

Kişi Başına Elektrik Tüketiminin Dalgacık Dönüşümüne Dayalı Tahmini

Aytaç PEKMEZCİ¹

¹Muğla Üniversitesi, Fen Fakültesi, İstatistik Bölümü, 48000, Muğla, Türkiye

(Alınış / Received: 05.10.2020, Kabul / Accepted: 02.11.2020, Online Yayınlanma / Published Online: 20.12.2020)

Anahtar Kelimeler

İstatistik,
Zaman Serileri,
Box-Jenkins Model,
Dalgacık Dönüşüm

Özet: Zaman serisi analizi, finans, ekonomi, istatistik, mühendislik gibi birçok alanda gelecekle ilgili karar verme olanağı sunduğu için oldukça önemlidir. Zaman serisi analizinde otoregresif model, hareketli ortalama modeli ve otoregresif hareketli ortalama modelini kapsayan Box-Jenkins modelleri yaygın olarak kullanılmaktadır. Ancak bu modellerden elde edilen tahmin sonuçlarının güvenilir olabilmesi için, serinin durağan olması, gürültülü veri içermemesi ve trend ya da mevsimsel hareket bileşenlerinden arındırılmış olması gerekir ki özellikle finansal zaman serilerinde bu oldukça güçtür. Bu problemin üstesinden gelmek amacıyla, son zamanlarda veri ön işleme adımında dalgacık dönüşümü (DD) kullanılmaktadır. DD, zaman serisinin uzun dönemli trend ve varyasyon şeklinde iki bileşene ayrılmasına dayanır. Böylece zaman serisinin her bir bileşeni için ayrı bir tahmin modeli elde edilmesi ve davranışının daha doğru bir şekilde tahmin edilmesini sağlar. Bu çalışmada Kişi Başına Elektrik Tüketiminin (KBET) DD ile tahmin edilmesi ve tahmin sonuçlarının geleneksel modeller ile karşılaştırılması amaçlanmıştır. Bu amaca yönelik olarak 26 farklı ülkenin 1960-2014 yıllarını kapsayan KBET verileri kullanılmıştır. Performans karşılaştırmaları için R^2 , Hata Kareler Ortalamasının Karekökü (HKOK) ve Ortalama Mutlak Yüzde Hata (OMYH) kriterleri kullanılmıştır. Bu karşılaştırma kriterlerine göre dalgacık dönüşümüne dayalı tahmin performansının daha iyi olduğu gözlenmiştir.

Forecasting of Per Capita Consumption of Electricity Based on Wavelet Decomposition

Keywords

Statistic,
Time Series,
Box-Jenkins Models,
Wavelet Decomposition

Abstract: Time series analysis is essential and takes a critical role in the areas such as finance, economics, statistic and engineering since it provides the opportunity of making decisions about the future. In time series analysis, Autoregressive (AR) models, Moving Average (MA) models, and Box-Jenkins, which includes Autoregressive Moving Average (ARMA) models, are widely used. However, in order: for the predicted results to be reliable from these models, the series must be stationary, has no noisy data and must be detrended or has no seasonality, which is particularly problematic in financial time series. Wavelet transform (WT), which is based on the separation of time series into two components which are long-term trend and variation, has been recently used in the data preprocessing step in order to overcome that kind of problem. Thus, it provides a separate estimation model for each component of the time series and provides a more accurate estimation of its behavior. In this study, it is aimed to estimate Electricity Consumption per Capita (kWh per capita) by WT and compare the results with the traditional models. For this purpose, kWh per capita data covering the period of 1960 and 2014 of 26 different countries are used. R^2 , Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE) criteria are used for performance comparison. According to these comparison criteria, it is observed that the performance of the prediction based on wavelet transform is better.

*İlgili yazar: aytac0803@mu.edu.tr

1. Giriş

Zaman serisi analizi, finans, ekonomi, fen bilimleri, mühendislik gibi birçok bilim dalında geniş uygulama alanı bulmaktadır. Zaman serisi analizi, genel olarak ilgilenilen bir değişkenin geçmiş değerlerine dayanarak, gelecekte alabileceği değerleri tahmin etmek amacıyla bir model geliştirme işlemidir. Doğrusal regresyon analizi, otoregresif model (AR), hareketli ortalama modeli (MA) ve otoregresif hareketli ortalama modeli (ARMA) bu amaca yönelik olarak kullanılan en popüler istatistiksel modellerdir [1]. Ancak bu modellerin uygulanabilmesi için zaman serisinin trend ve mevsimsel hareket etkisinden arındırılmış olması ve gürültülü veri içermemesi gerekmektedir. Aksi takdirde elde edilen tahmin sonuçları, zaman serisinin gerçek davranışını yansıtmayacaktır. Bu problemin üstesinden gelmek amacıyla veri ön işleme adımında, zaman serisi analizi, temel bileşenler analizi, Fourier ve DD gibi çeşitli teknikler uygulanmaktadır [1]. Ancak dönüştürülmüş seride zaman bilgisinin kaybolmaması, seriyi hem zaman hem de frekans uzayında etkili bir şekilde temsil etmesi DD'yi daha popüler hale getirmektedir. Bunun dışında, DD gürültülü veri filtrelemede de yaygın olarak kullanılan matematiksel araçlardan biridir.

DD'e dayalı tahmin yöntemleri kullanılarak gerçekleştirilen birkaç çalışma şu şekilde özetlenebilir. Aggarwal vd. [13] Ontario elektrik piyasasındaki elektrik ücretini tahmin etmek amacıyla DD'e dayanan yapay sinir ağları modelini önermiştir. Önerilen modelden elde edilen tahminler, sezgisel bir teknik, Ontario Bağımsız Elektrik Sistem Operatörü kullanılarak simule edilen bir model, çoklu doğrusal regresyon, geleneksel yapay sinir ağları, bütünlük ARMA (ARIMA), dinamik regresyon modeli ve transfer fonksiyon modelinden elde edilen tahminler ile karşılaştırılmıştır. Çalışma sonucunda önerilen yöntemden elde edilen tahmin sonuçlarının daha başarılı olduğu görülmüştür. Aggrawal vd. [14] ayrıca Avustralya elektrik piyasasındaki elektrik ücretlerini tahmin etmek amacıyla çoklu doğrusal regresyon ile DD'ü birleştiren yeni bir yöntem önermiştir. Önerilen yöntemin performansı, analitik model, geleneksel çoklu regresyon modeli ve yapay sinir ağları ile karşılaştırılmış ve tahmin sonuçlarının iyileştiği görülmüştür.

Rocha vd. [1] DD'e dayalı yapay sinir ağları modelini akut düşük tansiyonlu epizotların tahminine uygulamıştır. An vd. [15] rüzgar santral gücünü tahmin etmek amacıyla DD ile kaotik zaman serileri ve GM(1,1) yöntemini birleştiren yeni bir yöntem önermiş ve önerilen yöntemin tahmin sonuçlarını iyileştirdiğini tespit etmiştir. Karthikeyan ve Kumar [9] çalışmasında aylık akarsu hacmi ve aylık yağış miktarını tahmin etmek amacıyla dalgacık ve deneysel mod dönüşümüne dayanan zaman serisi analizi kullanmıştır. Çalışma sonucunda DD'e dayanan zaman serisi analizinin tahmin kapasitesinin daha iyi gözlenmiştir. Son olarak, Doucore vd. [10] yenilebilir enerji kaynaklarının

tahmini için DD ve yapay sinir ağlarına dayanan yeni bir yöntem önermiştir.

Bu çalışmada 26 OECD ülkesinin Kişi Başına Elektrik Tüketimi (KBET) zaman serisini modellemek amacıyla DD'e dayanan ARIMA modelleri kullanılmıştır. Bu alanda yapılmış ilk çalışmadır. Kullanılan modellerin performansını doğrulamak amacıyla, bu yöntemden elde edilen tahmin sonuçları geleneksel ARIMA modelleri ile karşılaştırılmıştır.

2. Materyal ve Metot

2.1. Dalgacık Dönüşümüne Dayalı Box-Jenkins Modelleri

Zaman serisi, genellikle gün, ay, yıl gibi düzenli aralıklarla ölçülen belirli bir değişkene ait seri şeklinde tanımlanabilir. Zaman serisi analizi matematiksel olarak, $Y = y_1, y_2, \dots, y_n$ şeklindeki serinin davranışının modellenmesi ve elde edilen model kullanılarak serinin gelecek değerlerinin ($y_{n+1}, y_{n+2}, \dots, y_{n+a}$) tahmin edilmesidir. Modelleme kısmında literatürde kullanılan çok sayıda yöntem bulunmaktadır. Bu çalışmanın ana konusu, zaman serisinin istatistiksel olarak modellenmesinde yaygın olarak kullanılan ARIMA modelleri olarak bilinen Box-Jenkins [11] yöntemidir. Bu yöntemde temel prensip, zaman serisi ile onun geçmiş değerleri ve (veya) olasılıksal hata terimi arasında doğrusal bir ilişki tespit etmektir. Ancak bu yöntemin uygulanabilmesi için zaman serisinin birtakım varsayımları sağlaması gerekir. Bu varsayımların başında durağanlık gelmektedir. Durağanlık genel olarak zaman serisinin ortalama, varyans ve kovaryansının zamanının bir fonksiyonu olmaması, bir başka deyişle, zaman içinde değişmemesi şeklinde tanımlanabilir. Ancak özellikle ekonometrik zaman serileri durağan olmayan bir davranış sergiler. Bunun dışında, tahmin işlemi zorlaştıran aykırı veya gürültülü gözlemler de içerebilmektedir. Bu tür zaman serilerini istatistiksel yöntemler ile analiz edebilmek için zaman serisine bir takım ön işleme işlemleri uygulanır. DD bu amaca yönelik olarak kullanılan yöntemlerden biridir.

DD kısaca, zaman serisinin ardışık olarak yaklaştırma ve detay şeklinde iki farklı bileşene ayrıştırılması işlemidir. DD'nin istatistiksel zaman serisi analizinde kullanılmasının avantajları aşağıdaki gibidir:

- DD, zaman serisinin hem zaman uzayında hem de frekans uzayında temsil edilmesini sağlar. Bu nedenle dönüşüm işlemi sonrasında zaman bilgisi kaybolmaz.
- DD sonucunda, ortalama, varyans ve kovaryansı daha stabil seriler elde edilir.
- DD, gürültülü ve aykırı gözlemlerin olumsuz etkilerinin azaltılmasını sağlar.
- DD sonucunda elde edilen serilerin her biri zaman serisinin farklı bir davranışını içerir. Böylece zaman serisinin her bir davranışı için ayrı bir model tahmin edilir ve zaman serisinin davranışı daha iyi temsil edilir.

DD'e göre bir zaman serisi aşağıdaki eşitliklerde verildiği gibi yazılabilir:

$$y(t) = \sum_{k=1}^n a_{j,k} \varphi_{j,k}(t) + \sum_{j=1}^s \sum_{k=1}^n d_{j,k} \psi_{j,k}(t) \quad (1)$$

$$y(t) = A_s(t) + \sum_{j=1}^s D_j(t) \quad t = 1, 2, \dots, n \quad (2)$$

Eşitliklerde $\varphi_{j,k}(t)$ ölçek fonksiyonunu, $\psi_{j,k}(t)$ dalgacık fonksiyonunu, j ölçek, k dönüşüm parametresini, s ayrıştırma seviyesini, $a_{j,k}$ ve $d_{j,k}$ sırasıyla j . ölçek k . lokasyondaki yaklaştırma ve detay katsayısını, n zaman serisi uzunluğunu, A_s ve D_j sırasıyla s . ayrıştırma seviyesindeki yaklaştırma ve detay serilerini göstermektedir. Burada dalgacık ve ölçek fonksiyonları ise aşağıdaki gibi tanımlanmaktadır:

$$\varphi_{j,k}(t) = 2^{-\frac{j}{2}} \varphi(2^{-j}t - k) \quad (3)$$


$$\psi_{j,k}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - k) \quad (4)$$

DD için yaklaştırma ($a_{j,k}$) ve detay ($d_{j,k}$) katsayılarının hesaplanması gerekir. Bunun için aşağıdaki eşitlikler kullanılmaktadır:

$$a_{j,k} = \int y(t) \varphi_{j,k}(t) dt \quad (5)$$

$$d_{j,k} = \int y(t) \psi_{j,k}(t) dt \quad (6)$$

Eşitlik (5) ve (6)'daki katsayıları hesaplamak amacıyla literatürde genellikle Mallat [12] algoritması kullanılır. Mallat algoritmasına göre, yaklaştırma ve detay katsayıları, ölçek fonksiyon tarafından üretilen alçak geçişli filtre (AGF) ve dalgacık fonksiyonu tarafından üretilen yüksek geçişli filtre (YGF) kullanılarak hesaplanabilir. Mallat algoritmasının genel işleyişi Şekil 1'de verilmektedir.



Şekil 1. Mallat Algoritması [12].

Şekil 1'deki Mallat algoritmasına göre, orijinal zaman serisi ilk olarak AGF ve YGF kullanılarak A_1 ve D_1 şeklinde iki bileşene ayrılır. Bir sonraki ayrıştırma seviyesinde, A_1 bileşeni tekrar A_2 ve D_2 şeklinde iki bileşene ayrılır. Bu işlem istenilen ayrıştırma seviyesine ulaşıncaya kadar devam eder. İşlem sonucunda s tane detay bir tane yaklaştırma serisi elde edilir.

DD'ye dayalı Box-Jenkins yönteminde bundan sonraki aşama elde edilen her bir seri için bir model tahmin etmektir. Dönüştürülmüş seriler için Box-Jenkins [11] modellerinin genel formu aşağıdaki gibidir:

$$A_{st} = \beta_0 + \sum_{i=1}^{p_1} \beta_i A_{st-i} + \sum_{j=1}^{q_1} \tau_j \varepsilon_{st-j} + \varepsilon_{st-j} \quad (7)$$

$$D_{kt} = \beta_0 + \sum_{i=1}^{p_2} \beta_i D_{kt-i} + \sum_{j=1}^{q_2} \tau_j \varepsilon_{kt-j} + \varepsilon_{kt-j} \quad (8)$$

Burada p_1 ve p_2 modelin otoregresif kısmın derecesini, q_1 ve q_2 hareketli ortalama kısmının derecesini, ε_{st-j} ise 0 ortalama sabit varyansla normal dağılan hata terimini göstermektedir. Eşitliklerde verilen modelleri tahmin etmek için ise birtakım adımların izlenmesi gerekmektedir. Bunların başında önceden de belirtildiği gibi durağanlık sınaması gelmektedir. Sınama sonucunda serinin durağan olduğuna karar verilirse bir sonraki adıma geçilir. Aksi takdirde serinin durağanlaşmıyacağı kadar farkı alınır. Durağanlık sınamasından sonra sırasıyla p ve q derecelerinin belirlenmesi, modelin tahmin edilmesi, modelin ve katsayılarının anlamlılığının sınanması, elde edilen hata terimlerinin normal dağılıp dağılmadığının test edilmesi gibi adımlar izlenir. Belirtilen adımlar izlendikten sonra gerçek tahmin değeri aşağıdaki eşitlik kullanılarak hesaplanır.

$$\hat{y}(t) = \hat{A}_s(t) + \sum_{j=1}^s \hat{D}_j(t) \quad t = 1, 2, \dots, n \quad (9)$$

Burada \hat{A}_s yaklaştırma serisinin tahmin değerini, \hat{D}_j ise detay serilerinin tahmin değerlerini göstermektedir.

3. Bulgular

Bu çalışmada 1960-2014 yıllarını kapsayan 26 ülkenin KBET tüketiminin DD'ye dayalı ve geleneksel Box-Jenkins modelleri ile elde edilen tahmin sonuçlarının karşılaştırılması amaçlanmıştır. KBET verileri dünya bankasının web sitesinden elde edilmiştir. Karşılaştırma kriteri olarak aşağıdaki gibi hesaplanan HKOK ve R^2 kriterleri kullanılmıştır.

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y}_t)^2} \quad (10)$$

$$HKOK = \sqrt{\sum_{t=1}^n e_t^2 / n} \quad (11)$$

$$OMYH = \frac{\sum_{t=1}^n |e_t / \bar{y}_t|}{n} \cdot 100 \quad (12)$$

3.1. Uygulama

Bu çalışmada ilk olarak incelenen KBET değişkenlerinin logaritması alınmıştır. Logaritmik serilerle çalışmak serilerin özelliklerini daha iyi incelemek, varyansı dengelemek ve serilerdeki aykırı gözlemlerin etkilerini azaltmak açısından daha çok tercih edilmektedir. DD'ye dayalı yapılan ARMA modelleri tahmini ile geleneksel Box-Jenkins modellerle elde edilen tahmin R², HKOK ve OMYH kriterleri kullanılarak karşılaştırılmıştır.

Her bir ülkenin ilgili serisine ait en uygun modelin belirlenme aşamasından önce serinin durağanlık seviyesi saptanmıştır. Eğer seri durağan değilse farkı alınarak durağanlaştırılmıştır. Her bir ülke için model için gerekli varsayımlara ve Bilgi kriterlerine göre karşılaştırarak en uygun model belirlenmiştir. Bu çalışma kapsamında orijinal verilere daha sonra DD yapılarak elde edilen iki seriye de işlemler farklı farklı uygulanarak her bir ülkeye ait serilerin düzeyde durağan oldukları saptanmış ve belirlenen en uygun modeller Tablo 1'de gösterilmiştir.

Tablo 1. İncelenen serilerin en uygun model yapısı

Ülke	Geleneksel Box-Jenkins	Yaklaşırma Dalgacık	Detay Dalgacık
ABD	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Almanya	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Avustralya	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Avusturya	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Belçika	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Birleşik Krallık	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Danimarka	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Finlandiya	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Fransa	ARMA(1,2)	ARMA(1,1)	ARMA(1,1)
Hollanda	ARMA(2,1)	ARMA(1,1)	ARMA(1,1)
İrlanda	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
İspanya	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
İsveç	ARMA(1,1)	AR(1)	ARMA(1,1)
İsviçre	ARMA(1,1)	ARMA(1,2)	AR(1)
İtalya	ARMA(1,1)	AR(1)	ARMA(1,1)
İzlanda	MA(1)	ARMA(1,1)	ARMA(1,2)
Japonya	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Kanada	ARMA(1,1)	ARMA(1,2)	MA(1)
Lüksemburg	ARMA(1,1)	AR(2)	MA(1)
Kuzey Amerika	ARMA(1,1)	ARMA(2,1)	ARMA(1,1)
Norveç	ARMA(1,2)	ARMA(1,1)	MA(1)
Polonya	ARMA(1,2)	ARMA(1,1)	MA(1)
Portekiz	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)
Türkiye	MA(1)	ARMA(1,1)	MA(1)
Yeni Zelanda	ARMA(2,1)	ARMA(1,1)	ARMA(1,1)
Yunanistan	ARMA(1,1)	ARMA(1,1)	ARMA(1,1)

Tablo 1 incelendiğinde 26 OECD ülkesi arasından aynı model yapısına sahip ve gerekli varsayımları sağlayan 13 ülke (ABD, Almanya, Avustralya, Avusturya, Belçika, Birleşik Krallık, Danimarka, Finlandiya, İrlanda, İspanya, Japonya, Portekiz ve Yunanistan) belirlenmiştir. Diğer ülkelerin aynı model yapısına sahip olmadığı ve varsayımlardan bazılarını da

sağlamadığı görülmüştür. Ayrıca aynı model yapısına ait ülkelerin tamamına bakıldığında model yapılarının ARMA(1,1) olduğu görülmüştür. Bu 13 ülkenin en uygun modeline göre geleneksel ve Dalgacık Box - Jenkins tahminleri elde edilerek her bir ülke için performans karşılaştırma kriter sonuçları Tablo 2'de gösterilmiştir.

Tablo 2. Performans karşılaştırma kriter sonuçları

Ülke	Geleneksel Box - Jenkins			Dalgacık Box - Jenkins		
	R ²	HKOK	OMYH	R ²	HKOK	OMYH
ABD	0,801	3456,6	0,297	0,985	439,9	0,040
Almanya	0,655	2540,9	0,398	0,942	425,8	0,087
Avustralya	0,845	3210,5	0,378	0,987	408,8	0,055
Avusturya	0,930	1633,9	0,263	0,995	178,6	0,034
Belçika	0,833	2589,5	0,381	0,978	391,1	0,061
Birleşik Krallık	0,730	1581,1	0,295	0,892	334,7	0,051
Danimarka	0,970	384,4	0,078	0,971	315,5	0,063
Finlandiya	0,810	5828,7	0,468	0,983	937,5	0,084
İrlanda	0,865	1990,6	0,456	0,958	413,6	0,083
İspanya	0,868	2089,9	0,519	0,962	357,9	0,089
Japonya	0,788	3127,7	0,478	0,974	2302	0,324
Portekiz	0,984	298,3	0,095	0,985	275,9	0,084
Yunanistan	0,854	2393,6	0,656	0,977	275,9	0,090

Tablo 2'deki R² performans karşılaştırma kriterine göre ülkelerin hepsinde Dalgacık Box-Jenkins R² değerinin daha yüksek olduğu ve elde edilen modelde bağımsız değişkenin bağımlı değişkeni daha iyi temsil ettiği görülmüştür. Aynı şekilde HKOK ve OMYH performans karşılaştırma kriterlerine göre ülkelerin hepsinde Dalgacık Box-Jenkins HKOK değerinin çok daha düşük olduğu ve modelden elde edilen hataların küçük olduğu görülmüştür. Buradan yola çıkarak geleneksel ve dalgacık Box-Jenkins için en yüksek ve en düşük R² ile hata değerini veren ülkelere ait model denklemleri aşağıdaki gibidir.

Geleneksel Box-Jenkins model:

En yüksek R² ve En düşük hata (Portekiz):

$$\hat{Y}_t = 0,036 + 0,849Y_{t-1} + 0,988e_{t-1} + u_t$$

En düşük R² (Almanya):

$$\hat{Y}_t = 0,027 + 0,591Y_{t-1} + 0,978e_{t-1} + u_t$$

En yüksek hata (Finlandiya):

$$\hat{Y}_t = 0,039 + 0,625Y_{t-1} + 0,999e_{t-1} + u_t$$

Dalgacık Box-Jenkins model:

En yüksek R² ve En düşük hata (Avusturya):

$$\hat{Y}_t = 0,027 + 0,562Y_{t-1} + 0,969e_{t-1} + u_t$$

En düşük R² (Birleşik Krallık):

$$\hat{Y}_t = 0,673Y_{t-1} + 0,947e_{t-1} + u_t$$

En yüksek hata (Finlandiya):

$$\hat{Y}_t = 0,955Y_{t-1} - 0,971e_{t-1} + u_t$$

4. Tartışma ve Sonuç

1960-2014 yılları arasında 26 OECD ülkesi arasından aynı model özelliklerine sahip olmayan ve gerekli varsayımları sağlayamayan 13 ülke analizden çıkartılmıştır. Geriye kalan 13 OECD ülkesinin KBET verileri incelendiğinde karşılaştırma kriterlerine göre DD'ye dayalı tahmin performansının geleneksel yöntemden çok daha iyi olduğu gözlenmiştir. Bunun sonucu bağımsız değişkenlerin bağımlı değişkeni daha iyi temsil ettiği, modelden elde edilen hataların minimum ve geleceğe yönelik yapılacak öngörünün daha tutarlı olduğu söylenmiştir.

Her iki yöntemde ait R^2 kriteri karşılaştırıldığında bazı ülkelerde (Almanya, Birleşik Krallık, ABD ve Japonya) tahmin performansı arasında çok büyük farklılıklar, bazı ülkelerde ise (Danimarka ve Portekiz) tahmin performansının birbirine çok yakın olduğu görülmüştür.

HKOK kriteri karşılaştırıldığında bazı ülkelerde (Avusturya, Yunanistan, ABD ve Avustralya) tahmin performansı arasında çok büyük farklılıklar, bazı ülkelerde ise (Danimarka ve Portekiz) tahmin performansının birbirine çok yakın olduğu görülmüştür.

OMYH kriteri karşılaştırıldığında bazı ülkelerde (ABD, Avusturya ve Yunanistan) tahmin performansı arasında çok büyük farklılıklar, bazı ülkelerde ise (Danimarka ve Portekiz) tahmin performansının birbirine çok yakın olduğu görülmüştür.

Etik Beyanı

Bu çalışmada, "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

Kaynakça

- [1] Rocha T., Paredes S., Carvalho P., Henriques J., Harris M. 2010. Wavelet based time series forecast with application to acute hypotensive episodes prediction, 32nd Annual International, Conference of IEEE EMBS, August 31-September, Buenos Alres, Argentina, 2403-2406.
- [2] Hiden, H., Willis, M., Tham, M., Montague, G. 1999. Non-linear principal components analysis using genetic programming, Computers and Chemical Engineering, 23, 413-425.
- [3] Schoukens, J., Pintelon, R. 1991. Identification of Linear Systems: a Practical Guideline to Accurate Modeling, Pergamon Press, London, 332s.

- [4] Yao, S., Song, Y., Zhang, L., Cheng, X. 2000. Wavelet transform and neural networks for short-term electrical load, Energy Conversion and Management, 41, 1975-1988.
- [5] Chong T. 2009. Financial Time Series Forecasting Using Improved Wavelet Neural Network, Master's Thesis, 113s.
- [6] Ng, K. Y., Awang, N. 2018. Multiple linear regression and regression with time series error models in forecasting PM10 concentrations in Peninsular Malaysia. Environmental monitoring and assessment, 190(2), 63.
- [7] Bhardwaj, S., Chandrasekhar, E., Padiyar, P., Gadre, V.M. 2020. A comparative study of wavelet-based ANN and classical techniques for geophysical time-series forecasting. Computers & Geosciences, 138, 104461.
- [8] Khan, M.M.H., Muhammad, N.S., El-Shafe, A. 2020. Wavelet based hybrid ANN-ARIMA models for meteorological drought forecasting. Journal of Hydrology, 590, 125380.
- [9] Karthikeyan L., Kumar D.N. 2013. Predictability of nonstationary time series using wavelet and EMD based ARMA models, Journal of Hydrology, 502, 103-119.
- [10] Doucoure B., Agbossou K., Cardenas A. 2016. Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data, Renewable Energy, 92, 202-211.
- [11] Box G.E.P., Jenkins G.M. 1970. Time Series Analysis Forecasting and Control Holden-Day, San Francisco, USA, 553s.
- [12] Mallat S. 1999. A wavelet tour of signal processing, Academic Press, London, UK, 832s.
- [13] Aggarwal S. K., Saini L.M., Kumar A., 2008. Electricity price forecasting in Ontario electricity market using wavelet transform in artificial neural network-based model, International Journal of Control, Automation, and Systems, 6(5), 639-650.
- [14] Aggarwal S. K., Saini L. M., Kumar A. 2008. Price forecasting using wavelet transform and LSE based mixed model in Australian electricity market, International Journal of Energy Sector Management, 2(4), 521-546.
- [15] An X., Jiang D., Liu C., Zhao M. 2011. Wind farm power prediction based on wavelet decomposition and chaotic time series, Expert Systems with Applications, 38(9), 11280-11285.