



Makine Öğrenmesi ve Optimizasyon Yöntemleri ile Uzun Dönem Elektrik Enerjisi Tahmini: Türkiye Örneği

Long-Term Electricity Demand Forecasting with Machine Learning and Optimization Methods: The Case of Turkey

¹Ömer Ali KARAMAN , ²Yasin BEKTAŞ 

¹Batman Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Batman, Türkiye

²Aksaray Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Aksaray, Türkiye

omer.ali.karaman@batman.edu.tr, yasinbektas@aksaray.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 29 May 2023

Accepted : 23 July 2023

Keywords:

Particle Swarm Optimization, Linear Regression, Gaussian Process Regression, Energy Demand Forecasting

ABSTRACT

Today, with the rapid increase in industrialization, the demand for energy has risen. To meet this growing energy demand and make accurate energy predictions, optimization and machine learning algorithms have become prominent. Particle swarm optimization (PSO), Linear Regression (LR) and Gaussian Process Regression (GSR) are included in these algorithms. In this study, using PSO, LR and GSR algorithms, Turkey's energy demand estimation between the years 2020-2040 was carried out. In order to make these estimations, the past population, exports, imports, gross domestic product (GDP) between 1980-2019 were used as input data, while energy consumption was used as output data. Coefficient of determination (R^2) value, root mean square error (RMSE), mean square error (MSE), and mean absolute error (MAE) error metrics were used to evaluate the performance results of the PSO, LR, and GSR methods. The R^2 values for the GSR, LR and PSO methods were obtained as 0.9983, 0.9923 and 0.9938, respectively.

© 2023 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 29 Mayıs 2023

Kabul : 23 Temmuz 2023

Anahtar Kelimeler:

Parçacık Sürü Optimizasyonu, Lineer Regresyon, Gauss Süreç Regresyonu, Enerji Talep Tahmini

ÖZET

Günümüzde sanayileşmenin hızla artmasıyla birlikte enerji ihtiyacı artmıştır. Bu artan enerji ihtiyacını karşılayabilmek ve ön görülebilecek enerji tahminlerini yapabilmek için optimizasyon ile makine öğrenme algoritmaları ön plana çıkmıştır. Parçacık sürü optimizasyonu (PSO), Lineer Regresyon (LR) ve Gauss Süreç Regresyonu (GSR) bu algoritmalar içerisinde yer almaktadır. Bu çalışmada PSO, LR ve GSR algoritmaları kullanılarak Türkiye'nin 2020-2040 yılları arasındaki enerji talep tahmini yapılmıştır. Bu tahmin işlemlerinin yapılabilmesi için 1980-2019 yılları arasında geçmiş nüfus, ihracat, ithalat, gayri safi yurtiçi hâsıla (GSYH) giriş verileri olarak kullanılırken enerji tüketimi çıkış verisi olarak kullanılmıştır. PSO, LR ve GSR yöntemlerinin performans sonuçlarını değerlendirebilmek için determinasyon katsayısı (R^2) değeri, kök ortalama kare hatası (KOKH), ortalama kare hatası (OKH) ve ortalama mutlak hata (OMH) hata metrikleri kullanıldı. GSR, LR ve PSO yöntemleri için R^2 değeri sırasıyla 0.9983, 0.9923 ve 0.9938 olarak elde edildi.

© 2023 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Günümüzde teknolojik gelişmelere ve nüfus artışına bağlı olarak enerji ihtiyacı da birlikte artmaktadır. Artan bu enerji ihtiyacı içerisinde elektrik enerjisi büyük bir paya sahiptir. Gelişmekte olan ekonomiler için teknoloji, sağlık, üretim, hizmet gibi birçok farklı alanda sürdürülebilir büyümeyi sağlamak için enerji kaynaklarının uzun vadeli planlanması zorunludur. Bu planlamalar yapılırken ülkenin dinamiklerini içeren parametrelerden faydalanılmalıdır. İthalat, nüfus, GSYH ve ihracat gibi sayısal veriler ülkenin büyümesine dair parametreler olarak kullanılabilir. Bu parametreler optimizasyon yöntemleriyle modellenerek enerji için gerekli alt yapı tesisinin planlanması ve bu alanda yatırımların artırılması için kullanılabilir. Bu nedenle enerji tahmini önemli ve gereklidir. Enerji ve yük tahminleri elektrik taleplerinden daha yüksek olduğunda aşırı sayıda güç kaynağı ünitesi devreye girerek aşırı miktarda elektrik kullanılmasına ve fazladan rezerv verilmesine neden olur. Öte yandan, daha düşük yük tahmin projeksiyonları, sistemi sınırlılıklar içinde çalışmaya zorlayarak yetersiz beslemeye neden olabilir [1,2]. Son 20 yılda, yük ve enerji tahmini hakkında çok sayıda literatür çalışması vardır. Bu literatür çalışması, Türkiye için geçerli ve ilgili çalışmaları kategorize etmeyi ve analiz etmeyi amaçlamaktadır. Burada önemli nokta, hangi yöntemlerin dikkate alındığını, girdi değişkenlerinin seçimini ve parametre değerlerinin düzenini belirlemektir. Bu araştırma, makine öğrenme yöntemleri LR ve GSR ve meta sezgisel algoritmalar dahil olmak üzere elektrik talebini tahmin etmek için kullanılan karma yöntemleri kapsamaktadır. Tablo 1, elektrik talebini tahmin etmek için yapılan araştırmalara genel bir bakış sunmaktadır.

Tablo 1. Literatürdeki elektrik enerjisi tüketimi ve talep tahmini için yapılan bazı çalışmalar

Yazar	Tahmin Edilen	Metot	Değişkenler
Saglam vd. [2]	Gökçeada Elektrik Talebi	YSA, PSO ve Çoklu lineer Regresyon (ÇLR)	İthalat, ihracat, araç ve turist sayısı
Zeng vd. [3]	Bina Elektrik Kullanımı tahmini	GSR	Elektrik tüketim data seti
Sen vd. [4]	Elektrik Tüketimi	YSA- DVM	Nüfus, GSYH, enflasyon ve işsizlik oranı
Zhai ve Che [5]	Pik Yük	PSO temelli SVR ve Rastgele Orman	Geçmiş yük verileri
Raju ve Laxmi [6]	Elektrik yük tahmini	LR, DVM, GSR, Ensemble Bagged (EB) regresyon, Ensemble Boosted (EBo) regresyon, Fine Tree (FT)	Elektrik tüketim data seti
Lu ve Wang [7]	Elektrik yük tahmini	SVR ve Balina Optimizasyon Algoritması (WOA)	Elektrik yük verileri ve elektrik fiyatları
Ramsami and King [8]	Elektrik yük talebi	Fuzzy temelli adaptif ağlar, YSA, RNN	Tarihsel elektrik verileri
Huang vd. [9]	Pik Yük	PSO tarafından optimize edilen SVR	Gerçek yük veri seti
Fan vd. [10]	Kısa dönem yük tahmini	Rastgele Orman	Saatlik yük veri setleri
Dua vd. [11]	Kısa dönem yük tahmini	SVR-Derin sinir ağları (DSA)	Hava ve zaman parametreleri
İbrahim vd. [12]	Kısa dönem yük tahmini	LSTM ve derin öğrenme	Yük ve sıcaklık parametreleri
Dhaval ve Deshpande [13]	Kısa dönem yük tahmini	ÇLR	Geçmiş tüketim değerleri
Tosun vd. [14]	Kısa dönem yük tahmini	YSA	Geçmiş tüketim değerleri, sıcaklık ve zaman veri setleri

Özkan tarafından 2018 yılında yapılan çalışmada, 1979-2015 yılları arasındaki GSYH, nüfus, ithalat ve ihracat verileri kullanılarak PSO ve genetik algoritma (GA) teknikleri ile Türkiye'nin 2018-2050 yılları arasındaki enerji talep tahmini yapılmıştır. 4 farklı senaryo oluşturulmuştur. Bu 4 senaryoya ait yüzde doğruluk ölçüt değerlerine bakıldığında tahmin doğruluğu açısından GA'ya ait değerlerin PSO algoritmalarının gerisinde kaldığı gözlemlenmiştir [15].

Martins ve arkadaşları tarafından 2019 yılında yapılan çalışmada, Ogun Eyaletindeki 10 yıllık enerji talep tahminini yapmak için LR tekniği kullanılmıştır. Elde edilen sonuçlarda enerji talebinde 2028 yılına kadar %53'lük bir artış göstereceği gözlemlenmiştir. Bu sonuçların operasyonel ve planlama faaliyetleri için İbadan Elektrik Dağıtım A.Ş.'ye (IBEDC) çok faydalı olacağı anlaşılmıştır [16].

Yakut ve Özkan tarafından 2020 yılında yapılan çalışmalarında, Enerjinin stratejik bir konumda olduğu günümüz dünyasında Türkiye'de 2018-2050 yılları arasında gereksinim duyulan enerji tüketimini tahmin etmek için PSO ve GA modelleri kullanılmıştır. İthalat, nüfus, GSYH ve ihracat parametrelerinin 1979-2017 yılları arasındaki verileri kullanılmıştır. Enerji tahmininde optimal değere ulaşabilmek için hızlı ekonomik gelişmeler, hükümet kararları, teknoloji ve diğer faktörlerden oluşan 4 farklı senaryo oluşturulmuştur. Çalışmalar neticesinde PSO ve GA

algoritmalarının ortalama mutlak yüzde hata (MAPE) değerlerinin %20'nin altında olması nedeniyle iyi sonuç veren modeller arasında yer alabileceği sonucuna ulaşmışlardır. MSE, MAPE ve RMSE sonuçları göz önünde bulundurulduğunda, PSO'nun GA'ya göre daha optimal sonuçlar verdiği görülmüştür [17].

Kayakuş tarafından 2020 yılında yapılan çalışmada, Türkiye'de Ocak 2016-Mart 2020 tarihleri arasındaki dönemlerde gerçekleşen aylık elektrik tüketim verileri kullanılarak enerji tahmini için bir model geliştirilmiştir. Bu modelde destek vektör regresyonu (DVR) ve yapay sinir ağları (YSA) kullanılmıştır. 15 bağımsız değişken değeri girdi olarak kullanılmış ve Türkiye'nin enerji tüketim değeri bağımlı değişken olarak tahmin edilmiştir. Çalışma verileri neticesinde YSA yönteminde DVR yöntemine göre daha başarılı sonuçlar elde edildiği gözlemlenmiştir [18].

Karaman ve Sağlam tarafından 2022 yılında yapılan çalışmada; PSO ve LR yöntemleri kullanılarak kişi başına tüketilecek enerji talebi tahmin edilmiştir. Hem PSO hem de LR Yöntemleri ile elde edilen sonuçlar MSE, RMSE ve MAE gibi istatistiksel hatalar kullanılarak analiz edilmiştir. Bu yöntemlerin analizi için 1980 ile 2019 yılları arasındaki nüfus, ithalat, ihracat ve GSYH gibi veriler giriş parametreleri olarak kullanılmıştır. Çalışmada; PSO yönteminin diğer modele göre daha iyi performans gösterdiği sonucuna varılmıştır [19].

Karaman ve Sağlam tarafından 2022 yılında yapılan çalışmada; GSYH, ithalat, ihracat ve nüfus gibi çeşitli giriş parametreleri kullanılarak Türkiye'nin yıllık tepe yükünü tahmin etmek için YSA ve LR yöntemleri MATLAB ortamında tasarlanmış ve uygulanmıştır. Çalışmada kullanılan modeller R² değerleri dikkate alındığında kullanılabilir sonuçlar göstermiş ancak YSA modelinin performansının LR modeline göre daha yüksek olduğu sonucuna varılmıştır [20].

Türkiye'nin gelecek enerji talebini tahmin etmek için Enerji ve Tabii Kaynaklar Bakanlığı da bazı çalışmalar yapmıştır. Yapılan çalışmalar neticesinde Enerji ve Tabii Kaynaklar Bakanlığı, 2035 yılında Türkiye'nin enerji talebinin 510,5 TWh olacağını öngörmektedir [21].

Derlediğimiz literatür araştırması sonucunda, Türkiye anakarasının 2040 yılına kadar enerji talep tahminine yönelik standart bir veri kümesi ve çözüm yönteminin ele alınmadığı, genellikle çalışmalarda yerel veriler üzerinden farklı algoritmalar ile kısa dönem tahminler yapıldığı gözlemlenmiştir.

Türkiye'nin sosyoekonomik ve geçmiş enerji tüketimleri göz önünde bulundurularak temel bir senaryo oluşturulmuştur. Bu temel senaryo kullanılarak giriş veri setleri elde edilmiştir. Bu veri setlerini işleyerek gelecek enerji tahminini yapmak için PSO, LR ve GSR algoritmaları kullanılmıştır. Bu algoritmaların tahmin performansını değerlendirmek üzere RMSE, MSE, MAE ve R² metrikleri kullanılmıştır.

2. MATERYAL VE METOT

Bu bölümde veri setinin hazırlanma süreci, kullanılan yöntemler ve bu yöntemlerin performanslarını ölçmek için kullanılan hata metriklerinden bahsedilecektir.

2.1. Veri Seti

Bu çalışmada ilk olarak tahmin etmek istediğimiz çıkış değişkeni olan elektrik enerjisi tüketimi, Türkiye Elektrik İletim A.Ş.'den (TEİAŞ) 1980-2019 dönemi baz alınarak yıllık olarak toplanmıştır [22]. İkinci adım olarak giriş değişkenleri olarak nüfus verisi Türkiye İstatistik Kurumundan (TÜİK) [23], ihracat, ithalat ve GSYH, Dünya Bankasından elde edilmiştir [24].

Modelleri geliştirmek ve eğitmek için, veri ön işleme çok önemli bir ilk adımdır. Başlangıçta, tüm değişkenler birleştirildi ve uygun bir formatta tek bir Excel dosyasında düzenlendi. Dosya daha sonra MATLAB R2019b sürümüne aktarıldı. Daha sonra, tüm veri seti, verilerin kronolojik sırası koruyarak bir eğitim seti (%70), test seti (%20) ve doğrulama seti (%10) olarak bölünmüştür. GSYH, ithalat ve ihracat ekonomik bir göstergedir.

Değişen dünyada nüfusun artması ve yeni teknolojilerin insan yaşamına girmesiyle birlikte enerjiye olan ihtiyaç daha da artmaktadır. Sürdürülebilir kalkınma açısından, gelişmekte olan Türkiye'nin 2023 ve sonrasında artan nüfusunun enerji ihtiyacını büyük ölçüde kendi imkânlarıyla karşılaması beklenmektedir. Bu amaçla Türkiye'nin; Önümüzdeki yıllarda birincil enerji ihtiyacının hesaplanması ve bu ihtiyacın nasıl karşılanabileceğinin araştırılması önemlidir. Tahmin işlemi için Türkiye'nin sosyoekonomik göstergeleri göz önünde bulundurularak Tablo 2'de gösterildiği gibi temel senaryo oluşturulmuştur. Temel senaryo oluşturulurken ithalat ve ihracat büyüme oranları Kıran ve ark.'nın [25] yaptığı çalışmadan, GSYH büyüme oranı Sağlam ve ark.'nın [26] yaptığı çalışmadan ve nüfus artış oranı TÜİK açık veri bankası verilerinden elde edilmiştir.

Tablo 2. Türkiye Ankarası giriş değişkenleri senaryoları.


Giriş Değişkenleri	Türkiye Ankarası
	Temel Senaryo
İthalat	5%
İhracat	4.5%
GSYH	5%
Nüfus	0.5%

Bu senaryoya göre veriler yeniden düzenlenerek giriş verileri oluşturulmuştur. Türkiye'nin 2040 yılına kadar ihtiyaç duyacağı enerji LR, GSR ve PSO yöntemleri kullanılarak tahmin edilmiştir. Tahmin performanslarını

değerlendirmek üzere hata metrikleri (MAE, R^2 , RMSE ve MSE) kullanılarak elde edilen sonuçlar karşılaştırılmıştır.

2.2. Lineer Regresyon Yöntemi

Bağımlı ve bağımsız değişkenler arasındaki neden-sonuç ilişkisini matematiksel bir model olarak ortaya koyan yöntemle lineer regresyon (LR) modeli denir. Bir LR modeli, bağımsız ve bağımlı değişkenler arasındaki ilişkiyi açıkça tanımlar. Şekil 1'de LR akış şeması gösterilmektedir. Giriş verileri LR yöntemi ile analiz edildikten sonra bir talep tahmini elde edilmektedir.



Şekil 1. LR akış diyagramı.

Bağımlı değişken y 'nin birden fazla bağımsız değişkenin (x_1, x_2, \dots, x_k) bir fonksiyonu olduğu elektrik talebi tahmininde doğrusal regresyon kullanılır. İlişki şu şekilde verilir:

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n \quad (1)$$

Denklem (1)'de, y elektrik talebini temsil eder, a_0, a_1 ve a_2 bilinmeyen regresyon katsayıları, x_1 ve x_2 ise dışsal değişkenlerdir. a_0, a_1 ve a_2 her bağımsız değişkenin bağımlı değişken üzerindeki etkisini gösterir. Denklem (2)'de şu şekilde basit bir şekilde ifade edilebilir:

$$y = a + bx_1 + cx_2 \quad (2)$$

Burada, a, b ve c, y 'nin ortalama değerini x_1 ve x_2 regresyon parametreleridir [27].

2.3. Gauss Süreç Regresyonu

GSR, rastgele değişkenler koleksiyonunu içeren stokastik bir süreç olarak tanımlanan parametrik olmayan bir modeldir. Bu değişkenlerin herhangi bir sonlu grubu ortak bir Gauss/normal dağılıma sahiptir [28]. GSR, küçük verilerde bile başarılı sonuçlar üretebilir. Gauss süreç fonksiyonu $f(x)$ denklem 3 de verilmektedir.

$$f(x) = GP(m(x), k(x, x')) \quad (3)$$

Burada $k(x, x')$ kovaryans fonksiyonu, $m(x)$ ortalama fonksiyonudur. Ortalama fonksiyonu denklem 4'te, kovaryans fonksiyonu ise denklem 5'te verilmektedir.

$$m(x) = E[f(x)] \quad (4)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (5)$$

Gauss sürecinin hiper-parametreleri ortalama fonksiyonu ve kovaryans fonksiyonudur. Ortalama fonksiyonu, x girdisine sahip $f(x)$ fonksiyonunun beklenen değerini göstermektedir. Ortalama fonksiyonu için güven düzeyinin bir ölçüsü kovaryans fonksiyonudur [29].

2.4. Parçacık Sürü Optimizasyonu

Parçacık Sürü Optimizasyonu (PSO) Algoritması 1995 yılında Kennedy ve Eberhart tarafından yazılmıştır. PSO, her türlü alandaki optimizasyon problemlerini başarıyla çözen sürü tabanlı stokastik ve akıllı bir algoritmadır [2, 30]. Bu yöntemde, sürü olarak bilinen her olası çözüm, bir popülasyonun parçacıklarını temsil eder. Bu yaklaşımda, parçacığın konumu çok yönlü bir arama bölgesinde optimum yanıtı ve/veya hesaplama kısıtlamalarına ulaşana kadar sürekli olarak değişir. Literatürde verilen bazı çalışmalar, bu yaklaşımın optimizasyon amaçlı etkinliğini ve kullanılabilirliğini göstermiştir [2, 31]. PSO algoritmasında her parçacığın konum ve hız tanımları en önemli parametrelerdir. Aşağıdaki stokastik ve deterministik yenileme kuralları, bir parçacığın hızının ve konumunun nasıl yenilendiğini gösterir. Parçacığın bir sonraki konumunu belirlemek için, parçacığın o noktaya kadarki konumları hakkındaki bilgiler kullanılarak sırasıyla Denklem 6 ve 7 ile hız ve yeni konum vektörü elde edilir.

$$\overline{V}_i^{t+1} = w\overline{V}_i^t + c_1r_1(\overline{P}_i^t - \overline{X}_i^t) + c_2r_2(\overline{G}^t - \overline{X}_i^t) \quad (6)$$

$$\overline{X}_i^{t+1} = \overline{X}_i^t + \overline{V}_i^{t+1} \quad (7)$$

Hız vektörünün 3 bileşeni vardır. Birincisi, hız çarpı w 'dir. Burada w , mevcut hızı korumak için gerekli bir terim olan atalet katsayısıdır. Ayrıca mevcut hareket yönünü korumaya çalışır. İkincisi bilişsel bileşendir. Literatürde bireysel bileşenler olarak da adlandırılırlar. Bunun, her bir parçacığın konumunun her bir parçacığın en iyi değerine (PBEST) uzaklığı olduğu söylenebilir. Son bileşene sosyal bileşen denir. Bu bileşen, her parçacığın tüm sürü ekibinin şimdiye kadar bulduğu en iyi değerden (GBEST) ne kadar uzakta olduğunu belirtir. Formüldeki r_1 ve r_2 katsayıları, algoritmayı stokastik yapmak için kullanılan sıfırdan bire değişen katsayılardır. Aynı zamanda, c_1 ve c_2 katsayıları stokastik terimlerin ivmesini ağırlıklandırmak için kullanılır.

Her parçacığın bir sonraki konumunu (X_i^{t+1}) bulmak için, bir sonraki iterasyondaki hız değeri (V_i^{t+1}) mevcut konumuna eklenir. Konum, hız, PBEST ve GBEST değerleri her yinelemede sürekli olarak güncellenir [2].

2.5. Hata Ölçütleri

Hata ölçütleri, MSE, MAE, RMSE, ve determinasyon katsayısını (R^2) içerir. MAE ve RMSE, tahmindeki pozitif ve negatif hataların karşılıklı olarak karşılaştırılmasından kaçınarak, sırasıyla tahmin edilen değerlerin gerçek değere yakınlığını ve tutarsızlığını değerlendirir. MSE, tahmin edilen değerlerin gerçek değerden sapmasını yansıtır. R^2 , bağımlı değişkendeki değişikliklerin ne kadarının bağımsız değişkendeki değişikliklerden kaynaklandığını gösterir ve $1 > R^2 > 0$ arasında değer almalıdır. R^2 değeri 1'e ne kadar yakınsa, regresyon doğrusunun o kadar iyi uyduğu söylenmektedir [2, 32]. Aşağıda sırasıyla R^2 , MSE, MAE ve RMSE'ye ait denklemler verilmektedir.

$$R^2 = \frac{(\sum_{i=1}^N (x_i^* - \bar{x}_i)(x_i - \bar{x}_i))^2}{\sum_{i=1}^N (x_i^* - \bar{x}_i)^2 \sum_{i=1}^N (x_i - \bar{x}_i)^2} \quad (8)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - x_i^*)^2 \quad (9)$$


$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - x_i^*| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i^* - x_i)^2} \quad (11)$$

Denklemlerde x_i , x_i^* , \bar{x}_i , \bar{x}_i^* , N sırasıyla gerçek değeri, tahmin edilen değeri, ortalama gerçek değeri, ortalama tahmin edilen değeri ve örneklem büyüklüğünü temsil eder.

3. DENEYSEL SONUÇLAR

Türkiye'nin 2023 ve sonrasında artan nüfusu göz önünde bulundurularak enerji ihtiyacını büyük ölçüde kendi imkânlarıyla karşılaması gerekmektedir. Bu amaçla Türkiye'nin; Önümüzdeki yıllarda birincil enerji ihtiyacının hesaplanması ve bu ihtiyacın nasıl karşılanabileceğinin araştırılması önemlidir. LR modeli kullanılarak elde edilen elektrik enerjisi talep tahmini ile gerçek değer arasındaki grafik Şekil 2'de gösterilmektedir.

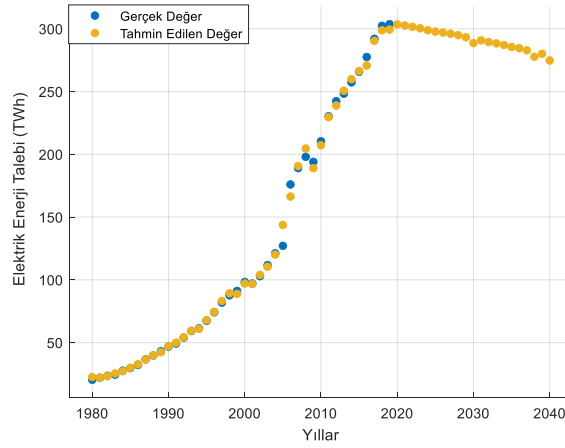


Şekil 2. Gerçek değer ve LR model tahmin değeri.

Şekilden görüleceği üzere 2019 yılına kadar gerçek değer ile LR model tahmin değerinin örtüştüğü görülmektedir. LR model 2020-2040 yılları arasında temel senaryoya göre lineer bir şekilde arttığı görülmektedir. Enerji ve Tabii Kaynaklar Bakanlığının 2035 yılında Türkiye enerji tüketiminin 510,5 TWh olacak tahmini göz önünde bulundurulduğunda, LR yönteminin benzer tahmin performansını tutturduğu söylenebilir.


GSR modeli kullanılarak elde edilen elektrik enerjisi talep tahmini ile gerçek değer arasındaki grafik Şekil 3'te gösterilmektedir.

Şekilden görüleceği üzere 2019 yılına kadar gerçek değer ile GSR model tahmin değerinin örtüştüğü görülmektedir. GSR model tahmin grafiği 2020-2040 yılları arasında temel senaryoya göre azalan eğimle devam ettiği görülmektedir.



Şekil 3. Gerçek değer ve GSR model tahmin değeri.

PSO modeli kullanılarak elde edilen elektrik enerjisi talep tahmini ile gerçek değer arasındaki grafik Şekil 4'te gösterilmektedir.



Şekil 4. Gerçek değer ve PSO model tahmin değeri.

Şekilden görüleceği üzere 2019 yılına kadar gerçek değer ile PSO model tahmin değerinin örtüştüğü görülmektedir. 2020 yılından sonra ise lineere yakın bir artışla devam ettiği görülmektedir. Her üç yöntem için istatistiksel analiz ve hata metrik sonuçları Tablo 3'te gösterilmektedir. Bu değerler 1980-2019 yılları arasındaki gerçek değerler ve yöntemlerin tahmin performans sonuçları kullanılarak elde edilmiştir.

Tablo 3. Anakara istatistiksel analiz sonuçları.

	Metotlar	Değerler
R²	GSR	0.9983
	LR	0.9923
	PSO	0.9938
RMSE	GSR	3.8141
	LR	8.5212
	PSO	7.3256
MSE	GSR	14.548
	LR	72.612
	PSO	53.665
MAE	GSR	2.1852
	LR	6.2095
	PSO	5.2215

Tablo 3 incelendiğinde her üç yöntemin geçmiş 1980-2019 yılları arasındaki tahmin performanslarının iyi olduğu görülmektedir. Hata metriklerine bakıldığında geçmiş 1980-2019 yılları arasında GSR modelinin sonuçları, diğer yöntemlere göre daha iyi olduğu söylenebilir. Ancak bu GSR yönteminin gelecek enerji tahmininde iyi bir yöntem olduğu anlamına gelmez. Daha sağlıklı bir değerlendirme bütün sonuçlara bakılarak, sonuç ve değerlendirme kısmında yapılmıştır.

Bağımsız girdi değişkenleri ile bağımlı elektrik tüketimi arasındaki ilişki Tablo 4'te gösterilmektedir. Elektrik tüketimi ile ihracat arasında güçlü bir ilişki (0.9910) olduğu görülmektedir.

Tablo 4. Bağımsız değişkenler ve bağımlı değişken arasındaki korelasyon.

Değişkenler	İthalat	İhracat	GSYH	Nüfus	Elektrik Tüketimi
İthalat	1	0.9895	0.9460	0.9232	0.9742
İhracat	0.9895	1	0.9727	0.9478	0.9910
GSYH	0.9460	0.9727	1	0.9684	0.9892
Nüfus	0.9232	0.9478	0.9684	1	0.9669
Elektrik Tüketimi	0.9742	0.9910	0.9892	0.9669	1

Elektrik tüketimi ile ihracattan sonra en güçlü ilişki sırasıyla GSYH, ithalat ve nüfus'tur. Aynı şekilde ithalat ile ihracat arasında güçlü bir ilişki (0.9895) olduğu görülmektedir.

4. SONUÇ VE DEĞERLENDİRME

Bu çalışmada 1980-2019 yılları arasında geçmiş nüfus, ihracat, ithalat, GSYH giriş verileri olarak ve enerji tüketimi çıkış verisi olarak belirlenmiştir. Bu giriş ve çıkış verileri kullanılarak PSO, LR ve GSR algoritmaları vasıtasıyla Türkiye'nin 2020-2040 yılları arasındaki enerji talep tahmini yapılmıştır. Tablo 3'teki sonuçlara ve Şekil 2, Şekil 3 ve Şekil 4'e bakıldığında geçmiş 1980-2019 yılları arasında her üç yöntemin de başarılı sonuçlar gösterdiği anlaşılmaktadır. Ancak gelecek 2020-2040 yılları arasında Şekil 2, Şekil 3 ve Şekil 4'e bakıldığında GSR yöntemi tahmin grafiğinin düşme eğilimi göstermesi, tahmin performansının kötü olduğu anlamına gelmektedir. LR ve PSO yöntemleri incelendiğinde gelecek 2020-2040 yılları arasında daha gerçekçi ve doğru tahmin performansı sergiledikleri söylenebilir. LR ve PSO'nun R² değerleri sırasıyla 0.9923 ve 0.9938'dir. Tablo 3'de görüleceği üzere LR ve PSO yöntemlerinin hata metriklerinin düşük olması bu yöntemlerin tahmin performansının iyi olduğunu gösteren bulgulardır.

Korelasyon matrisine bakıldığında elektrik tüketimi ile ihracat arasında güçlü bir ilişki (0.9910) olduğu anlaşılmaktadır. Dolayısıyla ihracat, üretimi yani sanayiye yansıtarak elektrik tüketimi üzerinde en çok etkiye sahip giriş parametresi denilebilir. Yine ithalat ve ihracat arasında güçlü bir ilişki (0.9895) vardır.

Enerji ve Tabii Kaynaklar Bakanlığının enerji tahmin çalışmaları ile kıyas edildiğinde PSO ve LR yöntemlerinin Türkiye'nin gelecek enerji talep tahmininde kullanılabileceği söylenebilir. İleriki çalışmalarda hibrit makine öğrenme yöntemleri kullanılarak enerji talep tahmini yapılabilir.

Yazar Katkıları

Yazarlar makaleye eşit derecede katkı sağlamıştır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

KAYNAKÇA

- [1] M.E. Gunay "Forecasting annual gross electricity demand by artificial neural networks using predicted values of socio-economic indicators and climatic conditions: Case of Turkey", Energy Policy, vol. 90, no.1, pp. 92-101, 2016.
- [2] M. Sağlam, C. Spataru and O.A. Karaman "Electricity Demand Forecasting with Use of Artificial Intelligence: The Case of Gokceada Island", Energies, vol.15 no.16, pp. 1-22, 2022.
- [3] A. Zeng, H. Ho and Y. Yu "Prediction of building electricity usage using Gaussian Process Regression", Journal of Building Engineering, vol.28, no.1, pp.1-8, 2019.
- [4] D. Sen, K.M. Tunç and M.E. Günay "Forecasting electricity consumption of OECD countries: A global machine learning modeling approach", Util. Policy, vol. 70, no. 1, pp. 1-15, 2021.
- [5] H. Zhai, and C. Jinxing "Combining PSO-SVR and Random Forest Based Feature Selection for Day-ahead Peak Load Forecasting", Engineering Letters vol. 30, no. 1, pp. 1-7, 2022.
- [6] M.P. Raju and A.J. Laxmi "IOT based online load forecasting using machine learning algorithms", Procedia Computer Science, vol. 171, no.1, pp 551-560, 2020.
- [7] Y. Lu and G.A. Wang "Load forecasting model based on support vector regression with whale optimization algorithm", Multimed Tools Appl vol. 82, no. 1, pp. 9939-9959, 2023.
- [8] P. Ramsami, and R.T.A. King "Neural Network Frameworks for Electricity Forecasting in Mauritius and Rodrigues Islands. In Proceedings of the 2021" 2021 IEEE PES/IAS Power Africa, pp. 1-5, 2021.
- [9] Y. Huang, N. Hasan, C. Deng, and Y. Bao "Multivariate empirical mode decomposition based hybrid model for day-ahead peak load forecasting", Energy, vol. 239, pp. 1-15, 2022.
- [10] G. F. Fan, L. Z. Zhang, M. Yu, W. C. Hong and S. Q. Dong "Applications of random forest in multivariable response surface for short-term load forecasting", International Journal of Electrical Power and Energy Systems, vol. 139, pp. 1-17, 2022.

- [11] S. Dua, S. Gautam, M. Garg, R. Mahla, M. Chaudhary and S. Vadhera “Short Term Load Forecasting using Machine Learning Techniques”, 2022 2nd International Conference on Intelligent Technologies (CONIT), pp. 1-6, 2022.
- [12] B. Ibrahim, L. Rabelo, E. Gutierrez-Franco and N. Clavijo-Buritica “Machine Learning for Short-Term Load Forecasting in Smart Grids”, *Energies*, vol. 15, no. 21, pp. 1-19, 2022.
- [13] K.A. Abdulsalam, and O.M. Babatunde “Electrical energy demand forecasting model using artificial neural network: A case study of Lagos State Nigeria”, *International Journal of Data and Network Science*, vol. 3, no. 4, pp. 305–322, 2019.
- [14] S. Tosun, A. Öztürk, and F. Taşpınar “Short Term Load Forecasting for Turkey Energy Distribution System with Artificial Neural Networks”, *Tehnički vjesnik*, vol. 26, no. 6, pp. 1545-1553, 2019.
- [15] E. Özkan “Parçacık Sürü Optimizasyonu ve Genetik Algoritma Kullanarak Türkiye'nin 2050 Yılına Kadar Enerji Tüketim Tahmininin Yapılması”, *Yüksek Lisans Tezi, Osmaniye Korkut Ata Üniversitesi, Türkiye*. pp. 59-60, 2018.
- [16] O. Martins, O.O. Ade-Ikuesan, and A. Oyedeji “Ogun Eyaletinde doğrusal regresyon uzun vadeli enerji talep tahmini modellenmesi”, *Nijerya Uygulamalı Bilimler ve Çevre Yönetimi Dergisi*, vol. 23, no. 4, pp. 753, 2019.
- [17] E. Yakut, ve E. Özkan “Parçacık Sürü Optimizasyonu ve Genetik Algoritma Kullanılarak Ekonomik Göstergelerle Enerji Tüketim Tahmininin Modellenmesi: 1979-2050 Yılları Arasında Türkiye'de Bir Uygulama”, *Alfanümerik Günlük*, vol. 8, no.1, pp. 59-78, 2020.
- [18] M. Kayakuş “The Estimation of Turkey's Energy Demand Through Artificial Neural Networks and Support Vector Regression Methods”, *Alphanumeric Journal*, vol. 8, no. 2, pp. 227-236, 2020.
- [19] Ö.A. Karaman, and M. Sağlam “Performance Analysis of Modern Methods For Estimating Electricity Energy Consumption Per Capita”, *International Informatics Congress (IIC2022)*, pp. 20-25, 2022.
- [20] Ö.A. Karaman, and M. Sağlam “Performance Analysis Of Modern Methods For Estimating Instantaneous Peak Load”, *International Informatics Congress (IIC2022)*, pp. 25-30, 2022.
- [21] <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik> (Erişim: 10 Haziran 2023).
- [22] Türkiye Elektrik İletim A.Ş. Erişim adresi: <https://www.teias.gov.tr/enUS/interconnections> (Erişim: 10 Mayıs 2023).
- [23] Türkiye İstatistik Kurumu. Erişim adresi: <https://data.tuik.gov.tr/Kategori/GetKategori?p=nufus-ve-demografi-109&dil=1> (Erişim: 10 Mayıs 2023).
- [24] World Bank, Erişim adresi: https://data.worldbank.org/?intcid=ecr_hp_BelTD_en_ext (Erişim: 10 Mayıs 2023).
- [25] M.S.Kıran, E. Özceylan, M. Gündüz, and 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*, vol. 53, no. 1, pp. 75-83, 2012.
- [26] M. Sağlam, C. Spataru, O.A. Karaman “Forecasting Electricity Demand in Turkey Using Optimization and Machine Learning Algorithms”, *Energies*, vol. 16, no. 11, p. 4499, 2023.
- [27] M. Binici “Turkey's energy consumption forecast by using mathematical modeling”, *Master Thesis, Sivas Cumhuriyet University, Turkey*, pp. 50-51, 2019.
- [28] Y. Guan, D. Li, S. Xue, and Y. Xi “Feature-fusion-kernel-based Gaussian process model for probabilistic long-term load forecasting”, *Neurocomputing*, vol. 426, pp. 174-184, 2021.
- [29] M. Korkmaz, A. Doğan and V. Kırmacı “Karşıt Akışlı Ranque – Hilsch Vorteks Tüpünün Lineer Regresyon, Destek Vektör Makineleri ve Gauss Süreç Regresyonu Yöntemi ile Performans Analizi”, *Gazi Mühendislik Bilimleri Dergisi*, vol. 8, pp. 361-370, 2022.
- [30] A. Anand, and L. Suganthi “Hybrid GA-PSO Optimization of Artificial Neural Network for Forecasting Electricity Demand”, *Energies (Basel)*, vol. 11, no. 4, pp. 1-15, 2018.
- [31] W.Chen, M. Panahi, H.R. Pourghasemi “Performance evaluation of GIS-based new ensemble data mining techniques of adaptive neuro-fuzzy inference system (ANFIS) with genetic algorithm (GA), differential evolution (DE), and particle swarm optimization (PSO) for landslide spatial modelling”, *CATENA*, vol. 157, pp. 310–324, 2017.
- [32] W. Zhang, W. Zhang, J. Wang and X. Niu “Hybrid system based on a multi-objective optimization and kernel approximation for multi-scale wind speed forecasting”, *Applied Energy*, vol. 277, pp. 1-19, 2020.