

Estimates of Energy Consumption Using Neural Networks with the Grey Wolf Optimizer Algorithm for Turkey

Ergun UZLU

Karadeniz Technical University, Faculty of Engineering, Department of Civil Engineering, Kanuni Campus, 61080, Ortahisar/TRABZON

Graphical/Tabular Abstract

Article Info:

Received: 30.01.2019

Revision :25.02.2019

Accepted: 03.03.2019

Highlights

Predicting energy consumption in Turkey

- Training of artificial neural networks with grey wolf optimizer algorithm.
- Energy consumption was forecasted until 2023

Keywords

Grey Wolf Optimizer Algorithm
 Artificial Bee Colony Algorithm
 Back Propagation Algorithm
 Energy Consumption/Demand
 Artificial Neural Networks
 Turkey

In this study artificial neural network model with the grey wolf optimizer algorithm was used to estimate annual energy consumption of Turkey. As shown in Fig. A, a three-layer network was selected for the present study. Gross domestic product, population, import, and export values were used in the input layer of the network. Energy consumption was used in the output layer. Grey wolf optimizer algorithm was used to train the network.

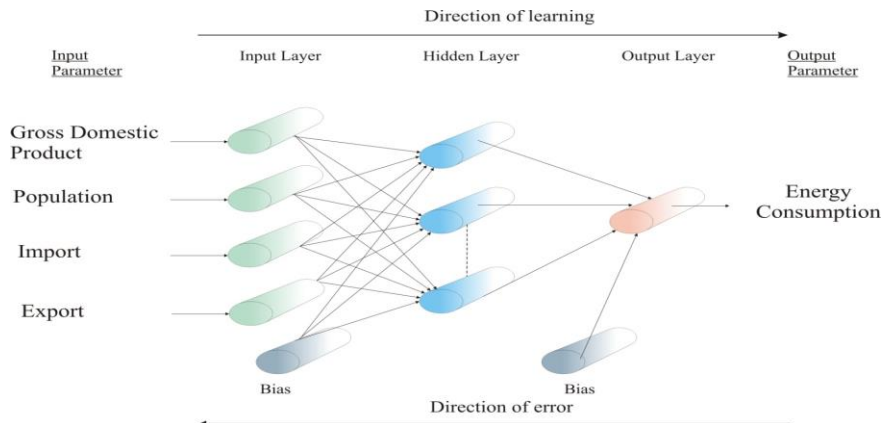


Figure A. Proposed ANN model for energy consumption

Purpose: The primary objective of this study was to train an artificial neural network (ANN) model with the grey wolf optimizer (GWO) algorithm to estimate future energy consumption (EC) of Turkey.

Theory and Methods: In the present study, gross domestic product (GDP), population, import and export data were used as independent variables to estimate the EC of Turkey. Historical data from 1980 to 2008 were used for the training procedure, while data from 2009 to 2014 were reserved for evaluating the performance of the trained network. GWO, back propagation (BP) and artificial bee colony (ABC) algorithms were used to train ANN models. To evaluate the performance of a trained ANN, average relative error (RE), root mean square error (RMSE), and mean absolute error (MAE) were used. After determining the best model according to the error values, two different scenarios were used to estimate future EC in Turkey.

Results: Simulation results show that, ANN-GWO models show better performance than ANN-BP and ANN-ABC models in EC estimation. For the proposed ANN-GWO model average RE, RMSE, and MAE values 1.252%, 2.114, and 1.349, respectively. Therefore ANN-GWO model was used in EC of Turkey.

Conclusion: In this study, the EC in Turkey between 1980 and 2023 was modeled based on GDP, population, import, and export indicators under two different scenarios. The two scenarios showed that the future EC of Turkey would vary between 183 and 191 Mtoe in 2023.



Türkiye için Gri Kurt Optimizasyon Algoritması ile Yapay Sinir Ağlarını Kullanarak Enerji Tüketiminin Tahmini

Ergun UZLU

Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Kanuni Kampüsü, 61080, Ortahisar/Trabzon

Öz

Makale Bilgisi

Başvuru: 30.01.2019
 Düzelme: 25.02.2019
 Kabul: 03.03.2019

Anahtar Kelimeler

Gri Kurt Optimizasyon Algoritması; Yapay Arı Kolonisi Algoritması; Geri Yayılımlı Algoritma; Enerji Tüketimi/Talebi; Yapay Sinir Ağları; Türkiye

Bu çalışmanın amacı gri kurt optimizasyon (GKO) algoritması ile eğitilmiş bir yapay sinir ağı (YSA) modelini kullanarak Türkiye'nin enerji tüketimini tahmin etmektir. Modelde gayri safi yurt içi hasıla, nüfus, ithalat ve ihracat verileri bağımsız değişken olarak seçilmiştir. Sunulan modelin uygulanabilirliğini ve doğruluğunu değerlendirmek için, YSA-GKO modeli yapay arı kolonisi (YAK) algoritması ve geri yayılımlı (GY) algoritma ile eğitilmiş YSA modelleri ile karşılaştırıldı. Yapılan karşılaştırmalar YSA-GKO modelinin YSA-YAK ve YSA-GY modellerinden daha üstün olduğunu göstermiştir. YSA-GKO modeli kullanılarak Türkiye'nin enerji tüketimi iki farklı senaryoya göre 2023'e kadar tahmin edilmiştir. Elde edilen sonuçlar Enerji ve Tabii Kaynaklar Bakanlığı ve literatürdeki çalışmalardan elde edilen sonuçlarla karşılaştırılmıştır. Sonuçlar YSA-GKO modelinin enerji tüketimi tahmininde kullanılabileceğini göstermiştir.

Estimates of Energy Consumption Using Neural Networks with the Grey Wolf Optimizer Algorithm for Turkey

Keywords

Grey Wolf Optimizer Algorithm; Artificial Bee Colony Algorithm; Back Propagation Algorithm; Energy Consumption/Demand; Neural Networks; Turkey

Abstract

The primary objective of this study was to apply the ANN (artificial neural network) model with the grey wolf optimizer (GWO) algorithm to estimate energy consumption of Turkey. Gross domestic product, population, import, and export data were selected as independent variables in the model. To assess the applicability and accuracy of the proposed method, ANN-GWO was compared with the ANN models trained with artificial bee colony (ABC) and back propagation (BP) algorithms. Solutions indicate that the ANN-GWO model is superior to ANN-ABC and ANN-BP models. Using the ANN-GWO model, future estimation of Turkey's energy consumption was projected up to 2023 according to two different scenarios. The forecasted results were compared with projections by the MENR (Ministry of Energy and Natural Resources) and other related studies in the literature. The results show that energy consumption can be modeled using the proposed model and the ANN-GWO can be used to predict future energy consumption.

1. GİRİŞ (INTRODUCTION)

Enerji çağımızda ülkelerarası ilişkileri ve ülkelerin ekonomik, siyasi ve sosyal gelişimini etkileyen temel etmenlerden birisi haline gelmiştir. Dünyanın önde gelen enerji tedarikçileri ile büyük tüketicileri arasında doğal bir coğrafi köprü, dolayısıyla da enerji merkezi ve koridoru oluşturan Türkiye, küresel enerji jeopolitiği ve Avrupa'nın doğal gaz arz güvenliği için büyük önem taşımaktadır.

2014 yılında dünya birincil enerji talebinin % 81'i petrol, doğal gaz ve kömürden karşılanmış olup, bu oran Türkiye'de % 91'dir [1, 2]. 2014 yılında 123,9 Mtoe olan Türkiye'nin birincil enerji talebinin 2022 yılı itibarıyla 222.4 Mtoe'ye ulaşması beklenmektedir [2, 3]. 2014 yılında Türkiye'de birincil enerji talebinin % 35'i doğal gazdan, % 28,5'i kömürden, % 27'si petrolden, % 7'si hidroelektrik santrallerinden, % 2,5'i de diğer yenilenebilir enerji kaynaklarından sağlanmaktadır [2]. Hızlı ve sürdürülebilir bir ekonomik büyümenin sağlanması, artan enerji ihtiyacının karşılanması ve uluslararası alanda rekabet gücünün korunması, enerji alanında etkin politikaların izlenmesini gerekli kılmaktadır. Gerçekçi ve güvenilir enerji talep projeksiyonları etkin bir enerji politikası izlenmesinde büyük öneme sahiptir. Türkiye 'de enerji talebi

için projeksiyonlar Enerji ve Tabii Kaynaklar Bakanlığı (ETBK) tarafından yapılmaktadır. ETBK tarafından yapılan talep projeksiyonları gerçek değerlerden oldukça yüksektir [4]. Bu durum enerji politikalarıyla ilgili karar vericileri yanlış yönlendirmektedir.

Bu nedenle, Türkiye’de enerji kaynaklarına ucuz, kesintisiz ve güvenilebilir bir biçimde ulaşılabilmesi için daha doğru enerji tüketim projeksiyonlarına ihtiyaç duyulmaktadır.

Bu çalışmada Türkiye’nin enerji tüketimini tahmin etmek için yeni ve gerçekçi bir model geliştirilmiştir. Model yapay sinir ağlarının (YSA) gri kurt optimizasyonu (GKO) algoritması ile eğitilmesi sonucu oluşturulmuştur. Gayri safi yurt içi hasıla (GSYİH), nüfus, ithalat ve ihracat verileri geliştirilen modelde bağımsız değişkenler olarak kullanılmıştır. Geliştirilen model kullanılarak Türkiye’nin gelecekteki enerji tüketim değerleri iki farklı senaryo için tahmin edilmiştir.

2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Dünyanın farklı yerlerinde enerji tüketimini ve talebini modellemek için birçok teknik ileri sürülmüştür. Çin’in enerji tüketimini tahmin etmek için Guo vd. [5] LEAP modelini, Yu vd. [6] parçacık sürüsü optimizasyonu (PSO) algoritması ve genetik algoritmadan (GA) oluşan bir hibrit modeli, Fan ve Xia [7] geliştirilmiş RAS yöntemini, Zeng vd. [8] ADE-BPNN modelini ve Wang vd. [9] AMVO-SVM modelini kullanmıştır. Geem ve Roper [10], Ekonomou [11], Oludolapo vd. [12] ve Muralitharan vd. [13] YSA’yı kullanarak sırasıyla Güney Kore, Yunanistan, Güney Afrika ve Texas’taki enerji tüketimini tahmin etmiştir. Sutthichaimethee ve Ariyasajakorn [14] ARIMAX modelini kullanarak Tayland’ın enerji tüketimini tahmin etmiştir. Ayrıca Behrang vd. [15] İran’da aynı amaç için arı algoritmasını kullanmıştır.

Benzer şekilde Türkiye’nin enerji tüketimini ve talebini tahmin etmek için birçok farklı teknik kullanıldı. Tablo 1’den görüldüğü gibi, Sozen vd. [16-18], Kankal vd. [19] ve Es vd. [20] YSA tekniğini, Ozturk vd. [21], Canyon vd. [22], Ceylan vd. [23] ve Ceylan ve Ozturk [24] GA’yı, Toksari [25] karınca kolonisi optimizasyonu algoritmasını (ACO), Unler [26] PSO algoritmasını, Kıran ve Gunduz [27] PSO ve yapay arı kolonisi (YAK) algoritmasını, Kıran vd. [28] PSO ve YAK algoritmalarından oluşan bir hibrit modeli, Ediger ve Akar [29] ve Mucuk ve Uysal [30] ARIMA modelini, Uzlu vd. [4] öğretim öğrenme tabanlı optimizasyonu (TLBO) algoritması ile eğitilmiş YSA modelini, Say ve Yücel [31] ve Aydın [32] regresyon analizini, Ediger ve Tatlidil [33] istatistiksel bir teknik olan çevrim analizini ve Tefek vd. [34] ise TLBO’yu kullanarak Türkiye’nin enerji tüketimini tahmin etmişlerdir.

Bu çalışmada, Türkiye’nin enerji tüketimini tahmin etmek için GKO algoritması ile eğitilmiş bir YSA modeli oluşturulmuştur. Literatüre göre, enerji tüketiminin modellenmesinde ve tahmininde YSA-GKO modeli daha önce hiç kullanılmamıştır.

Tablo 1. Türkiye’de Enerji Tüketimi ve Talebinin Tahmin Edilmesine Yönelik Çalışmalar


Kullanılan yöntem	Referans	Tahmin edilen değer	Bağımsız değişkenler	Kullanılan veriler	Tahmin edilen yıllar
YSA tekniği	Sozen ve Arcaklioglu [16]	Enerji tüketimi	GSMH, GSYİH, nüfus, kurulu güç, elektrik üretimi, ithalat, ihracat	1968-2005	Model kuruldu
	Sozen vd. [17]	Enerji tüketimi	Nüfus, toplam üretim, kurulu kapasite, diğer yıllar	1975-2003	Model kuruldu
	Sozen vd. [18]	Enerji tüketimi	Nüfus, toplam üretim kurulu kapasite	1953-2000	Model kuruldu
	Kankal vd. [19]	Enerji tüketimi	GSYİH, nüfus, ithalat, ihracat	1980-2007	2008-2014
	Es vd. [20]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat, araç sayısı, bina yüzey alanı	1970-2010	2011-2025
Genetik algoritma	Ozturk vd. [21]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1975-2002	2003-2020
	Canyurt vd. [22]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1970-2001	2002-2025
	Ceylan vd. [23]	Enerji tüketimi	GSYİH, nüfus, ithalat, ihracat	1990-2000	2001-2020
	Ceylan ve Ozturk [24]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1970-2001	2002-2025
ACO	Toksari [25]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1970-2005	2006-2025
PSO	Unler [26]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1979-2005	2006-2025
PSO ve YAK hibrid modeli	Kıran ve Gunduz [27]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1979-2005	2006-2015
PSO ve ACO hibrid modeli	Kıran vd. [28]	Enerji talebi	GSYİH, nüfus, ithalat, ihracat	1979-2005	2006-2025
ARIMA modeli	Ediger ve Akar [29]	Enerji talebi	-	1950-2004	2005-2020
	Mucuk ve Uysal [30]	Enerji talebi	-	1970-2006	2007-2015
Regresyon analizi	Say ve Yuçel [31]	Enerji tüketimi	GSMH, nüfus	1970-2002	2010 ve 2015
	Aydın [32]	Enerji tüketimi	GSYİH, nüfus	1971-2010	2011-2025
Çevrim analizi	Ediger ve Tatlıdil [33]	Enerji talebi	-	1950-1999	2000-2010
YSA-TLBO	Uzlu vd. [4]	Enerji tüketimi	GSYİH, nüfus, ithalat, ihracat	1980-2012	2013-2020
TLBO	Tefek vd. [34]	Enerji talebi	GSYİH, nüfus, kurulu güç, toplam elektrik üretimi, net elektrik tüketimi	1980-2014	2015-2030
YSA-GKO	Bu çalışma	Enerji tüketimi	GSYİH, nüfus, ithalat, ihracat	1980-2014	2015-2023

3. YÖNTEM (METHODOLOGY)


3.1. Veri Seti (Data Set)

Sunulan çalışmada Türkiye’nin enerji tüketimini tahmin etmek için GSYİH, nüfus, ithalat ve ihracat verileri bağımsız değişken olarak kullanılmıştır. Bu değişkenler enerji tüketimini tahmin etmek için literatürde [19, 22-28] yaygın bir şekilde kullanılmaktadır. YSA modellerinde kullanılan veriler iki gruba ayrılmıştır. 1980’den 2007’ye kadar olan veriler eğitim sürecinde, 2008’den 2014’e kadar olan veriler ise geliştirilen modellerin test edilmesinde kullanılmıştır. Beş değişken için farklı kaynaklardan veriler elde edilmiştir.


Elde edilen enerji tüketim verileri Şekil 1’de, nüfus verileri Şekil 2’de ve GSYİH, ithalat ve ihracat verileri ise Şekil 3’te sunulmuştur.



Şekil 1. Enerji tüketim verilerinin yıllara göre değişimi [2]



Şekil 2. Nüfus verilerinin yıllara göre değişimi [35]



Şekil 3. GSYİH, ithalat ve ihracat verilerinin yıllara göre değişimi [36, 37]

Nüfus, ithalat ve ihracat verileri (Türkiye İstatistik Kurumu) TÜİK'den elde edilmiştir [35, 36]. GSYİH değerleri Strateji ve Bütçe Başkanlığından [37] alınmıştır. Enerji tüketim verileri ise Enerji ve Tabii Kaynaklar Bakanlığı'ndan alınmıştır [2]. YSA modellerinin eğitimini kolaylaştırmak için giriş ve çıkış verileri [0.1, 0.9] aralığına indirgenmiştir. YSA'nın girdi ve çıktı katmanlarında kullanılan aktivasyon fonksiyonlarının daha etkin sonuçlar üretebilmesi için 0 yerine 0.1, 1 yerine 0.9 değerleri verilmesi daha uygun olmaktadır [38]. İndirgeme işlemi aşağıdaki denklem kullanılarak yapılmıştır.

$$\text{İndirgenen değer} = \left[\frac{\text{Ham değer} - \text{Minimum değer}}{\text{Maksimum değer} - \text{Minimum değer}} \right] \times (0.9 - 0.1) + 0.1 \quad 1$$

3.2. Yapay Sinir Ağları (Artificial Neural Networks (ANNs))

Yapay sinir ağları enerji modellenmesi alanında yaygın bir şekilde kullanılmaktadır [4]. Bu çalışmada, enerji tüketimini tahmin etmek için çok katmanlı ileri beslemeli bir yapay sinir ağı yapısı kullanılmıştır. Seçilen yapay sinir ağı modeli bir ara katman, bir giriş katmanı ve bir çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Geçmiş çalışmalar [4, 19, 39, 40, 41] incelendiğinde bir ara katmanlı YSA modellerinin oldukça iyi sonuçlar verdiği gözlenmiştir. Ayrıca tek ara katman kullanmak optimizasyon sürecini kısaltmaktadır. Bu nedenle bu çalışmadaki YSA modellerinde tek ara katman kullanılmıştır.

Ara katmandaki nöron sayısını belirlemek için 5, 10, 15 ve 20 değerleri girilip denemeler yapılmıştır. Aktivasyon fonksiyonu olarak, giriş katmanı ile ara katman arasında tanjant sigmoid fonksiyonu, ara katman ile çıkış katmanı arasında ise lineer fonksiyon kullanılmıştır. Geri yayılım (GY), YAK ve GKO algoritmaları YSA modellerinin eğitiminde kullanılmıştır.

YSA eğitiminde amaç fonksiyonu olarak ortalama karesel hata (OKH) kullanılmıştır. GY, YAK ve GKO algoritmaları amaç fonksiyonunu minimize etmeye çalışır. OKH aşağıdaki denklemle ile hesaplanır.

$$OKH = \frac{1}{n} \sum_{k=1}^n (y_k - o_k)^2 \quad 2$$

Denklem 2’de o_k YSA’nın tahmin ettiği değer, y_k gerçek değer, ve n ise toplam veri sayısıdır.

3.3. Geri Yayılımlı Algoritma (Back Propagation Algorithm)

Rumelhart vd. [42] tarafından geliştirilen GY algoritması yapay sinir ağlarının eğitiminde kullanılan en eski ve yaygın yöntemlerden biridir [43]. GY algoritmasının amacı giriş verilerine en yakın çıkış verilerini üreten yapay sinir ağı ağırlıklarını bulmaktır. Giriş ve çıkış verileri arasında hesaplanan hata değeri ağırlık katmanlarına geri yayılır. Ağırlıklar hata fonksiyonuna katkı miktarlarına göre güncellenir. Bu değer aşağıdaki gibi hesaplanır.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad 3$$

Denklem 3’de η ağırlık değerinde yapılacak değişimin miktarını belirleyen öğrenme katsayısıdır.

GY algoritması birçok çalışmada detaylı olarak anlatılmıştır [4, 39, 42]. Tekrara düşmemek için bu kısım mümkün olduğunca kısa tutulmuştur. GY algoritması yapay sinir ağlarının eğitiminde sıklıkla kullanılmasına rağmen, ezberleme problemin olması, yerel bir çözüme takılması, en uygun öğrenme ve momentum katsayılarının ayarlanma güçlüğü gibi bazı sakıncaları vardır. Bu sebeplerden dolayı ağırlık eğitilmesi güçleşmektedir.

3.4. Yapay Arı Kolonisi Algoritması (Artificial Bee Colony Algorithm)

YAK algoritması bal arılarının yiyecek arama davranışları modellenerek Karaboğa tarafından 2005 yılında geliştirilmiştir [44]. Algoritmada yiyecek kaynaklarının yerleri eniyileme problemine ait olası çözümlere, kaynakların nektar miktarı ise o kaynaklarla ilgili çözümlerin kalitesine (uygunluk) karşılık gelmektedir [39]. Bu çalışmada yapay sinir ağı modelindeki ağırlıklar çözüm parametrelerini oluşturmaktadır.

YAK algoritmasında üç çeşit arı vardır bunlar: işçi, gözcü ve kaşif arılardır. Algoritmanın ilkendirme aşamasında arama uzayındaki çözümlere karşılık gelen rastgele yiyecek kaynağı yerleri üretilir (Denklem 4) ve bu yerler için nektar miktarı (uygunluk değeri) hesaplanır (Denklem 5) [44].

$$x_{ij} = x_j^{\min} + rand(0, 1)(x_j^{\max} - x_j^{\min}) \quad 4$$

$$fit_i = \begin{cases} \frac{1}{1 + f_i} & \text{if } f_i \geq 0 \\ 1 + abs(f_i) & \text{if } f_i < 0 \end{cases} \quad 5$$

Burada $i = 1 \dots SN$; $j = 1 \dots D$; SN yiyecek kaynağı sayısı ve D ise optimize edilecek parametre sayısıdır. x_j^{\min} j. parametrenin alt sınırı, x_j^{\max} j. parametrenin üst sınırı, f_i ise amaç fonksiyonunun değeridir. Her işçi arı bu ilk kaynak yerlerinin komşuluğunda nektar miktarı daha fazla olan yeni kaynak yerleri bulmaya çalışır (Denklem 6) [39].

$$v_{ij} = x_{ij} + \varphi_{ij}(x_{ij} - x_{kj}) \quad 6$$

x_i ile gösterilen her bir kaynak için bu kaynağın yani çözümün tek bir parametresi (rastgele seçilen parametresi, j) değiştirilerek x_i komşuluğunda v_i kaynağı bulunur. Burada j ve k sırasıyla $\{1, 2, \dots, D\}$ ve

$\{1,2,\dots, SN\}$ aralıklarında rastgele seçilen indislerdir. φ_{ij} ise $[-1,1]$ aralığında rastgele seçilen bir sayıdır [42].

Tüm görevli arılar bir çevrimde araştırmalarını tamamladıktan sonra kovana dönüp buldukları kaynakların nektar miktarları ile ilgili gözcü arılara bilgi aktarır. Gözcü arılar görevli arı tarafından sağlanan uygunluk (fit_i) değerini kullanarak bir olasılık değeri (Denklem 7) hesaplar. Bu olasılık değerine göre bir kaynak yeri seçer [42].

$$p_i = \frac{fit_i}{\sum_{i=1}^{SN} fit_i} \quad 7$$

Bir arının gidip geldiği kaynağın nektarının tükenip tükenmediğinin belirlenmesi için kullanılan eşik değeri “limit” olarak adlandırılmaktadır. Bir kaynak için çözüm geliştirememeye sayacı limit değerinin üzerindeyse, bu kaynağın görevli arısı bu çözümü bırakarak kaşif arıya dönüşür ve kendisi için daha iyi bir çözüm aramaya başlar (Denklem 4). Bulunan yeni kaynak yeri daha iyi ise eski kaynak yeri unutulur ve iyi olan hafızada tutulur. Bu döngü maksimum çevrim sayısına kadar devam eder.

YAK algoritmasında üç adet kontrol parametresi vardır. Bunlardan ilki yiyecek kaynağı sayısıdır ve popülasyonun büyüklüğünün yarısına eşittir. Bu değer aynı zamanda görevli arı sayısına eşittir. İkincisi maksimum çevrim sayısı, üçüncüsü ise limit değeridir. YAK algoritması ile ilgili detaylı bilgi literatürdeki çalışmalarda [39, 44] bulunabilir.

3.5. Gri Kurt Optimizasyon Algoritması (Grey Wolf Optimizer Algorithm)

Çoğu evrimsel ve yapay zeka algoritmaları olasılık içeren algoritmalar olup bir problemin optimizasyon sürecinde popülasyon hacmi, yineleme hacmi gibi genel kontrol parametreleri gerektirmektedirler. Bu genel kontrol parametrelerinin yanı sıra, farklı algoritmalar kendi özel kontrol parametrelerini de gerektirmektedirler. Örneğin, GA, bir optimizasyon probleminin çözümünde mutasyon oranı, çaprazlama oranı ve seçim operatörlerini kullanırken, YAK algoritması, seyirci arı, işçi arı, izci arı gibi kendi özel kontrol parametrelerini kullanmaktadırlar. Bu eniyileme algoritmalarının performanslı çalışması bahsedilen bu kontrol parametrelerinin doğru kullanımına bağlıdır. Bu açıdan bakıldığında zaman kontrol parametresi az olan eniyileme algoritmalarının kullanımı daha cazip hale gelecektir.

Araştırmacı Mirjalili vd. [45] tarafından 2014’te geliştirilen ve GKO olarak adlandırılan bir başka optimizasyon algoritması, yukarıda sözü edilen kontrol parametrelerinin kullanımını en aza indirgeyerek oluşturulan bir yapay zeka algoritmasıdır. GKO algoritmasında kontrol parametresi olarak popülasyon büyüklüğü ve iterasyon sayısı kullanılır.

GKO algoritması gri kurtların doğadaki yiyecek arama davranışlarından ve liderlik hiyerarşisinden esinlenilerek geliştirilmiştir. Liderlik hiyerarşisini simüle etmek için GKO’da dört çeşit kurt vardır. Bunlar (α) alfa, (β) beta, (δ) delta ve (ω) omega’dır [45].

GKO’da en iyi çözüm (α) olarak adlandırılır. İkinci ve üçüncü en iyi çözüm ise sırasıyla (β) ve delta (δ) olarak adlandırılır. Geriye kalan aday çözümler ise (ω) olarak adlandırılır. Avlanma (optimizasyon) (α), (β) ve (δ) tarafından yönlendirilir. Optimizasyon sırasında kurtlar pozisyonlarını α , β yada δ etrafında aşağıdaki gibi güncellerler [46].

$$\vec{D} = \left| \vec{C} \cdot \vec{X}_p(t) - \vec{X}(t) \right| \quad 8$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad 9$$

Denklem 8 ve 9'da, t mevcut iterasyonu gösterir. \vec{A} ve \vec{C} katsayı vektörleridir. \vec{X}_p ve \vec{X} ise sırasıyla avın bir gri kurdun konumunu gösteren vektörlerdir. \vec{A} ve \vec{C} vektörleri aşağıdaki gibi hesaplanır.

$$\vec{A} = 2 \cdot \vec{a} \cdot \vec{r}_1 - \vec{a} \quad 10$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad 11$$

Denklem 10'da \vec{a} vektörünün bileşenleri optimizasyon sırasında 2'den sıfıra doğru lineer olarak azalır. \vec{r}_1 ve \vec{r}_2 ise $[0, 1]$ aralığında rastgele vektörlerdir. Bir gri kurt denklem 8 ve 9'u kullanarak konumunu, avın etrafındaki rastgele bir yer olarak değiştirebilir [45].

GKO algoritmasında, alfa, beta ve deltanın avın potansiyel yeri hakkında daha iyi bilgiye sahip olduğu varsayılmaktadır. Optimizasyon sırasında, şimdiye kadar elde edilen ilk üç en iyi çözüm sırasıyla α , β ve δ olarak kabul edilir. Daha sonra, diğer kurtlar ω olarak kabul edilir ve α , β ve δ 'ya göre yeniden konumlandırılabilir [45, 46]. ω kurtlarının konumunu yeniden ayarlamak için önerilen matematiksel ifade şu şekildedir:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad 12$$

$$\vec{D}_\beta = |\vec{C}_1 \cdot \vec{X}_\beta - \vec{X}| \quad 13$$

$$\vec{D}_\delta = |\vec{C}_1 \cdot \vec{X}_\delta - \vec{X}| \quad 14$$

yukarıda \vec{X}_α , \vec{X}_β ve \vec{X}_δ sırasıyla alfa, beta ve deltanın konumunu gösterir. \vec{C}_1 , \vec{C}_2 ve \vec{C}_3 rastgele vektörlerdir. \vec{X} ise mevcut çözümün konumunu gösterir. Denklem 12, 13 ve 14, mevcut çözüm ile alfa, beta ve delta arasındaki yaklaşık mesafeyi hesaplar. Mesafeleri belirledikten sonra, mevcut çözümün son konumu aşağıdaki gibi hesaplanır [45, 46].

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha) \quad 15$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta) \quad 16$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad 17$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad 18$$

yukarıda \vec{A}_1 , \vec{A}_2 ve \vec{A}_3 rastgele vektörlerdir, t ise iterasyon sayısını gösterir.

GKO algoritmasının genel adımları aşağıdaki gibidir:

- Değişkenlerin üst ve alt sınırlarına bağlı olarak rastgele bir kurt popülasyonu başlat.
- Her bir kurt için karşılık gelen amaç fonksiyonu değerini hesapla.
- İlk üç en iyi kurdu seç ve bunları α , β ve δ olarak kaydet.

- Nüfusun geri kalanının (ω kurtlarının) konumunu denklem 12'den 16'ya kadar olan denklemleri kullanarak güncelle.
- α , A ve C parametrelerini güncelle.
- En iyi yakınsanan değer olarak α 'nın konumuna geri dön.

GKO algoritması ile ilgili detaylı bilgi literatürdeki çalışmalarda [45, 46] bulunabilir.

3.6. GY, YAK ve GKO Algoritmaları ile YSA Eğitimi (ANN's Training with BP, ABC, and GWO algorithms)

Bu çalışmada GY, YAK ve GKO algoritmaları kullanılarak YSA eğitilmiştir. Algoritmaların amacı YSA için seçilen amaç fonksiyonun değerini en aza indirmektir. Eğitim sırasında amaç fonksiyonu en aza indirgenirken, ağırlık değerleri de sürekli güncellenir. Eğitim süreci, amaç fonksiyonu kabul edilebilir bir değere inene kadar ya da istenilen koşurma sayısına ulaşıncaya kadar devam eder. Bu çalışmada amaç fonksiyonu olarak OKH (Denklem 1) seçilmiştir.

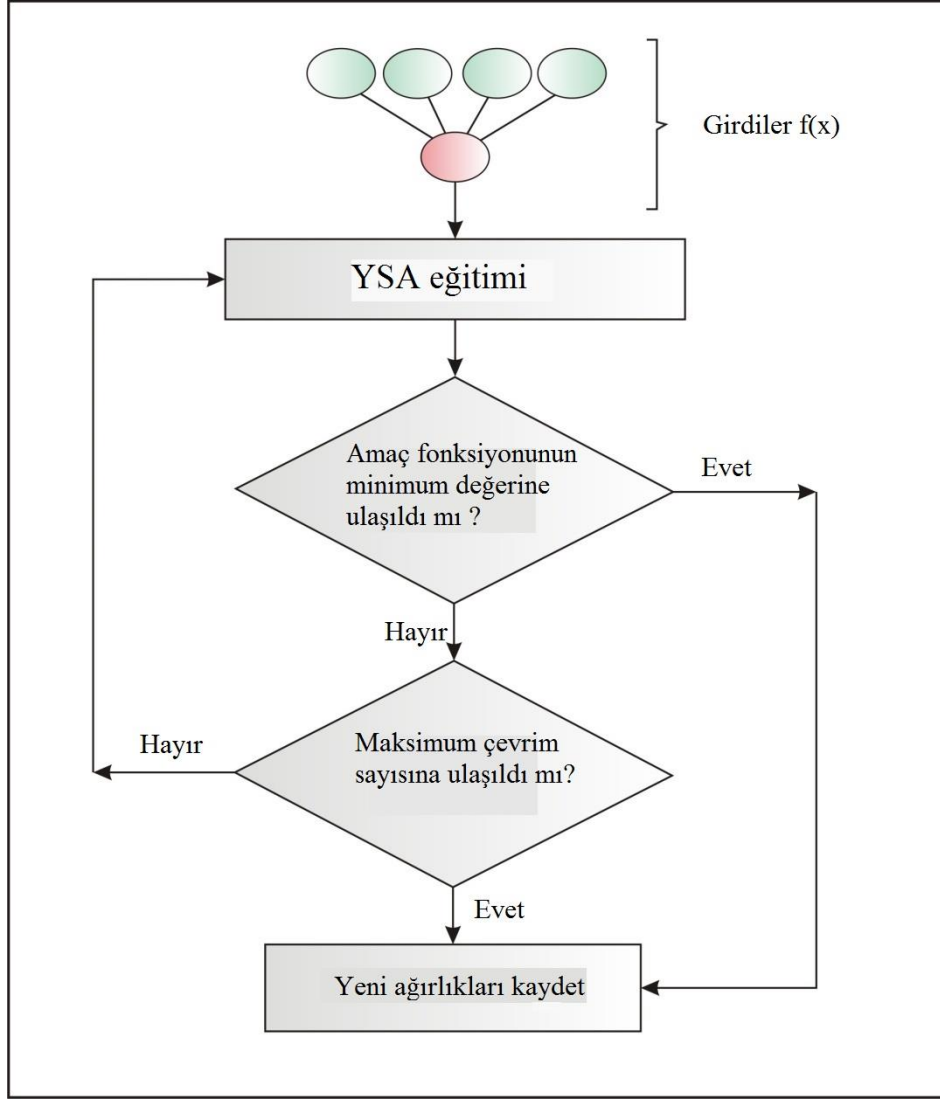
Eğitilen YSA modellerinin performansını hesaplamak için ortalama rölatif hata (RH), ortalama karesel hataların karekökü (OKHK) ve ortalama mutlak hata (OMH) kullanılmıştır. Bu hata değerleri YSA tarafından tahmin edilen enerji tüketim değerlerinin (y_k) gerçek enerji tüketim değerlerine (o_k) ne kadar yaklaştığını gösterir. Ortalama RH, OKHK ve OMH aşağıdaki gibi hesaplanır.

$$\text{ortalama RH} = \frac{\sum_{i=1}^n \left(\frac{y_k - o_k}{y_k} \right)}{n} \times 100 \quad 19$$

$$\text{OKHK} = \left[\frac{1}{n} \sum_{i=1}^n (y_k - o_k)^2 \right]^{1/2} \quad 20$$

$$\text{OMH} = \frac{1}{n} \sum_{i=1}^n |(y_k - o_k)| \quad 21$$

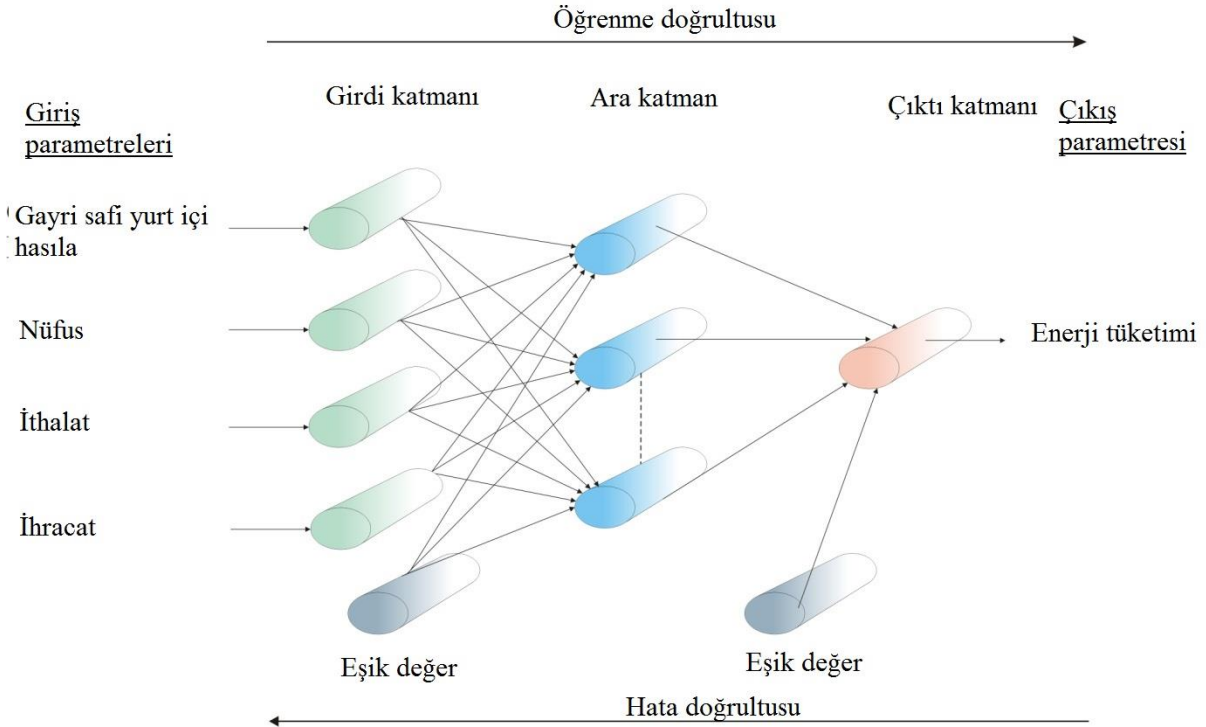
YAK ve GKO algoritmalarında ortak kontrol parametreleri olan maksimum iterasyon sayısı ve popülasyon büyüklüğü sırasıyla 5,000 ve 50 olarak seçilmiştir. Ayrıca YAK algoritmasında, limit değeri ve gözcü arı sayısı sırasıyla 100 ve 25 olarak ayarlanmıştır. YSA'nın ağırlık değerleri için çözüm aralığı [-1, 1] ve amaç fonksiyonun indirgeneceği en küçük değer 8×10^{-8} olarak seçilmiştir. YSA eğitimi için akış şeması Şekil 4'te sunulmaktadır.



Şekil 4. YSA için önerilen eğitim şeması

4. TAHMİN MODELİNİN PERFORMANS DEĞERLENDİRMESİ (PERFORMANCE EVALUATION OF FORECASTING MODEL)

Şekil 5'ten görüldüğü gibi, geliştirilen model için üç katmanlı bir ağ seçilmiştir. GSYİH, nüfus, ithalat ve ihracat verileri YSA modelinin girdi katmanında kullanılmıştır. Enerji tüketimi ise çıktı katmanında kullanılmıştır. GY, YAK ve GKO algoritmaları YSA'yı eğitmek için kullanılmıştır. Tablo 2'de üç farklı algoritma için YSA eğitiminden elde edilen en küçük yakınsama değerleri sunulmaktadır.



Şekil 5. Enerji tüketimi için önerilen YSA modeli

Tablo 2. YSA Eğitimi için GY, YAK ve GKO Algoritmalarının En İyi Yakınsama Değerleri

YSA yapısı	MSE		
	GY Algoritması	YAK Algoritması	GKO Algoritması
4-5-1	12.374	4.359	7.906
4-10-1	7.741	3.958	2.834
4-15-1	7.710	10.815	4.807
4-20-1	6.764	6.154	5.148

Not: Koyu yazılan değer önerilen model için hata değerini göstermektedir.

En küçük yakınsama değerleri YSA-GY (4-20-1), YSA-YAK (4-5-1) ve YSA-GKO (4-10-1) için sırasıyla 6.764, 4.359 ve 2.834 olarak bulunmuştur. Tablo 2'deki değerlerden görüleceği üzere GKO algoritması YSA eğitiminde GY ve YAK algoritmasından daha iyi performans göstermiştir. Fakat eğitilen modellerin tahmin yeteneklerinin doğruluğuna karar verirken test setinin hataları dikkate alınmıştır. Tablo 3'te eğitilen YSA modellerinin test seti için hesaplanan hata değerleri sunulmaktadır. Tablo 2 ve Tablo 3'teki değerler incelendiğinde hem eğitim hem de test seti için en küçük hata değerleri ara katmanında 10 eleman bulunan YSA-GKO (4-10-1) modelinden elde edilmiştir. Önerilen YSA-GKO (4-10-1) modeli için hesaplanan ortalama RH, OKHK ve OMH değerleri sırasıyla 1.252, 2.114 ve 1.349'dur.

Tablo 3. Test Seti için Modellerin Sonuçları

YSA yapısı	Ortalama rölatif hata (%)			OKHK (Mtoe)			OMH (Mtoe)		
	GY	YAK	GKO	GY	YAK	GKO	GY	YAK	GKO
4-5-1	2.223	1.561	1.304	2.932	2.566	2.211	2.514	1.692	1.395
4-10-1	2.186	1.357	1.252	2.938	2.317	2.114	2.417	1.456	1.349
4-15-1	2.035	1.841	1.296	3.482	2.652	2.464	2.201	2.044	1.369
4-20-1	1.811	1.307	1.292	2.874	2.446	2.344	1.954	1.388	1.376

Not: Koyu yazılan değerler önerilen model için hata değerleridir.

Kıran vd. [28], Canyurt vd. [22], Ceylan vd. [23], Ceylan ve Ozturk [24], Ediger ve Akar [29], ve Uzlu vd. [4] tarafından Türkiye için geliştirilen enerji tüketim tahmin modellerinin ortalama rölatif hata değerleri sırasıyla 2.77%, 2.72%, 1.77%, 6.16%, 3.3% ve 1.50%'dir. Görüldüğü gibi tüm rölatif hata değerleri önerilen YSA-GKO modelinin hata değerinden yüksektir. Fakat literatürdeki modellerin eğitim ve test aşamalarında farklı zaman aralıklarındaki veriler kullanıldığı için, bu durum önerilen modelin literatürdeki modellerden daha iyi olduğu anlamına gelmemektedir.

Fakat Tefek vd. [34] enerji tüketim tahmin modellerini geliştirmek için 1980'den 2010'a kadar olan verileri eğitim, 2011'den 2014'e kadar olan verileri ise geliştirdikleri modeli test etmek için kullanmışlardır. Bu çalışmada ise test seti için 2008'den 2014'e kadar olan veriler kullanılmıştır. Tefek vd. [34] ve bu çalışmada geliştirilen model arasında bir karşılaştırma yapabilmek için 2011 ve 2014 arasındaki enerji tüketim değerleri dikkate alınarak hata değerleri hesaplanmıştır. Tefek vd. [34] ve bu çalışmada geliştirilen modellerin 2011 ve 2014 arasındaki enerji tüketim verileri dikkate alınarak hesaplanan ortalama RH değerleri sırasıyla 0.920 ve 0.517, OKHK değerleri ise sırasıyla 1.171 ve 0.705'dir. Sonuçlar önerilen modelin Tefek vd. [34] tarafından geliştirilen modelden daha iyi tahmin yaptığını göstermektedir.

5. ENERJİ TÜKETİMİNİN GELECEKTEKİ TAHMİNLERİ (FUTURE PREDICTIONS OF ENERGY CONSUMPTION)

İki farklı senaryo kullanılarak Türkiye'nin 2015 ve 2023 yılları arasındaki enerji tüketim değerleri tahmin edilmiştir. Senaryolarda kullanılan verilerin bir kısmı devlet raporlarından diğerleri ise orjinal büyüme oranları dikkate alınarak elde edilmiştir. Senaryolarda kullanılan nüfus verileri TÜİK'ten alınmıştır [35]. Tüm Senaryolar ve senaryolarda kullanılan GSYİH, nüfus, ithalat ve ihracat değerleri sırasıyla Tablo 4 ve 5'te sunulmaktadır.

Tablo 4. Senaryolarda Kullanılan GSYİH, Nüfus, İthalat ve İhracat Değerleri

Yıl	GSYİH (milyar \$)	Nüfus (10 ⁶)	İthalat (Milyar \$)		İhracat (Milyar \$)	
	Büyüme oranı 6.82%	TÜİK [35]	Büyüme oranı 11.20%	TİM [47]	Büyüme oranı 13.17%	TİM [47]
2015	854.674	78.151	269.301	272.689	178.367	204.877
2016	912.963	78.965	299.463	304.048	201.858	228.438
2017	975.227	79.766	333.002	339.013	228.443	254.709
2018	1,041.738	80.551	370.299	378.000	258.529	284.000
2019	1,112.784	81.321	411.772	397.199	292.577	317.759
2020	1,188.676	82.076	457.890	444.863	331.109	355.890
2021	1,269.743	82.816	509.174	498.246	374.717	398.597
2022	1,356.340	83.540	566.201	558.036	424.067	446.429
2023	1,448.843	84.247	629.616	625.000	479.916	500.000


Tablo 5. Türkiye'nin Enerji Tüketimi için Senaryolar

Senaryolar	GSYİH	Nüfus	İthalat	İhracat
Senaryo 1	Gerçek büyüme oranı (yaklaşık 6.82%)	TÜİK'den alınan nüfus verileri [35]	Gerçek büyüme oranı (yaklaşık 11.20%)	Gerçek büyüme oranı (yaklaşık 13.17%)
Senaryo 2	Gerçek büyüme oranı (yaklaşık 6.82%)	TÜİK'den alınan nüfus verileri [35]	TİM raporundan alınan veriler [47]	TİM raporundan alınan veriler [47]

Elde edilen gelecek enerji tüketim değerleri ve bu değerlerin Kıran vd. [28], Tefek vd. [34], ve ETKB [3] tarafından yapılan tahminlerle karşılaştırılması Şekil 6 ve Tablo 6'da sunulmaktadır. Şekil 6 ve Tablo 6 incelendiğinde, senaryo 1'in senaryo 2'den daha düşük değerler verdiği, Kıran vd. [28] ve Tefek vd. [34] tarafından yapılan tahminlerin benzer sonuçlar verdiği görülmüştür. Ayrıca tüm senaryolar ve literatürdeki çalışmaların [28, 34] ETKB tarafından yapılan projeksiyondan daha düşük değerler verdiği tespit edilmiştir. ETBK [2] verilerine göre 2015, 2016 ve 2017 yılları için gerçekleşen enerji tüketim değerleri 129.14, 136.23 ve 145.31 Mtoe'dir. 2015-2017 dönemi gerçek enerji tüketim verileri kullanılarak bu çalışma ve literatürdeki çalışmalardan elde edilen enerji tüketim tahminleri için rölatif hatalar hesaplanmış ve Tablo 6'da sunulmuştur. Tablo 6'daki verilere göre 2015-2017 dönemi için ortalama RH değerleri senaryo 1, senaryo 2, Kıran vd. [28], Tefek vd. [34] ve ETBK projeksiyonu [3] için sırasıyla 0.41%, 2.20%, 4.76%, 4.3% ve 30.69%'dur. Sonuç olarak iki senaryoya göre Türkiye'nin 2023'deki enerji tüketimi 183 ile 191 Mtoe arasında değişecektir. Kıran vd. [28] göre bu değer yaklaşık 165 Mtoe, Tefek vd. [34] göre ise yaklaşık 164 Mtoe'dir.

Tablo 6. Kıran vd. [28], Tefek vd. [34], ETKB Projeksiyonu [3] ve Senaryolara Göre Gelecekteki Enerji Tüketim ve Rölatif Hata Değerleri

Yıl	Senaryo 1 (Mtoe)	RH (%)	Senaryo 2 (Mtoe)	RH (%)	Kıran vd. [28] (Mtoe)	RH (%)	Tefek vd. [34] (Mtoe)	RH (%)	ETKB projeksiyonu [3] (Mtoe)	RH (%)
2015	129.24	0.08	133.27	3.2	125.53	2.79	126.70	1.89	170.15	31.76
2016	136.54	0.23	139.77	2.6	130.19	4.43	130.80	3.99	178.46	31.00
2017	143.96	0.93	146.47	0.80	135.04	7.06	135.10	7.02	187.92	29.33
2018	151.36	-	153.35	-	140.07	-	139.60	-	198.91	-
2019	158.60	-	160.60	-	145.21	-	144.20	-	210.24	-
2020	165.52	-	168.03	-	150.41	-	149.00	-	222.42	-
2021	171.96	-	175.58	-	155.59	-	154.00	-	-	-
2022	177.77	-	183.19	-	160.66	-	159.20	-	-	-
2023	182.85	-	190.76	-	165.47	-	164.50	-	-	-

**Şekil 6.** İki senaryonun, ETKB [3], Kıran vd. [28] ve Tefek vd. [34] tarafından yapılan tahminlerle karşılaştırılması

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada Türkiye'nin 1980 ve 2023 yılları arasında enerji tüketim değerleri GSYİH, nüfus, ithalat ve ihracat dayalı olarak modellenmiştir. Test seti için hesaplanan ortalama RH, OKHK ve OMH değerleri dikkate alındığında, önerilen YSA-GKO modeli enerji tüketimini YSA-GY ve YSA-YAK modellerinden daha iyi tahmin etmiştir. Bu nedenle 2015 ve 2023 yılları arasında Türkiye'nin enerji tüketim değerlerini tahmin etmek için YSA-GKO algoritması kullanılmıştır. Senaryoların sonuçları literatürdeki çalışmalar [28, 34] ve ETKB [3] tarafından yapılan tahminlerle karşılaştırılmıştır. Her iki senaryo da ETKB projeksiyonundan daha düşük değerler verirken, Kıran vd. [28] ve Tefek vd. [34] tarafından yapılan tahminlerden daha büyük değerler tahmin etmiştir. Bu çalışmaya göre RH, OKHK ve OMH değerleri sırasıyla 1.252, 2.114 ve 1.349'dur. Bu değerlere göre GKO algoritmasının bu çalışmadaki sonuçları kabul

edilebilir doğruluktadır. Bu nedenle GKO algoritmasının enerji modellenmesi alanında kullanımı gelecekteki çalışmalar için teşvik edilmelidir.

GKO algoritmasında kurtlar alfa, beta, delta ve omega olarak sınıflandırılmıştır. Bu sınıflandırmadan ötürü parametre sayısının artması bir dezavantaj olarak görülebilir. Bu parametrelerin uygun yöntemlerle azaltılması algoritmayı daha kullanışlı hale getirebilir.

KAYNAKLAR (REFERENCES)

- [1] Boru Hatları İle Petrol Taşıma Anonim Şirketi (BOTAŞ). 2015 Sektör raporu https://www.botas.gov.tr/docs/raporlar/tur/sektorap_2015.pdf. Erişim Tarihi Temmuz, 10, 2018.
- [2] Enerji ve Tabii Kaynaklar Bakanlığı (ETKB). İstatistikler, denge tabloları <http://www.eigm.gov.tr/tr-TR/Denge-Tabloları/Denge-Tabloları>. Erişim Tarihi Temmuz, 12, 2018.
- [3] Enerji ve Tabii Kaynaklar Bakanlığı (ETKB). Enerji ve tabii kaynaklar bakanlığı ile bağlı ve ilgili kuruluşlarının amaç ve faaliyetleri. http://www.enerji.gov.tr/File/?path=ROOT%2F1%2FDocuments%2FMavi%20Kitap%2FMavi%20Kitap_2012.pdf. Erişim Tarihi Temmuz, 17, 2018.
- [4] E. Uzlu, M. Kankal, A. Akpınar, T. Dede, Estimates of energy consumption in Turkey using neural networks with the teaching-learning-based optimization algorithm, *Energy* 75 (2014) 295–303.
- [5] B. Guo, Y. Wang, A. Zhang, China's energy future: leap tool application in China, *East Asia Energy Futures (EAEF)*. In: Asia energy security project energy paths analysis, methods training workshop, vancouver, British Columbia, Canada;2003.
- [6] S.W. Yu, Y.M. Wei, K. Wang, A PSO-GA optimal model to estimate primary energy, *Energy Policy* 42 (2012) 329–340.
- [7] Y. Fan, Y. Xia, Exploring energy consumption and demand in China, *Energy* 40 (2012) 23–30.
- [8] Y.R. Zeng, Y. Zeng, B. Choi, L. Wang, Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network, *Energy* 127 (2017) 381–396.
- [9] X. Wang, D.L. Xu, Z.Z. Sun. Estimates of energy consumption in China using a self-adaptive multi-verse optimizer-based support vector machine with rolling cross-validation, *Energy* 152 (2018) 539–548.
- [10] Z.W. Geem, W.E. Roper, Energy demand estimation of South Korea using artificial neural network, *Energy Policy* 37 (2009) 4049–4054.
- [11] L. Ekonomou, Greek long-term energy consumption prediction using artificial neural networks, *Energy* 35 (2010) 512–517.
- [12] O.A. Oludolapo, A.A. Jimoh, P.A. Kholopane, Comparing performance of MLP and RBF neural network models for predicting South Africa's energy consumption, *Journal of Energy in South Africa* 23 (2012) 40–6.
- [13] K. Muralitharan, R. Sakthivel, R. Vishnuvarthan, Neural network based optimization approach for energy demand prediction in smart grid, *Neurocomputing* 273 (2018) 199–208.
- [14] P. Sutthichaimethee, D. Ariyasajjakkorn, Forecasting energy consumption in short-term and long-term period by using arimax model in the construction and materials sector in Thailand, *Journal of Ecological Engineering* 18 (2017) 52–59.
- [15] M.A. Behrang, E. Assareh, M.R. Assari, A. Ghanbarzadeh, Total energy demand estimation in Iran using bees algorithm, *Energy Sources, B: Economics, Planning and Policy* 6 (2011) 294–303.
- [16] A. Sozen, E. Arcaklioglu, Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey, *Energy Policy* 35 (2007) 4981–4992.

- [17] A. Sozen, E. Arcaklioglu, M. Ozkaymak, Turkey's net energy consumption, *Applied Energy* 81 (2005) 209–221.
- [18] A. Sozen, M.A. Akcayol, E. Arcaklioglu, Forecasting net energy consumption using artificial neural network, *Energy Sources, B: Economics, Planning and Policy* 1 (2006) 147–155.
- [19] M. Kankal, A. Akpinar, M.I. Komurcu, T.S. Ozsahin, Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables, *Applied Energy* 88 (2011) 1927–1939.
- [20] H.A. Es, F.Y. Kalender, C. Hamzaçebi, Forecasting the net energy demand of Turkey by artificial neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University* 29 (2014) 495–504.
- [21] H.K. Ozturk, O.E. Canyurt, A. Hepbasli, Z. Utlu, Residential–commercial energy input estimation based on genetic algorithm approaches: an application of Turkey, *Energy and Buildings* 36 (2004) 175–183.
- [22] O.E. Canyurt, H. Ceylan, H.K. Ozturk, A. Hepbasli, Energy demand estimation based on two-different genetic algorithm approaches, *Energy Sources* 26 (2004) 1313–1320.
- [23] H. Ceylan, H.K. Ozturk, A. Hepbasli, Z. Utlu Estimating energy and exergy production and consumption values using three different genetic algorithm approaches, part 2: application and scenarios, *Energy Sources* 27 (2005) 629–639.
- [24] H. Ceylan, H.K. Ozturk, Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach, *Energy Conversion and Management* 45 (2004) 2525–2537.
- [25] M.D. Toksari, Ant colony optimization approach to estimate energy demand of Turkey, *Energy Policy* 35 (2007) 3984–3990.
- [26] A. Unler, Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025, *Energy Policy* 36 (2008) 1937–1944.
- [27] M.S. Kıran, M. Gunduz, A recombination–based hybridization of particle swarm optimization and artificial bee colony algorithm for continuous optimization problems, *Applied Soft Computing* 13 (2013) 2188–2203.
- [28] M.S. Kıran, E. Ozceylan, M. Gunduz, T. Paksoy, A novel hybrid approach based on Particle Swarm Optimization and Ant Colony Algorithm to forecast energy demand of Turkey, *Energy Conversion and Management* 53 (2012) 75–83.
- [29] V.S. Ediger, S. Akar, ARIMA forecasting of primary energy demand by fuel in Turkey, *Energy Policy* 35 (2007) 1701–1708.
- [30] M. Mucuk, D. Uysal Turkey's energy demand, *Current Research Journal of Social Sciences* 1 (2009) 123–128.
- [31] N.P. Say, M. Yucel, Energy consumption and CO₂ emissions in Turkey: Empirical analysis and future projection based on an economic growth, *Energy Policy* 34 (2006) 3870–3876.
- [32] G. Aydin, Modeling of energy consumption based on economic and demographic factors: the case of Turkey with projections, *Renewable and Sustainable Energy Reviews* 35 (2014) 382–389.
- [33] V.S. Ediger, H. Tatlıdil, Forecasting the primary energy demand in Turkey and analysis of cyclic patterns, *Energy Conversion and Management* 43 (2002) 473–487.
- [34] M.F. Tefek, H. Uğuz, M. Güçyetmez, A new hybrid gravitational search–teaching–learning-based optimization method for energy demand estimation of Turkey, *Neural Computing and Applications* 2017. <http://dx.doi.org/10.1007/s00521-017-3244-9>.

- [35] Türkiye İstatistik Kurumu (TÜİK). Nüfus ve demografi, nüfus istatistikleri. <http://www.tuik.gov.tr/UstMenu.do?metod=temelist>. Erişim Tarihi Temmuz, 17, 2018.
- [36] Türkiye İstatistik Kurumu (TÜİK). Dış ticaret, yıllara göre dış ticaret. <http://www.tuik.gov.tr/UstMenu.do?metod=temelist>. Erişim Tarihi Temmuz, 17, 2018.
- [37] Strateji ve Bütçe Başkanlığı (SBB), Ekoomik ve sosyal göstegeler, milli gelir ve ürerim <http://www.sbb.gov.tr/Pages/EkonomikSosyalGostergeler.aspx>. Erişim Tarihi Temmuz, 17, 2018.
- [38] M. Kankal, Ö. Yüksek, Artificial neural network approach for assessing harbor tranquility: The case of Trabzon Yacht Harbor, Turkey, *Applied Ocean Research* 38 (2012) 23–31.
- [39] E. Uzlu, A. Akpınar, H.T. Öztürk, S. Nacar, M. Kankal, Estimates of hydroelectric generation using neural networks with artificial bee colony algorithm for Turkey, *Energy* 69 (2014) 638–647.
- [40] M. Kankal, E. Uzlu, Neural network approach with teaching-learning-based optimization for modeling and forecasting long-term electric energy demand in Turkey, *Neural Computing and Applications* 28 (2017) 737–747.
- [41] M. Sincen, B. Kaya, Ö. Yıldız, Aydın ilinde insan sağlığını birincil dereceden etkileyen hava değişkenlerine yönelik yapay sinir ağı tabanlı erken uyarı modeli, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji* 5(4) (2017) 121–131.
- [42] D.E. Rumelhart, G.E. Hinton, R.J. Williams, Learning representations by back–propagating errors, *Nature* 323 (1986) 533–536.
- [43] V. Gümüş, A. Başak, K. Yengün, Yapay sinir ağları ile Şanlıurfa istasyonunun kuraklığının tahmini, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji* 6(3) (2018) 621–633.
- [44] D. Karaboga, An idea based on honey bee swarm for numerical optimization. Technical Report-TR06, Erciyes University Engineering Faculty Computer Engineering Department; 2005.
- [45] S. Mirjalili, M.S. Mirjalili, A. Lewis, Grey wolf optimizer. *Advances in Engineering Software* 69 (2014) 46–61.
- [46] S. Mirjalili, How effective is the Grey Wolf optimizer in training multi-layer perceptrons, *Applied Intelligence* 43 (2015) 150–161.
- [47] Türkiye İhracatçılar Meclisi (TİM). 2023 Türkiye ihracat stratejisinin uygulamaya aktarılması ve sektörel kırılımı. <http://www.tim.org.tr/files/downloads/2023/tim%202023%20ihracat%20stratejisi%20raporu.pdf>. Erişim Tarihi Temmuz, 17, 2018.