

Estimating Electric Energy Consumption in Turkey Using Artificial Neural Networks Optimized with Jaya Algorithm

 Ergun UZLU*  Tayfun DEDE 

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

Graphical/Tabular Abstract

Article Info:

Research article

Received: 05/02/2020

Revision: 01/06/2020

Accepted: 03/07/2020

Highlights

- Jaya Algorithm.
- ANN Training.
- Energy Forecasting.

Keywords

 Jaya Algorithm
 Electric Energy
 Consumption/Demand
 Artificial Neural Networks
 Turkey

In this study, Turkey's electric energy consumption was predicted by using artificial neural networks with Jaya algorithm. As shown in Fig. A, three-layer ANN model encompassing GDP, population, and import-export values as entry parameters was formed with electric energy consumption as the exit parameter. Jaya algorithm was employed for network training.

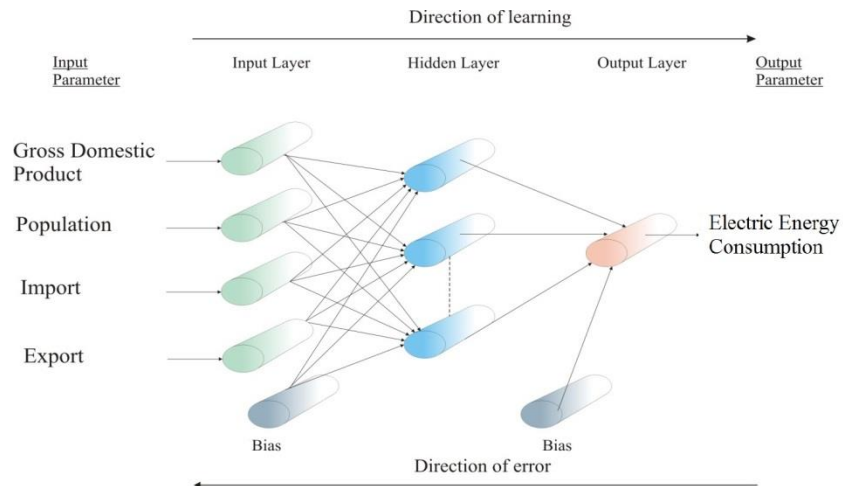


Figure A. Proposed ANN model for electric energy consumption

Purpose: The main objective of the present study was to apply ANN (artificial neural network) model with the Jaya algorithm to estimate electric energy consumption (EEC) in Turkey.

Theory and Methods: The model estimates EEC based on gross domestic product (GDP), population, import, and export data. Data from 1980 to 2008 were used to develop the model and data from 2009 to 2014 were used to evaluate the model's predictive ability. ANN-Jaya model's performance was compared with the performance of artificial bee colony (ABC) and teaching learning based optimization (TLBO) algorithm-trained ANN models. After defining the best model according to various error criteria, EEC values for Turkey were predicted under two different scenarios.

Results: Simulation results show that, ANN-Jaya modeling performed better results than ANN-TLBO or ANN-ABC modeling. According to the root mean square error values obtained for the test set, the proposed ANN-Jaya model performed 58.9% and 43.9% better than the ANN-ABC and ANN-TLBO models, respectively.

Conclusion: In this study, the EEC 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 EEC of Turkey would vary between 311.5 and 333.6 TWh in 2023.



Jaya Algoritması ile Optimize Edilmiş Yapay Sinir Ağlarını Kullanarak Türkiye’de Elektrik Enerjisi Tüketiminin Tahmini

Ergun UZLU*^{ID} Tayfun DEDE^{ID}

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

Öz

Bu çalışmanın temel amacı, Türkiye'nin gelecekteki elektrik enerjisi tüketimini (EET) tahmin etmek için Jaya algoritması kullanılarak eğitilmiş bir yapay sinir ağı (YSA) modeli oluşturmaktır. Gayri safi yurtiçi hasıla (GSYİH), nüfus, ithalat ve ihracat verileri modelde bağımsız değişkenler olarak kullanılarak önerilen yöntem irdelenmiştir. Önerilen yöntemin doğruluğunu göstermek için YSA-Jaya diğer iki yüksek performanslı optimizasyon yöntemi olan yapay arı kolonisi (YAK) ve öğretme öğrenme tabanlı optimizasyon (ÖÖTO) algoritmaları eğitilmiş YSA modelleri ile karşılaştırılmıştır. YSA-Jaya modeli, test veri setinde YSA-YAK ve YSA-ÖÖTO modellerinden daha küçük hata değerlerine yakınsamıştır. Bu nedenle, YSA-Jaya algoritması kullanılarak Türkiye'nin EET projeksiyonu iki farklı senaryoya göre 2023 yılına kadar yapılmıştır. Sonuçlar TEİAŞ (Türkiye Elektrik İletim Anonim Şirketi) tarafından yapılan projeksiyonlar ve literatürdeki diğer ilgili çalışmalarla karşılaştırılmıştır. Sonuçlar, EET'nin YSA-Jaya kullanılarak doğru bir şekilde modellenebileceğini ve bu optimizasyon yönteminin gelecekteki elektrik tüketimini tahmin etmek için avantajlı olduğunu göstermektedir.

Makale Bilgisi

Araştırma makalesi
Başvuru: 05/02/2020
Düzeltilme: 01/06/2020
Kabul: 03/07/2020

Anahtar Kelimeler

Jaya Algoritması
Elektrik Enerjisi
Tüketimi/Talebi
Yapay Sinir Ağları
Türkiye

Keywords

Jaya Algorithm
Electric Energy
Consumption/Demand
Artificial Neural Networks
Turkey

Estimating electric energy consumption in Turkey using artificial neural networks optimized with Jaya algorithm

Abstract

This study's primary objective was to use a Jaya algorithm to train an artificial neural network (ANN) model such that it can estimate Turkey's future electric energy consumption (EEC). Employing gross domestic product (GDP), population, import, and export data as independent variables, the proposed method was examined. In order to show accuracy of proposed method, ANN-Jaya was compared with ANN models trained with two other high-performing optimization methods, namely the artificial bee colony (ABC) method and the teaching-learning-based optimization (TLBO) method. The ANN-Jaya model converges to a lower error on the test dataset than the ANN-ABC and ANN-TLBO models. Thus, using the ANN-Jaya model, Turkey's EEC was projected out to 2023 under two different scenarios. The results were compared with projections by TEİAŞ (Turkish Electricity Transmission Corporation) and other related studies in the literature. The results show that EEC can be accurately modeled using ANN-Jaya, and that this optimization method is advantageous for predicting future electricity consumption.

1.GİRİŞ (INTRODUCTION)

Elektrik enerjisi tüketimi (EET) gelişmekte olan ülkelerde hızla artmaktadır. Örneğin, Türkiye’de EET değeri 1990 yılında 56.81 TWh iken bu değer 2014’te 257.22 TWh olarak gerçekleşmiştir [1]. Türkiye’nin güçlü ekonomik büyümesi, genç nüfusu ve hızlı kentleşmesi nedeniyle EET’nin önümüzdeki yıllarda artmaya devam etmesi beklenmektedir. Türkiye’de resmi EET tahminleri Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) tarafından yapılmaktadır. Resmi tahminler genellikle gerçek değerlerden oldukça yüksek çıkmaktadır ve güvenilir olarak kabul edilmemektedir. Gelecekteki elektrik enerjisi gereksinimlerini karşılamak ve planlamak için Türkiye hükümetinin gerçekçi EET tahminlerine ihtiyacı vardır. Ek olarak, EET’nin kısa vadeli doğru tahminleri, kesintisiz ve bol miktarda elektrik enerjisi sağlanmasında anahtar rol oynamaktadır. Yanlış tahminler elektrik enerjisi temininde aksaklıklara yada

enerji israfına yol açabilmektedir. Bu nedenle doğru EET tahmini hayati öneme sahiptir. EET, nüfus, ekonomik büyüme, enerji tesisleri ve iklim gibi çok çeşitli faktörlerden etkilenmektedir. Bu durum EET'nin kesin tahminini çok zorlaştırmaktadır [2, 3].

Bu çalışmanın temel amacı, Jaya algoritması ile eğitilmiş bir yapay sinir ağı (YSA) temelinde, Türkiye'de EET tahmini için yeni ve gerçekçi bir model sunmaktır. Model dört farklı giriş verisi (GSYİH (gayri safi yurt içi hasıla), nüfus, ithalat ve ihracat verileri) ve bir çıkış verisinden (EET) oluşmaktadır. Geliştirilen YSA-Jaya modeli kullanılarak, gelecekteki EET değerleri iki ayrı senaryo için tahmin edilmiştir.

2.LİTERATUR TARAMASI (LITERATURE REVIEW)

EET tahmin yöntemleri zaman serileri analizi, regresyon analizi ve yapay zeka yöntemleri olarak üç ana başlık altında sınıflandırılabilir. Bütünlenen otoregresif hareketli ortalama (ARIMA) yöntemi ve gri tahmin modeli en çok kullanılan zaman serileri analizlerindedir. Yapay zeka yöntemleri içerisinde ise YSA ve meta-sezgisel algoritmalar (yapay arı kolonisi (YAK), öğretme öğrenme tabanlı optimizasyon (ÖÖTO), karınca kolonisi optimizasyonu (ACO), parçacık sürüsü optimizasyonu (PSO), genetik algoritma (GA) ve bulanık mantık) ön plana çıkmaktadır.

EET tahmininde yer alan problemlerle başa çıkmak için, dünyanın farklı ülkelerinde yukarıda bahsedilen yöntemler kullanılarak birçok çalışma gerçekleştirilmiştir. Ding vd. [2] ve Xu vd. [4] Çin'in elektrik tüketimini tahmin etmek için gri tahmin modelini kullanmışlardır. Kasule ve Ayan [5] Uganda'da EET tahmini için PSO ve YAK algoritmalarından oluşan melez bir model geliştirmişlerdir. Kaboli vd. [6] ve Askarzadeh [7] İran'daki EET'yi tahmin etmek için sırasıyla yapay kooperatif arama ve PSO algoritmalarını kullanmışlardır. An vd. [8] tarafından Avustralya'daki elektrik talebinin yarım saatlik bir ölçekte tahmin etme potansiyeli araştırılmıştır. Pal ve Kar [9] hisse senedi fiyatlarını tahmin etmek için bulanık mantık yöntemi ile kaba küme teorisinden oluşan melez bir model geliştirmişlerdir. Önerdikleri model mevcut modeller ile karşılaştırarak daha iyi sonuç verdiğini tespit etmişlerdir. Das vd. [10] bulanık mantık yöntemi için bir korelasyon katsayısı ve bu korelasyon katsayısını uygulamak için bir algoritma önermişlerdir. Geliştirdikleri yöntemi gerçek hayatta uygulanabilir iki örnek üzerinde test ederek başarılı sonuçlar elde etmişlerdir. Bu çalışmalar incelendiğinde zaman serileri analizi tekniklerinin [2, 4] ve meta-sezgisel algoritmaların [5-10] EET tahmininde yaygın bir şekilde kullanıldığı ve başarılı sonuçlar verdiği görülmüştür. Dünyada EET tahmininde yaygın olarak kullanılan bir diğer teknik ise YSA'dır. Pao [11] Taiwan'daki, Wang vd. [12] ve Gonzalez vd. [13] ise Çin'deki EET'yi tahmin etmek için YSA'yı kullanmışlardır. Geliştirdikleri YSA modellerini ARIMA yöntemiyle karşılaştırmışlardır. YSA modellerinin ARIMA modellerinden daha iyi sonuç verdiğini tespit etmişlerdir. Son zamanlarda metasezgisel algoritmalar YSA eğitiminde sıklıkla kullanılmaktadır. Ardakani ve Ardehali [14], İran ve ABD'deki EET'yi tahmin etmek için bir melez YSA-PSO tekniği geliştirmişlerdir. Geliştirdikleri modelden elde ettikleri sonuçları regresyon analizinden elde ettikleri sonuçlarla karşılaştırmışlardır. YSA-PSO tekniğinin regresyon analizinden daha iyi sonuç verdiğini tespit etmişlerdir. Pal ve Kar [15] yapay sinir ağlarının ağırlıklarını bulanık mantık yöntemini kullanarak optimize etmişlerdir. Geliştirdikleri modeli Mackey-Glass zaman serisi yöntemi ile karşılaştırmışlardır. Önerdikleri yöntemin daha iyi sonuç verdiğini tespit etmişlerdir.

Dünya'nın farklı bölgelerinde olduğu gibi, Türkiye'de de EET'yi tahmin etmek için birçok farklı teknik kullanılmıştır. Hamzacebi ve Kutay [16], Hamzacebi [17], Kavaklıoğlu vd. [18], Bilgili vd. [19], Oğcu vd. [20], Gürbüz vd. [21], Kaytez vd. [22], Birim ve Tümtürk [23], Günay [24] ve Kankal ve Uzlu [25] YSA'yı, Öztürk vd. [26] GA'yı, Yumurtacı ve Asmaz [27] ve Tunc vd. [28] regresyon analizini, Akay ve Atak [29] gri yuvarlanma tahmin modelini, Hamzaçebi ve Es [30] optimize edilmiş gri modeli, Erdoğan [31] ve Sumer vd. [32] ARIMA modelini, Dilaver ve Hunt [33] yapısal zaman analizi tekniğini, Toksarı [34] ACO algoritmasını, Küçükali ve Barış [35] bulanık mantık tekniğini, Demirel vd. [36] uyarlanabilir ağ tabanlı bulanık mantık ve ARIMA'yı, Kavaklıoğlu [37] destek vektör regresyonunu, ve Kiran vd. [38] YAK ve PSO yöntemlerini kullanarak Türkiye'nin EET'sini tahmin etmişlerdir. Türkiye'de regresyon analizi [27, 28] ve zaman serileri analizi [29-33] gibi istatistiksel yöntemler EET modellenmesi alanında sıklıkla kullanılmaktadır. Ancak bu tür yöntemler bazı kesin matematiksel ifadelerle dayandığından EET ve EET'yi etkileyen bağımsız değişkenlerdeki dalgalanmalara yeterince uyum sağlayamamaktadır. Bu nedenle bu tür yöntemlerin EET tahmininde tatmin edici performans elde etmesi güçleşmektedir. Bu

eksikliği giderme noktasında kesin matematiksel ifadelerle dayanmayan ve doğrusal olmayan modelleme yeteneği yüksek olan YSA ve meta-sezgisel algoritmalar gibi yapay zeka yöntemleri ön plana çıkmaktadır. Önceki çalışmalar [21, 26, 38, 39] incelendiğinde, istatistiksel yöntemlerden biri olan regresyon tekniğindeki bu eksikliği gidermek için regresyon fonksiyonlarının GA, YAK, PSO ve ÖÖTO gibi algoritmalarla optimize edilmeye çalışıldığı görülmektedir. Buna ek olarak, YSA ve meta-sezgisel algoritmaların bu tür istatistiksel yöntemlerden daha iyi sonuç verdiği önceki çalışmalarda [11-16, 19, 40] belirtilmiştir. Ayrıca YSA tekniğinin, zaman serileri ve regresyon analizine göre çok daha az sayıda veri kullanarak daha başarılı sonuçlar elde etmektedir [16]. EET tahmini için YSA [16-20, 23] kullanılan çalışmalarda ise, ağ eğitiminde geleneksel geri yayımlı (GY) algoritma kullanılmıştır. GY algoritmasının yerel minimuma takılma, ezberleme gibi problemler nedeniyle YSA eğitiminde yetersiz kalmaktadır [25]. Bu sorunların üstesinden gelebilmek için GY yerine YAK ve ÖÖTO gibi algoritmalar kullanılmaktadır [25, 41, 42]. Yapılan bu değerlendirmelerden Türkiye’de EET tüketiminin tahmini ile ilgili modellerin hala geliştirilmesi gerektiği açıktır.

Burada önerilen Jaya tekniği, hem basit hem de sağlam yeni bir meta-sezgisel algoritmayı içerir. Jaya, sınırlandırılmış veya sınırlandırılmamış optimizasyon problemlerini çözmek için kullanılabilir. Jaya algoritması nispeten yeni olmasına rağmen, mekanik [43], elektrik [44], termal [45] ve inşaat mühendisliği [46] gibi çeşitli mühendislik alanlarında uygulanmıştır. Ayrıca önceki çalışmalar [47-49] incelendiğinde, Jaya’nın PSO, YAK, ÖÖTO gibi gelişmiş optimizasyon tekniklerinden daha iyi bir performans gösterdiği tespit edilmiştir. Ek olarak, Jaya algoritması sadece iki kontrol parametresine (maksimum iterasyon sayısı ve popülasyon büyüklüğü) sahiptir, bu onu diğer meta-sezgisel algoritmalara göre avantajlı kılmaktadır [49].

Bu çalışmada, Türkiye’de EET’yi tahmin etmek için melez bir YSA-Jaya modeli geliştirilmiştir. Modelde GSYİH, nüfus, ithalat ve ihracat verileri giriş, EET ise çıkış verisi olarak kullanılmıştır. YSA’nın mimarisi ve kullanılacak transfer fonksiyonları deneme yanılma yöntemiyle ve daha önceki çalışmalar dikkate alınarak belirlenmiştir. Yapılan çalışmalar sonucunda üç katmanlı, tek ara katmana sahip ve ara katmanından 5 nöron bulunduran ağ yapısının en uygun olduğu tespit edilmiştir. Transfer fonksiyonu olarak giriş katmanı ile ara katman arasında tanjant sigmoid fonksiyonu, ara katman ile çıkış katmanı arasında ise doğrusal fonksiyon kullanılmıştır. Modelin ağırlıkları ise Jaya algoritması kullanılarak optimize edilmiştir. Literatür taramasına göre, daha önce yayınlanmış hiçbir çalışmada, YSA-Jaya’nın EET’yi modelleme ve tahmin etme kabiliyeti test edilmemiştir. Bu nedenle, çalışma hem Türkiye’de EET’ye özgü pratik bir uygulama hem de genel olarak enerji sektörü için yenidir.

3. YÖNTEM (METHODOLOGY)

3.1. Yapay Sinir Ağı Modeli (Artificial Neural Network (ANN) Model)

Bir ara katmana sahip olan YSA modelleri önceki çalışmalarda [25, 41, 42] çok iyi sonuçlar vermiştir. Ayrıca tek ara katman kullanılması durumunda optimize edilecek YSA ağırlıklarının sayısı azalmakta bu da YSA eğitimini kolaylaştırmaktadır. Bu nedenle, EET’yi tahmin etmek için bir giriş, bir çıkış ve bir ara katmandan oluşan çok katmanlı ileri beslemeli bir sinir ağı kullanılmıştır. Ara katmandaki nöron sayısını belirlemek için kesin bir yöntem bulunmadığı için nöron sayısı deneme yanılma yöntemi ile belirlenmektedir [50]. Önceki çalışmalara göre [25, 40] ara katmanda 5, 10, 15 ve 20 nöron kullanımının iyi sonuçlar verdiği tespit edilmiştir. Bu nedenle, bu çalışmada, ara katmanın 5, 10, 15 veya 20 nöron içerdiği YSA mimarileri test edilmiştir. Ağda, transfer fonksiyonu olarak tanjant sigmoid fonksiyonu (giriş katmanı → ara katman) ve doğrusal (ara katman → çıkış katmanı) fonksiyon kullanılmıştır. YSA eğitimi için YAK, ÖÖTO ve Jaya algoritmaları kullanılmıştır.

YSA modellerinde amaç fonksiyonu olarak denklemi aşağıda verilen ortalama karesel hata (OKH) kullanılmıştır [51]. YSA eğitimi süresince YAK, ÖÖTO ve Jaya algoritmaları en küçük OKH değerini verecek YSA ağırlıklarını bulmaya çalışırlar.

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

Denklem 1’de o_k YSA’nın tahmin ettiği değer, y_k gerçek değer, ve n ise toplam veri sayıdır.

3.2. Yapay Arı Kolonisi Algoritması (Artificial Bee Colony (ABC) Algorithm)

YAK algoritması önceki çalışmalarda [42, 52, 53] detaylı bir şekilde açıklanmıştır. Bu nedenle, tekrara düşmemek için, bu bölüm sadece YAK algoritmasının ana kavramlarını kapsayacaktır. 2005 yılında Karaboğa tarafından tanıtılan YAK algoritması, bal arılarının yiyecek arama davranışlarından esinlenilerek geliştirilmiştir [52]. YAK algoritmasında, her bir çözüm bir gıda kaynağına karşılık gelir ve arılar çözüm uzayındaki en kaliteli (nektar miktarı en yüksek) gıda kaynaklarının yerini bulmaya çalışır. Arı sürüsü işçi arı, gözlemci arı ve kaşif arılardan oluşur [54]. Gözlemci ve işçi arıların sayısı birbirine eşittir. Yani işçi arıların sayısı gıda kaynaklarının sayısına eşittir. Bu çalışmada YSA modelinin ağırlıkları çözüm uzayındaki gıda kaynaklarına karşılık gelir, yani YAK algoritması YSA için en uygun ağırlıkları arar. YAK algoritmasının performansı kullanılan arı sayısı (popülasyonun büyüklüğü), limit değeri ve maksimum döngü sayısından oluşan kontrol parametrelerine bağlıdır. İlk gıda kaynağı yerleri yani çözümler algoritma tarafından rastgele seçilir ve algoritma çözümleri değerlendirir. İstenen yakınsama değerine yada maksimum döngü sayısına ulaşıncaya kadar aşağıdaki adımlar tekrarlanır:

- (1) İşçi arılar, rastgele seçilen gıda kaynaklarının yakınında yeni gıda kaynakları ararlar.
- (2) İşçi arılar daha sonra gıda kaynaklarının kalitesi ve kaynak konumları hakkındaki bilgileri gözlemci arılarla paylaşır.
- (3) Bir gözlemci arı, işçi arılar tarafından sağlanan bilgilere dayanarak performansı en yüksek olan besin kaynağını seçer.
- (4) Arılar, şu ana kadar elde edilen en yüksek performanslı gıda kaynaklarını hafızaya alırlar.
- (5) Önceden belirlenen limit değeri dahilinde bir gıda kaynağının kalitesini artırmak mümkün olmadığında, işçi arı onu terk eder ve bir kaşif arı rolünü üstlenir.
- (6) Kaşif arılar potansiyel olarak daha zengin besin kaynaklarını rastgele bir şekilde keşfetmek için dışarı çıkarlar.

3.3. Öğretme Öğrenme Tabanlı Optimizasyon (ÖÖTO) Algoritması (Teaching–Learning-Based Optimization (TLBO) Algorithm)

Rao vd. [55] tarafından geliştirilen ÖÖTO algoritması öğretmenlerin ve öğrencilerin öğretme ve öğrenme süreçlerinden esinlenilerek geliştirilmiş popülasyon tabanlı bir algoritmadır. Bu tekniğin temelini, bir popülasyonda öğretmen olarak adlandırılan en bilgili bir birey ve bu öğretmenin bilgisinden yararlanarak kendisini geliştiren öğrenci olarak adlandırılan bireyler oluşturmaktadır. Popülasyon içerisindeki bireyler birbiri ile etkileşime girerek kendilerini geliştirir ve sorunu çözmek için ideal bireyi (global çözüm) elde etmeye çalışırlar.

Algoritma öğretme ve öğrenme aşamalarından oluşur. Öğretme aşamasında amaç fonksiyonun değerine göre popülasyon içerisindeki en bilgili kişi öğretmen olarak seçilir. Bu aşamada popülasyon içerisindeki tüm öğrenciler öğretmenle etkileşime girer ve güncellenir. Güncellenen her bir öğrenci için amaç fonksiyonu değeri yeniden hesaplanır. Bu etkileşimin ardından amaç fonksiyonunun değeri iyileşirse güncel öğrenci eski öğrenci ile değiştirilir aksi takdirde eski öğrenci korunur. Öğretme aşamasının amacı, öğrencilerin bilgisinin öğretmenin bilgisine göre geliştirilmesidir [25, 56].

Öğrenme aşamasında ise, birinci aşamada öğretmenden etkilenerek oluşturulan öğrenci bireyler birbiri ile kıyaslanarak iyi olana göre tekrar kendilerini yenilerler. Son yinelemenin ardından bir öğrenci en iyi çözüm olarak seçilir [57]. Öğrenme aşamasının sonunda ÖÖTO için bir döngü (iterasyon) tamamlanmış olur. Öğretme ve öğrenme aşamaları amaç fonksiyonu istenilen değere ulaşıncaya veya maksimum iterasyon sayısına ulaşıncaya kadar devam eder. Popülasyon içerisindeki öğretme-öğrenme etkileşimi aşağıdaki denklemler kullanılarak gerçekleştirilir.

$$\text{öğrenci}_i = [X_{i,1} \ X_{i,2} \ \dots \ X_{i,D_n}], \quad i = 1, 2, \dots, P_n \quad 2$$

$$\text{ortalama} = [\text{ortalama}(X_1) \ \text{ortalama}(X_2) \ \dots \ \text{ortalama}(X_{D_n})] \quad 3$$

$$\text{öğrenci}_{\text{yeni}_i} = \text{öğrenci}_i + r * (\text{öğretmen} - \text{ÖF} * \text{ortalama})$$

4

Yukarıda P_n popülasyonun büyüklüğü (birey sayısı), D_N optimize edilecek parametre sayısı, r [0, 1] arasında değişen rastgele bir sayı, ÖF (1 ya da 2 alınabilir) öğretim faktörüdür. Bu çalışmada X_i yapay sinir ağlarının optimize edilecek ağırlıklarıdır.

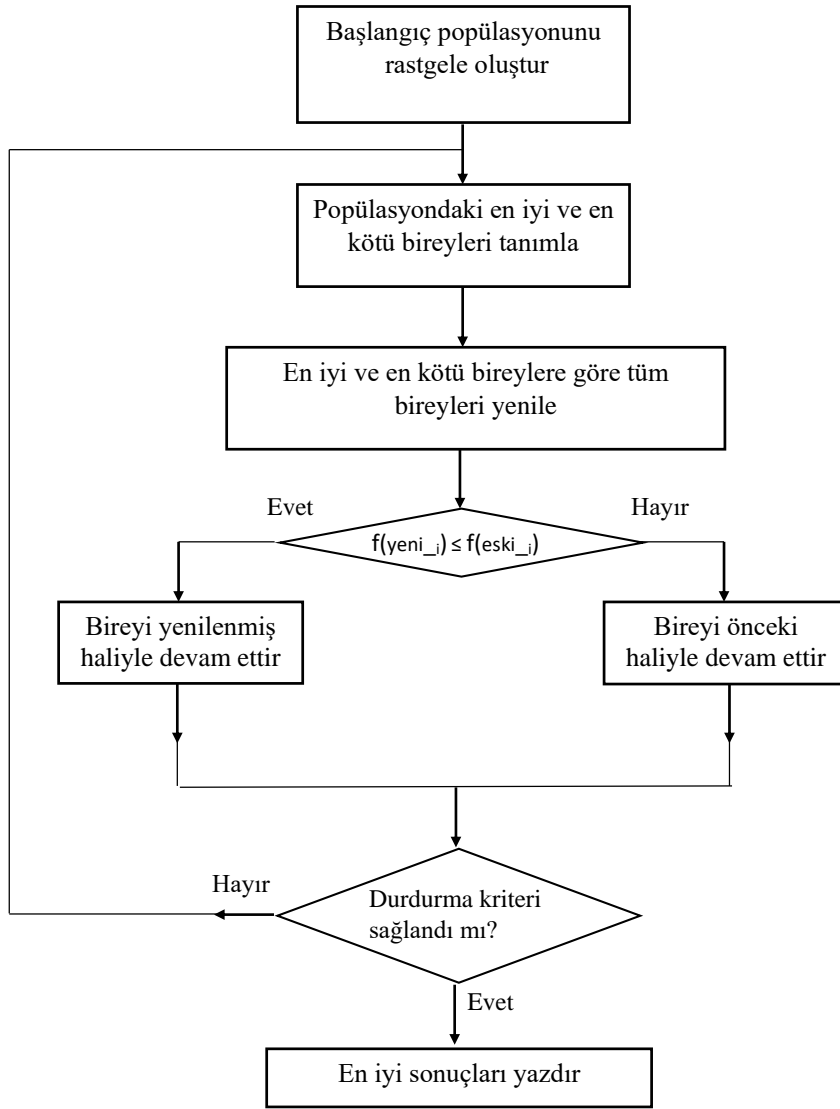
ÖÖTO algoritması diğer popülasyon tabanlı algoritmalar gibi özel kontrol parametreleri içermez. ÖÖTO algoritmasının kontrol parametreleri popülasyonun büyüklüğü ve maksimum iterasyon sayısıdır. Bu iki kontrol parametresi tüm popülasyon tabanlı algoritmalarda bulunmaktadır. Bu nedenle ÖÖTO algoritmasının bir optimizasyon problemine uygulanması çok basittir. Bu özelliğinden dolayı ÖÖTO algoritması son yıllarda birçok araştırmacı tarafından tercih edilmektedir. ÖÖTO algoritması ve uygulanması ile ilgili daha fazla detay önceki çalışmalarda [41, 55, 58] bulunabilir.

3.4. Jaya Algoritması (Jaya Algorithm)

Popülasyon büyüklüğü ve maksimum iterasyon sayısı tüm popülasyon tabanlı optimizasyon algoritmalarının ortak kontrol parametreleridir. Bu ortak kontrol parametrelerinin yanı sıra, farklı algoritmalar kendi özel kontrol parametrelerini de gerektirmektedirler. Örneğin, GA, bir optimizasyon probleminin çözümünde mutasyon oranı, çaprazlama oranı ve seçim operatörü gibi özel kontrol parametreleri gerektirir. Benzer şekilde YAK algoritması, gözlemci arı, işçi arı, kaşif arı gibi kendi özel kontrol parametrelerini kullanmaktadır. Ayrıca PSO, arı kolonisi algoritması, uyum arama, emperyalist rekabet ve diferansiyel evrim gibi algoritmalarda kendi özel kontrol parametrelerini içermektedirler [59]. Kontrol parametrelerinin doğru seçimi oldukça zor olmakla birlikte algoritmanın performansına doğrudan etki etmektedir. Kontrol parametrelerinin sayısı arttıkça optimizasyon süreci uzamakta ve güçleşmektedir. Bu nedenle ÖÖTO ve Jaya gibi sadece ortak kontrol parametrelerini içeren algoritmalar özel kontrol parametreleri içeren diğer algoritmalarla göre daha avantajlıdır.

Araştırmacı Rao R.V. [60] tarafından geliştirilen ve JAYA olarak adlandırılan optimizasyon algoritması, yukarıda sözü edilen kontrol parametrelerinin kullanımını en aza indirgeyerek oluşturulan bir yapay zeka algoritmasıdır. JAYA algoritmasında kontrol parametresi olarak popülasyon büyüklüğü (P_n) ve en büyük yineleme sayısı kullanılır. JAYA, araştırmacı Rao R.V. tarafından daha önce geliştirilmiş algoritma olan ÖÖTO'daki gibi öğretim ve öğrenme aşamaları yerine sadece bir popülasyondaki en iyi ve en kötü bireylerin etkileşiminden yeni bireyler oluşturmak üzerine kurulmuştur. Yani ÖÖTO'nun aksine Jaya tek bir aşamadan oluşur ve basit bir nümerik yapıya sahiptir [60]. Bu nedenle Jaya'yı uygulamak ve kodlamak çok basittir. Ayrıca Jaya basit yapısı nedeniyle daha hızlı çalışarak sonuçta daha kısa sürede ulaşır. Tüm bu özellikler Jaya'yı ÖÖTO, YAK ve diğer popülasyon tabanlı algoritmalarla göre üstün kılmaktadır.

Algoritmasının akış diyagramı Şekil 1'de verilmektedir. Şekil 1'de $f(\text{yeni}_i)$ i. yeni bireyin amaç fonksiyonu değeri, $f(\text{eski}_i)$ ise i. eski bireyin amaç fonksiyonu değeridir. JAYA kelimesi, Sanskritçe dilinde zafer anlamına gelmektedir. Algoritmanın amacı, popülasyondaki bireylerin en başarılı bireye yaklaşması ve en kötü bireyden uzaklaşmasıdır [61].



Şekil 1. JAYA algoritmasının akış diyagramı [61]

Algoritmanın akış diyagramından görüleceği üzere yine bir rastgele başlangıç popülasyonu oluşturulur. Popülasyonda, problemin amaç fonksiyonu kullanılarak en iyi ve en kötü bireyler belirlenir. En iyi bireye yaklaşmak ve en kötü bireyden uzaklaşmak düşüncesiyle yapılan etkileşim ile bireyler yenilenir. Yenilenen her bir birey kendisinin yenilenmeden önceki haline ait amaç fonksiyonu değeri dikkate alınarak, bir sonraki yinelemede eski ya da yeni haliyle popülasyonda kalacağına karar verilir. Bu düşünce ile bütün bireyler yenilenerek probleme ait durdurma kriteri sağlanıncaya kadar yinelemeler sürdürülür. Çözümler (bireyler) aşağıdaki denkleme göre güncellenir:

$$X'_{j,k,i} = X_{j,k,i} + r_{1,j,i} (X_{j,en\ iyi,i} - |X_{j,k,i}|) - r_{2,j,i} (X_{j,en\ kötü,i} - |X_{j,k,i}|) \quad 5$$

Bu denklemde $X_{j,k,i}$ i. iterasyonda k. çözüm için j. tasarım değişkenini, $X_{j,en\ iyi,i}$ en iyi çözümün j. tasarım değişkenini ve $X_{j,en\ kötü,i}$ ise en kötü çözümün j. tasarım değişkenini temsil etmektedir. $X'_{j,k,i}$ değeri $X_{j,k,i}$ 'nin bu algoritmaya göre değiştirilmiş hali ve $r_{1,j,i}$ ve $r_{2,j,i}$ ise i. iterasyon boyunca j. tasarım değişkeni için [0-1] aralığında oluşturulan rasgele iki değerdir [62].

Yeni önerilen çözümün amaç fonksiyonu (hata) değeri mevcut çözümün amaç fonksiyonunun değerinden daha az ise, yeni çözüm varsayılan mevcut çözümün yerine geçer. Aksi takdirde, algoritma mevcut çözümü korur. Bu döngü, yakınsama gereksinimleri karşılanana kadar tekrar edilir. Jaya algoritması hakkında ayrıntılı bilgi literatürde bulunabilir [47, 59, 62].

3.5. YAK, ÖÖTO ve Jaya Algoritmaları ile YSA Eğitimi (ANN Training with ABC, TLBO and Jaya Algorithm)

Geleneksel olarak, YSA'lar GY algoritması ile eğitilirler [43]. Bununla birlikte, YAK ve ÖÖTO algoritmalarının yapay sinir ağlarının eğitimindeki performansının GY algoritmasından daha iyi olduğu önceki çalışmalarda belirtilmiştir [25, 41, 42, 63]. Bu nedenle, bu çalışma YSA'yı eğitmek için GY algoritması kullanmamıştır. Bunun yerine, YSA'nın ağırlıkları, amaç fonksiyonun değeri kabul edilebilir bir değere düşene kadar YAK, ÖÖTO veya Jaya algoritmaları tarafından optimize edilmeye çalışılmıştır. Minimize edilmesi amaçlanan fonksiyon her durumda MSE'dir (1).

Eğitilen YSA modellerinin performansını değerlendirmek için ortalama rölatif hata (RH) [64], ortalama karesel hatanın karekökü (OKHK) [42], ortalama mutlak hata (OMH) [25], korelasyon katsayısı (R) [65] ve U-istatistik [66] değerleri kullanılmıştır. Bu ölçüm değerleri, tahmin edilen enerji tüketim değerleri (y_k) ile gerçek enerji tüketim değerleri (o_k) arasındaki uzaklığı tanımlar. RH, OKHK ve OMH değerleri küçüldükçe model daha gerçekçi tahminler yapmaktadır. Ayrıca, R değeri 1'e, U-istatistik değeri ise 0'a yaklaştıkça modelin performansı artmaktadır. Denklem 9 'da \bar{y}_k EET değerlerinin ortalamasını, \bar{o}_k ise gerçek EET değerlerinin ortalamasını göstermektedir. Ortalama RH, OKHK, OMH, R ve U-istatistik aşağıdaki gibi tanımlanır:

$$\text{ortalama RH} = \frac{\sum_{i=1}^n \left(\frac{y_k - o_k}{y_k} \right)}{n} \times 100 \quad 6$$

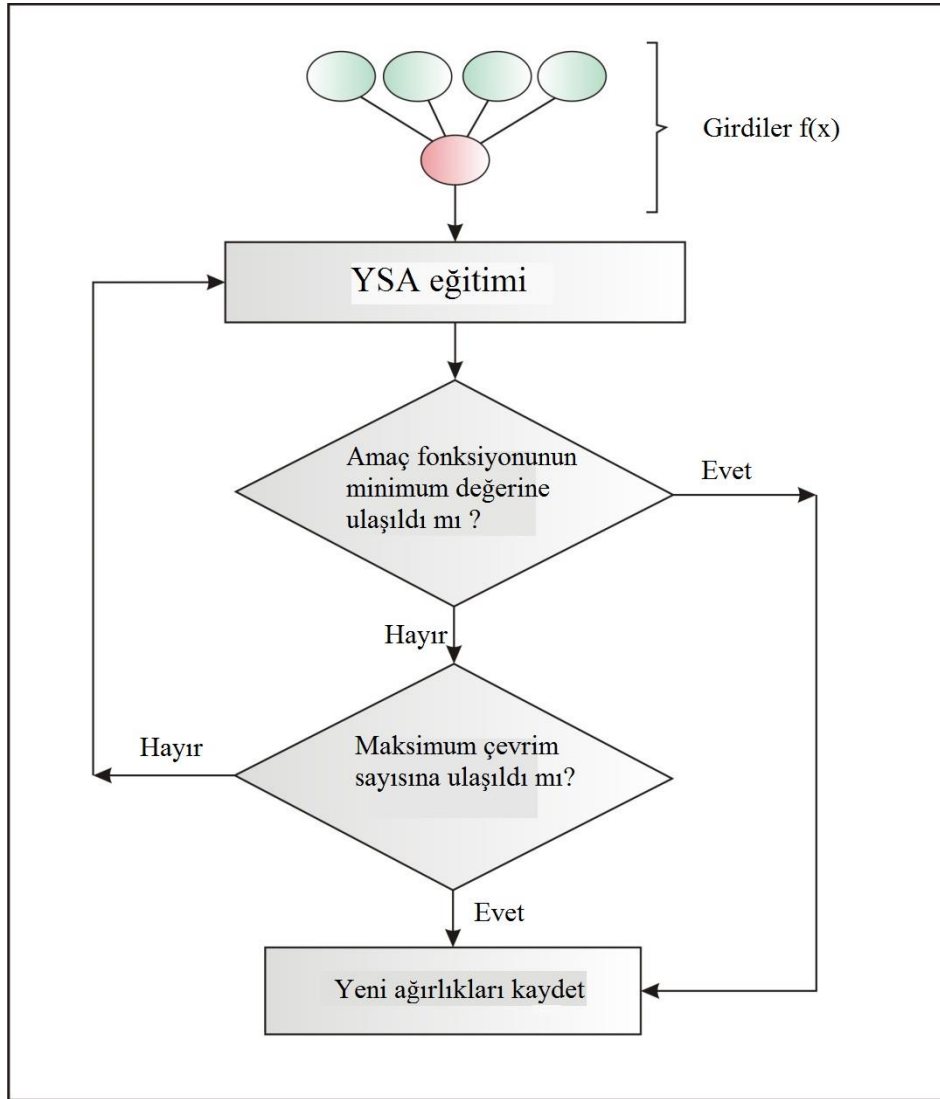
$$\text{OKHK} = \left[\frac{1}{n} \sum_{i=1}^n (y_k - o_k)^2 \right]^{1/2} \quad 7$$

$$\text{OMH} = \frac{1}{n} \sum_{i=1}^n |(y_k - o_k)| \quad 8$$

$$R = \frac{\left(\sum_{i=1}^n (o_k - \bar{o}_k)(y_k - \bar{y}_k) \right)}{\sqrt{\sum_{i=1}^n (o_k - \bar{o}_k)^2 \sum_{i=1}^n (y_k - \bar{y}_k)^2}} \quad 9$$

$$U = \frac{\text{OKHK}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_k)^2 + \frac{1}{n} \sum_{i=1}^n (y_k)^2}} \quad 10$$

YSA modellerinin eğitiminde maksimum iterasyon sayısı 5000 olarak seçilmiştir. YAK, ÖÖTO ve Jaya algoritmaları için popülasyon büyüklüğü 50 olarak belirlenmiştir. Popülasyon büyüklüğü sabit olup modelleme çalışmaları sırasında hep aynı değer kullanılmıştır. YAK algoritmasında limit değeri ve işçi arı sayısı sırasıyla 100 ve 25 olarak belirlenmiştir. YSA ağırlıkları için çözüm aralığı [-1, 1] olarak seçilmiştir. Amaç fonksiyonu (OMH) için hedef değer 8×10^{-8} 'dir. Eğitim süreci maksimum iterasyon sayısına ulaşıncaya veya amaç fonksiyonu istenilen değere indirgenene kadar devam eder. YSA eğitiminin akış şeması Şekil 2'de sunulmuştur.



Şekil 2. YSA için önerilen eğitim şeması [63]

3.6. Veri Seti (Data Set)

Bu çalışmada, Türkiye'nin EET'sini tahmin etmek için GSYİH, nüfus ve ithalat ve ihracat verileri bağımsız değişkenler olarak kullanılmıştır. Bu dört değişken literatürde EET'yi tahmin etmek için sıkça kullanılmıştır [14, 25, 26, 34, 38]. 1980–2008 dönemine ait tarihsel veriler ağı eğitimi için, 2009–2014 dönemine ait veriler ise eğitilmiş ağı performansını değerlendirmek için ayrılmıştır. Her bir bağımsız değişken için farklı kaynaklardan toplanan veriler Tablo 1'de sunulmaktadır.

Tablo 1. EET ve bağımsız değişken değerleri [1, 67, 68, 69]

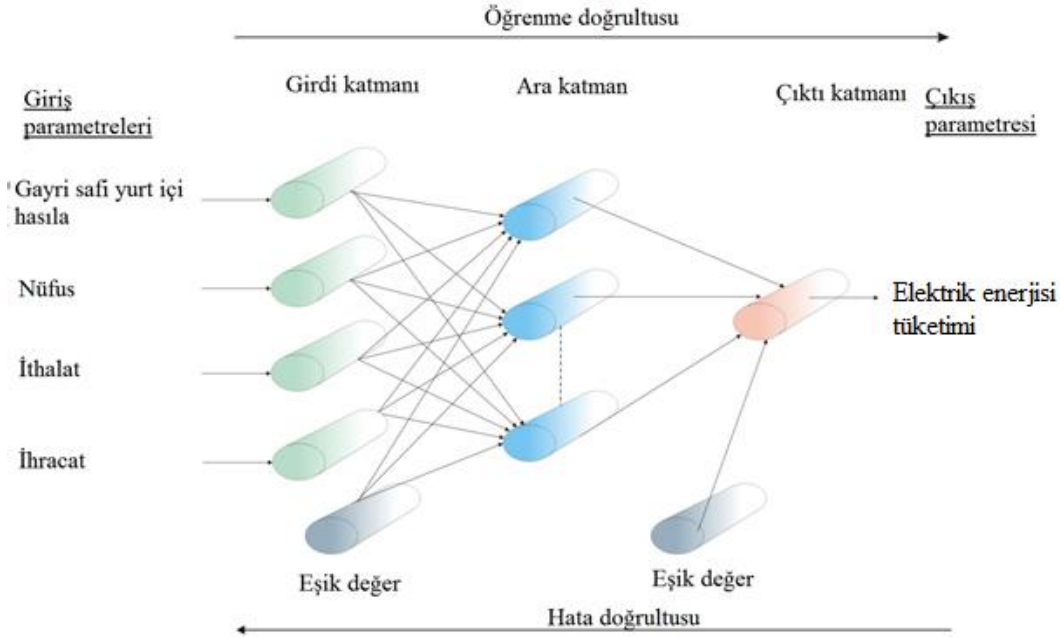
Veri seti	Yıllar	GSYİH (milyar \$)	Nüfus (milyon kişi)	İthalat (milyar \$)	İhracat (milyar \$)	Elektrik Enerjisi Tüketimi (TWh)
Eğitim seti	1980	92.86	44.74	7.91	2.91	24.62
	1981	96.92	45.54	8.93	4.70	26.29
	1982	87.41	46.69	8.84	5.75	28.32
	1983	83.09	47.86	9.24	5.73	29.57
	1984	80.72	49.07	10.76	7.13	33.27
	1985	91.41	50.66	11.34	7.96	36.36
	1986	103.30	51.43	11.10	7.46	40.47
	1987	117.87	52.56	14.16	10.19	44.93
	1988	124.60	53.72	14.34	11.66	48.43
	1989	146.07	54.89	15.79	11.62	52.60
	1990	205.38	56.47	22.30	12.96	56.81
	1991	205.33	57.19	21.05	13.59	60.50
	1992	215.65	58.25	22.87	14.71	67.22
	1993	244.12	59.32	29.43	15.35	73.43
	1994	181.21	60.42	23.27	18.11	77.78
	1995	231.38	61.53	35.71	21.64	85.55
	1996	249.27	62.67	43.63	23.22	94.79
	1997	259.81	63.82	48.56	26.26	105.52
	1998	277.43	65.00	45.92	26.97	114.02
	1999	253.38	66.20	40.67	26.59	118.48
2000	271.55	67.80	54.50	27.77	128.28	
2001	200.65	65.14	41.40	31.33	126.87	
2002	236.36	66.01	51.55	36.06	132.55	
2003	314.05	66.87	69.34	47.25	141.15	
2004	402.67	67.73	97.54	63.17	150.02	
2005	499.74	68.58	116.77	73.48	160.79	
2006	547.59	69.42	139.58	85.53	174.64	
2007	678.64	70.59	170.06	107.27	190.00	
2008	774.37	71.52	201.96	132.03	198.09	
Test seti	2009	646.89	72.56	140.93	102.14	194.08
	2010	772.37	73.72	185.54	113.88	210.43
	2011	831.69	74.72	240.84	134.91	230.31
	2012	871.12	75.63	236.55	152.46	242.37
	2013	950.35	76.67	251.66	151.80	246.36
	2014	934.86	77.70	242.18	157.61	257.22

Nüfus, ithalat ve ihracat verileri Türkiye İstatistik Kurumu'ndan (TÜİK) alınmıştır [67, 68]. EET verileri TEİAŞ'dan temin edilmiştir [1]. GSYİH verileri Türkiye Kalkınma Bakanlığı raporlarından alınmıştır [69]. YSA eğitimini kolaylaştırmak için tüm giriş ve çıkış değişkenlerini denklem (11) kullanarak [0.1, 0.9] aralığına indirgenmiştir.

$$\text{İndirgenen değer} = \left[\frac{\text{Ham değer} - \text{Minimum değer}}{\text{Maksimum değer} - \text{Minimum değer}} \right] \times (0.9 - 0.1) + 0.1 \quad 11$$

4. TAHMİN MODELİNİN GELİŞTİRİLMESİ VE PERFORMANSI (DEVELOPMENT and PERFORMANCE of FORECASTING MODEL)

Bu çalışma için Şekil 3'te gösterilen tek ara katmana sahip üç katmanlı ağ seçilmiştir. Ağın girdi katmanında GSYİH, nüfus, ithalat ve ihracat değerleri kullanılmıştır. Tahmin edilen değişken olan EET, çıktı katmanındadır. Ağı eğitmek için YAK, ÖÖTO ve Jaya algoritmaları kullanılmıştır. Eğitilen YSA modelleri için elde edilen en küçük yakınsama değerleri Tablo 2'de sunulmuştur.



Şekil 3. Elektrik enerjisi tüketimi için önerilen YSA modeli

Tablo 2. YSA eğitimi için YAK, ÖÖTO ve Jaya algoritmalarının en iyi yakınsama değerleri

YSA mimarisi	OKH		
	YAK	ÖÖTO	Jaya
4-5-1	23.869	13.828	17.765
4-10-1	30.117	31.578	39.156
4-15-1	35.689	35.426	21.272
4-20-1	26.925	30.164	25.886

En iyi yakınsama (minimum OKH) değerleri YSA-YAK (4-5-1) için 23.869, YSA-ÖÖTO (4-5-1) için 13.828 ve YSA-Jaya (4-5-1) için 17.765'tir. ÖÖTO algoritması ağ eğitiminde YAK ve Jaya algoritmalarından daha iyi performans göstermiştir. Ancak Tablo 2'de sunulan bu OKH değerleri geliştirilen YSA modellerinin eğitim seti için hesaplanan hata değerleridir ve tek başlarına ağın tahmin gücü hakkında fikir veremezler. Çünkü, bazen yerel bir çözüme takılma yada ezberleme gibi problemler nedeniyle ağın eğitim performansı yüksek çıkmakta ancak tahmin gücü düşük olmaktadır. Bu sebeple, her zaman eğitim hatası en küçük olan YSA modelinin tahmin gücü en yüksek olmamaktadır. Tahmin gücü en yüksek modeli belirleyebilmek için test seti hata değerleri dikkate alınmalıdır. Tüm YSA modelleri için test seti hata değerleri Tablo 3'de sunulmuştur. YSA-ÖÖTO (4-5-1) eğitim seti için minimum OKH değerini elde etmesine rağmen, YSA-Jaya (4-5-1) test seti için en küçük ortalama RH, OKHK ve OMH değerlerine sahiptir. Bu nedenle, en iyi model açıkça ara katmanında 5 nöron bulunduran YSA-Jaya (4-5-1) modelidir. YSA-Jaya (4-5-1) modeli için test seti verileri kullanılarak elde edilen ortalama RH, OKHK ve OMH hata değerleri sırasıyla % 0.618, 1.735 ve 1.336'dır. Ayrıca önerilen modelin doğruluğunu

göstermek için eğitim ve test setleri için R ve U-istatistik değerleri hesaplanmıştır. Önerilen YSA-Jaya modelinin eğitim ve test setleri için R değerleri sırasıyla 0.993 ve 0.996, U-istatistik değerleri ise sırasıyla 0.016 ve 0.002'dir. R ve U-istatistik değerleri önerilen modelin tahmin gücünün kabul edilebilir olduğunu göstermektedir.

Tablo 3. YSA-YAK, YSA-ÖÖTO VE YSA-Jaya için test seti verileri kullanılarak hesaplanan hata değerleri.

YSA mimarisi	Ortalama RH (%)			OKHK (TWh)			OMH (TWh)		
	YAK	ÖÖTO	Jaya	YAK	ÖÖTO	Jaya	YAK	ÖÖTO	Jaya
4-5-1	1.762	1.308	0.618	4.787	3.564	1.735	3.942	2.953	1.336
4-10-1	2.077	1.982	1.909	6.446	5.090	5.241	4.991	4.592	4.233
4-15-1	1.301	1.212	0.920	4.222	3.097	2.319	3.159	2.706	2.038
4-20-1	1.412	1.367	0.922	4.219	4.167	2.309	3.011	2.843	2.059

Koyu değerler en iyi model için elde edilen sonuçları göstermektedir.

Kankal ve Uzlu [25], Öztürk vd. [26], Akay ve Atak [29], Hamzacebi ve Es [30], Erdoğan [31], Küçükaliye Barış [35] ve Kıran vd. [38] tarafından Türkiye'nin gelecekteki EET değerlerini tahmin etmek için önerilen modellerin ortalama RH'ları sırasıyla 1.21%, 2.99%, 3.43%, 3.28%, 2.18%, 4.1% ve 2.27%'dir. Bu değerler önerilen YSA-Jaya modelinin ortalama RH değerinden büyüktür. Bununla birlikte, bu karşılaştırma önerilen YSA-Jaya modelinin performansının alternatif projeksiyon modellerinin performansından daha iyi veya daha kötü olup olmadığını göstermemektedir, çünkü çalışmalar farklı zaman aralıklarındaki veriler kullanılarak gerçekleştirilmiştir.

5. ELEKTRİK ENERJİSİ TÜKETİM TAHMİNLERİ (ELECTRIC ENERGY CONSUMPTION PREDICTIONS)

Önerilen model kullanılarak Türkiye'nin 2015-2023 yılları arasındaki EET değerleri iki farklı senaryoya göre tahmin edilmiştir. Senaryolarda kullanılan nüfus verileri TÜİK nüfus projeksiyonundan [70] alınmıştır. Diğer değişkenler, gerçek yada ortalama büyüme oranları dikkate alınarak, iki senaryoda farklı şekillerde ele alınmıştır. Senaryolarda kullanılan veriler ve senaryolar sırasıyla Tablo 4 ve 5'te sunulmuştur.

Tablo 4. Senaryolarda kullanılan GSYİH, nüfus, ithalat ve ihracat değerleri

Yıl	GSYİH (Milyar \$)		Nüfus (10 ⁶)	İthalat (Milyar \$)		İhracat (Milyar \$)	
	Büyüme oranı	Büyüme oranı	TÜİK [70]	Büyüme oranı	Büyüme oranı	Büyüme oranı	Büyüme oranı
	3.50%	6.82%		5%	11.20%	5%	13.17%
2015	967.575	998.613	78.741	254.286	269.30	165.491	178.37
2016	1001.441	1066.718	79.815	267.000	299.463	173.765	201.858
2017	1036.491	1139.468	80.811	280.350	333.002	182.453	228.443
2018	1072.768	1217.180	81.867	294.368	370.299	191.576	258.529
2019	1110.315	1300.192	82.886	309.086	411.772	201.155	292.577
2020	1149.176	1388.865	83.900	324.540	457.891	211.213	331.110
2021	1189.397	1483.585	84.909	340.768	509.174	221.773	374.717
2022	1231.026	1584.766	85.911	357.806	566.202	232.862	424.067
2023	1274.112	1692.847	86.907	375.696	629.617	244.505	479.917


Tablo 5. Türkiye'nin elektrik enerjisi tüketimi için senaryolar

Senaryolar	GSYİH	Nüfus	İthalat	İhracat
Senaryo 1	Ortalama büyüme oranı (yaklaşık 3.5%)	TÜİK'den alınan nüfus verileri [70]	Ortalama büyüme oranı (yaklaşık 5%)	Ortalama büyüme oranı (yaklaşık 5%)
Senaryo 2	Gerçek büyüme oranı (yaklaşık 6.82%)	TÜİK'den alınan nüfus verileri [70]	Gerçek büyüme oranı (about 11.20%)	Ortalama büyüme oranı (yaklaşık 5%)

Tablo 6 ve Şekil 4, YSA-Jaya tarafından tahmin edilen EET değerlerini Birim ve Tümtürk [23], Hamzacebi ve Es [30], ve TEİAŞ [71] tarafından yapılan tahminlerle karşılaştırmaktadır. Şekil 4 ve Tablo 6'deki değerlere göre senaryo 1 senaryo 2'den daha düşük EET değerleri vermektedir. Şekil 4 ve Tablo 6 incelendiğinde, her iki TEİAŞ [71] senaryosunun da hem bu çalışmada hem de literatürde önerilen EET tüketim tahminlerinin [23, 30] çok üzerinde olduğu tespit edilmiştir. Dolayısıyla TEİAŞ [71] tarafından gerçekleştirilen EET projeksiyonları enerji kaynaklarının planlanması ve etkin bir şekilde kullanılması konusunda karar vericiler için yanıltıcı olmaktadır. Ayrıca Birim ve Tümtürk [23] ve Hamzacebi ve Es [30] tarafından yapılan EET tahminlerinin bu çalışmada önerilen tahminlere yakın olması önerilen modelin doğruluğunu göstermektedir. Sonuç olarak, bu çalışmaya göre, 2023 yılında Türkiye'nin EET değerinin 311.487 ile 333.640 Twh arasında olması beklenmektedir. Birim ve Tümtürk [23] ve Hamzacebi ve Es [30]'e göre ise bu değer sırasıyla yaklaşık 337 ve 339 Twh olacaktır.

Tablo 6. Birim ve Tümtürk [23], Hamzacebi ve Es [30], TEİAŞ projeksiyonları [71] ve senaryolara göre gelecekteki EET değerleri (TWh)

Yıl	Senaryo 1	Senaryo 2	Birim ve Tümtürk [23]	Hamzacebi ve Es [30]	TEİAŞ [71] projeksiyonu (düşük talep)	TEİAŞ [71] projeksiyonu (yüksek talep)
2015	263.626	265.037	224.512	224.723	-	-
2016	272.008	275.042	259.299	236.078	-	-
2017	279.441	284.354	269.347	252.829	-	-
2018	286.726	293.779	276.502	270.92	301.512	307.212
2019	293.193	302.683	294.144	282.629	315.807	323.788
2020	298.973	311.195	302.936	294.867	328.409	343.242
2021	303.996	319.24	314.335	308.973	341.037	363.443
2022	308.191	326.752	326.709	327.054	354.156	384.848
2023	311.487	333.640	337.087	339.575	367.876	407.889



Şekil 4. İki senaryo için elde edilen EET değerlerinin Birim ve Tümtürk [23], Hamzacebi ve Es [30] ve TEİAŞ [71] tarafından yapılan tahminlerle karşılaştırılması

6. SONUÇLAR (CONCLUSIONS)

EET değerlerinin farklı senaryolar altındaki tahminleri enerji politikalarının geliştirilmesi açısından kritik öneme sahiptir. EET tahminleri, önemli sermaye yatırımlarını gerçekleştirmek için verilecek kararlarda karar vericilere yardımcı olabilir [54].

Bu çalışmada, Türkiye'nin 1980 ve 2023 yılları arasındaki EET değerleri GSYİH, nüfus, ithalat ve ihracat göstergelerine dayalı olarak modellenmiştir. YSA-Jaya modeli, EET'yi tüm hata ölçümlerinde, YSA-YAK ve YSA-ÖÖTO modellerinden daha iyi tahmin etmiştir. Bu nedenle, Türkiye'nin 2015 ve 2023 yılları arasındaki EET değerlerini tahmin etmek için YSA-Jaya modeli kullanılmıştır. EET tahmini için iki farklı senaryo kullanılmıştır. İncelenen senaryolar için elde edilen EET tahminleri literatürdeki ilgili çalışmalardan [23, 30, 71] elde edilen tahminlerden daha düşük çıkmıştır. Bu çalışmaya göre Türkiye'nin 2023 yılındaki EET değeri 311.5 ile 333.6 TWh arasında olacaktır.

Bu sonuçlardan ve literatürdeki çalışmalardan [23, 25, 30, 31] görülebileceği üzere, Türkiye'deki resmi EET tahminleri gerçek EET değerlerinden önemli ölçüde yüksek olma eğilimindedir. Türkiye'deki elektrik üretiminin birincil kaynakları kömür, hidroelektrik enerji ve doğal gazdır. Ancak, Türkiye doğal gaz ve petrol kaynaklarına sahip olmadığı için bu kaynaklardan elektrik üretimini azaltmak zorundadır. Ayrıca gelişmekte olan bir ülke olarak Türkiye, kaynaklarını en verimli şekilde kullanabilmesi için EET talebini çok dikkatli bir şekilde planlamalıdır. Bu bağlamda, Türkiye'deki tüm ilgili kurumlar, EET tahminlerinin neden yanıtıcı olduğunu çözmek ve gelecekteki elektrik talebinin daha doğru tahminlerini geliştirmek için adımlar atmalıdır. Bu çalışmadan elde edilen sonuçlar oldukça tatmin edicidir. Bu nedenle enerji modelleme alanında Jaya algoritmasının kullanımı teşvik edilmelidir.

KAYNAKLAR (REFERENCES)

- [1] Türkiye Elektrik İletim A.Ş. (TEİAŞ). Türkiye brüt elektrik enerjisi üretim-ithalat-ihracat ve talebinin yıllar itibariyle gelişimi. <https://www.teias.gov.tr/tr/iii-elektrik-enerjisi-uretimi-tuketimi-kayıplar> Erişim Tarihi Ağustos, 20, 2019.
- [2] S. Ding, K.W. Hipel, Y. Dang, Forecasting China's electricity consumption using a new grey prediction model, Energy 149 (2018) 314–28.

- [3] S.H.A. Kaboli, A. Fallahpour, J. Selvaraj, N.A. Rahim, Long-term electrical energy consumption formulating and forecasting via optimized gene expression programming, *Energy* 126 (2017) 144-64.
- [4] N. Xu, Y. Dang, Y. Gong, Novel grey prediction model with nonlinear optimized time response method for forecasting of electricity consumption in China, *Energy* 118 (2017) 473-80.
- [5] A. Kasule, K. Ayan, Forecasting Uganda's net electricity consumption using a hybrid pso-abc algorithm. *Arabian Journal for Science and Engineering* 44 (2019) 3021-31.
- [6] S.H.A. Kaboli, J. Selvaraj, N.A. Rahim, Long-term electric energy consumption forecasting via artificial cooperative search algorithm, *Energy* 115 (2016) 857-71.
- [7] A. Askarzadeh, Comparison of particle swarm optimization and other metaheuristics on electricity demand estimation: a case study of Iran, *Energy* 72 (2014) 484-91.
- [8] N. An, W. Zhao, J. Wang, D. Shang, E. Zhao, Using multi-output feedforward neural network with empirical model decomposition based signal filtering for electricity demand forecasting, *Energy* 49 (2013) 279-88.
- [9] S.S. Pal, S. Kar, Time series forecasting for stock market prediction through data discretization by fuzzistics and rule generation by rough set theory, *Mathematics and Computers in Simulation* 162 (2019) 18-30.
- [10] S. Das, D. Malakar, S. Kar, T. Pal, Correlation measure of hesitant fuzzy soft sets and their application in decision making, *Neural Computing and Applications* 31 (2019) 1023-1039.
- [11] H.T. Pao, Comparing linear and nonlinear forecasts for Taiwan's electricity consumption, *Energy* 31 (2006) 2129-41.
- [12] L. Wang, H. Hu, X.Y. Ai, H. Liu, Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm, *Energy* 153 (2018) 801-15.
- [13] R.E. Gonzalez, M.M. Jaramillo, F.D. Carmona, Monthly electric energy demand forecasting based on trend extraction, *IEEE Transactions on Power Systems* 21 (2006) 1946-53.
- [14] F.J. Ardakani, M.M. Ardehali, Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types, *Energy* 65(2014) 452-61.
- [15] S. S. Pal, S. Kar, A hybridized forecasting method based on weight adjustment of neural network using generalized type-2 fuzzy set, *International Journal of Fuzzy Systems* 21(2019) 308-320.
- [16] C. Hamzacebi, F. Kutay, Electric consumption forecasting of Turkey using artificial neural networks up to year 2010, *Journal of the Faculty of Engineering and Architecture of Gazi University* 19 (2004) 227-33.
- [17] C. Hamzacebi, Forecasting of Turkey's net electricity energy consumption on sectoral bases, *Energy Policy* 35 (2007) 2009-16.
- [18] K. Kavaklioglu, H. Ceylan, H.K. Ozturk, O.E. Canyurt, Modeling and prediction of Turkey's electricity consumption using artificial neural networks, *Energy Conversion Management* 50 (2009) 2719-27.
- [19] M. Bilgili, Estimation of net electricity consumption of Turkey, *Journal of Thermal Science and Technology* 29 (2009) 89-98.
- [20] G. Oğcu, O.F. Demirel, S. Zaim, Forecasting electricity consumption with neural networks and support vector regression, *Procedia-Social and Behavioral Sciences* 58 (2012) 1576-85.

- [21] F. Gürbüz, C. Öztürk, P. Pardalos, Prediction of electricity energy consumption of Turkey via artificial bee colony: a case study, *Energy Systems* 4 (2013) 289–300.
- [22] F. Kaytez, M.C. Taplamacioglu, E. Cam, F. Hardalac, Forecasting electricity consumption: a comparison of regression analysis, neural networks and least squares support vector machines, *Electrical Power and Energy Systems* 67 (2015) 431–8.
- [23] Ş. Birim, A. Tümtürk, Modeling and forecasting Turkey's electricity consumption by using artificial neural network, *American Scientific Research Journal for Engineering, Technology and Sciences* 25 (2016) 192–208.
- [24] M. E. Günay, Forecasting annual gross electricity demand by artificial neural networks using predicted values of socio-economic indicators and climatic conditions: case of Turkey, *Energy Policy* 90 (2016) 92–101.
- [25] 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) 737–47.
- [26] H.K. Ozturk, H. Ceylan, O.E. Canyurt, A. Hepbasli, Electricity estimation using genetic algorithm approach: a case study of Turkey, *Energy* 30 (2005) 1003–12.
- [27] Z. Yumurtaci, E. Asmaz, Electric energy demand of Turkey for the year 2050, *Energy Sources* 36 (2004) 1157–64.
- [28] M. Tunc, U. Camdali, C. Parmaksizoglu, Comparison of Turkey's electrical energy consumption and production with some european countries and optimization of future electrical power supply investments in Turkey, *Energy Policy* 34 (2006) 50–9.
- [29] D. Akay, M. Atak. Grey prediction with rolling mechanism for electricity demand forecasting of Turkey, *Energy* 32 (2007) 1670–5.
- [30] C. Hamzacebi, H.A. Es, Forecasting the annual electricity consumption of Turkey using an optimized grey model, *Energy* 70 (2014) 165–71.
- [31] E. Erdogdu, Electricity demand analysis using cointegration and ARIMA modelling: a case study of Turkey, *Energy Policy* 35 (2007) 1129–46.
- [32] K.K. Sumer, O. Goktas, A. Hepsag, The application of seasonal latent variable in forecasting electricity demand as an alternative method, *Energy Policy* 37 (2009) 1317–22.
- [33] Z. Dilaver, L.C. Hunt, Turkish aggregate electricity demand: an outlook to 2020, *Energy* 36 (2011) 6686–96.
- [34] M.D. Toksarı, Estimating the net electricity energy generation and demand using the ant colony optimization approach: case of Turkey, *Energy Policy* 37 (2009) 1181–7.
- [35] S. Kucukali, K. Baris, Turkeys short-term gross annual electricity demand forecast by fuzzy logic approach, *Energy Policy* 38 (2010) 2438–45.
- [36] O. Demirel, A. Kakilli, M. Tektas, Electric energy load forecasting using anfis and arma methods, *Journal of the Faculty of Engineering and Architecture of Gazi University* 25 (2010) 601–10.
- [37] K. Kavaklioglu, Modeling and prediction of Turkey's electricity consumption using support vector regression, *Applied Energy* 88 (2011) 368–75.
- [38] M.S. Kiran, E. Özceylan, M. Gündüz, T. Paksoy, Swarm intelligence approaches to estimate electricity energy demand in Turkey, *Knowledge-Based System* 36 (2012) 93–103.

- [39] M. F. Tefek, H. Uguz, Estimation of turkey electric energy demand until year 2035 using TLBO algorithm, *Intelligent Systems and Applications in Engineering* 4 (2016) 48-52
- [40] M. Kankal, A. Akpınar, M.İ. Kömürcü, T.Ş. Özşahin, Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables, *Applied Energy* 88 (2011) 1927-39.
- [41] 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.
- [42] 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) 638-47.
- [43] R.V. Rao, D.P. Rai, J. Ramkumar, J. Balic, A new multi-objective Jaya algorithm for optimization of modern machining processes, *Advances in Production Engineering & Management* 11 (2016) 271-86.
- [44] M. Bhoje, M.H. Pandya, S. Valvi, I.N. Trivedi, P. Jangir, S.A. Parmar, An emission constraint economic load dispatch problem solution with microgrid using JAYA algorithm, In: 2016 International conference on energy efficient technologies for sustainability (ICEETS) Nagercoil, (2016) 497-502.
- [45] R.V. Rao, K.C. More, Design optimization and analysis of selected thermal devices using self-adaptive Jaya algorithm, *Energy Conversion and Management* 140 (2017) 24-35.
- [46] T. Dede, Jaya algorithm to solve single objective size optimization problem for steel grillage structures, *Steel And Composite Structures* 26 (2018) 163-70.
- [47] R.V. Rao, Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems, *International Journal of Industrial Engineering Computations* 7 (2016) 19-34.
- [48] R.V. Rao, K.C. More, J. Taler, P. Oclon, Dimensional optimization of a micro-channel heat sink using Jaya algorithm, *Applied Thermal Engineering* 103 (2016) 572-82.
- [49] D.C. Du, H.H. Vinh, V.D. Trung, N.T.H. Quyen, N.T. Trung, Efficiency of Jaya algorithm for solving the optimization-based structural damage identification problem based on a hybrid objective function, *Engineering Optimization* 50 (2018) 1233-51.
- [50] M. Çunkaş, A. A. Altun, Long term electricity demand forecasting in Turkey using artificial neural networks, *Energy Sources, Part B: Economics, Planning and Policy* 5 (2010) 279-89.
- [51] 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 (2018) 621-633.
- [52] D. Karaboga, An idea based on honey bee swarm for numerical optimization. Technical Report-TR06, Erciyes University Engineering Faculty Computer Engineering Department 2005.
- [53] E. Uzlu, M.İ. Kömürcü, M. Kankal, T. Dede, H.T. Öztürk, Prediction of berm geometry using a set of laboratory tests combined with teaching-learning-based optimization and artificial bee colony algorithms, *Applied Ocean Research* 48 (2014) 103-13.
- [54] C. Ozkan, O. Kisi, B. Akay, Neural networks with artificial bee colony algorithm for modeling daily reference evapotranspiration, *Irrigation Science* 29 (2011) 431-41.
- [55] R.V. Rao, V.J. Savsani, D.P. Vakharia, Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems, *Computer-Aided Design* 43 (2011) 303-15.

- [56] 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* 31 (2019) 2939-54.
- [57] T. Dede, Y. Ayvaz, Combined size and shape optimization of structures with a new meta-heuristic algorithm, *Applied Soft Computing* 28 (2015) 250–8.
- [58] T. Dede, Optimum design of grillage structures to LRFD–AISC with teaching–learning based optimization, *Structural and Multidisciplinary Optimization* 48 (2013) 955–64.
- [59] R.V. Rao, A. Saroj, Constrained economic optimization of shell-and-tube heat exchangers using elitist-Jaya algorithm, *Energy* 128 (2017) 785–800.
- [60] R.V. Rao, Jaya: A Simple and New Optimization Algorithm For Solving Constrained and Unconstrained Optimization Problems, *International Journal of Industrial Engineering Computations*, 7 (2016) 19–34.
- [61] E. Uzlu, Kırıya dik katı madde hareketi sonucu oluşan yığılma profilinin fiziksel modelle incelenmesi, Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Trabzon 2016.
- [62] R.V. Rao, G. Waghmare, A new optimization algorithm for solving complex constrained design optimization problems, *Engineering Optimization* 49 (2017) 60–83.
- [63] E. Uzlu, Türkiye için gri kurt optimizasyon algoritması ile yapay sinir ağlarını kullanarak enerji tüketiminin tahmini, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji* 7 (2018) 245–262.
- [64] 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.
- [65] A.R. Rafieerad, A.R. Bushroa, B. Nasiri-Tabrizi, A. Fallahpour, J. Vadivelu, S.N. Musa, S.H.A. Kaboli, GEP-based method to formulate adhesion strength and hardness of Nb PVD coated on Ti-6Al-7Nb aimed at developing mixed oxide nanotubular arrays, *Journal of the Mechanical Behavior of Biomedical Materials* 61 (2016) 182–96.
- [66] A.R. Rafieerad, A.R. Bushroa, B. Nasiri-Tabrizi, S.H.A. Kaboli, S. Khanahmadi, A. Amiri, J. Vadivelu, F. Yusof, W. J. Basirun, K. Wasa, Toward improved mechanical, tribological, corrosion and in-vitro bioactivity properties of mixed oxide nanotubes on Ti-6Al-7Nb implant using multi-objective PSO, *Journal of the Mechanical Behavior of Biomedical Materials* 69 (2017) 1–18.
- [67] Türkiye İstatistik Kurumu (TÜİK). Nüfus ve demografi, nüfus istatistikleri. <http://www.tuik.gov.tr/UstMenu.do?metod=temelist>. Erişim Tarihi Ağustos, 17, 2018.
- [68] Türkiye İstatistik Kurumu (TÜİK). Dış ticaret, yıllara göre dış ticaret. <http://www.tuik.gov.tr/UstMenu.do?metod=temelist>. Erişim Tarihi Temmuz, 17, 2018.
- [69] Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, Gösterge ve istatistikler, göstergeler, ekonomik ve sosyal göstergeler, 1. Bölüm Milli gelir ve üretim. <http://www.sbb.gov.tr/ekonomik-ve-sosyal-gostergeler/> Erişim Tarihi Ağustos, 20, 2019.
- [70] Türkiye İstatistik Kurumu (TÜİK). Temel istatistikler, nüfus ve demografi, nüfus projeksiyonları. <http://www.tuik.gov.tr/UstMenu.do?metod=temelist> Erişim Tarihi Ağustos, 20, 2019.
- [71] Türkiye Elektrik İletim A.Ş. (TEİAŞ). 10 Yıllık talep tahminleri raporu. https://www.teias.gov.tr/sites/default/files/2018-02/Taleprapor_2017.pdf Erişim Tarihi Ağustos, 20, 2019.