sonuçlarının, doğrusal ve üstel modele göre daha doğru ve gerçek değere daha yakın sonuçlar ürettiği gözlemlendi.

Test veri kümesi için dört farklı optimizasyon algoritmasından ikinci dereceden modele göre elde edilen sonuçlar Şekil 8'de verilmiştir. Dört algoritma için genel olarak ikinci dereceden matematiksel modelin sonuçlarının, doğrusal ve üstel modele göre daha doğru ve gerçek değere daha yakın sonuçlar ürettiğini gözlemledik. Ancak, 5400 MScM'nin üstündeki doğal gaz talep değerlerinde ve 2800 MScM'nin altındaki doğal gaz talep tahminlerinde, algoritmalar gerçek tüketim değerlerinden sapan değerler üretmiştir.

İkinci dereceden matematiksel model için maliyet fonksiyonu (cost function) grafiği Şekil 9'da sunulmuştur. CSA-Q algoritması başlanıçta diğer algoritmalara göre daha geç yakınsamış fakat hızlı bir öğrenme ile 120.iterasyondan sonra MSE oranının diğer algoritmalarından daha düşük olduğu görülmektedir. CSS-Q algoritması diğer algoritmalara göre daha geç yakınsamıştır. Algoritmaların öğrenme iterasyonları birbirinden oldukça farklıdır.

4. Sonuçlar (Conclusions)

Eğitim verileri için CSS-Q modeli, dört farklı algoritma ve üç modelin tümünde (doğrusal, üstel, ikinci dereceden) gerçek doğal gaz tüketim verilerini tahmin eden en başarılı modeldir. Test verileri içinde CSA-Q modeli, her üç modelde de en başarılı tahminde bulunan modeldir. Doğrusal modeller için eğitim verilerinde en başarılı sonuç CSA-L modeli iken, test verileri için ABC-L modelidir. Üstel modeller için eğitim verilerinde en başarılı sonuç HSA-E modeller iken, test verileri için CSA-E modelidir. Eğitim verileri için ABC-L modeli, dört farklı algoritma ve üç modelin tümünde (doğrusal, üstel, ikinci dereceden) gerçek doğal gaz tüketim verilerini tahmin eden en başarısız modeldir.



Şekil 9. İkinci dereceden matamatiksel modelin cost function grafiği (The cost function graph of the quadratic mathematical model)

Test verileri içinde CSS-L modeli, her üç modelde de en başarısız tahminde bulunan modeldir. Üstel modeller için eğitim verilerinde en başarısız sonuç CSS-E modeli iken, test verileri için CSA-E ve ABC-E modelleridir. İkinci dereceden modeller için eğitim ve test verilerinde en başarısız sonuç ABC-Q modelidir. Kaveh vd. [57] CSS ve PSO algoritmaları ile kıyaslanmış ve CSS algoritmasının performansının PSO algoritmasına göre daha başarılı olduğunu göstermişlerdir. Bizim çalışmamızda da ise CSS algoritması diğer algoritmalarla göre çok başarılı sonuçlar verememiştir. Karaboğa vd. [58] sinyal işleme sistemleri için YSA, ABC, DE, ve PSO algoritmalarını karşılaştırmış ve en iyi sonucun ABC algoritması tarafından bulunduğunu ispatlamışlardır. Benzer şekilde çalışmamızda doğrusal matamatiksel modelde ABC algoritması test verilerinde en iyi sonucu bulan algoritma olmuştur.

Sonuç olarak, Türkiye'nin doğal gaz tüketim tahmini için dört farklı metasezgisel algoritma üç farklı modelle başarıyla uygulanmıştır. Bu çalışmada sunulan modellerin sonuçları, politika yapımcılar tarafından Türkiye'de gelecekteki doğal gaz enerji planları için bir rehber olarak kullanılabilir. Çalışmamızda kullandığımız meteorolojik değişkenlerin ileriye dönük tahminlerinin doğruluğu oldukça önemlidir. Eğer sıcaklık, basınç, nemi rüzgar ve yağış tahminlerinin hata oranları yüksek olursa doğal gaz tüketiminin tahmin hatasıda yüksek olacaktır. Önerilen model ile farklı ülkelerden veri setleri uygulanarak çalışma genişletilebilir. Sonraki yapılacak çalışmalarda Bakteriyel Toplayıcılık Optimizasyon Algoritması (BFO: Bacterial Foraging), Biyocoğrafya Tabanlı Optimizasyon (BBO: Biogeography-based optimization), Guguk Kuşu Arama Algoritması (CS: Cuckoo Search), Sosyal Örümcek Optimizasyonu (SSO: Social Spider Optimization), Balina Optimizasyon Algoritması (WOA: Whale Optimization Algorithm) gibi diğer metasezgisel yöntemlerin daha ileri çalışmalarda değerlendirilmesi önerilmektedir.

Sonraki çalışmalar için önerdiğimiz bu algoritmalar çalışmamızda ele aldığımız problemin çözümünde henüz kullanılmamıştır ve bu problemlerin çözümündeki başarıları hakkında literatürde herhangi bir bilgiye rastlanmamıştır. Bunun yanında algoritmaların bazıları 'State of Algorithm' olarak geçen güncel metasezgisel algoritmalar ve bu

problem üzerinde yerel optimumda takılı kalma durumları ve performanslarının analiz edilmesi önem arz etmektedir. Belirtilen algoritmalar kullanılarak elde edilecek sonuçların çalışmamızda sunduğumuz sonuçlarımızla karşılaştırılma yapılması önerilmektedir.

Kaynaklar (References)

1. Abas N., Kalair A., Khan N., Review of fossil fuels and future energy technologies, *Futures*, 69, 31–49, 2015.
2. Pavlovic D., Banovac E., Vistica N., Defining a composite index for measuring natural gas supply security-The Croatian gas market case, *Energy Policy*, 114, 30–38, 2018.
3. Organisation for economic co-operation and development. World Energy Statistics 2019. <https://data.oecd.org/energy.htm>. Yayın tarihi Eylül 18, 2019. Erişim tarihi Ocak 11, 2022.
4. Dünya Enerji Konseyi, Türkiye enerji piyasaları araştırma raporu 2018. <https://www.dunyaenerji.org.tr/wp-content/uploads/2018/07/TEPG1.pdf>. Yayın tarihi Temmuz 2018. Erişim tarihi Ocak 9, 2022.
5. Montuori L., Alcazar-Ortega M., Demand response strategies for the balancing of natural gas systems: Application to a local network located in The Marches (Italy), *Energy*, 225, 120293, 2021.
6. Doğan G. E., karadeniz bölgesinde boru hatları jeopolitiği, *Karadeniz Araştırmaları*, 57, 17–31, 2018.
7. Dubsy Z., Tichy L., Pavlinak D., A quantifiable approach to the selection of criteria and indexation for comparison of the gas pipeline projects leading to the EU: diversification rationality against securitisation?, *Energy*, 120238, 2021.
8. Kaynak B., From Blue Stream To Turkish Stream An Assesment Of Turkey's Energy Dependence On Russia, *Aurum J. Soc. Sci.*, 3 (1), 79–90, 2018.
9. Türkiye İstatistik Kurumu, Enerji kaynaklarına göre elektrik enerjisi üretimi ve payları, <https://data.tuik.gov.tr/>. Yayın tarihi Mart 31, 2022. Erişim tarihi Nisan 11, 2021.
10. Enerji Piyasası Düzenleme Kurumu, Elektrik piyasası 2018 yılı piyasa gelişim raporu, <https://www.epdk.gov.tr/Detay/Icerik/3-0-107/yillik-sektor-raporu>. Yayın tarihi Mart 01, 2019. Erişim tarihi Ocak 16, 2022.
11. World Bank. The World Bank Annual Report 2020 : Supporting countries in unprecedented times. World Bank, Washington, DC. © World Bank. <https://openknowledge.worldbank.org/handle/10986/34406> License: CC BY-NC-ND 3.0 IGO. 2020.

12. Enerji Piyasası Düzenleme Kurumu, Doğal gaz piyasası 2020 yılı sektör raporu, <https://www.epdk.gov.tr/Detay/Icerik/3-0-107/yillik-sektor-raporu>. Yayın tarihi Nisan 01, 2021. Erişim tarihi Aralık 08, 2021.
13. Türkiye Doğalgaz Dağıtıcıları Birliği, 2017 yılı doğal gaz dağıtım sektörü raporu (Gazbir), <https://www.gazbir.org.tr/>. Erişim tarihi Temmuz 08, 2021.
14. Erdoğan E., Natural gas demand in Turkey, *Appl. Energy*, 87 (1), 211–219, 2010.
15. Asche F., Nilsen O. B., Tveteras R., Natural gas demand in the European household sector, *Energy J.*, 29 (3), 2008.
16. Shaikh F., Ji Q., Forecasting natural gas demand in China: Logistic modelling analysis, *Int. J. Electr. Power Energy Syst.*, 77, 25–32, 2016.
17. Karadede Y., Özdemir G., Aydemir E., Breeder hybrid algorithm approach for natural gas demand forecasting model, *Energy*, 141, 1269–1284, 2017.
18. Panapakidis I. P., Dagoumas A. S., Day-ahead natural gas demand forecasting based on the combination of wavelet transform and ANFIS/genetic algorithm/neural network model, *Energy*, 118, 231–245, 2017.
19. Wu Y. H., Shen H., Grey-related least squares support vector machine optimization model and its application in predicting natural gas consumption demand, *J. Comput. Appl. Math.*, 338, 212–220, 2018.
20. Su H., Zio E., Zhang J., Xu M., Li X., Zhang Z., A hybrid hourly natural gas demand forecasting method based on the integration of wavelet transform and enhanced Deep-RNN model, *Energy*, 178, 585–597, 2019.
21. Bianco V., Scarpa F., Tagliafico L. A., Scenario analysis of nonresidential natural gas consumption in Italy, *Appl. Energy*, 113, 392–403, 2014.
22. Oliver R., Duffy A., Enright B., O'Connor R., Forecasting peak-day consumption for year-ahead management of natural gas networks, *Util. Policy*, 44, 1–11, 2017.
23. Taşpınar F., Celebi N., Tutkun N., Forecasting of daily natural gas consumption on regional basis in Turkey using various computational methods, *Energy Build.*, 56, 23–31, 2013.
24. Szoplik J., Forecasting of natural gas consumption with artificial neural networks, *Energy*, 85, 208–220, 2015.
25. Beyca O. F., Ervural B. C., Tatoglu E., Ozuyurk P. G., Zaim S., Using machine learning tools for forecasting natural gas consumption in the province of Istanbul, *Energy Econ.*, 80, 937–949, 2019.
26. Potočník P., Šilc J., Papa G., A comparison of models for forecasting the residential natural gas demand of an urban area, *Energy*, 167, 511–522, 2019.
27. Karabiber O. A., Xydis G., Forecasting day-ahead natural gas demand in Denmark, *J. Nat. Gas Sci. Eng.*, 76, 103193, 2020.
28. Zhu L., Li M. S., Wu Q. H., Jiang L., Short-term natural gas demand prediction based on support vector regression with false neighbours filtered, *Energy*, 80, 428–436, 2015.
29. Rui C., Jian W., Li W., Ningjie Y., Pengyan Z., The forecasting of China natural gas consumption based on genetic algorithm, in 2009 Fifth International Joint Conference on INC, IMS and IDC, 1436–1439, 2009.
30. Ma H., Wu Y., Grey predictive on natural gas consumption and production in China, in 2009 Second Pacific-Asia Conference on Web Mining and Web-based Application, 91–94, 2009.
31. Wan X., Zhang Q., Dai G., Research on forecasting method of natural gas demand based on GM (1, 1) model and Markov chain, in 2014 IEEE 13th International Conference on Cognitive Informatics and Cognitive Computing, 436–441, 2014.
32. Rahman M. D. Z., Sajib M. D. N., Rifat M. M. S. H., Hossam-E-Haider M., Khan M. A. A., Forecasting the long term energy demand of Bangladesh using SPSS from 2011–2040, in 2016 3rd International Conference on Electrical Engineering and Information Communication Technology (ICEEICT), 1–5, 2016.
33. Brown R. H., Vitullo S. R., Corliss G. F., Adya M., Kaefer P. E., Povinelli R. J., Detrending daily natural gas consumption series to improve short-term forecasts, 2015 IEEE Power & Energy Society General Meeting, Denver, USA, 1–5, 2015.
34. Khani H., Farag H. E. Z., An online-calibrated time series based model for day-ahead natural gas demand forecasting, *IEEE Trans. Ind. Informatics*, 15 (4), 2112–2123, 2018.
35. Qiao W., Yang Z., Kang Z., Pan Z., Short-term natural gas consumption prediction based on Volterra adaptive filter and improved whale optimization algorithm, *Eng. Appl. Artif. Intell.*, 87, 103323, 2020.
36. Liu C., Wu W.Z., Xie W., Zhang T., Zhang J., Forecasting natural gas consumption of China by using a novel fractional grey model with time power term, *Energy Reports*, 7, 788–797, 2021.
37. Akpınar M., Yumuşak N., Daily basis mid-term demand forecast of city natural gas using univariate statistical techniques, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (2), 725–742, 2020.
38. Zheng C., Wu W.Z., Xie W., Li Q., A MFO-based conformable fractional nonhomogeneous grey Bernoulli model for natural gas production and consumption forecasting, *Appl. Soft Comput.*, 99, 106891, 2021.
39. Andelkovic A. S., Bajatovic D., Integration of weather forecast and artificial intelligence for a short-term city-scale natural gas consumption prediction, *J. Clean. Prod.*, 266, 122096, 2020.
40. Azadeh A., Asadzadeh S. M., Ghanbari A., An adaptive network-based fuzzy inference system for short-term natural gas demand estimation: Uncertain and complex environments, *Energy Policy*, 38 (3), 1529–1536, 2010.
41. Rodger J. A., A fuzzy nearest neighbor neural network statistical model for predicting demand for natural gas and energy cost savings in public buildings, *Expert Syst. Appl.*, 41 (4), 1813–1829, 2014.
42. Viet N. H., Mandziuk J., Neural and fuzzy neural networks for natural gas consumption prediction, in 2003 IEEE XIII Workshop on Neural Networks for Signal Processing (IEEE Cat. No. 03TH8718), 759–768, 2003.
43. Forouzanfar M., Doustmohammadi A., Menhaj M. B., Hasanazadeh S. Modeling and estimation of the natural gas consumption for residential and commercial sectors in Iran, *Applied Energy*, 87 (1), 268–274, 2010.
44. Karimi H., Dastranj J., Artificial neural network-based genetic algorithm to predict natural gas consumption, *Energy Syst.*, 5 (3), 571–581, 2014.
45. Yu F., Xu X., A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network, *Appl. Energy*, 134, 102–113, 2014.
46. Ma X., Mei X., Wu W., Wu X., Zeng B., A novel fractional time delayed grey model with Grey Wolf Optimizer and its applications in forecasting the natural gas and coal consumption in Chongqing China, *Energy*, 178, 487–507, 2019.
47. Sun L., Koopialipour M., Jahed Armaghani D., Tarinejad R., Tahir M. M., Applying a meta-heuristic algorithm to predict and optimize compressive strength of concrete samples, *Eng. Comput.*, 37 (2), 1133–1145, 2021.
48. Karaboga D., An idea based on honey bee swarm for numerical optimization, Technical report-tr06, https://abc.erciyes.edu.tr/pub/tr06_2005.pdf. Erciyes university, engineering faculty, Yayın tarihi Ekim, 2005. Erişim tarihi Şubat 28, 2021.
49. Özdemir D., Dörterler S. An adaptive search equation-based artificial bee colony algorithm for transportation energy demand forecasting, *Turkish Journal of Electrical Engineering and Computer Sciences*, 30 (4), 1251-1268, 2022.
50. Kaveh A., Talatahari S., A novel heuristic optimization method: charged system search, *Acta Mech.*, 213 (3), 267–289, 2010.
51. Sharbatdar M. K., Talatahari S., Mousavi M. R., Developing new charged system search-based algorithm: application in the time-cost trade-off problems, *Turkish Online J. Des. ART Commun.*, 6, 1773–1788, 2016.
52. Askarzadeh A., A novel metaheuristic method for solving constrained engineering optimization problems: crow search algorithm, *Comput. Struct.*, 169, 1–12, 2016.
53. Andiç C., Öztürk A., Tosun S., Türkiye'deki güç sisteminde karga arama algoritması kullanılarak ekonomik yük dağıtımı, *Düzce Üniversitesi Bilim ve Teknoloji Derg.*, 8 (1), 428–436, 2020.
54. Lee K. S., Geem Z. W., A new structural optimization method based on the harmony search algorithm, *Comput. Struct.*, 82 (9), 781–798, 2004.
55. Manjarres, D., Landa-Torres, I., Gil-Lopez, S., Del Ser, J., Bilbao, M. N., Salcedo-Sanz, S., & Geem, Z. W. A survey on applications of the harmony search algorithm. *Engineering Applications of Artificial Intelligence*, 26 (8), 1818-1831, 2013.
56. Nguyen N. T., Tran T. T., Optimizing mathematical parameters of Grey system theory: an empirical forecasting case of Vietnamese tourism, *Neural Comput. Appl.*, 31 (2), 1075–1089, 2019.

57. Kaveh A., Talatahari S., A hybrid CSS and PSO algorithm for optimal design of structures, *Struct. Eng. Mech.*, 42, (6), 783–797, 2012.
58. Karaboga D., Akay B., Artificial bee colony (ABC) algorithm on training artificial neural networks, in 2007 IEEE 15th Signal Processing and Communications Applications, 1–4, 2007.
59. Yi J., Gao L., Li X., Gao J., An efficient modified harmony search algorithm with intersect mutation operator and cellular local search for continuous function optimization problems, *Appl. Intell.*, 44 (3), 725–753, 2016.

