



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 03.01.2024
Kabul Tarihi : 14.02.2024

Received Date : 03.01.2024
Accepted Date : 14.02.2024

DENİZ YIRTICILARI ALGORİTMASI İLE TÜRKİYE’NİN ENERJİ TALEBİNİN TAHMİN EDİLMESİNE YÖNELİK KAPSAMLI BİR ÇALIŞMA

A COMPREHENSIVE STUDY ON FORECASTING TURKEY'S ENERGY DEMAND WITH THE MARINE PREDATORS ALGORITHM

Ahmet ÖZKİŞ¹ (ORCID: 0000-0002-1899-5494)

¹ Necmettin Erbakan Üniversitesi, Bilgisayar Mühendisliği Bölümü, Konya, Türkiye

*Sorumlu Yazar / Corresponding Author: Ahmet ÖZKİŞ, aozkis@erbakan.edu.tr

ÖZET

Enerjiye olan talep her geçen gün artmakta ve bu talebin önceden tahmin edilebilmesi büyük önem arz etmektedir. Bu çalışma, yakın zamanda önerilen deniz avcıları algoritması (MPA) ile Türkiye'nin 1979 – 2015 yılları arasındaki enerji talebini tahmin etmek amacıyla yapılmıştır. Çalışmada kullanılan doğrusal ve ikinci dereceden regresyon modellerinin ağırlıklarının belirlenmesinde MPA'dan yararlanılmıştır. Yapılan incelemelere göre MPA literatürde ilk kez bu amaçla kullanılmaktadır. MPA'nın toplam karesel hata ve toplam bağıl yüzde hatası metrikleri için elde ettiği sonuçlar, literatürde iyi bilinen diferansiyel evrim, Arşimet optimizasyon, güve alev optimizasyonu ve gri kurt algoritmaları ile kıyaslanmıştır. Literatürdeki diğer çalışmalardan farklı olarak performans karşılaştırmaları sadece en iyi değer üzerinden değil; en iyi, en kötü, ortalama ve standart sapma değerlerine göre yapılmıştır. Elde edilen sonuçlar MPA'nın enerji talep tahmin probleminde karşılaştırılan algoritmalarından daha başarılı ve kararlı bir yapıya sahip olduğunu göstermiştir.

Anahtar Kelimeler: Deniz avcıları algoritması, enerji talep tahmini, regresyon analizi, metasezgisel algoritmalar.

ABSTRACT

The energy demand is increasing day by day, and it is of great importance to predict this demand. This study was conducted to estimate Turkey's energy demand between 1979 - 2015 with the recently proposed marine predators algorithm (MPA). To determine the weights of the linear and quadratic regression models used in the study is utilized from the MPA. According to the studies, MPA is used for this purpose for the first time in the literature. The results obtained by the MPA for sum-squared-error and total-relative-percentage-error metrics were compared with algorithms well-known in the literature differential evolution, Archimedes optimization, moth flame optimization, and grey wolf optimizer. Unlike other studies in the literature, performance comparisons are not only based on the best value; it was made according to the best, worst, average, and standard deviation values. The results showed that MPA has a more successful and stable structure than the compared algorithms in the energy demand forecasting problem.

Keywords: Marine predator algorithm, energy demand estimation, regression analysis, metaheuristic algorithms

GİRİŞ

Enerji, ülkelerin ekonomik açıdan kalkınmaları için en önemli konu başlıklarından biridir. Enerji tüketim göstergeleri bir ülkenin refah ve gelişmişlik düzeyine işaret eden önemli metriklerdendir (Anwar, 2016). Yirminci yüzyıldan önce kömür gibi katı yakıtlar enerji üretimi için yoğun bir şekilde kullanılmaktaydı. Sanayileşmeyle birlikte enerjiye olan talep arttı ve petrol bazlı yakıtların kullanımı yaygınlaştı. Günümüzde, her ne kadar alternatif enerji kaynakları

ToCite: ÖZKİŞ, A., (2024). DENİZ YIRTICILARI ALGORİTMASI İLE TÜRKİYE’NİN ENERJİ
TALEBİNİN TAHMİN EDİLMESİNE YÖNELİK KAPSAMLI BİR ÇALIŞMA. *Kahramanmaraş Sütçü
İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 27(2), 615-630.

kullanılmaya başlansa da hala enerji üretiminin büyük bölümü fosil yakıtlardan sağlanmaktadır. Tablo 1'deki 2022 yılına ait enerji üretim kaynakları incelendiğinde dünyadaki toplam enerjinin %60'ından fazlasının kömür, doğal gaz ve likit yakıtlardan üretildiği görülmektedir (International Energy Outlook - U.S. Energy Information Administration (EIA), 2023).

Tablo 1. Dünya'da 2022 Yılındaki Enerji Üretim Kaynakları

Kaynak	MKWS türünden üretilen enerji miktarı	Toplam elektrik üretimi içindeki oranı
Fosil		
Sıvı yakıt	733	2,60%
Doğal gaz	6,699	23,72%
Kömür	9,696	34,34%
<i>Toplam fosil</i>	<i>17,128</i>	<i>60,66%</i>
Nükleer	2,666	9,44%
Yenilenebilir		
Hidro	4,320	15,30%
Rüzgâr	1,967	6,96%
Jeotermal	67	0,24%
Güneş	1,421	5,03%
Diğer	669	2,37%
<i>Toplam yenilenebilir</i>	<i>8,444</i>	<i>29,90%</i>

MKWS: milyar kilowatt saat

Fosil yakıtların aşırı kullanımı atmosfere karbonik gaz salınımına neden olmakta ve küresel ısınmayı ciddi oranda arttırmaktadır (Zergane vd., 2018). Küresel enerji tüketimindeki artışa paralel olarak 2030 yılına kadar dünyadaki enerji talebinin %50'nin üzerinde artacağı tahmin edilmektedir (Suganthi ve Samuel, 2012). Çevre dostu yenilenebilir enerji kaynaklarının da toplam talebin yaklaşık %30'unu karşılayabildiği düşünüldüğünde, ülkelerin enerji konusundaki planlamalarının önemi daha iyi anlaşılmaktadır (Ghalekhondabi vd., 2017). Özellikle uzun vadeli enerji talep tahminlerinin yapılması ve bu talebi karşılamaya yönelik kaynakların planlanması hayati bir öneme sahiptir.

Enerji konusunda Türkiye'deki duruma bakıldığında, %2,52'lik enerji tüketimi artış oranıyla üst-orta gelirli ülkelerden biri olup, Ekonomik Kalkınma ve İşbirliği Örgütü'nün (OECD) 2018 yılı verilerine göre 144,2 milyon ton petrol eşdeğeri (millions of tonnes of oil equivalent, MTOE) enerji ile enerji tüketiminde 17. sırada yer almaktadır (Özdemir vd., 2022). Türkiye Cumhuriyeti Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre 2022 yılında Türkiye'deki elektrik üretiminin, %34,6'sı kömürden, %22,9'u doğal gazdan, %20,3'ü hidrolik enerjiden, %10,6'sı rüzgârdan, %5,1'i güneşten, %3,4'ü jeotermal enerjiden ve %3'ü diğer kaynaklardan elde edilmiştir. Türkiye elektrik enerjisi tüketimi 2022 yılında bir önceki yıla göre %0,5 oranında azalarak 331,1 terawatt saat (TWh), elektrik üretimi ise bir önceki yıla göre %1,9 azalarak 328,3 TWh olarak gerçekleşmiştir. Türkiye Ulusal Enerji Planı çalışmasının sonuçlarına göre elektrik tüketiminin 2025 yılında 380,2 TWh, 2030 yılında 455,3 TWh, 2035 yılında ise 510,5 TWh seviyesine ulaşması beklenmektedir ("TC Enerji ve Tabii Kaynaklar Bakanlığı," 2023). Türkiye, enerji üretmek için kullandığı doğalgaz ve petrol ürünlerinin büyük bir bölümünü Orta Doğu ülkeleri ve Rusya'dan ithal ettiği için enerji kaynakları bakımından dışa bağımlıdır. Literatürdeki çalışmalara göre enerji kaynağı konusunda dışa bağımlılık oranı %70 civarındadır (Aslan, 2023; Özdemir vd., 2022). Enerji üretim maliyetlerinin yüksekliği ve üretilen enerjinin büyük ölçüde depolanamaması nedeniyle enerji arz ve talebi arasında bir dengenin olması gerekmektedir. Bunun için gelecekteki enerji talebinin başarılı bir şekilde tahmin edilmesi ve bu talebe göre enerji üretim, dağıtım ve fiyatlandırma çalışmalarının yapılması kritik bir öneme sahiptir (Ünler, 2008).

Bu çalışmada Türkiye'nin enerji talebini tahmin etmek için Faramarzi vd. (2020) tarafından önerilen deniz avcıları algoritması (marine predators algorithm, MPA) kullanılmıştır. Çalışmada yapılanlar ve çalışmanın literatüre katkıları aşağıda maddeler halinde sunulmuştur:

- Bu çalışmada, Türkiye'nin 1979 – 2015 yılları arasındaki enerji talebini tahmin etmek için doğrusal ve ikinci dereceden 2 farklı model kullanılmıştır.
- Modellerde gayri safi yurtiçi hasıla, popülasyon, ithalat ve ihracat girdi değerlerini; enerji talebi ise çıktıyı ifade eder.
- Modellerdeki ağırlık katsayılarının optimum değerini belirlemek için deniz avcılığı algoritmasından faydalanılmıştır.
- Elde edilen sonuçlar deniz avcılığı algoritmasının karşılaştırılan algoritmalara göre oldukça başarılı ve kararlı sonuçlar ürettiğini göstermiştir.

LİTERATÜR ÖZETİ

Literatür incelendiğinde, enerji talep tahmini problemi için farklı yöntemlerin kullanıldığı görülmektedir. Bunlardan ilki istatistik tabanlı yöntemlerdir. Baum (1984), gelişmekte olan ülkelerin enerji planlamasında istatistiksel yöntemleri kullanarak bu alandaki çalışmaların öncüsü olmuştur. Ediger ve Tatlıdil (2002) Türkiye'nin enerji talebini tahmin etmek için yarı istatistiksel bir yöntem olan çevrim analizinden faydalanmıştır. Dilaver ve Hunt (2011), 1960 – 2008 yılları arasındaki verilerle Türkiye'nin endüstriyel enerji talebini yapısal zaman serisi analizi yöntemini kullanarak tahmin etmiştir. Aynı yöntem Top ve Vapur (2018) tarafından Türkiye'nin genel enerji stratejisinin tahmininde kullanılmıştır. Ozturk ve Ozturk (2018) ARIMA istatistiksel yöntemi ile Türkiye'nin enerji talebini tahmin etmiştir. de Oliveira ve Oliveira (2018) ise orta ve uzun vadeli elektrik enerjisi tüketim tahmini için ARIMA istatistiksel yöntemini ve üstel bir hesaplama modelini kullanmıştır. Cihan (2022) aynı yöntemi COVID-19 döneminde uygulanan karantınaların, sanayi bölgelerindeki elektrik ve doğal gaz tüketimine etkisini tahmin etmek için kullanmıştır. Talep tahmin problemlerinde kullanılan bir diğer yöntem yapay sinir ağları (artificial neural network, ANN) algoritmasıdır. Gorucu (2004) Ankara'nın gaz tüketimini tahmin etmek için YSA'yı kullanmıştır. Aynı yöntem, Yunanistan'ın (Economou, 2010) ve Türkiye'nin (Es vd., 2014; Kankal ve Uzlu, 2017) enerji tüketimini tahmin etmek amacıyla da kullanılmıştır. Talep tahmini problemlerinde yaygın olarak kullanılan diğer bir yöntem ise metasezgisel algoritmalar. Çeşitli araştırmacılar genetik algoritmayı kullanarak Türkiye'nin enerji talebi üzerine çeşitli tahmin çalışmaları yapmıştır (Ceylan ve Ozturk, 2004; Haldenbilen ve Ceylan, 2005; H. K. Ozturk vd., 2005). Ardından Toksarı (2007) Türkiye'nin enerji talebini tahmin etmek için 1979 – 2005 yılları arasındaki gayri safi yurt içi hasıla, nüfus, ithalat ve ihracat verilerini kullanarak karınca koloni optimizasyonu algoritması ile doğrusal ve karesel hesaplama modelleri önermiştir. Bu öncü çalışmaların ardından çok sayıda araştırmacı metasezgisel tabanlı enerji tahmin çalışmaları yapmıştır. Bu çalışmalardan bazıları kullanılan algoritmalara göre gruplanarak Tablo 2'de sunulmuştur.

Tablo 2. Bazı Metasezgisel Tabanlı Enerji Talep Tahmin Çalışmaları

Araştırmacılar	Kullanılan Algoritma
Ünler (2008), Gulcu ve Kodaz (2017) (Aslan, 2023)	Parçacık sürü optimizasyonu (particle swarm optimization, PSO)
Aslan ve Beşkirli (2022)	Arşimet optimizasyon algoritması (Archimedes optimization algorithm, AOA)
(Toksarı, 2007, 2009)	Aritmetik optimizasyon algoritması (arithmetic optimization algorithm, AOA)
Özkış (2020)	Karınca koloni optimizasyonu (ant colony optimization, ACO)
Özdemir vd. (2022)	Girdap arama, (vortex search, VS) algoritması
Kıran vd. (2012a)	Yapay arı kolonisi, (artificial bee colony, ABC)
Kıran vd. (2012b)	PSO ve ACO
Koc vd. (2019)	ABC ve PSO
İsmail vd. (2018)	Gri kurt optimizasyonu (grey wolf optimizer, GWO)
	Yerçekimi arama algoritması (gravity search algorithm, GSA) ve yabancı ot optimizasyon algoritması (invasive weed optimization, IWO)

Bilici ve Özdemir (2023)

ABC, yüklü sistem arama algoritması (charged system search algorithm, CSS), karga arama algoritması (Crow search algorithm, CSA) ve harmoni arama algoritması (harmony search algorithm, HSA)

Enerji tahmin problemiyle ilgili literatür incelendikten sonra, bu çalışmada kullanılan MPA yöntemiyle ilgili çalışmalar incelenmiştir. MPA, 2020 yılında önerilmiş güçlü bir metasezgisel algoritmadır. Yapısında barındırdığı üç farklı arama stratejisi sayesinde benchmark problemlerinin optimizasyonunda (Arslan, 2023), yapay sinir ağlarının eğitilmesinde (Baştemur Kaya, 2023; Ikram vd., 2022), öznelik seçim problemlerinde (Abd Elminaam vd., 2021), görüntü işleme problemlerinde (Abdel-Basset vd., 2022), parametre tahmini problemlerinde (Abdel-Basset vd., 2021) ve çok amaçlı problemlerin çözümünde (Jangir vd., 2023; Zhong vd., 2021) başarılı olduğu görülmüştür.

MATERYAL VE METOT

Enerji Talep Tahmin Problemi

Literatürdeki pek çok çalışmada (Toksarı, 2007; Ünler, 2008), bir ülkenin enerji talebi ile belirtilen dört faktör arasında kuvvetli bir ilişki olduğu belirtilmiştir:

- 1) Gayri safi yurtiçi hasıla (GSYH)
- 2) Popülasyon
- 3) İthalat
- 4) İhracat

Özkan (2018) çalışmasında; Türkiye İstatistik Kurumu (TÜİK), Uluslararası Enerji Ajansı (IEA) ve OECD tarafından yayınlanan verilerle Tablo 3'teki veri setini oluşturmuştur. Tablo 3'te, 1979 – 2015 yılları arasındaki Türkiye'nin enerji talep miktarları ve bu talebe etki eden dört faktörün değerleri sunulmuştur. Literatürde (Toksarı, 2007; Ünler, 2008), bu dört faktöre dayalı olarak enerji talebinin tahmin edilebilmesi için iki farklı matematiksel model kullanılmıştır. Bunlardan ilki Denklem (1)'de verilen doğrusal (lineer) modeldir.

$$E_{lineer} = w_1 + w_2 \cdot x_1 + w_3 \cdot x_2 + w_4 \cdot x_3 + w_5 \cdot x_4 \quad (1)$$

Denklem (1)'deki x_1 , x_2 , x_3 ve x_4 girdi parametreleri sırasıyla Tablo 3'te verilen GSYH, nüfus, ithalat ve ihracat değerlerini; w_2 , w_3 , w_4 ve w_5 ise sırasıyla bu değerlerin ağırlık katsayılarını ifade etmektedir. Modeldeki w_1 serbest ağırlık katsayısını, E_{lineer} ise modelin enerji talep tahmin sonucunu ifade eder.

Tablo 3. Türkiye'nin 1979 – 2015 Yılları Arasındaki GSYH, Nüfus, İthalat ve İhracat Değerleri

Yıl	GSYH (\$10 ⁹)	Nüfus (10 ⁶)	İthalat (\$10 ⁹)	İhracat (\$10 ⁹)	Enerji Talebi (MTOE)
1979	81	43,53	5,07	2,26	30,25
1980	68	44,438	7,91	2,91	31,45
1981	71	45,54	8,93	4,7	31,71
1982	64	46,688	8,84	5,75	33,7
1983	60	47,864	9,24	5,73	35,68
1984	59	49,07	10,76	7,13	37,11
1985	67	50,306	11,34	7,95	39,32
1986	75	51,433	11,1	7,46	42,36
1987	86	52,561	14,16	10,19	46,97
1988	90	53,715	14,34	11,66	47,29
1989	107	54,893	15,79	11,62	49,1
1990	150	56,203	22,3	12,96	52,7
1991	149	57,305	21,05	13,59	51,98
1992	157	58,401	22,87	14,72	53,63
1993	178	59,491	29,43	15,35	56,89
1994	132	60,576	23,27	18,11	56,21
1995	168	61,644	35,71	21,64	61,57
1996	181	62,697	43,63	23,22	66,92
1997	189	62,48	48,56	26,26	70,41
1998	207	63,459	45,92	26,97	71,74
1999	187	64,345	40,67	26,59	70,43

2000	200	67,461	54,5	27,78	75,92
2001	146	68,618	41,4	31,33	70,2
2002	181	69,626	51,55	36,06	74,21
2003	239	70,712	69,34	47,25	77,87
2004	299	71,789	97,54	63,17	80,72
2005	361	72,065	116,77	73,48	84,21
2006	400	72,974	139,58	85,53	93,15
2007	648	70,586	169,99	107,15	100
2008	742	71,517	201,96	132,02	98,7
2009	616	72,561	140,78	102,17	97,79
2010	731	73,723	185,49	113,93	106,65
2011	772	74,724	240,84	134,91	113,46
2012	786	75,627	236,55	152,46	118,14
2013	820	76,667	251,65	151,87	116,85
2014	780	77,695	242,18	157,61	121,5
2015	720	78,741	207,2	143,94	128,81

Diğer model ise Denklem (2)'de verilen ikinci dereceden (quadratic) modeldir.

$$E_{quadratic} = w_1 + w_2 \cdot x_1 + w_3 \cdot x_2 + w_4 \cdot x_3 + w_5 \cdot x_4 + w_6 \cdot x_1 \cdot x_2 + w_7 \cdot x_1 \cdot x_3 + w_8 \cdot x_1 \cdot x_4 + w_9 \cdot x_2 \cdot x_3 + w_{10} \cdot x_2 \cdot x_4 + w_{11} \cdot x_3 \cdot x_4 + w_{12} \cdot x_1^2 + w_{13} \cdot x_2^2 + w_{14} \cdot x_3^2 + w_{15} \cdot x_4^2 \quad (2)$$

Denklem (2)'deki $x_1 - x_4$ ve $w_1 - w_5$ Denklem (1)'deki ile aynı görevi yerine getirir. Denklemdeki $w_6 - w_{11}$ katsayıları ise girdi parametrelerinin ikili kombinasyonlarının ağırlıklarını, $w_{12} - w_{15}$ ise girdi parametrelerinin ikinci dereceden kuvvetlerinin ağırlık katsayılarını ifade etmektedir. $E_{quadratic}$ ise modelin enerji talep tahmin sonucunu ifade eder.

Ağırlık katsayıları belirlendikten sonra Denklem (1) ve Denklem (2)'deki modellerle her bir yıl için enerji talep tahminleri hesaplanır. Bu tahminlerin, Tablo 3'teki enerji talep değerlerine yakın değerler üretmesi hedeflenir. Bu hedefi gerçekleştirmek için Denklem (3)'te verilen toplam karesel hata (sum squared error, SSE) matematiksel modeli amaç fonksiyonu olarak kullanılmıştır.

$$SSE = \text{Min } f(W) = \sum_{r=1}^R (E_r^{gercek} - E_r^{tahmin})^2 \quad (3)$$

Burada W ağırlık vektörünü, R toplam yıl (örnek) sayısını, $r = 1, 2, \dots, R$ tahmin edilen yılın indisini, E_r^{gercek} ve E_r^{tahmin} r .yıl için sırasıyla gerçek ve tahmin edilen enerji talep değerlerini ifade etmektedir. Burada hedef, SSE metriğini minimize edecek ağırlık katsayılarını bulmaktır.

SSE metriğinin örnek sayısına bölünmesi ile Denklem (4)'te verilen ortalama karesel hata (mean squared error, MSE), MSE değerinin karekökünün alınması ile de Denklem (5)'te verilen ortalama karesel hatanın karekökü (root mean squared error, RMSE) metrikleri elde edilir.

$$MSE = \frac{SSE}{R} \quad (4)$$

$$RMSE = \sqrt{MSE} \quad (5)$$

Her yılki enerji talep tahminlerinin yüzde bağıl hatası (absolute percentage error, APE) Denklem (6) ile, yüzde bağıl hataların ortalaması (mean absolute percentage error, MAPE) ise Denklem (7) ile hesaplanır.

$$APE_r = \text{abs}(E_r^{observed} - E_r^{predicted}) * 100 / E_r^{observed} \quad (6)$$

$$MAPE = \frac{1}{R} \sum_{r=1}^R APE_r \quad (7)$$

Deniz Avcıları Algoritması (Marine Predators Algorithm, MPA)

MPA, Faramarzi vd. (2020) tarafından okyanuslardaki av–avcı arasındaki biyolojik etkileşimde optimal karşılaşma oranı politikasından ilham alan, bir metasezgisel bir algoritmadır.

MPA'nın konum güncelleme mekanizması

MPA, deniz canlılarının av – avcı durumundaki hızlarını dikkate alarak üç farklı konum güncelleme mekanizmasına (KGM) sahiptir:

KGM-1) Av, avcıdan daha hızlı hareket ettiğinde:

Bu senaryo, algoritmanın keşif (genel arama) sürecinde olduğu ilk yinelemelerde ortaya çıkar. Bu durumda avcı için en iyi strateji hiç hareket etmemektir. $MakIter$ sonlandırma kriterini, $iter$ o anki iterasyonu tanımlamak üzere $iter < 1/3 MakIter$ iken, avların konumları Denklem (8) kullanılarak güncellenir.

$$\begin{aligned}\overrightarrow{stepsize}_i &= \vec{R}_B \otimes (\overrightarrow{Elite}_i - \vec{R}_B \otimes \overrightarrow{Prey}_i) \quad i = 1, \dots, n \\ \overrightarrow{Prey}_i &= \overrightarrow{Prey}_i + P \cdot \vec{R} \otimes \overrightarrow{stepsize}_i\end{aligned}\quad (8)$$

Burada n popülasyondaki toplam av sayısını, $Prey_i$ i. avın konumunu, $Elite_i$ (avcı) popülasyondaki en iyi uygunluğa sahip bireyi ifade eder. R_B , Denklem (9)'da verilen Brownian hareketini temsil eder ve normal dağılıma göre rastgele sayılardan oluşan bir vektördür, \otimes sembolü ise girişlerin çarpımını temsil eder. $\vec{R}_B \otimes \overrightarrow{Prey}_i$ avın hareketini tanımlar. $P = 0,5$ bir sabittir ve R $[0,1]$ aralığında rastgele sayılardan oluşan bir vektördür.

$$f_B(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) \quad (\mu = 0), \quad (\sigma^2 = 1) \quad (9)$$

KGM-2) Av ve avcı yaklaşık olarak aynı hızla hareket ettiğinde:

Bu senaryo, keşfin sömürüye (yerel arama) dönüştüğü ara aşamadır. Bu aşamada hem keşif hem de sömürü önemlidir ve popülasyonun yarısı keşif, diğer yarısı ise sömürü için kullanılır. $1/3 MakIter < iter < 2/3 MakIter$ iken popülasyonun ilk yarısının konumu sömürü amacıyla Denklem (10) ile güncellenir.

$$\begin{aligned}\overrightarrow{stepsize}_i &= \vec{R}_L \otimes (\overrightarrow{Elite}_i - \vec{R}_L \otimes \overrightarrow{Prey}_i) \quad i = 1, \dots, n/2 \\ \overrightarrow{Prey}_i &= \overrightarrow{Prey}_i + P \cdot \vec{R} \otimes \overrightarrow{stepsize}_i\end{aligned}\quad (10)$$

Burada R_L , Lévy dağılımına dayanan rastgele sayıların bir vektörüdür. Avlar $\vec{R}_L \otimes \overrightarrow{Prey}_i$ matematiksel modeline göre küçük adımlar oluşturur ve avların konum güncellemesi taklit edilir.

Popülasyonun ikinci yarısının konumu ise keşif amacıyla Denklem (11) ile güncellenir.

$$\begin{aligned}\overrightarrow{stepsize}_i &= \vec{R}_B \otimes (\vec{R}_B \otimes \overrightarrow{Elite}_i - \overrightarrow{Prey}_i) \quad i = n/2, \dots, n \\ \overrightarrow{Prey}_i &= \overrightarrow{Elite}_i + P \cdot CF \otimes \overrightarrow{stepsize}_i\end{aligned}\quad (11)$$

Avcının konumu Brownian hareketinin etkisiyle güncellenir. CF , avcının konumu güncellenirken adım boyutunu kontrol eden adaptif bir parametredir ve Denklem (12) kullanılarak hesaplanır.

$$CF = \left(1 - \frac{Iter}{Max_Iter}\right)^{\left(2 \frac{Iter}{Max_Iter}\right)} \quad (12)$$

KGM-3) Avcı, avdan daha hızlı hareket ettiğinde:

Bu durumla genellikle arama sürecinin son evresinde ($iter > 2/3 MakIter$) karşılaşılır. Yüksek sömürüye ihtiyaç duyulan bir evredir. Avcılar için en iyisi Denklem (13) ile Lévy tarzı arama yapmaktır.

$$\begin{aligned}\overrightarrow{stepsize}_i &= \vec{R}_L \otimes (\vec{R}_L \otimes \overrightarrow{Elite}_i - \overrightarrow{Prey}_i) \quad i = 1, \dots, n \\ \overrightarrow{Prey}_i &= \overrightarrow{Elite}_i + P \cdot CF \otimes \overrightarrow{stepsize}_i\end{aligned}\quad (13)$$

Burada $\vec{R}_L \otimes \overrightarrow{Elite}_i$ işlemi avcının Lévy tarzı hareketini simüle eder.

Balık toplama cihazları (Fish aggregating devices, FADs)

Yukarıda belirtilen adımların yanı sıra, MPA deniz avcılarının besin arama stratejilerini daha iyi modellemek için Denklem (14)'te verilen balık toplama cihazları (Fish Aggregating Devices, FADs) veya girdap dönüşümü olarak adlandırılan hareketi de taklit eder.

$$\vec{Prey} = \begin{cases} \vec{Prey} + CF[\vec{X}_{min} + \vec{R} \otimes (\vec{X}_{max} - \vec{X}_{min})] \otimes \vec{U} & \text{if } r \leq FADs \\ \vec{Prey} + [FADs(1-r) + r](\vec{Prey}_{r1} - \vec{Prey}_{r2}) & \text{if } r > FADs \end{cases} \quad (14)$$

Burada $r(0, 1)$ aralığında rastgele bir sayı ve \vec{U} çözülen problemle aynı boyuta sahip ikili bir vektördür. \vec{U} vektörünün her bir boyutu için $(0, 1)$ aralığında rastgele bir sayı üretilir. Üretilen sayı $FADs = 0.2$ değerinden küçükse \vec{U} vektörünün ilgili boyutu 1, değilse 0 değerini alır. Yukarıdaki birinci model avların konumlarının \vec{U} vektörüne göre rastgele olarak dağılma olasılığını ifade eder. İkinci modeldeki r_1 ve r_2 ise av matrisinin rastgele indisleridir (Arslan, 2023).

Deniz hafızası

Deniz avcılarının bol miktarda avın bulunduğu yerleri hatırlama konusunda iyi bir hafızaları vardır. MPA'da deniz yırtıcılarının bu yeteneği açgözlü arama yöntemiyle uygulanmaktadır. Her avın uygunluk değeri bir önceki yinelemedeki uygunluk değeriyle karşılaştırılır ve daha iyi olan bir sonraki yineleme için kullanılır. O ana kadar elde edilen en iyi çözüm *Elite* matriste tutulur.

MPA'nın sözde kodu Şekil 1'de verilmiştir.

```

Arama ajanları (av) popülasyonunu başlat  $i = 1, \dots, n$ 
While  $iter < MakIter$ 
    Uygunluğu hesapla, Elite matrisi oluştur ve deniz hafızasını kullan
     $iter++$ 
    If  $iter < MakIter/3$  ise
        Avı KGM-1'e göre güncelle
    Elseif  $MakIter/3 < iter < 2 * MakIter/3$ 
        Avı KGM-2'ye göre güncelle
    Elseif  $iter > 2 * MakIter/3$  ise
        Avı KGM-3'e göre güncelle
    End if
    Uygunluğu hesapla, Elite matrisi oluştur, deniz hafızasını kullan
    Elite matrisi güncelle
     $iter++$ 
    FADs etkisini uygulama
End while
Elite bireyi gönder

```

Şekil 1. MPA'nın Sözde Kodu

PERFORMANS ANALİZİ VE İSTATİSTİKSEL BULGULAR

Çalışmada MPA, AOA (Hashim vd., 2021), DEA (Storn ve Price, 1997), GWO (Mirjalili vd., 2014) ve MFO (Karakoyun ve Özkış, 2021; Mirjalili, 2015) algoritmaları ile oluşturulan doğrusal ve ikinci dereceden regresyon modellerinin elde ettikleri ağırlık katsayıları, *SSE*, *MSE*, *RMSE*, *APE* ve *MAPE* değerleri sunulmuştur. Tüm algoritmalar 100 birey ve 5000 iterasyon için 30 tekrarlı olarak çalıştırılmıştır. Algoritmalara özgü parametreler Tablo 4'te verilmiştir.

Doğrusal Modelle İlgili Performans Karşılaştırmaları

Tablo 5'te algoritmaların doğrusal model için 30 çalıştırma sonucunda elde ettiği en iyi *SSE*, *MSE* ve *RMSE* metrik değerleri ve bu değerleri üreten ağırlıklar verilmiştir.

Tablo 4. Algoritmaların Özgü Parametre Değerleri

Algoritma	Parametre Değerleri
MPA	P = 0,5 FADs = 0,2
AOA	C1 = 1 C2 = 2 C3 = 1 C4 = 1 u = 0,9 l = 0,1
DEA	CR = 0,9 F = 0,5
GWO	a = [0, 2]
MFO	b = 1

Tablo 5. Algoritmaların Doğrusal Model için Elde Ettiği En İyi SSE, MSE Ve RMSE Değerleri ve Ağırlıkları

	MPA	AOA	DEA	GWO	MFO
w_1	-51,224479	-51,221094	-51,224479	-51,230486	-51,224481
w_2	0,019056	0,019059	0,019056	0,019078	0,019056
w_3	1,784920	1,784861	1,784920	1,784978	1,784920
w_4	0,006418	0,005541	0,006418	0,006557	0,006418
w_5	0,125734	0,127109	0,125734	0,125421	0,125734
SSE	244,677	244,679	244,677	244,677	244,677
MSE	6,613	6,613	6,613	6,613	6,613
RMSE	2,572	2,572	2,572	2,572	2,572

Tablo 6'da ise algoritmaların doğrusal model için 30 çalıştırma sonucunda elde ettiği en iyi ve en kötü SSE değerleri, SSE değerlerinin ortalamaları ve standart sapmaları verilmiştir. En iyi sonuçlar incelendiğinde AOA 244,679 değerini elde ederken, diğer algoritmalar ise 244,67 değerini elde ederek ilk sırayı paylaşmıştır. En kötü sonuçlar açısından MFO 8957,074 değeri ile en büyük SSE değerine sahip olurken, AOA 1244,86, GWO ise 269,924 SSE değerine sahip olmuştur. MPA ve DEA ise 244,677 SSE değeri ile en iyi sonucu elde etmişlerdir. Ortalama açısından MPA ve DEA 244,677 değeri ile ilk sırayı paylaşırken, GWO 253,282 ve AOA 287,647 değerleri ile 2. ve 3.sırayı elde etmiştir. MFO ise 2749,253 değeri ile ortalama performans açısından en kötü sonucu elde etmiştir.

Tablo 6. Doğrusal Model için 30 Çalıştırma Sonucunda Elde Edilen En İyi ve En Kötü SSE Değerleri, SSE Değerlerinin Ortalaması ve Standart Sapması

	MPA	AOA	DEA	GWO	MFO
En iyi	244,677	244,679	244,677	244,677	244,677
En Kötü	244,677	1244,860	244,677	269,924	8957,074
Ortalama	244,677	287,647	244,677	253,282	2749,253
S. sapma	1,86E-13	1,81E+02	2,36E-13	1,06E+01	3,82E+03

Doğrusal model için elde edilen ağırlık değerleriyle hesaplanan tahminler ve bu tahminlerin APE, toplam APE ve MAPE değerleri Tablo 7'de sunulmuştur. Burada GWO algoritması az bir farkla en iyi toplam APE değerini elde ederken, tüm algoritmaların birbirine yakın ve rekabetçi değerler elde ettiği görülmektedir.

Tablo 7. Algoritmaların Doğrusal Model için Elde Ettiği En İyi Ağırlıklarla Hesaplanan Tahminler, APE, Toplam APE ve MAPE Değerleri

Yıl	Gerçek Enerji Talebi	MPA		AOA		DEA		GWO		MFO	
		Tahmin	APE	Tahmin	APE	Tahmin	APE	Tahmin	APE	Tahmin	APE
1979	30,710	31,922	3,947	31,922	3,946	31,922	3,947	31,921	3,942	31,922	3,947
1980	31,970	29,810	6,757	29,808	6,763	29,810	6,757	29,808	6,762	29,810	6,757
1981	32,050	32,081	0,097	32,081	0,095	32,081	0,097	32,079	0,091	32,081	0,097
1982	34,390	34,113	0,806	34,114	0,804	34,113	0,806	34,110	0,813	34,113	0,806
1983	35,700	36,125	1,190	36,125	1,192	36,125	1,190	36,122	1,183	36,125	1,190
1984	37,430	38,451	2,729	38,452	2,731	38,451	2,729	38,449	2,722	38,451	2,729
1985	39,400	40,924	3,868	40,926	3,872	40,924	3,868	40,921	3,861	40,924	3,868
1986	42,470	43,012	1,277	43,013	1,280	43,012	1,277	43,010	1,272	43,012	1,277
1987	46,880	45,602	2,726	45,604	2,722	45,602	2,726	45,600	2,731	45,602	2,726

1988	47,910	47,935	0,051	47,938	0,059	47,935	0,051	47,932	0,046	47,935	0,051
1989	50,710	50,370	0,670	50,373	0,665	50,370	0,670	50,368	0,674	50,370	0,670
1990	52,980	53,560	1,094	53,558	1,092	53,560	1,094	53,559	1,093	53,560	1,094
1991	54,270	55,557	2,372	55,558	2,373	55,557	2,372	55,557	2,371	55,557	2,372
1992	56,680	57,756	1,898	57,756	1,899	57,756	1,898	57,755	1,897	57,756	1,898
1993	60,260	60,187	0,121	60,183	0,129	60,187	0,121	60,188	0,120	60,187	0,121
1994	59,120	61,562	4,131	61,567	4,139	61,562	4,131	61,560	4,127	61,562	4,131
1995	63,680	64,791	1,745	64,790	1,743	64,791	1,745	64,791	1,744	64,791	1,745
1996	69,860	67,342	3,604	67,336	3,613	67,342	3,604	67,343	3,603	67,342	3,604
1997	73,780	69,961	5,176	69,955	5,184	69,961	5,176	69,962	5,175	69,961	5,176
1998	74,710	72,426	3,058	72,423	3,062	72,426	3,058	72,426	3,057	72,426	3,058
1999	76,770	74,516	2,937	74,516	2,936	74,516	2,937	74,515	2,938	74,516	2,937
2000	80,500	76,769	4,635	76,759	4,647	76,769	4,635	76,770	4,634	76,769	4,635
2001	75,400	77,798	3,180	77,804	3,188	77,798	3,180	77,795	3,176	77,798	3,180
2002	78,330	80,784	3,133	80,789	3,139	80,784	3,133	80,782	3,131	80,784	3,133
2003	83,840	85,071	1,468	85,075	1,473	85,071	1,468	85,069	1,466	85,071	1,468
2004	87,820	90,039	2,527	90,040	2,528	90,039	2,527	90,037	2,525	90,039	2,527
2005	91,580	95,889	4,705	95,887	4,703	95,889	4,705	95,888	4,704	95,889	4,705
2006	99,590	99,876	0,287	99,872	0,283	99,876	0,287	99,878	0,289	99,876	0,287
2007	107,630	99,471	7,581	99,470	7,582	99,471	7,581	99,471	7,581	99,471	7,581
2008	106,270	105,982	0,271	105,987	0,266	105,982	0,271	105,981	0,272	105,982	0,271
2009	106,140	107,143	0,945	107,161	0,962	107,143	0,945	107,145	0,947	107,143	0,945
2010	109,270	108,927	0,314	108,922	0,319	108,927	0,314	108,929	0,312	108,927	0,314
2011	114,480	114,583	0,090	114,558	0,068	114,583	0,090	114,589	0,095	114,583	0,090
2012	118,140	119,429	1,091	119,432	1,094	119,429	1,091	119,430	1,092	119,429	1,091
2013	116,850	121,956	4,370	121,945	4,361	121,956	4,370	121,960	4,373	121,956	4,370
2014	121,500	123,690	1,802	123,695	1,806	123,690	1,802	123,690	1,802	123,690	1,802
2015	128,810	122,470	4,922	122,487	4,909	122,470	4,922	122,468	4,923	122,470	4,922
Toplam APE		91,576		91,625		91,576		91,546		91,576	
MAPE		2,475		2,476		2,475		2,474		2,475	

Tablo 8’de ise algoritmaların doğrusal model için 30 çalıştırma sonucunda elde ettiği en iyi ve en kötü *Toplam APE* değerleri, *Toplam APE* değerlerinin ortalamaları ve standart sapmaları verilmiştir. Elde edilen en iyi sonuçlar incelendiğinde tüm algoritmaların küçük farklarla benzer değerler elde ettiği görülmektedir. En kötü değerlere bakıldığında ise MFO 932,025 ile en büyük *Toplam APE* değerine sahip olurken, AOA 331,864, GWO 102,634, MPA ve DEA ise 91,576 değerine sahip olmuştur. Ortalama açısından MPA ve DEA 91,576 değeri ile ilk sırayı paylaşırken, GWO 94,147 ve AOA 103,339 değerleri ile 2. ve 3.sırayı elde etmiştir. MFO ise 360,264 değeri ile ortalama performans açısından en kötü sonucu elde etmiştir. Standart sapma değerleri incelendiğinde, MPA ve DEA’nın 30 çalıştırmanın tamamında neredeyse aynı performansı elde ettiği ve sifıra yakın bir standart sapmaya sahip olduğu görülmektedir. Bu durum, her iki algoritmanın doğrusal model için kararlı bir yapıya sahip olduğunu gösterir.

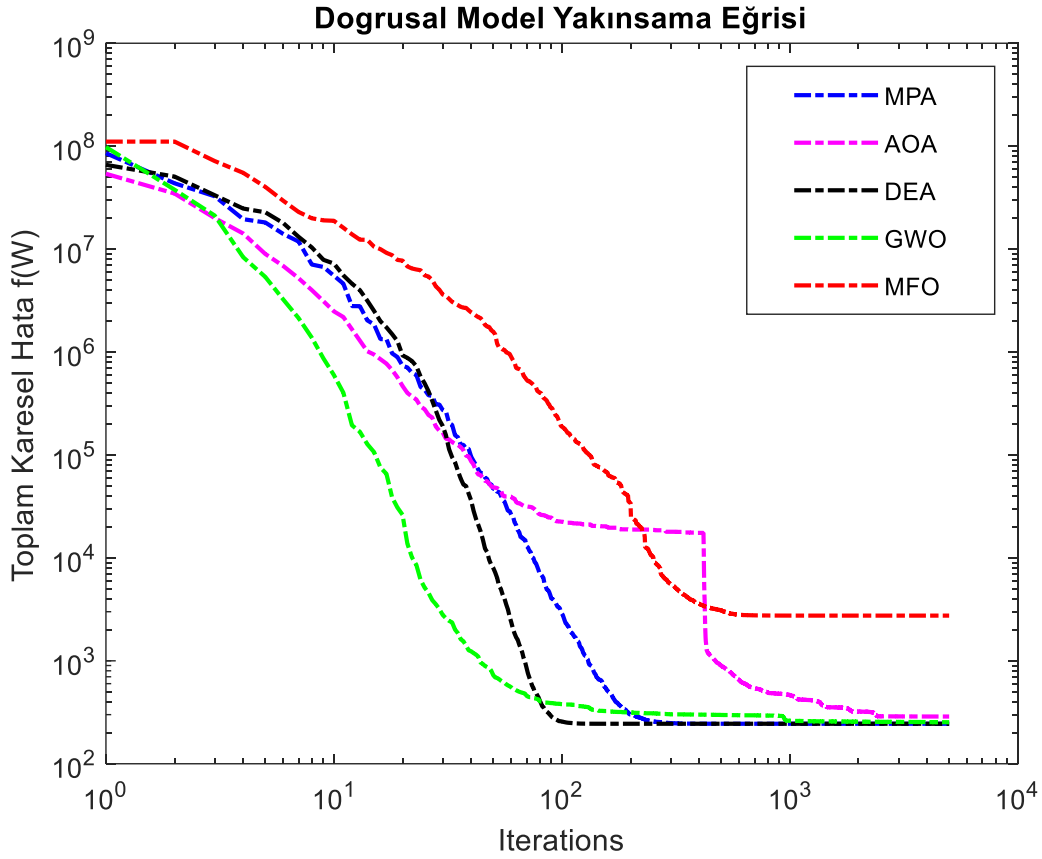
Tablo 8. Doğrusal Model için 30 Çalıştırma Sonucunda Elde Edilen En İyi ve En Kötü *Toplam APE* Değerleri, *Toplam APE* Değerlerinin Ortalaması ve Standart Sapması

	MPA	AOA	DEA	GWO	MFO
En iyi	91,576	90,912	91,576	90,902	91,576
En Kötü	91,576	331,864	91,576	102,634	932,025
Ortalama	91,576	103,339	91,576	94,147	360,264
S. sapma	5,44E-07	4,34E+01	5,28E-07	4,41E+00	3,61E+02

Doğrusal modelde, algoritmaların her iterasyon için elde ettiği *SSE* değerleri kullanılarak yakınsama grafikleri oluşturulmuş ve Şekil 2’de sunulmuştur. Buradan MPA ve DEA’nın diğer algoritmalarından daha başarılı bir yakınsama performansına sahip olduğu gözlenmektedir.

İkinci Dereceden Modelle İlgili Performans Karşılaştırmaları

Tablo 9’da algoritmaların ikinci dereceden model için 30 çalıştırma sonucunda elde ettiği en iyi *SSE*, *MSE* ve *RMSE* metrik değerleri ve bu değerleri üreten ağırlıklar verilmiştir.



Şekil 2. Algoritmaların Doğrusal Model için Yakınsama Grafiği

Tablo 9. Algoritmaların İkinci Dereceden Model için Elde Ettiği En İyi *SSE*, *MSE* ve *RMSE* Değerleri ve Ağırlıkları

	MPA	AOA	DEA	GWO	MFO
w_1	-68,408165	0,002728	-68,406015	1,987522	100,000000
w_2	-0,262545	-0,001249	-0,262558	0,000097	100,000000
w_3	2,619311	0,000331	2,619246	-0,043970	-100,000000
w_4	3,956309	0,012023	3,956221	-0,020622	-100,000000
w_5	-4,329726	0,175248	-4,329523	-0,213955	-100,000000
w_6	0,005889	0,001468	0,005889	-0,000095	-2,922746
w_7	-0,003094	-0,000291	-0,003094	-0,002179	0,950379
w_8	0,010866	0,000192	0,010866	-0,000407	-7,452941
w_9	-0,056668	0,000282	-0,056666	-0,001113	4,142511
w_{10}	0,057130	-0,005220	0,057127	0,008616	3,288050
w_{11}	-0,016784	-0,000581	-0,016786	0,000551	26,888251
w_{12}	-0,000690	-0,000064	-0,000690	0,000305	0,626126
w_{13}	-0,010023	0,014076	-0,010023	0,016097	2,203389
w_{14}	0,010676	0,000547	0,010677	0,004103	-10,174738
w_{15}	-0,013351	0,001624	-0,013351	0,000219	-2,280638
SSE	79,001	210,526	79,001	472,734	91085030,841
MSE	2,135	5,690	2,135	12,777	2461757,590
RMSE	1,461	2,385	1,461	3,574	1568,999

Tablo 10'da ise algoritmaların ikinci dereceden model için 30 çalıştırma sonucunda elde ettiği en iyi ve en kötü *SSE* değerleri, *SSE* değerlerinin ortalamaları ve standart sapmaları verilmiştir. En iyi sonuçlar incelendiğinde, MPA ve

DEA 79,001 değeriyle ilk sırayı paylaşırken, AOA 210,526, GWO 472,734 değerleriyle 2. ve 3. sırayı elde etmiştir. MFO ise en iyi olarak 91085030,841 SSE değerini elde ederek diğer algoritmalara göre oldukça başarısız bir performans göstermiştir. En kötü sonuçlar açısından MFO 400236548396,422 değeri ile en büyük SSE değerine sahip olurken, GWO 2895433845,587, AOA ise 4234,821 SSE değerine sahip olmuştur. DEA 82,225 ile en iyi 2. değeri elde ederken, MPA 79,001 ile en iyi sonucu elde etmiştir. Ortalama açısından MPA 79,001 SSE değeri ile ilk sırayı alırken, DEA 79,186 SSE değeri ile az farkla 2. olmuştur. AOA 502,861 değeri ile 3. olurken GWO 155091179,635 ile 4. ve son olarak MFO 71693180344,079 değeri ile en kötü sonucu elde etmiştir.

Tablo 10. İkinci Dereceden Model için 30 Çalıştırma Sonucunda Elde Edilen En İyi ve En Kötü SSE Değerleri, SSE Değerlerinin Ortalaması ve Standart Sapması

	MPA	AOA	DEA	GWO	MFO
En iyi	79,001	210,526	79,001	472,734	91085030,841
En Kötü	79,001	4234,821	82,225	2895433845,587	400236548396,422
Ortalama	79,001	502,861	79,186	155091179,635	71693180344,079
S. sapma	4,65E-07	8,67E+02	6,12E-01	5,35E+08	1,01E+11

İkinci dereceden model için elde edilen ağırlık değerleriyle hesaplanan tahminler ve bu tahminlerin APE, toplam APE ve MAPE değerleri Tablo 11’de sunulmuştur. Burada 61,957 toplam APE değeri ile MPA ve DEA ilk sırayı paylaşırken, AOA 91,97 ile 2. ve GWO ise 142,664 ile 3. sırayı almıştır. MFO 49518,999 değeri ile diğer algoritmaların oldukça gerisinde kalmıştır.

Tablo 11. Algoritmaların İkinci Dereceden Model için Elde Ettiği En İyi Ağırlıklarla Hesaplanan Tahminler, APE, Toplam APE ve MAPE Değerleri

Yıl	Gerçek Enerji Talebi	MPA		AOA		DEA		GWO		MFO	
		Tahmin	APE	Tahmin	APE	Tahmin	APE	Tahmin	APE	Tahmin	APE
1979	30,710	29,703	3,279	34,060	10,909	29,703	3,279	34,236	11,481	1223,111	3882,777
1980	31,970	31,770	0,625	31,817	0,479	31,770	0,625	31,913	0,180	669,186	1993,168
1981	32,050	32,621	1,782	33,463	4,408	32,621	1,782	33,667	5,045	359,250	1020,906
1982	34,390	33,821	1,655	34,550	0,464	33,821	1,655	35,414	2,979	-109,997	419,851
1983	35,700	36,627	2,597	35,953	0,709	36,627	2,597	37,081	3,869	-96,632	370,678
1984	37,430	38,788	3,629	37,564	0,359	38,788	3,629	39,038	4,295	-98,120	362,142
1985	39,400	40,580	2,994	39,829	1,088	40,580	2,994	41,172	4,498	-222,008	663,471
1986	42,470	42,806	0,792	42,034	1,027	42,806	0,792	43,031	1,320	-229,145	639,547
1987	46,880	44,924	4,173	44,339	5,420	44,924	4,173	45,214	3,555	-411,539	977,856
1988	47,910	45,996	3,996	46,333	3,291	45,996	3,996	47,579	0,690	-823,009	1817,823
1989	50,710	49,300	2,780	49,386	2,610	49,300	2,780	49,731	1,932	-670,820	1422,855
1990	52,980	53,323	0,648	53,978	1,884	53,323	0,648	52,099	1,663	1032,123	1848,137
1991	54,270	54,692	0,777	55,791	2,802	54,692	0,777	54,516	0,454	251,397	363,234
1992	56,680	57,030	0,617	58,089	2,487	57,030	0,617	56,655	0,044	197,527	248,495
1993	60,260	60,274	0,023	61,238	1,623	60,274	0,023	58,087	3,605	1921,819	3089,212
1994	59,120	60,845	2,918	60,123	1,697	60,845	2,918	61,041	3,250	-1638,339	2871,209
1995	63,680	66,569	4,537	64,446	1,204	66,569	4,537	62,771	1,427	-356,126	659,244
1996	69,860	70,600	1,059	67,419	3,494	70,600	1,059	64,600	7,530	237,752	240,326
1997	73,780	73,308	0,640	69,979	5,152	73,308	0,640	67,391	8,660	32,517	55,927
1998	74,710	74,013	0,933	73,136	2,107	74,013	0,933	70,544	5,577	-435,837	683,372
1999	76,770	75,458	1,709	74,761	2,616	75,458	1,709	74,248	3,285	-1453,532	1993,359
2000	80,500	78,698	2,238	77,667	3,519	78,699	2,238	75,306	6,453	-162,254	301,558
2001	75,400	74,113	1,707	75,432	0,043	74,113	1,707	80,482	6,740	681,210	803,461
2002	78,330	78,730	0,510	79,641	1,674	78,730	0,510	83,081	6,065	159,552	103,692
2003	83,840	84,148	0,368	85,001	1,385	84,148	0,368	87,115	3,906	-355,707	524,269
2004	87,820	88,105	0,325	90,401	2,939	88,105	0,325	93,198	6,124	2012,042	2191,098
2005	91,580	94,405	3,084	97,617	6,592	94,405	3,084	99,608	8,766	1166,033	1173,240
2006	99,590	100,739	1,154	102,052	2,472	100,739	1,154	98,089	1,507	-1636,964	1743,704
2007	107,630	102,573	4,699	99,746	7,325	102,573	4,699	98,382	8,592	2305,722	2042,267
2008	106,270	108,624	2,215	105,281	0,930	108,624	2,215	102,585	3,468	3065,087	2784,245
2009	106,140	106,100	0,038	106,223	0,078	106,100	0,038	108,204	1,944	1285,748	1111,370

2010	109,270	108,648	0,569	110,013	0,680	108,648	0,569	107,264	1,836	-733,441	771,219
2011	114,480	115,170	0,603	112,781	1,484	115,170	0,603	115,720	1,083	-2640,635	2406,635
2012	118,140	119,253	0,942	117,986	0,130	119,253	0,942	116,363	1,504	890,493	653,761
2013	116,850	116,019	0,711	119,036	1,871	116,019	0,711	119,421	2,200	1148,252	882,672
2014	121,500	121,342	0,130	124,835	2,745	121,342	0,130	127,138	4,641	1877,544	1445,303
2015	128,810	128,166	0,500	125,880	2,275	128,166	0,500	125,594	2,496	-6256,193	4956,916
Toplam APE		61,957		91,970		61,957		142,664			49518,999
MAPE		1,675		2,486		1,675		3,856			1338,351

Tablo 12’de ise algoritmaların ikinci dereceden model için 30 çalıştırma sonucunda elde ettiği en iyi ve en kötü *Toplam APE* değerleri, *Toplam APE* değerlerinin ortalamaları ve standart sapmaları verilmiştir. Elde edilen en iyi sonuçlar incelendiğinde DEA 60,285 ile ilk sırada yer alırken, MPA 61,955 ile 2., AOA 91,97 ile 3., GWO 142,664 ile 4. olmuştur. En kötü değerlere bakıldığında ise MFO 5728800 ile en büyük *Toplam APE* değerine sahip olurken, GWO 325880, AOA 537,286, DEA 63,629 ve MPA 61,959 değerine sahip olmuştur. Ortalama açısından MPA 61,957 değeri ile ilk sırada yer alırken, DEA 61,959 ile 2., AOA 136,756 ile 3., GWO 39343 ile 4. ve MFO 1555800 değeri ile son sırada yer almıştır. Standart sapma değerleri incelendiğinde, MPA’nın 30 çalıştırmanın tamamında neredeyse aynı performansı elde ettiği ve sıfıra yakın bir standart sapmaya sahip olduğu görülmektedir. Bu durum, MPA’nın ikinci dereceden model için kararlı bir yapıya sahip olduğunu gösterir.

Tablo 12. İkinci Dereceden Model için 30 Çalıştırma Sonucunda Elde Edilen En İyi ve En Kötü *Toplam APE* Değerleri, *Toplam APE* Değerlerinin Ortalaması ve Standart Sapması

	MPA	AOA	DEA	GWO	MFO
En iyi	61,955	91,970	60,285	142,664	49519,000
En Kötü	61,959	537,286	63,629	325880,000	5728800,000
Ortalama	61,957	136,756	61,959	39343,000	1555800,000
S. sapma	1,10E-03	1,03E+02	5,39E-01	6,78E+04	1,59E+06

Şekil 3’te ikinci dereceden model için algoritmaların 30 çalıştırma sonucunda elde ettikleri ortalama yakınsama grafikleri sunulmuştur. Buradan doğrusal modelde olduğu gibi MPA ve DEA’nın diğer algoritmalarından daha başarılı bir yakınsama performansına sahip olduğu gözlenmektedir.

TARTIŞMA VE SONUÇ

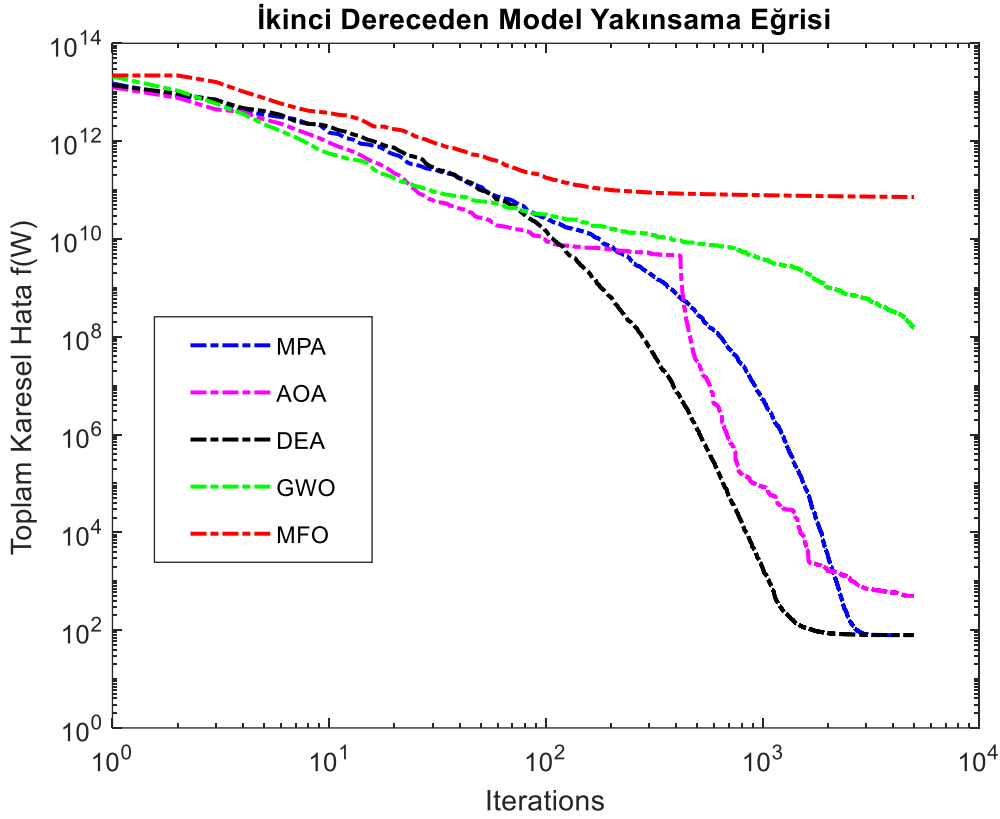
Bu çalışmada, Türkiye’nin enerji talebinin tahmin edilmesine yönelik 1979 – 2015 yılları arasındaki veriler kullanılarak doğrusal ve ikinci dereceden regresyon modelleri geliştirilmiştir. Modellerin geliştirilmesinde MPA, DEA, AOA, GWO ve MFO metasezgisel algoritmalarından faydalanılmıştır. Literatür incelendiğinde MPA’nın bu alanda ilk kez kullanıldığı görülmektedir. Ayrıca literatürdeki önceki çalışmalarda sadece elde edilen en iyi sonuç üzerinden bir kıyaslama yapılırken bu çalışmada en iyi, en kötü, ortalama ve standart sapma üzerinden daha kapsayıcı bir karşılaştırma yapılmıştır.

Doğrusal model için elde edilen sonuçlar incelendiğinde, MPA ve DEA 30 çalıştırma boyunca kararlılıklarını korurken, GWO küçük bir miktar sapma göstermiştir. AOA ve MFO algoritmalarının 30 çalıştırma için elde ettikleri en iyi ve en kötü değerlerin birbirinden oldukça farklı olması, ortalama ve standart sapma değerlerinin de diğer algoritmalarından oldukça büyük olması bu iki algoritmanın kararsız bir yapıda olduklarına işaret etmektedir.

İkinci dereceden model için elde edilen sonuçlar incelendiğinde, MPA 30 çalıştırma boyunca optimum değeri elde ederek kararlılığını ortaya koyarken, DEA küçük bir miktar sapma göstermiştir. AOA ikinci derece modelde yine bir miktar sapma göstererek MPA ve DEA’nın gerisinde kalmıştır. GWO algoritması doğrusal modelin aksine ikinci dereceden modelde büyük bir standart sapmaya sahip olarak başarısız bir performans ortaya koymuştur. MFO algoritması ise her açıdan oldukça başarısız sonuçlar elde ederek bu model için de diğer algoritmaların gerisinde kalmıştır.

Ayrıca, algoritmaların 30 çalıştırma sonucunda elde ettikleri ortalama yakınsama grafikleri incelendiğinde her iki model için de DEA’nın en hızlı yakınsama performansına sahip olduğu, MPA’nın ikinci sırayı alarak rekabetçi bir yakınsama performansına sahip olduğu gözlenmiştir. GWO ve AOA doğrusal modelde son iterasyonlarda DEA ve MPA’nın elde ettiği hata değerine yaklaşmayı başarırken, MFO bir noktadan sonra yerel minimuma takılarak

yakınsama performansını sürdürmemiştir. İkinci derece modelde ise AOA son iterasyonlara doğru DEA ve MPA'nın elde ettiği hata değerine yaklaşırken, GWO ve MFO oldukça kötü bir yakınsama performansı göstermiştir. MPA'nın bu başarısında, arama uzayının detaylı bir şekilde aranmasını sağlayan üçlü konum güncelleme stratejisinin ve algoritmanın yerel minimuma takılmasını önleyen *balık toplama cihazları* hareketinin önemli bir payı olduğu düşünülmektedir. DEA ve MPA dışındaki algoritmaların konum güncelleme stratejilerinde genel en iyi çözümden yoğun bir şekilde faydalanmaları ve yerel minimumlardan kurtulma stratejilerinin olmaması algoritmaların başarısızlığına neden olmuş olabilir.



Şekil 3. Algoritmaların İkinci Dereceden Model için Yakınsama Grafiği

Özetle, tüm karşılaştırma durumları dikkate alındığında MPA'nın enerji tahmin probleminde oldukça kararlı ve başarılı bir algoritma olduğu görülmektedir. Buradan hareketle sonraki çalışmalar için aşağıdaki önerilerde bulunulabilir:

- Bu çalışmada kullanılan doğrusal ve ikinci dereceden model dışındaki regresyon modelleri ile MPA'nın performansı enerji tahmin problemi üzerinde test edilebilir.
- Enerji tahmin problemi dışındaki problemler için MPA tabanlı regresyon modelleri geliştirilebilir.
- MPA başkaca sürekli optimizasyon problemlerinin çözümünde kullanılarak performansı analiz edilebilir.

KAYNAKLAR

Abd Elminaam, D. S., Nabil, A., Ibraheem, S. A., & Houssein, E. H. (2021). An efficient marine predators algorithm for feature selection. *IEEE Access*, 9, 60136-60153. <https://doi.org/10.1109/ACCESS.2021.3073261>

Abdel-Basset, M., El-Shahat, D., Chakraborty, R. K., & Ryan, M. (2021). Parameter estimation of photovoltaic models using an improved marine predators algorithm. *Energy Conversion Management*, 227, 113491. <https://doi.org/10.1016/j.enconman.2020.113491>

Abdel-Basset, M., Mohamed, R., & Abouhawwash, M. (2022). Hybrid marine predators algorithm for image segmentation: Analysis and validations. *Artificial Intelligence Review*, 1-53. <https://doi.org/10.1007/s10462-021-10086-0>

- Anwar, J. (2016). Analysis of energy security, environmental emission and fuel import costs under energy import reduction targets: A case of Pakistan. *Renewable Sustainable Energy Reviews*, 65, 1065-1078. <https://doi.org/10.1016/j.rser.2016.07.037>
- Arslan, S. (2023). Güncel Metasezgisel Algoritmalarının Performansları Üzerine Karşılaştırılmalı Bir Çalışma. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(4), 1861-1884. <https://doi.org/10.29130/dubited.1150453>
- Aslan, M. (2023). Archimedes optimization algorithm based approaches for solving energy demand estimation problem: a case study of Turkey. *Neural Computing and Applications*, 35(26), 19627-19649. 10.1007/s00521-023-08769-6
- Aslan, M., & Beşkirli, M. (2022). Realization of Turkey's energy demand forecast with the improved arithmetic optimization algorithm. *Energy Reports*, 8, 18-32. <https://doi.org/10.1016/j.egy.2022.06.101>
- Baştemur Kaya, C. (2023). On Performance of Marine Predators Algorithm in Training of Feed-Forward Neural Network for Identification of Nonlinear Systems. *Symmetry*, 15(8), 1610. <https://doi.org/10.3390/sym15081610>
- Baum, V. (1984). *Energy planning in developing countries*. USA: Oxford University Press.
- Bilici, Z., & Özdemir, D. (2023). Comparative analysis of metaheuristic optimization algorithms for natural gas demand forecast with meteorological parameters. *Journal of the Faculty of Engineering Architecture of Gazi University*, 38(2), 1153-1167. <https://doi.org/10.1016/j.jer.2023.100127>
- Ceylan, H., & Ozturk, H. K. (2004). Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach. *Energy Conversion Management*, 45(15-16), 2525-2537. <https://doi.org/10.1016/j.enconman.2003.11.010>
- Cihan, P. (2022). Impact of the COVID-19 lockdowns on electricity and natural gas consumption in the different industrial zones and forecasting consumption amounts: Turkey case study. *International Journal of Electrical Power & Energy Systems*, 134, 107369. <https://doi.org/10.1016/j.ijepes.2021.107369>
- de Oliveira, E. M., & Oliveira, F. L. C. (2018). Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods. *Energy*, 144, 776-788. <https://doi.org/10.1016/j.energy.2017.12.049>
- Dilaver, Z., & Hunt, L. C. (2011). Industrial electricity demand for Turkey: a structural time series analysis. *Energy Economics*, 33(3), 426-436.
- Ediger, V. Ş., & Tatlıdil, H. (2002). Forecasting the primary energy demand in Turkey and analysis of cyclic patterns. *Energy Conversion and Management*, 43(4), 473-487. [https://doi.org/10.1016/S0196-8904\(01\)00033-4](https://doi.org/10.1016/S0196-8904(01)00033-4)
- Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35(2), 512-517. <https://doi.org/10.1016/j.energy.2009.10.018>
- Es, H., Kalender Öksüz, F., & Hamzacebi, C. (2014). Forecasting the net energy demand of Turkey by artificial neural networks. *Journal of the Faculty of Engineering Architecture of Gazi University*, 29(3).
- Faramarzi, A., Heidarinejad, M., Mirjalili, S., & Gandomi, A. H. (2020). Marine Predators Algorithm: A nature-inspired metaheuristic. *Expert systems with applications*, 152, 113377. <https://doi.org/10.1016/j.eswa.2020.113377>
- Ghalekhondabi, I., Ardjmand, E., Weckman, G. R., & Young, W. A. (2017). An overview of energy demand forecasting methods published in 2005–2015. *Energy Systems*, 8, 411-447. <http://dx.doi.org/10.1007%2Fs12667-016-0203-y>
- Gorucu, F. B. (2004). Artificial Neural Network Modeling for Forecasting Gas Consumption. *Energy Sources*, 26(3), 299-307. 10.1080/00908310490256626
- Gulcu, S., & Kodaz, H. (2017). The estimation of the electricity energy demand using particle swarm optimization algorithm: A case study of Turkey. *Procedia computer science*, 111, 64-70. <https://doi.org/10.1016/j.procs.2017.06.011>
- Haldenbilen, S., & Ceylan, H. (2005). Genetic algorithm approach to estimate transport energy demand in Turkey. *Energy Policy*, 33(1), 89-98. [https://doi.org/10.1016/S0301-4215\(03\)00202-7](https://doi.org/10.1016/S0301-4215(03)00202-7)

- Hashim, F. A., Hussain, K., Houssein, E. H., Mabrouk, M. S., & Al-Atabany, W. (2021). Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems. *Applied Intelligence*, 51, 1531-1551. <https://doi.org/10.1007/s10489-020-01893-z>
- Ikram, R. M. A., Ewees, A. A., Parmar, K. S., Yaseen, Z. M., Shahid, S., & Kisi, O. (2022). The viability of extended marine predators algorithm-based artificial neural networks for streamflow prediction. *Applied Soft Computing*, 131, 109739. <https://doi.org/10.1016/j.asoc.2022.109739>
- International Energy Outlook - U.S. Energy Information Administration (EIA). (2023). <https://www.eia.gov/outlooks/ieo/data.php> Erişim: 13.11.2023
- İsmail, K., Nureddin, R., & Kahramanlı, H. (2018). Türkiye'de enerji talebini tahmin etmek için doğrusal form kullanarak gsa (yerçekimi arama algoritması) ve iwo (yabani ot optimizasyon algoritması) tekniklerinin uygulanması. *Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi*, 6(4), 529-543. <https://doi.org/10.15317/Scitech.2018.150>
- Jangir, P., Buch, H., Mirjalili, S., & Manoharan, P. (2023). MOMPA: Multi-objective marine predator algorithm for solving multi-objective optimization problems. *Evolutionary Intelligence*, 16(1), 169-195. <https://doi.org/10.1007/s12065-021-00649-z>
- Kankal, M., & Uzlu, E. (2017). Neural network approach with teaching–learning-based optimization for modeling and forecasting long-term electric energy demand in Turkey. *Neural Computing Applications*, 28, 737-747. <https://doi.org/10.1007/s00521-016-2409-2>
- Karakoyun, M., & Özkış, A. (2021). Transfer Fonksiyonları Kullanarak İkili Güve-Alev Optimizasyonu Algoritmalarının Geliştirilmesi ve Performanslarının Karşılaştırılması. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 3(2), 1-10. <https://doi.org/10.47112/neufmbd.2021.7>
- Kıran, M. S., Özceylan, E., Gündüz, M., & Paksoy, T. (2012a). A novel hybrid approach based on particle swarm optimization and ant colony algorithm to forecast energy demand of Turkey. *Energy Conversion and Management*, 53(1), 75-83. <https://doi.org/10.1016/j.enconman.2011.08.004>
- Kıran, M. S., Özceylan, E., Gündüz, M., & Paksoy, T. (2012b). Swarm intelligence approaches to estimate electricity energy demand in Turkey. *Knowledge-Based Systems*, 36, 93-103. <https://doi.org/10.1016/j.knosys.2012.06.009>
- Koc, I., Kivrak, H., & Babaoglu, I. (2019). The estimation of the energy demand in turkey using grey wolf optimizer algorithm. *Annals of the Faculty of Engineering Hunedoara*, 17(1), 113-117.
- Mirjalili, S. (2015). Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm. *Knowledge-Based Systems*, 89, 228-249. <https://doi.org/10.1016/j.knosys.2015.07.006>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Özdemir, D., Dörterler, S., & Aydın, D. (2022). A new modified artificial bee colony algorithm for energy demand forecasting problem. *Neural Computing and Applications*, 34(20), 17455-17471. <https://doi.org/10.1007/s00521-022-07675-7>
- Özkan, E. (2018). Parçacık Sürü Optimizasyonu ve Genetik Algoritma Kullanarak Türkiye'nin 2050 Yılına Kadar Enerji Tüketim Tahmininin Yapılması. Yüksek Lisans Tezi. Korkut Ata Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Ana Bilim Dalı, Osmaniye 108s.
- Özkış, A. (2020). A new model based on vortex search algorithm for estimating energy demand of Turkey. *Pamukkale University Journal of Engineering Sciences*, 26(5), 959-965. <https://dx.doi.org/10.5505/pajes.2020.74943>
- Ozturk, H. K., Ceylan, H., Canyurt, O. E., & Hepbasli, A. (2005). Electricity estimation using genetic algorithm approach: a case study of Turkey. *Energy*, 30(7), 1003-1012. <https://doi.org/10.1016/j.energy.2004.08.008>
- Ozturk, S., & Ozturk, F. (2018). Forecasting energy consumption of Turkey by Arima model. *Journal of Asian Scientific Research*, 8(2), 52.
- Storn, R., & Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11, 341-359. <https://doi.org/10.1023/A:1008202821328>

- Suganthi, L., & Samuel, A. A. (2012). Energy models for demand forecasting—A review. *Renewable Sustainable Energy Reviews*, 16(2), 1223-1240. <https://doi.org/10.1016/j.rser.2011.08.014>
- TC Enerji ve Tabii Kaynaklar Bakanlığı. Enerji üretim kaynakları ve gelecekteki talep tahminleri.(2023). <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik#:~:text=2022%20y%C4%B1nda%20elektrik%20%C3%BCretimimizin%2C%20%34,%C3%BC%20di%C4%9Fer%20kaynaklardan%20elde%20edilmi%C5%9Ftir.> Erişim: 21.12.2023
- Toksarı, M. D. (2007). Ant colony optimization approach to estimate energy demand of Turkey. *Energy Policy*, 35(8), 3984-3990. <https://doi.org/10.1016/j.enpol.2007.01.028>
- Toksarı, M. D. (2009). Estimating the net electricity energy generation and demand using the ant colony optimization approach: case of Turkey. *Energy Policy*, 37(3), 1181-1187. <https://doi.org/10.1016/j.enpol.2008.11.017>
- Top, S., & Vapur, H. (2018). Evolution of energy strategies in Turkey: Forecasts by time series. *Journal of Energy Research Reviews*, 1(4), 1-16.
- Ünler, A. (2008). Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025. *Energy Policy*, 36(6), 1937-1944. <https://doi.org/10.1016/j.enpol.2008.02.018>
- Zergane, S., Smaili, A., & Masson, C. (2018). Optimization of wind turbine placement in a wind farm using a new pseudo-random number generation method. *Renewable Energy*, 125, 166-171. <https://doi.org/10.1016/j.renene.2018.02.082>
- Zhong, K., Zhou, G., Deng, W., Zhou, Y., & Luo, Q. (2021). MOMPA: Multi-objective marine predator algorithm. *Computer Methods in Applied Mechanics Engineering*, 385, 114029. <https://doi.org/10.1007/s12065-021-00649-z>