

**ÇOKLU REGRESYON, ARIMA VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE TÜRKİYE  
ELEKTRİK PİYASASINDA FİYAT TAHMİN VE ANALİZİ\*****Burak ARSLAN** \* **Prof. Dr. İrfan ERTUĞRUL** \* **ÖZET**

Türkiye’de EPIAŞ aracılığıyla işletilen ve operasyon süreçlerinden birisi olarak elektrik piyasalarında arza çıkan her birim elektrik için arz ve talep dengesine göre piyasa takas fiyatı oluşmaktadır. Piyasa takas fiyatı saatlik olarak oluşmakta katılımcılara ve halka açık olarak şeffaf platformlarda bildirilmektedir. Bu çalışmada R istatistik paket programı kullanılarak Çoklu Regresyon yöntemi ve Yapay Sinir Ağı modelleri; Eviews paket programı ile ise ARIMA yöntemi kullanılarak geçmiş piyasa fiyatının analizi ve tahmini gerçekleştirilmiştir. Çoklu Regresyon ve Yapay Sinir Ağları yöntemleri ile piyasa fiyatını doğrudan etkileyen etmenler bağımsız değişkenler olarak ele alınmıştır. ARIMA yönteminde ise verinin geçmiş değerleri referans olarak alınarak analizler gerçekleştirilmiştir. Çalışmada kullanılan analiz yöntemleri sonucunda en iyi performansın sırasıyla Yapay Sinir Ağları, Çoklu Regresyon yöntemi ve ARIMA yönteminden elde edildiği belirlenmiştir.

**Anahtar Kelimeler:** Çoklu Regresyon, Yapay Sinir Ağları, ARIMA, Piyasa Takas Fiyatı (PTF)

**Jel Kodları:** C40, C50, C53

**FORECASTING AND ANALYSIS IN TURKISH ELECTRICITY MARKET WITH  
MULTIPLE REGRESSION, ARIMA AND ARTIFICIAL NEURAL NETWORK METHODS****ABSTRACT**

For each unit of electricity supplied in electricity markets, one of the operation processes and operated through EPIAŞ in Turkey, a market-clearing price is formed according to the supply and demand balance. The market-clearing price is formed hourly and reported to the participants on transparent platforms. The aim of this study is to analyse the market-clearing price in Turkish Electricity Markets and to compare the performances of statistical prediction analysis methods frequently used in the literature. In this study, multiple regression method and artificial neural networks models were applied by using R statistical package program; with the Eviews package program the analysis and estimation

\* Bu çalışma, Pamukkale Üniversitesi İşletme Anabilim Dalı için yazılan “Karşılaştırmalı İstatistiksel Yöntemler ile Türkiye Elektrik Piyasasında Fiyat Tahmin ve Analizi” isimli yüksek lisans tezinden türetilmiştir.

\* Pamukkale Üniversitesi Üniversitesi, S.B.E., İşletme A.B.D., Denizli/ Türkiye. E-mail: [brkarslan20@gmail.com](mailto:brkarslan20@gmail.com)

\* Pamukkale Üniversitesi, İ.İ.B.F., İşletme Bölümü, Denizli/ Türkiye. E-mail: [iertugrul@pau.edu.tr](mailto:iertugrul@pau.edu.tr)

**Makale Geçmişi/Article History**

Başvuru Tarihi / Date of Application : 28 Ağustos / August 2021

Düzeltilme Tarihi / Revision Date : 10 Aralık / December 2021

Kabul Tarihi / Acceptance Date : 01 Şubat / February 2022

of the past market price was performed using the ARIMA method. Analyses were applied to 2928 data of market clearing prices realized in March, April, May and June 2020. In the multiple regression and artificial neural network models, factors, thought to directly affect the market price, are considered as independent variables. In the ARIMA method, analyses were carried out by taking the past values of the data as a reference. The results of the analysis methods used in the study show that the best performance was obtained through artificial neural networks, multiple regression method and ARIMA method, respectively.

**Keywords:** Multiple Regression, Artificial Neural Networks, ARIMA, Market Clearing Price (MCP).

**Jel Codes:** C40, C50, C53.

## 1. GİRİŞ

Enerjiye olan talebin geçtiğimiz yüzyıl boyunca önemli bir şekilde artması dünya enerji piyasalarında ciddi düzenlemelerin uygulanmasını zorunlu kılmıştır. Özellikle dünya elektrik piyasalarında başlayan değişimler Türkiye’de de zamanla oluşmaya başlayan elektrik piyasası kavramının gelişmesinde büyük bir etkiye sahip olmuştur. 1980’li yıllar ile birlikte hız kazanan ilerlemeler ve beraberinde getirdiği düzenlemeler elektrik piyasalarının daha özgür bir sisteme geçiş aşamasının temelini oluşturmaktadır. Dikey bütünleşik bir yapı olarak ortaya çıkan elektrik piyasaları reformları ile birlikte katılımcıların da dahil olduğu liberal olarak adlandırılan yeni yapısına kavuşmuştur (Çetintaş ve Bicil, 2015: 20).

Sistemin liberalleşmesi ile beraber piyasaya katılım sağlayan birçok özel sektör katılımcısı ortaya çıkarak enerji sektörünün gelişmesine büyük bir katkı sağlanmıştır. Daha önce devlet hâkimiyetinde olan elektrik sektörüne katılımcıların dahil olması yeni uygulamaları da beraberinde getirmiştir. Dünyada teknolojinin büyük bir hızla gelişmesi ile beraber enerjiye olan talep her daim yüksek kalmış ve sistemin teknolojiye ayak uydurması sağlanmıştır. Küresel düzeyde başlayan serbestleşme süreci ile beraber enerji alışverişi için bir sistem ihtiyacı ortaya çıkmıştır. Enerji ticareti için borsaya benzer bir sistemin kurulması enerji ticareti yapan katılımcılar için büyük bir kolaylık sağlamış, havuz sistemine benzer bir yapıda ticaret gerçekleştirilmeye başlanmıştır. Böylelikle ülkeler kendi enerji piyasalarını oluşturmaya başlamış ve enerji ticaretlerini bu ortamlarda yapabilme fırsatı yakalamışlardır.

Elektrik piyasası esasında elektrik üreticileri, sistem operatörleri, piyasa operatörleri ve alıcılar gibi birçok destek birimi ve katılımcının yer aldığı anlaşmalara dayalı bir sistemdir. Piyasanın yapısı gereği sistemde üreticiler elektriği en yüksek fiyattan satmak isterken, alıcılar ise piyasadaki en düşük fiyattan almak isterler. Elektrik piyasalarına katılım gönüllü veya zorunlu olabilir. Katılımın zorunlu olduğu elektrik piyasalarında ise daha az üretim gücüne sahip işletmeler dışında bütün üreticiler sisteme dahil olmak zorundadırlar. Elektrik piyasalarının temeli üreticilerin hangi fiyattan ne kadar elektrik üretebileceklerini sisteme teklif etmeleri ile başlamaktadır. Piyasa sistemi genel olarak üretim yapan üreticinin saatlik bazda oluşan talebi karşılama esasına dayalıdır (Onaiwu, 2009: 2-8).

PTF sisteme katılan piyasa oyuncuları için oldukça önemlidir. PTF'yi katılımcılar kendilerine referans olarak almakta ve işlemlerini buna göre planlamaktadırlar. Gün Öncesi Piyasasında arz ve taleplere göre oluşan PTF özellikle üreticiler için ayrı bir öneme sahiptir. Elektrik üretiminin zorlu süreçler sonucunda oluştuğu gerçeği ile üreticiler her bir birim elektrik miktarını en yüksek fiyattan satmak isterler. Özellikle büyük havzalara sahip baraj tipi elektrik üretim santrali işletmecileri bunu göz önünde bulundurarak fiyatın düşük olduğu zamanlarda havzalarında bulunan suyu tutarak fiyatların yükselmesini beklemektedirler.

Üreticiler için PTF'nin bilinmesi piyasada optimum işlem yapabilmelerinin yanında ikili anlaşmaları etkin bir şekilde yürütebilmeleri açısından da oldukça önemlidir. Kısa vadede piyasa fiyatının bilinebilmesi piyasa katılımcılarının portföylerini dengelemeye yardımcı olurken özellikle orta ve uzun vadede PTF'nin ulaşması beklenen fiyatların aylar bazında tahmin edilebilmesi şirketler açısından optimum fiyattan ikili anlaşma sözleşmeleri yapmaları bakımından oldukça kritiktir (Conejo vd., 2005: 436).

Elektrik ticareti yapan perakende ve büyük tüketiciler içinde PTF'nin analizi ve tahmini üreticiler kadar önemlidir. Aynı şekilde piyasada ticarete bulunan bu katılımcılar için piyasa fiyatı tahmininin yapılabilmesi finansal açıdan riskleri belirlemelerine yardımcı olacak aynı zamanda etkin bir planlama yapabilmelerine olanak sağlayacaktır (Conejo vd., 2005: 436).

Piyasa fiyatının bu denli önemli olduğu elektrik piyasalarında tahmin çalışmaları oldukça hız kazanmıştır. Teknolojik ilerlemeler ve gelişmeler piyasa yapılarını da değiştirmiş ve sürekli olarak araştırmaların güncel tutulmasını gerektirmiştir. Aylara ve mevsimlere göre değişen piyasa fiyatının analizi yapılarak fiyatı etkileyen önemli bileşenlerin tespiti önem arz etmektedir. Özellikle ülkemizde piyasalarda yaşanan gelişmelere istinaden istatistik, yapay zeka gibi tahmin araçlarıyla PTF'nin tahmin edilmeye çalışıldığı görülmektedir. Literatürde sıklıkla kullanılan tahmin yöntemlerinden hangilerinin daha etkin sonuç vereceğinin belirlenmesi ileride bu alanda yapılacak araştırmalara ışık tutacaktır.

## **2. LİTERATÜR ARAŞTIRMASI**

Alan yazında elektrik fiyatlarının tahmini ile ilgili yapılan ulusal ve uluslararası pek çok çalışma bulunmaktadır.

Contreas (2003), Bir sonraki gün fiyat tahmini çalışması için İspanya piyasası ve Kaliforniya elektrik piyasalarında ARIMA modelini uygulamıştır. İspanya piyasası için üç haftalık veri kullanmıştır. İspanya piyasası için 2000 yılı Mayıs, Ağustos ve Kasım aylarının son haftalarındaki oluşan piyasa fiyat verilerini, Kaliforniya piyasası için ise sadece 2000 yılı nisan ayındaki 3 günlük veriyi kullanarak farklı piyasalar için ARIMA yöntemini uygulayarak gelecek günlerin piyasa fiyatını tahmin etmeye çalışmıştır.

Torro (2007), Norveç bölgesi için Nord Pool Elektrik Piyasasında haftalık fiyat tahmini çalışmasında bulunmuştur. Tahmin çalışmasında ARIMAX yöntemini kullanarak çalışmasına dışsal değişkenleri de dâhil etmiştir. Dışsal değişken olarak ise sıcaklık, yağış ve rezervuar seviyesi gibi değerleri kullanmıştır. Alternatif tahmin yöntemi kullanan ilk çalışma olması nedeniyle önemlidir. Yaptığı çalışmada ARIMAX yönteminin başarılı sonuçlar verdiğini tespit etmiştir.

Carpio vd. (2012), Singapur Elektrik Piyasaları için gün öncesi fiyat tahmini yapmışlardır. 2005 yılı Nisan ve Haziran aylarını veri olarak kullanmışlardır. Fiyat tahmini çalışmalarında ARIMA ve Wavelet ARIMA yöntemlerini kullanarak karşılaştırma yapmışlardır. Nisan ayı için ARIMA modeli daha fazla performans gösterirken, Haziran ayında Wavelet ARIMA modeli daha başarılı olmuştur.

Özözen vd. (2016), PTF tahmini için Zaman Serileri ve Yapay Sinir Ağları yöntemlerini kullanmışlardır. 2014 ve 2015 yılları için bütün saatlik verileri kullanarak 17.520 adet veri üzerinde çalışmalarının gerçekleştirmişlerdir. Hibrit tahmin yöntemlerin başarılı olduğunu kanıtlamak için SARIMA ve Geri Beslemeli Yapay Sinir Ağları yöntemlerini birlikte kullanarak hibrit bir model oluşturmuşlardır. Yaptıkları çalışma sonucu hibrit yöntemin sadece SARIMA yöntemi kullanılarak yapılan tahmine göre daha başarılı olduğu sonucuna varmışlardır.

Ferreira vd. (2019), İspanya ve Portekiz elektrik piyasaları için Çoklu Regresyon yöntemi ile uzun dönem fiyat ön görüşünde bulunmuşlardır. Çalışmalarında farklı tipte değişken kullanmışlardır. Bu değişkenler arasından elektrik tüketimi ve hidroelektrik üretimi girdi değişkeni olarak ele aldıkları verilerden bazılarıdır. Analizlerinde Portekiz elektrik piyasasında elde ettikleri sonuçlar İspanya piyasalarına göre daha iyi olarak elde edilmiştir. Yaptıkları çalışmada bu iki piyasa için piyasayı etkileyen etmenlerin farklı olduğunu tespit etmişlerdir.

Kalfa vd. (2021), Türkiye elektrik piyasaları için yaptıkları çalışmada 2019 yılı verilerini kullanarak Çoklu Regresyon yöntemi ile fiyat analizi yapmışlardır. Karşılaştırma yapmak amacı ile Yapay Sinir Ağlarını da çalışmalarında kullanmışlardır. Çalışmalarında girdi değişkenleri olarak doğalgaz, hidroelektrik, termik ve rüzgar üretimlerini almışlardır. Ocak ve Haziran aylarına ilişkin yaptıkları analizlerde Yapay Sinir Ağlarının Çoklu Regresyon yöntemine göre daha başarılı olduğu sonucuna ulaşmışlardır. Ayrıca Çoklu Regresyon yönteminin değişkeni etkileyen parametrelerin analizi ve tespiti konusunda iyi sonuçlar verdiğini göstermişlerdir.

Bu çalışmanın amacı ise gün öncesi piyasa verilerini kullanarak PTF'yi etkileyen etmenleri analiz etmek ve tahmin yöntemlerinin performansını karşılaştırmaktır.

### **3. VERİ VE YÖNTEM**

#### **3.1. Veri**

Bu çalışmada analizler 2020 yılı Mart, Nisan, Mayıs ve Haziran aylarında gerçekleşmiş olan 2.928 adet saatlik olarak oluşan , birimi arz ve talep edilen enerjinin kesişme noktası olan (TL/MWh)

piyasa takas fiyatı verisi ve piyasa takas fiyatını etkileyen birimi üretilen toplam elektrik miktarı (MWh) olan hangi enerji kaynağından ne kadar MWh elektrik üretildiğini gösteren diğer saatlik bağımsız değişkenler (Doğalgaz Üretim Miktarı, Rüzgar Üretim Miktarı, Hidroelektrik Üretim Miktarı, Termik Üretim Miktarı) ve o günkü ihtiyaç duyulan elektrik miktarını gösteren birimi tüketilen toplam elektrik miktarı (MWh) olan Talep Miktarı ile gerçekleştirilmiştir. Veriler EPIAŞ'ın halka açık olarak paylaştığı şeffaflık platformundan elde edilmiştir.

### 3.2. Yöntem

Türkiye elektrik piyasaları gün öncesi elektrik piyasasında oluşan PTF bu çalışmanın konusunu oluşturmuştur. PTF'yi etkileyen birçok parametre bulunmaktadır. PTF dış etkenlere bağlı olarak artmakta veya azalmaktadır. Bu çalışmada aylara ve mevsimlere göre değişen bu dalgalanma grafikler ile analizi yapılarak fiyatı etkileyen en önemli bileşenler çoklu regresyon analizi yöntemi ile tespit edilmiştir. Çoklu regresyon yöntemi ile oluşturulan modelde değişkenlerin etkisi incelenmiş, aynı zamanda farklı ayların farklı günleri için tahmin öngörüsünde bulunulmuştur. Aynı veriler yapay sinir ağları kullanılarak da analiz edilmiş ve farklı nöron sayılarına sahip modellerin fiyat tahmin analizi gerçekleştirilmesi ile beraber çoklu regresyon yöntemi ile elde edilen sonuçların, tahmin performansı kıyaslaması amacıyla karşılaştırılması yapılmıştır. Geleneksel tahmin yöntemleri ile kıyaslama yapabilmek için ARIMA yöntemi de çalışmada kullanılmış ve tahmin yöntemlerinin performans kıyaslaması yapılmıştır. Girdi verileri için literatürde benzer çalışmalarda ele alınan değişkenler analiz edilmiştir. Genel olarak PTF'yi doğrudan etkileyen değişkenlerden hidroelektrik, termik ve talep miktarları bağımsız değişkenler olarak ele alınırken dolaylı yoldan etkileyen gün, nem, sıcaklık, yakıt maliyetleri gibi değişkenlerin de diğer bağımsız değişkenler olarak ele alındığı belirtilmiştir (Aggarwal vd., 2009:15). Çalışmada ise değişkenler belirlenirken PTF'yi doğrudan etkileyen diğer değişkenler de modele dahil edilmiş hidroelektrik, doğalgaz, rüzgar, termik üretimleri ve enerjiye olan talep miktarları PTF'yi doğrudan etkileyen bağımsız değişkenler olarak belirlenmiştir.

**Tablo 1. Girdi Değişkenleri**

Girdi Değişkenleri
Doğalgaz Üretim Miktarı
Rüzgâr Üretim Miktarı
Hidroelektrik Üretim Miktarı (Akarsu + Baraj)
Termik Üretim Miktarı (Linyit + Taşkömürü)
Talep Miktarı

#### 3.2.1. Çoklu Doğrusal Regresyon Modeli

Bağımlı değişkeni etkileyen birden fazla değişken parametre bulunabilmektedir. Çoklu regresyon modelleri sayesinde bu ilişkiler irdelenmekte ve analizleri yapılabilmektedir (Yavuz, 2009: 125). Çoklu Regresyon Modeli eldeki verilere dayanarak bağımsız değişkenler üzerinden bağımlı değişkeni açıklayacak bir model kurma sürecidir. Tahmini yapılacak tek bir değişkene karşılık değişkeni etkileyebilecek birden fazla veri modele dahil edilmektedir. Çoklu regresyon modeli ile beraber yapılan

analizlerde bağımlı değişkeni etkileyen parametreler belirlenmekte, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisi incelenebilmekte ve bağımlı değişkenin ileride göstereceği hareketler tahmin edilmektedir. Çoklu regresyon modeli analizlerinde tahmin yapılırken en küçük kareler yöntemine başvurulur. En optimal regresyon katsayıları elde edilerek bağımlı değişkenin gelecekteki değerleri analiz edilebilir (Mazengia, 2008: 21). Çoklu regresyon yönteminde kullanılan en küçük kareler yöntemi meydana gelen hataların karelerinin toplamını en aza indirgeyecek katsayıların hesaplanmasıdır. Aynı zamanda hatanın minimuma yakınsayabilmesi için gerçekleşen verilerin etrafından geçecek en optimal doğrusal eğrinin çizilmesi olarak da ifade edilmektedir (Karagöz, 1999: 198).

Çoklu regresyon modeli Eşitlik 1.'deki gibi gösterilmektedir (Ferreira vd., 2019: 3).

$$y_t = \beta_0 + \beta_1 x_{1t} + \beta_2 x_{2t} + \beta_j x_{pt} + \dots + \beta_l x_{lt} + \varepsilon_t \quad (1)$$

$$t = 1, 2, \dots, n, p = 1, 2, \dots, l \quad (2)$$

Modelde  $\beta_0$  regresyon katsayısını,  $\beta_j$  modelin parametresini,  $\varepsilon_t$  ise modelin stokastik olduğunu ve modele dahil edilmeyen değişkenlerin hata terimini ifade etmektedir.

Bağımsız değişkenlerin hedef (bağımlı) değişkeni açıklama oranı  $R^2$  olarak ifade edilmektedir.  $R^2$  değeri 0 ve 1 arasında değer almaktadır. Bu değer 0'a yaklaşması modelin bağımsız değişkenlerinin hedef değişkeni açıklayamadığını, 1'e yaklaşması ise bağımsız değişkenlerin hedef (bağımlı) değişkeni iyi şekilde açıkladığını göstermektedir (Tutar vd., 2010:212).

Denklem kurulduktan sonra analiz sonuçlarının güvenilirliği için tahmin doğruluğunun ölçülmesi gerekmektedir. İstatistiksel olarak tahmin doğruluğunun ölçülmesinde birden fazla yöntem bulunmaktadır. Çalışmalarda sık olarak kullanılan Ortalama Mutlak Hata Oranı (MAPE) olarak adlandırılan ölçüm yöntemine değinilmiştir. Bu yöntem her bir zaman periyodu için mutlak olarak gerçek ve tahmin farklarını alır ve gerçek değere bölerek sonuç verir. MAPE'nin gösterimi eşitlikte ifade edilmiştir (Ferreria vd., 2019: 3).

$$MAPE = \frac{1}{n} \sum_{x=1}^n \left| \frac{A_x - F_x}{A_x} \right| \quad (3)$$

MAPE  $\leq$  %10 olduğu durumlar yüksek tahmin doğruluğu, %10 ile %20 aralığı iyi tahmin doğruluğu, %20 ila %50 arası normal tahmin doğruluğu %50 ve daha fazlası ise kötü tahmin doğruluğu olarak ifade edilmektedir (Kumar vd., 2016:590).

### **3.2.2. Box-Jenkins Yöntemi (ARIMA)**

Box-Jenkins tahmin modelleri Zaman Serisi Analizlerinde sık kullanılan bir tahmin yöntemidir. İlk olarak 1976 yılında Box ve Jenkins tarafından tanıtılan model ARIMA modelleri olarak bilinir. Box-Jenkins tahmin modelleri üzerinde analiz yapılırken serilerin durağan bir davranış göstermesi yani serilerin varyans, ortalama ve kovaryansları zaman boyunca sabit kalması gerekmektedir. Durağanlığın

sağlanması zaman serisi analizinde klasik regresyonun geçerli olması açısından önemlidir. Box-Jenkins yönteminde analizlerin doğru yapılması açısından durağan olmayan zaman serilerinin durağan olması sağlanmaktadır (Peter vd., 2012: 136).

Zaman serileri analiz yönteminde ARIMA modeli stokastik bir süreç olarak anılmaktadır. Bu sebeple bu model doğrusal, stokastik ve kesikli zaman serisine sahip verilerde kullanılır (Contreas, 2003: 1014). ARIMA modeli incelendiğinde AR ve MA modellerinin birleşiminin farkı alınmış şekli olarak ifade edilmektedir. Zaman serilerinde durağan bir davranış göstermeyen fakat farkı alınarak durağan yapılan zaman serileri durağan olmayan zaman serileri olarak ifade edilmektedir.

ARIMA modeli ifade edilirken geleneksel olarak ARIMA( $p, d, q$ ) şeklinde gösterilir. Modelde yer alan  $p$  parametresi otoregresyon modelinin seviyesini,  $d$  parametresi zaman serisinin kaç defa farkının alındığını,  $q$  parametresi ise hareketli ortalama modelinin seviyesini göstermektedir.

Modelde bağımlı olarak ifade edilen değişkenin gelecek tahminleri, bağımsız değişkeninin geçmişte elde edilen verileri ve meydana gelen hataları şeklinde ifade edilmektedir. Denklem 4'de ARIMA modelinin denklemi gösterilmiştir (Peter vd., 2012: 136).

$$Y_t = Z + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \vartheta_1 \varepsilon_{t-1} + \vartheta_2 \varepsilon_{t-2} + \dots + \vartheta_j \varepsilon_{t-j} \quad (4)$$

$Y_t$  bir ve birden fazla kere farkı alınmış zaman serisini oluşturmaktadır. Diğer parametreler ise şu şekildedir;

Z: sabit

$\phi_p$ : AR model parametresi

$\vartheta_j$ : MA model parametresi

$\varepsilon_t$ : Hata

Model kurulurken ilk olarak serinin durağanlığına, tespit edilen modelin uygunluğuna ve tahmin sonuçlarına, doğru modelin seçimine ve yeterliliğine bakılmaktadır (Eravcı, 2018: 62).

Modeller analiz edilirken zaman serisinin durağan olup olmadığı zaman serisinin varyansı, ortalaması ve kovaryansı zaman içerisinde farklılık göstermiyor ise bu zaman serisinin durağan olduğunu gösterir. Durağanlık analizi Dickey-Fuller (DF) ve Phillips-Perron (PP) testleri aracılığıyla tespit edilebilir. Dickey Fuller denklemi aşağıda gösterilmiştir (Dickey vd., 1979: 427).

$$Y_t = \rho Y_{t-1} + \varepsilon \quad (5)$$

$H_0: \rho = 1$  (Durağan Olmama Durumu)

$H_1: \rho < 1$  (Durağan Olma Durumu)

Hipoteze göre  $\rho = 1$  olduğunda zaman serisinin durağan olmadığı,  $\rho < 1$  olduğunda ise zaman serisinin durağan olduğu ifade edilir.

ACF (Autocorrelation Function) olarak adlandırılan otokorelasyon fonksiyon grafiği de durağanlığın tespit edilmesi hususunda araştırmacılara yol göstermektedir. ACF grafiğinde gecikme uzunluğuna paralel olarak zaman serisi çizgileri yavaş bir şekilde azalarak uzun çizgiler ile eksen kesmekte ise zaman serisinin durağan olmadığı anlaşılmaktadır ve model üzerinde fark alma işleminin uygulanması gerektirmektedir.

Modelin uygulununun sınanması için ise bazı testler uygulanmaktadır. Literatürde yaygın olarak kullanılan testler bilgi teorisine bağlı olarak AIC (Akaike's Information Criterion), BIC (Bayesian Information Criterion) yöntemi ve  $R^2$  belirlenim katsayısıdır. AIC yönteminde amaç veri tipinin uygunluğuna göre modelin tasarlanması iken BIC gerçek modelin tanımlanması için oluşturulmuş bilgi kriterine dayalı bir yöntemdir (Kaya vd., 2012: 40).

AIC ve BIC bilgi ölçütleri aşağıdaki denklemdeki gibi gösterilmektedir (Akaike, 1974:716; Stone, 1979:276):

$$AIC = -2 \cdot \ln(L) + 2 \cdot k \quad (6)$$

$$BIC = -2 \cdot \ln(L) + 2 \cdot \ln(N) \cdot k \quad (7)$$

L: olasılık değeri

N: yapılan ölçüm sayısı

k: Tahmin edilen parametre sayısı

Uygun model seçilirken büyük  $R^2$  değeri ile beraber minimum AIC ve BIC değerlerine sahip model seçilir.

### **3.2.3. Yapay Sinir Ağları**

Yapay sinir ağları ile ilgili çalışmalar 1940'lı yıllarda bilgisayar ile ilgili teknolojinin ilerleme kaydetmesiyle hız kazanmıştır. İnsan biyolojik sinir sistemine benzer olarak yapılandırıldığından yapay sinir ağları ismini almıştır. Yapay sinir ağları modelleme konusunda daha karmaşık olan ilişkilerin irdelenmesi açısından yaygın olarak kullanılmaktadır. Bunun yanında yapay sinir ağlarının lineerlik koşulu aramaması, herhangi bir varsayıma gerek duymaması, hataya karşı toleranslı olması, makine öğrenmesini gerçekleştirerek benzer durumlara karşısında mantıklı kararlar verebilmesi yapay sinir ağlarının avantajları olarak ele alınmakta ve bu avantajlar yapay sinir ağlarının yaygın olarak kullanılma sebepleri arasında gösterilmektedir (Mijwel, 2018:1). Yapay sinir ağlarının çalışma prensibi sinir sistemi mekanizması örnek alınarak hazırlanmış ve makine öğrenmesine dayalı modeller olarak tanımlanmaktadır. Bir diğer ifade ile yapay sinir ağları birden fazla bağlı işlemlerin ihtiyaç duyulan



problem çözümlerinde algoritmalar kullanılarak hesaplanmasıdır (Öztemel, 2006:1). Şekil 1’de girdi ve çıktı katmanından oluşan bir yapay sinir hücre yapısı gösterilmektedir.


**Şekil 1. Yapay Sinir Hücre Yapısı**



**Kaynak:** Gershensun, 2003: 2

Yapay sinir ağlarında teknik olarak beklenen durum ağa tanıtılan bir girdi setine karşılık bir çıktı setinin oluşturulmasıdır. Bu ise ağın benzer örnekler ile eğitilerek istenen düzeye getirilmesi şekliyle oluşur. Yapay sinir ağları incelendiğinde 3 kısımdan oluştuğu tespit edilmektedir. Bunlar Şekil 2’de gösterildiği gibi girdi, gizli ve çıktı katmanları olarak isimlendirilmektedir.

**Şekil 2. Yapay Sinir Ağı Giriş, Gizli ve Çıkış Katmanı**



**Kaynak:** Yıldırım, 2018: 98

Girdi katmanında gelen girdi verileri herhangi bir işleme tabi tutulmadan gizli katmana iletilmektedir. Gizli katmanda ise gelen girdi verileri işleme tabi olmaktadır. Gizli katmanlar ara katmanlar olarak da adlandırılabilirler ve sayıları birden fazla olabilir. Burada işlenen veriler ise çıktı katmanına gönderilirler. Ara katmandan gelen işlenmiş veriler çıkış katmanına ulaşarak modelin beklenen çıktısı elde edilir (Öztemel, 2006: 53).

Yapay Sinir Ağları yapıları ve öğrenme yöntemlerine göre sınıflandırılmaktadırlar. Yapılarına göre sınıflandırılan yapay sinir ağları ileri beslemeli ağlar ve geri beslemeli ağlar olmak üzere 2’ye ayrılmaktadır. İleri beslemeli ağlarda bilgi işleme aşaması eğitim setinde yer alan örneklemin girdi katmanından ağa gösterilmesi ile başlamaktadır. İleri beslemeli bir ağ giriş, çıkış ve gizli katmanlardan oluşmaktadır. İşlem yapan eleman veri üzerinde bağımsız bir çözümlene yaparak sonucu diğer katmana iletir. Aynı şekilde bir sonraki katman aynı işlemleri tekrarlayarak sonucu bir sonraki katmana iletir. Bu şekilde oluşan süreçte bir veya birden fazla ara katman ağın vereceği sonucu belirlemiş olur. Geri beslemeli ağlar ileri beslemeli ağlara oranla analizi daha karmaşık bir yapıdadır. Geri beslemeli ağlarda

yapay sinir ağı bir geri bildirim mekanizması ile işlemektedir. Nöronlar arasındaki tüm olası bağlantılara ise izin verilmektedir. Yapay sinir ağına verilen girdinin verdiği sonuçlar ile beklenen sonuçlar karşılaştırılarak hata oranı tespit edilerek hata ağırlıklara dağıtılır ve yapay sinir ağına tekrar kazandırılır. Bu şekilde hatanın azaltılması amaçlanır (Öztemel, 2006: 78; Khare, 2006: 32). Çoğu yapay sinir ağıları modelleri denetimli öğrenme algoritmalarını kullanır. Birçok öğrenme yöntemi olmakla beraber yaygın olarak kullanılan öğrenme algoritması geriyayılım algoritmasıdır. (Khare, 2006:34)

Geriyayılım algoritması Werbos (1974) tarafından geliştirildikten sonra Rumelhar ve McClelland (1986) tarafından ileri beslemeli yapay sinir ağlarında kullanılmak üzere iyileştirilmiştir. Bu algoritma ileri besleme ile beraber meydana gelen hatanın azaltılması için geriyayılım yapılarak ağırlıkların revize edilmesi esasına dayanır. Geriyayılım algoritmasının temel hedefi yapay sinir ağı eğitim örneklemini öğrenene kadar hatayı azaltmaktır. Yapay sinir ağları eğitilirken ilk olarak ağırlıklar rastgele olarak dağıtılır. Beklenen çıktı ve ağın ürettiği çıktı mukayese edilir. Gerçekleşen çıktı ve beklenen çıktı arasındaki fark hata olarak değerlendirilir. Hata minimize edilene kadar ağırlıklar yeniden düzenlenerek döngü tekrar edilir.

#### **3.2.4. Bulgular**

Çoklu Regresyon yöntemi bu çalışmada kullanılan ilk analiz yöntemi olarak ele alınmıştır. Çoklu regresyon yönteminin gerçekleştirilmesi için analiz edilen veri setinin normal dağılıma sahip olması gereklidir. Normallik sınavında test yöntemlerinden birisi olan Kurtosis ve Skewness analizi veri setinin normal dağılım sergileyip sergilemediğinin analizi için kullanılmaktadır. Bu sebeple çoklu regresyon analizinde normallik sınavları için Kurtosis (basıklık) ve Skewness (çarpıklık) değerleri dikkate alınmıştır. Çalışmada kullanılan aylar için analizin sonuçları Tablo 2’de gösterilmiştir.

**Tablo 2. Kurtosis ve Skewness Değerleri**

	<b>Mart</b>	<b>Nisan</b>	<b>Mayıs</b>	<b>Haziran</b>
<b>Kurtosis</b>	0,35	-1,05	-0,85	0,76
<b>Skewness</b>	-0,94	-0,35	-0,62	-1,3

Aylar bazında Kurtosis ve Skewness değerleri incelendiğinde sonuçların beklenen aralıklar dahilinde olduğu görülmektedir. Değerler  $+\infty$  ile  $-\infty$  arasında bulunabilmektedir. Genel olarak bu değerlerin -3 ile +3 veya -1.5 ile +1.5 değerleri arasında normal kabul edildiği ifade edilmektedir (Kalayci, 2014: 6) (Tabachnick and Fidell, 2013).

**Tablo 3. Mart Ayı Çoklu Regresyon Tablosu**

	$\beta$	Std. Hata	t	p	
<b>Sabit Terim</b>	-2,06E+02	2,11E+01	-9,75	< 2e-16	***
<b>Doğalgaz</b>	9,65E-03	2,18E-03	4,43	1,09E-05	***
<b>Hidroelektrik</b>	1,03E-02	1,65E-03	6,28	5,79E-10	***
<b>Termik</b>	-1,90E-02	1,82E-03	-10,35	<2e-16	***
<b>Talep</b>	1,13E-02	9,77E-04	11,53	<2e-16	***

Anlamlılık Dereceleri '\*\*\*' 0,001 '\*\*' 0,01 '\*' 0,05

 $R^2$ : 0,6514 Düzeltilmiş R-kare: 0,6495

p-değeri : &lt;2,2e-16

**Tablo 4. Nisan Ayı Çoklu Regresyon Tablosu**

	$\beta$	Std. Hata	t	p	
<b>Sabit Terim</b>	-2,25E+02	1,82E+01	-12,378	< 2e-16	***
<b>Doğalgaz</b>	3,32E-02	3,54E-03	9,368	< 2e-16	***
<b>Termik</b>	3,26E-02	2,47E-03	13,207	< 2e-16	***
<b>Hidroelektrik</b>	8,67E-03	1,18E-03	7,344	5,66E-13	***
<b>Rüzgar</b>	-4,97E-03	1,79E-03	-2,776	0,00564	**

Anlamlılık Dereceleri '\*\*\*' 0,001 '\*\*' 0,01 '\*' 0,05

 $R^2$ : 0,6423 Düzeltilmiş R-kare: 0,6403

p-değeri : &lt;2,2e-16

Mart Ayı analizinde dört bağımsız değişken ile kurulan çoklu regresyon modelinde Bağımsız değişken 1 Doğalgaz, Değişken 2 Termik, Değişken 3 Rüzgâr üretim miktarlarına karşılık gelirken, Değişken 4 ise Talep miktarını karşılamaktadır. Model oluşturulma aşamasında saçılım grafiğinde talep arzı ve hidroelektrik üretimi arasında yüksek bir korelasyon meydana geldiği tespit edildiğinden modelin daha doğru yorumlanabilmesi amacıyla yalnızca Hidroelektrik üretim değişkeni modele dahil edilmiştir. Tablo 3 çoklu regresyon modelinde her bir değişkenin p değerinin 0,001 anlamlılık düzeyini karşıladığı tespit edilmiştir. Modelde  $\beta$  katsayısının artı olması bağımsız değişkenin bağımlı değişken üzerinde pozitif bir etkisi olduğunu, eksi olması ise negatif yönlü bir etkisi olduğunu göstermektedir (Demirel vd., 2009:140). Düzeltilmiş  $R^2$  oranı incelendiğinde ise bağımlı değişkendeki değişimin % 64,95'i bağımsız değişkenler ile açıklanabilmektedir. Modelin performansına bakıldığında ise tahmin edilen değerler gerçek değerlerden %6,64 oranında sapmaktadır.

Nisan ayı analizinde dört bağımsız değişken ile kurulan çoklu regresyon modelinde Bağımsız değişken 1 (Doğalgaz üretimi), Bağımsız değişken 2 (Termik üretimi), Bağımsız değişken 3 (Hidroelektrik üretimi) ve Bağımsız değişken 4 (Rüzgar Üretimi) ile model açıklanmıştır. Tablo 4 her bir bağımsız değişkenin 0,001 ve 0,01 anlamlılık düzeylerini sağladığı açıkça görülmektedir. Mart ayı analizinin aksine bağımsız değişken olarak aralarında yüksek korelasyon bulunan Hidroelektrik ve Talep miktarı değişkenleri arasında modeli daha iyi açıklayacağı düşünülen daha yüksek R-kare değerine sahip Hidroelektrik üretimi değişkeni olarak alınarak Talep miktarı modele dahil edilmemiştir.

Bağımsız değişkenlerin modeli açıklama oranına bakıldığında düzeltilmiş  $R^2$  değeri % 64,03 olarak hesaplanmıştır. Tahmin edilen değerler gerçek değerlerden %13,30 oranında sapmaktadır.

**Tablo 5. Mayıs Ayı Çoklu Regresyon Modeli**

	$\beta$	Std. Hata	t	p	
<b>Sabit Terim</b>	-1,73E+02	1,65E+01	-10,482	< 2e-16	***
<b>Doğalgaz</b>	3,11E-02	2,84E-03	10,932	< 2e-16	***
<b>Termik</b>	2,51E-02	2,19E-03	11,493	< 2e-16	***
<b>Talep</b>	3,76E-03	9,65E-04	3,901	0,000105	***

Anlamlılık Dereceleri '\*\*\*' 0,001 '\*\*' 0,01 '\*' 0,05  
 $R^2$  : 0,6487 Düzeltilmiş R-kare: 0,6472  
p-değeri : <2,2e-16

**Tablo 6. Haziran Ayı Çoklu Regresyon Tablosu**

	$\beta$	Std. Hata	t	p	
<b>Sabit Terim</b>	66,85	2,12E+01	3,15	0,0017	**
<b>Doğalgaz</b>	-1,83E-02	6,92E-03	-2,642	0,00842	**
<b>Hidroelektrik</b>	-3,18E-02	6,96E-03	-4,575	5,62E-06	***
<b>Termik</b>	-3,22E-02	7,11E-03	-4,537	6,69E-06	***
<b>Rüzgar</b>	-3,24E-02	6,68E-03	-4,857	1,46E-06	***
<b>Talep</b>	-3,51E-02	6,97E-03	5,031	6,17E-07	***

Anlamlılık Dereceleri '\*\*\*' 0,001 '\*\*' 0,01 '\*' 0,05  
 $R^2$  : 0,498 Düzeltilmiş R-kare: 0,4945  
p-değeri : <2,2e-16

Mayıs ayı analizinde üç adet bağımsız değişken ile kurulan çoklu regresyon modelinde Bağımsız değişken 1 (Doğalgaz üretimi), Bağımsız değişken 2 (Termik üretimi), Bağımsız Değişken 3 (Talep miktarını) ile model açıklanmıştır. Tablo 5'te her bir bağımsız değişkenin 0,001 anlamlılık düzeyini sağladığı görülmektedir. Mayıs ayı analizinde her bir değişken sırayla test edilerek en iyi  $R^2$  değerini veren model tercih edilmiştir. Bu sebeple Rüzgar ve Hidro değişkenleri modele dahil edilmemiştir. Bağımsız değişkenlerin modeli açıklama oranına bakıldığında ise düzeltilmiş  $R^2$  değerinin % 64,72 olarak hesaplandığı görülmektedir. Modelin tahmin performansı incelendiğinde ise tahmin edilen değerler gerçek değerlerden %10,87 oranında sapmaktadır.

Haziran ayı analizinde beş adet bağımsız değişken ile kurulan çoklu regresyon modelinde Bağımsız değişken 1 (Doğalgaz üretimi), Bağımsız değişken 2 (Hidroelektrik üretimi), Bağımsız değişken 3 (Termik üretimi), Bağımsız değişken 4 (Rüzgâr üretimi) ve Bağımsız değişken 5 (Talep miktarı) olmak üzere beş değişken ile model açıklanmıştır. Tablo 6'da bağımsız değişkenlerin 0,001 ve 0,01 anlamlılık düzeylerini sağladığı görülmektedir. Modelde  $\beta$  katsayının eksi olması bağımsız değişkenlerin bağımlı değişken üzerinde negatif yönlü bir etkisi olduğunu göstermektedir (Demirel vd., 2009:140). Diğer ayların analizinin aksine haziran ayında beş adet değişken birlikte kullanılmıştır. Elde edilen sonuca göre bağımsız değişkenlerin sayısı arttıkça aralarındaki korelasyon olabilen bağımsız

değişkenlerin modeli açıklama oranı diğer aylara kıyasla daha düşük kaldığı tespit edilmiştir. Düzeltilmiş  $R^2$  değeri ise % 49,45 olarak hesaplanmıştır. Modelin tahmin performansı incelendiğinde ise tahmin edilen değerler gerçek değerlerden %16,93 oranında sapmaktadır.

Piyasa takas fiyatı verileri literatürde sıklıkla kullanılan ARIMA yöntemi ile de analiz edilmiş ve çıkan sonuçlar diğer yöntemler ile karşılaştırılmıştır. Aylar bazında analizler gerçekleştirilmeden önce zaman serisinin durağanlığı teste tabi tutulmuştur. Bu bağlamda aylara göre zaman serilerinin birinci farkları alınmış hali serinin durağan halde olduğunu göstermektedir. Zaman serilerinin durağanlık şartını sağladığı Tablo 7’de gösterilmiştir.

**Tablo 7. Birim Kök Testi Analiz**

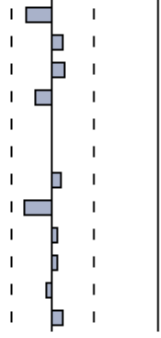
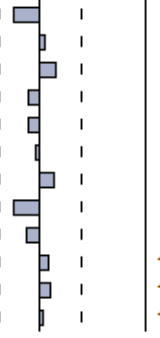
Test Kritik Değerleri	ADF Test İstatistiği		Mart	Nisan	Mayıs	Haziran
	1%	-3,43				
	5%	-2,86				
	10%	-2,85				

**Tablo 8. Mart Ayı ARIMA Modeli**

Değişken	Katsayı	Hata	t-istatistiği	Prob
C	-0,047	0,086	-0,550	0,5822
AR(1)	-0,158	0,024	-6,548	0,0000
AR(2)	0,896	0,044	2,038	0,0000
AR(4)	-0,117	0,039	-2,998	0,0028
MA(2)	-0,985	0,012	-8,403	0,0000
AIC (Akaike Bilgi Kriteri)				10,48

Tablo 8’de gösterilen mart ayına ilişkin birinci dereceden farkı alınmış olan AR(1), AR(2), AR(4) ve MA(2) modeli diğer modeller arasından en iyi model olarak seçilmiş ve modelin çıktısı gösterilmiştir. Model dereceleri belirlenirken ilk olarak model oluşturulmuş katsayıların  $p < 0,05$ ’e göre anlamlı olup olmadığı analiz edilmiştir. Anlamlı olmayan modeller için farklı dereceler alınarak analize devam edilmiştir. Anlamlı olan modellere ulaşıldığında ise en küçük AIC bilgi kriterine sahip model analiz için seçilmiştir. Model uygunluk analizi için Tablo 9’da yer alan kalıntı korelogramında otokorelasyon ve kısmi otokorelasyon grafikleri çizdirilmiş otokorelasyon ve kısmi otokorelasyon değerleri güven aralıkları içerisinde kalan ve bütün gecikmelerde p değeri 0,1’den büyük olan model Tablo 8’de gösterildiği gibi en iyi model olarak belirlenmiştir. Tablo 8’de gösterilen ve dereceleri AR(1), AR(2), AR(4), MA(2) olan ARIMA modeli mart ayı için bütün kriterleri karşılayan model olarak ifade edilmektedir. Diğer aylara ilişkin model derecesi belirleme aşamasında aynı yöntem kullanılmıştır.

**Tablo 9. Mart Ayına İlişkin Kalıntıların Korelogram Diyagramı**

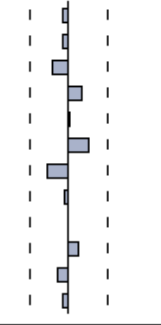
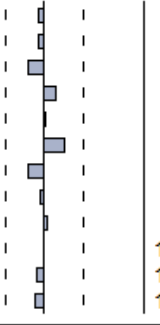
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.255	-0.255	1.7575	0.185
		2 0.104	0.042	2.0641	0.356
		3 0.124	0.172	2.5219	0.471
		4 -0.156	-0.099	3.2809	0.512
		5 -0.007	-0.106	3.2824	0.657
		6 -0.005	-0.026	3.2831	0.773
		7 0.085	0.146	3.5475	0.830
		8 -0.269	-0.250	6.3656	0.606
		9 0.044	-0.139	6.4479	0.694
		10 0.051	0.093	6.5641	0.766
		11 -0.060	0.108	6.7384	0.820
		12 0.114	0.028	7.4167	0.829

**Tablo 10. Nisan Ayı ARIMA Modeli**

Değişken	Katsayı	Hata	t-istatistiği	Prob
C	0,341	1,059	0,322	0,7472
AR(1)	-0,146	0,029	-4,895	0,0000
AR(2)	-0,198	0,032	-6,107	0,0000
AR(4)	0,336	0,108	3,106	0,0020
MA(4)	-0,542	0,102	-5,326	0,0000
AIC (Akaike Bilgi Kriteri)				10,99

Tablo 10’da gösterilen nisan ayına ilişkin birinci dereceden farkı alınmış olan AR(1), AR(2), AR(4) ve MA(4) diğer modeller arasından en iyi model olarak seçilmiş ve modelin çıktısı gösterilmiştir. Tablo 10’da oluşturulan ARIMA modelinin katsayıları  $p < 0,05$  ‘e göre anlamlıdır. Modelin uygunluk sınaması için Tablo 11’de kalıntı korelogramı çizdirilmiş ve değerlerin güven aralıkları arasında yer aldığı sonucuna ulaşılmıştır. Tablo 10’da gösterilen ve dereceleri AR(1), AR(2), AR(4), MA(4) olan ARIMA modeli nisan ayı verileri için bütün kriterleri karşılayan model olarak ifade edilmektedir.

**Tablo 11. Nisan Ayına İlişkin Kalıntıların Korelogram Diyagramı**

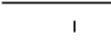
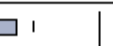
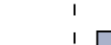

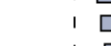

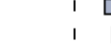

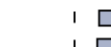
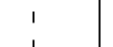
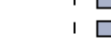

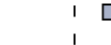

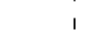









Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.059	-0.059	0.0956	0.757
		2 -0.051	-0.054	0.1680	0.919
		3 -0.163	-0.170	0.9550	0.812
		4 0.150	0.129	1.6551	0.799
		5 0.013	0.012	1.6608	0.894
		6 0.208	0.209	3.1573	0.789
		7 -0.221	-0.169	4.9442	0.667
		8 -0.027	-0.034	4.9731	0.760
		9 0.004	0.032	4.9737	0.837
		10 0.113	0.005	5.5430	0.852
		11 -0.115	-0.078	6.1736	0.862
		12 -0.053	-0.086	6.3222	0.899

**Tablo 12. Mayıs Ayı ARIMA Modeli**

Değişken	Katsayı	Hata	t-istatistiği	Prob
C	-0,008	2,011	-0,004	0,9968
AR(1)	0,563	0,060	9,320	0,0000
AR(2)	-1,417	0,065	-21,662	0,0000
AR(3)	0,418	0,065	6,399	0,0000
AR(4)	-0,853	0,046	-18,448	0,0000
MA(1)	-0,700	0,064	-10,898	0,0000
MA(2)	1,499	0,083	18,158	0,0000
MA(3)	-0,510	0,082	-6,245	0,0000
MA(4)	0,794	0,051	15,623	0,0000
<b>AIC (Akaike Bilgi Kriteri)</b>				10,48

Tablo 12’de mayıs ayına ilişkin birinci dereceden farkı alınmış olan AR(1), AR(2), AR(3), AR(4), MA(1), MA(2), MA(3) ve MA(4) modelinin çıktısı gösterilmiştir. Tablo 12’de oluşturulan ARIMA modelinin katsayıları  $p < 0,05$  ‘e göre anlamlıdır. Modelin uygunluk sınaması için Tablo 13’te kalıntı korelogramı çizdirilmiş ve değerlerin güven aralıkları arasında yer aldığı sonucuna ulaşılmıştır. Tablo 12’de gösterilen ve dereceleri AR(1), AR(2), AR(3), AR(4), MA(1), MA(2), MA(3) ve MA(4) olan ARIMA modeli mayıs ayı verileri için bütün kriterleri karşılayan model olarak ifade edilmektedir.

**Tablo 13. Mayıs Ayına İlişkin Kalıntıların Korelogram Diyagramı**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.259	0.259	1.8250	0.177
		2	0.044	-0.025	1.8791	0.391
		3	-0.187	-0.206	2.9191	0.404
		4	-0.152	-0.057	3.6380	0.457
		5	-0.112	-0.051	4.0523	0.542
		6	-0.029	-0.021	4.0820	0.666
		7	-0.167	-0.211	5.1011	0.648
		8	-0.177	-0.149	6.3197	0.611
		9	-0.173	-0.132	7.5670	0.578
		10	-0.128	-0.167	8.3009	0.599
		11	-0.017	-0.089	8.3140	0.685
		12	-0.023	-0.181	8.3411	0.758

**Tablo 14. Haziran Ayı ARIMA Modeli**

Değişken	Katsayı	Hata	t-istatistiği	Prob
C	0,012	0,020	0,561	0,5751
AR(1)	0,166	0,000	1,416	0,0000
AR(2)	-0,646	0,001	-4,368	0,0000
AR(3)	0,684	0,001	4,062	0,0000
MA(1)	-0,612	0,029	-2,059	0,0000
MA(2)	0,544	0,017	3,108	0,0000
MA(3)	-1,062	0,083	-1,286	0,0000
MA(4)	0,129	0,010	1,184	0,0000
<b>AIC (Akaike Bilgi Kriteri)</b>				9,97


Tablo 14’de haziran ayına ilişkin birinci dereceden farkı alınmış olan AR(1), AR(2), AR(3), MA(1), MA(2), MA(3) ve MA(4) modelinin çıktısı gösterilmiştir. Tablo 14’de oluşturulan ARIMA

modelinin katsayıları  $p < 0,05$  'e göre anlamlıdır. Modelin uygunluk sınaması için Tablo 15'te kalıntı korelogramı çizdirilmiş ve değerlerin güven aralıkları arasında yer aldığı sonucuna ulaşılmıştır. Tablo 12'de gösterilen ve dereceleri AR(1), AR(2), AR(3), MA(1), MA(2), MA(3) ve MA(4) olan ARIMA modeli haziran ayı verileri için bütün kriterleri karşılayan model olarak ifade edilmektedir.

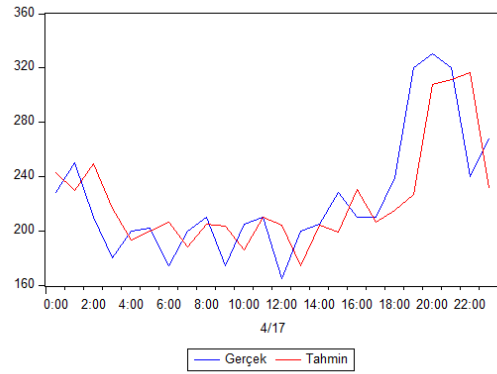
**Tablo 15. Haziran Ayına İlişkin Kalıntıların Korelogram Diyagramı**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.122	-0.122	0.4011	0.527
		2	0.021	0.006	0.4131	0.813
		3	0.244	0.250	2.1759	0.537
		4	0.224	0.307	3.7415	0.442
		5	0.080	0.180	3.9531	0.556
		6	-0.186	-0.265	5.1580	0.524
		7	0.273	0.043	7.8933	0.342
		8	-0.103	-0.206	8.3108	0.404
		9	-0.073	-0.087	8.5320	0.482
		10	-0.127	-0.193	9.2533	0.508
		11	-0.109	-0.185	9.8235	0.546
		12	0.114	0.149	10.498	0.572

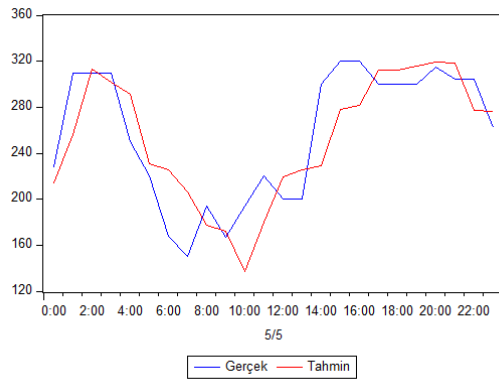
**Şekil 3. Mart Ayı ARIMA Modeli**




**Şekil 4. Nisan Ayı ARIMA Modeli**



**Şekil 5. Mayıs Ayı ARIMA Modeli**



**Şekil 6. Haziran Ayı ARIMA Modeli**



Kurulan ARIMA modellerine göre mart ayı için tahmin edilen değerler gerçek değerlerden %9,44 oranında, nisan ayı için tahmin edilen değerler gerçek değerlerden %11,13 oranında, mayıs ayı için





tahmin edilen değerler gerçek değerlerden %11,85 oranında ve haziran ayı için tahmin edilen değerler gerçek değerlerden %18,48 oranında sapmaktadır.

Çoklu regresyon ve ARIMA yöntemleri ile elde edilen analiz sonuçlarının karşılaştırılabilmesi amacıyla mart, nisan, mayıs ve haziran aylarına ait veriler Yapay Sinir Ağları yöntemleri kullanılarak analiz edilmiş ve çıkan sonuçlar karşılaştırılmıştır. Doğru modelin oluşturulması için güvenilir veri kaynağının var olması gereklidir. Benzer çalışmalarda da YSA'dan doğru bir çıktı elde edilebilmesi amacıyla veri kaynağı dikkatli bir şekilde seçilmekte ve modele girdi olarak verilmektedir. Literatür analizi ve değerlendirmesi yapan Aggarwal vd. (2009)'un çalışması incelendiğinde en çok kullanılan girdi verilerinin geçmiş elektrik talebi, mevcut üretim kapasiteleri (nükleer, termal, hidroelektrik vd.), sıcaklık, gün ve geçmiş fiyatlar olduğu belirtilmiştir. Analizler için bütün girdilerin kullanılabilir olmasına rağmen en sık kullanılan girdilerden birisinin ise talep miktarı olduğu ifade edilmiştir. Bu çalışmada değişkenler tanımlanırken EPİAŞ'ın saatlik olarak paylaştığı doğalgaz, hidroelektrik, rüzgâr, termik üretim ve talep miktarları modele aylık veriler şeklinde girdi olarak verilmiştir. Veriler YSA modelinde eğitilmeden önce 0 ile 1 aralığında normalize edilmiştir. Analizler yapılırken verilerin %90'ı eğitim amacıyla kullanılmış geri kalan %10'luk kısım ise teste tabi tutulmuştur. Teste tabi tutulan verilerin geriyayılım algoritması aracılığı ile öğretilmesi gerçekleştirilmiştir. Analiz esnasında yaygın olarak kullanılan sigmoid aktivasyon fonksiyonu kullanılarak model oluşturulmuştur. Aylara ilişkin oluşturulan YSA modelinin özellikleri Tablo 16'da ifade edilmiştir.



**Tablo 16. YSA Model Özellikleri**

	<b>Mart ve Mayıs</b>	<b>Nisan ve Haziran</b>
<b>Gizli Katman Sayısı</b>	1	1
<b>Gizli Katman Nöron Sayısı</b>	9	12
<b>Aktivasyon Fonksiyonu</b>	Sigmoid	Sigmoid
<b>Öğrenme Algoritması</b>	Geriyayılım	Geriyayılım
<b>Girdi Seti</b>	Geçmiş EPİAŞ verileri	Geçmiş EPİAŞ verileri


**Şekil 7. Mart Ayı YSA Modeli**



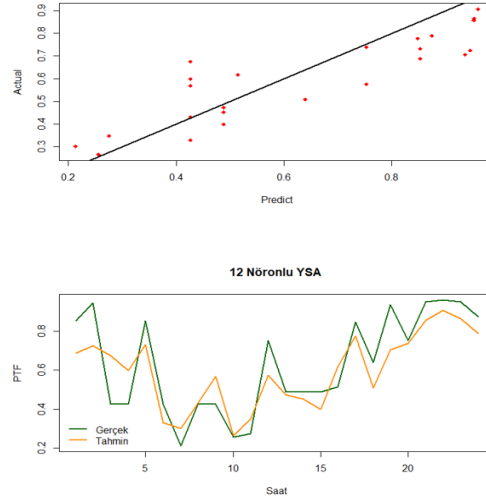
**Şekil 8. Nisan Ayı YSA Modeli**



**Şekil 9. Mayıs Ayı YSA Modeli**



**Şekil 10. Haziran Ayı YSA Modeli**



Şekil 7, Şekil 8, Şekil 9 ve Şekil 10'da mart, nisan, mayıs ve haziran aylarına ilişkin model kurulduktan sonra diğer modeller ile performans karşılaştırması yapılması için rastgele seçilen günlere ilişkin regresyon ve tahmin performans grafikleri gösterilmiştir. Her bir aya ilişkin analizler gerçekleştirilirken YSA modelleri en uygun nöron sayılarına göre belirlenmiştir. Bütün analizler 6 nöron sayısı başlamış 24 nöron sayısına kadar bütün modeller analiz edilmiştir. En iyi sonucu veren modellerin mart ve mayıs ayları için 9 nöron, nisan ve haziran ayları için 12 nörona sahip YSA modelleri olduğu tespit edilmiştir. Şekil 7 mart ayı regresyon doğrusuna göre tahmin edilen değerler gerçek değerlerden %6,25, Şekil 8 nisan ayı regresyon doğrusuna göre tahmin edilen değerler gerçek değerlerden %8,16, Şekil 9 mayıs ayı regresyon doğrusuna göre tahmin edilen değerler gerçek değerlerden %8,92, Şekil 10 haziran ayı regresyon doğrusuna göre tahmin edilen değerler gerçek değerlerden %18,61 oranında sapma göstermiştir.

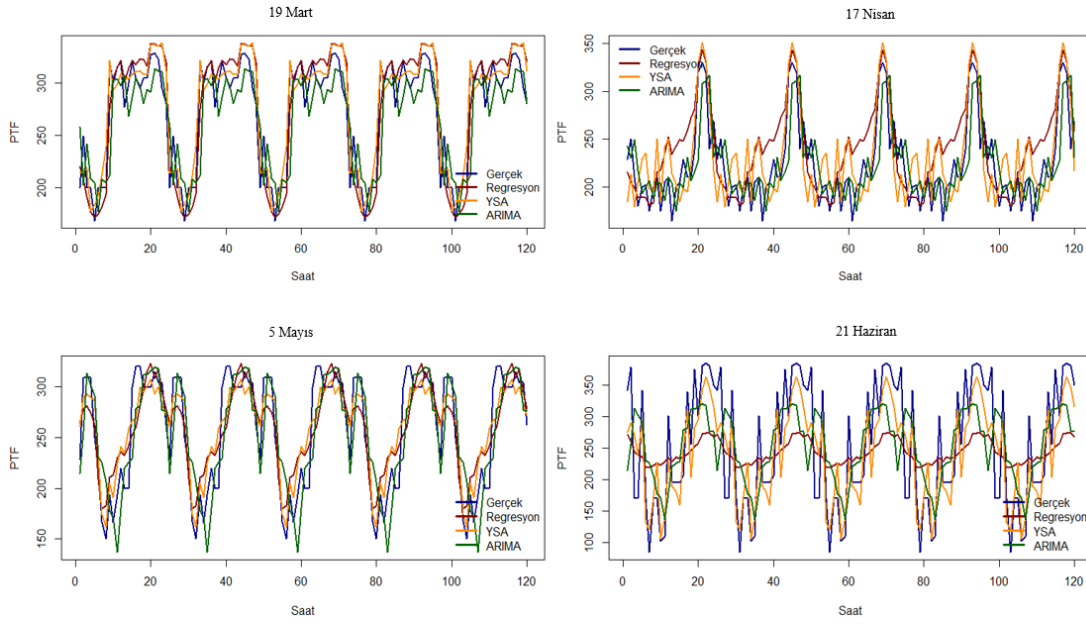
Analizleri gerçekleştirilen verilerin çoklu regresyon, ARIMA ve yapay sinir ağları ile rastgele seçilen günler bazında elde edilen tahmin performanslarının sonuçları Tablo 17'de gösterilmiştir.

**Tablo 17. Modellerin Tahmin Performans Karşılaştırması**

MAPE(%)	19.Mar	17.Nis	5.May	21.Haz
Çoklu Regresyon	6,64%	13,30%	10,87%	16,93%
ARIMA	9,44%	11,13%	11,85%	18,48%
YSA	6,25%	8,16%	8,92%	18,61%

Ayrıca her bir analiz tahmin sonuçları tek bir grafikte çizdirilerek Şekil 11’de gösterilmiştir. Karşılaştırmalı grafikler oluşturulurken analiz tahmin sonuçları için 24 saatlik veriler 120 saatlik zaman dilimine göre gösterilmiştir. Karşılaştırmalı grafik analizinden de görüleceği üzere sapmalar olsa dahi bütün modeller gerçek veriyi takip etme eğilimindedir. Bu sonuç ise kullanılan yöntemlerin oluşturulan modelleri iyi ifade ettiğinin bir göstergesidir.

**Şekil 11. Karşılaştırmalı Grafik Analizi**



#### 4. SONUÇ

Bu çalışmada PTF’yi etkileyen değişkenlerin tespiti ve etkileme düzeylerinin analizi yapılmıştır. Aynı zamanda farklı tahmin modelleri kullanılarak kurulan modellerin tahmin performanslarının analizi gerçekleştirilmiştir. Piyasa fiyatının saatlik olarak oluşmasından kaynaklı olarak girdi verileri de saatlik olarak elde edilmiş ve modellere uygulanmıştır. Çalışmada diğer araştırmalardan farklı olarak analizler gerçekleştirilirken çoklu regresyon yöntemi diğer uygulama yöntemleri ile beraber kullanılmıştır. Çoklu regresyon yöntemi ile beraber karşılaştırma yapılabilmesi amacı ile geleneksel tahmin yöntemi olan arıma ve literatürde sıklıkla kullanılan yapay sinir ağları da uygulama yöntemi olarak ele alınmıştır. Analizler yapılırken 2020 yılının mart, nisan, mayıs ve haziran ayları örneklem ayları olarak seçilmiştir. Çoklu regresyon yöntemi ile birlikte piyasa fiyatını doğrudan etkileyen veriler modelde girdi olarak kullanılmıştır. Bu girdiler hidroelektrik üretim miktarı, doğalgaz üretim miktarı, termik üretim miktarı, rüzgâr üretim miktarı ve talep miktarı olarak belirlenmiştir. Çoklu regresyon yöntemi ile yapılan analizler sonucunda piyasa takas fiyatını etkileyen değişkenlerden doğalgaz ve termik üretimlerinin çoğunlukla dışa bağımlı olmamızdan kaynaklı olarak piyasa takas fiyatını arttırıcı etkisi olduğu gözlemlenmiştir. Aynı şekilde enerjiye olan talep miktarının piyasa takas fiyatı üzerinde

pozitif korelasyon oluşturduğu tespit edilmiştir. Rüzgâr üretim miktarının ise modellerde kullanılan aylar bazında piyasa fiyatı ile olan ilişkisi negatif yönde seyretmiştir. Yani rüzgâr kaynağından elektrik üretiminin artması piyasa fiyatını düşürücü bir etkiye sahip olduğunu göstermektedir. Hidroelektrik üretim miktarının ise fiyatı arttıran diğer değişkenler kadar olmasa da piyasa fiyatı üzerinde pozitif bir etkisi olduğu tespit edilmiştir. Yapılan bu analizin yanında her üç model içinde seçilen günler için tahmin performansı analizi yapılmıştır. Aylar bazında yapılan analiz sonuçlarına göre yapay sinir ağı modelinin haziran ayı dışında diğer yöntemlere göre en başarılı yöntem olduğu tespit edilmiştir.

ARIMA ve çoklu regresyon modellerinin ise farklı günler için benzer hata sonuçları verdiği gözlemlenmiştir. Arıma yönteminin diğer modellere göre avantajı yorumlamayı araştırmacıya bırakarak en iyi sonucun deneme yöntemiyle tespit edilmesine olanak sağlamasıdır. Çoklu regresyon yönteminin yapay sinir ağı yöntemine göre başarısı ise oldukça düşük kalmıştır. Bunun sebepleri arasında yapay sinir ağlarının model oluşturma aşamasında çoklu regresyon yöntemine göre daha kompleks bir yapı kurması ve öğrenme algoritmaları yöntemiyle sinir ağının öğrenmesinin sağlanmasıdır ki bu da tahmin performansını arttırmaktadır.

Bu çalışmada ortalama hatalar ARIMA için %9,44 ile %18,48 aralığında ve yapay sinir ağları için %6,25 ile %18,61 aralığında elde edilerek Contreas (2003) ve Kölmek vd. (2012)'nin yaptıkları çalışma ile benzer sonuçlara ulaşılmıştır. Ranjbar vd. (2006)'da Kanada piyasalarında farklı katmanlara sahip yapay sinir ağı modellerini test ettikleri çalışmada teste tabi tuttukları modelin MAPE değerlerinin Haziran ile Eylül ayları arasında %7,52 ile %12,68 aralığında değiştiğini göstermişlerdir. Ranjbar vd. (2006)'nin çalışmalarına kıyasla ise bu çalışmada yapay sinir ağlarının tahmin performansı %6,25 ile %18,61 aralığında olmak üzere ortalama olarak daha düşük elde edilmiştir. Bozkurt vd. (2017) kısa dönemli tahmin çalışmalarında yapay sinir ağı modelinin %1,80 MAPE, mevsimsel ARIMA modelinin ise %2,60 MAPE hata oranı ile tahmin öngörüsü yaptığını tespit etmişlerdir. Bozkurt vd. (2017)'nin çalışmalarına kıyasla bu çalışmada elde edilen sonuçlar %6,25 ile %18,61 hata oranı aralığında olmak üzere tahmin performansı daha düşük olarak elde edilmiştir. Çalışmalarında hibrit tahmin yöntemlerini kullanmaları daha iyi performans gösteren modeller oluşturmalarını sağlamıştır. Kalfa vd. (2021) Türkiye elektrik piyasalarında yaptıkları çalışmada çoklu regresyon yönteminin ocak ve haziran ayları için sırası ile ortalama %19,2 ile %36, yapay sinir ağları için ise ocak ve haziran ayları için sırası ile ortalama 12,3 ile %23,2 aralığında hata oranı ile tahmin performansı sergilediğini göstermişlerdir. Çalışmalarına kıyasla bu çalışmada daha yüksek tahmin performansı gösteren modeller oluşturulmuştur.

Yapılan bu çalışmada tahmin yöntemlerinin performanslarının analiz edilmesi ile beraber diğer çalışmalara da referans sağlaması ön görülmüştür. Girdi değişkenleri çeşitlendirilerek, tahmin yöntemi için farklı zaman dönemi sınıflandırılması yapılarak ve hibrit tahmin yöntemleri uygulanarak ileriki çalışmalarda daha iyi performans gösteren analizler gerçekleştirilebilir. Ayrıca elektrik piyasa sisteminin dinamik bir yapıya sahip olması bu alanda yapılan çalışmaların güncel tutulmasını gerektirmekte ve farklı araştırma fırsatlarına açık olduğunu göstermektedir.

## KAYNAKÇA

- Aggarwal, S. K., Saini, L. M., and Kumar, A. (2009) “Electricity Price Forecasting in Deregulated Markets: A Review and Evaluation”, *International Journal of Electrical Power & Energy Systems*, 31(1):13-22.
- Akaike, H. (1974) “A New Look at the Statistical Model Identification”, *IEEE Transactions on Automatic Control*, 19(6):716-723.
- Arslan, B. (2021) “Karşılaştırmalı İstatistiksel Yöntemler ile Türkiye Elektrik Piyasasında Fiyat Tahmin ve Analizi”, Yüksek Lisans Tezi, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü, Denizli.
- Carpio, K. J. E., Go, A. M. L., ve Roncal, C. K. M. (2012) “Forecasting Day-Ahead Electricity Prices of Singapore through ARIMA and Wavelet-ARIMA”, *DLSU Business & Economic Review*, 22(1): 97-118.
- Conejo, A. J., Contreas J., Espinola R., ve Plazas, M. A (2005) “Forecasting Electricity Prices for A Day-Ahead Pool-Based Electric Energy Market”, *International Journal of Forecasting*, 435-462.
- Çetintaş H. ve Bicil İ.M. (2015) “Elektrik Piyasalarında Yeniden Yapılanma ve Türkiye Elektrik Piyasasında Yapısal Dönüşüm”, *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*, 2(2):1-15.
- Demirel, Y., ve Özçınar, M. F. (2009) “Örgütsel Vatandaşlık Davranışının İş Tatmini Üzerine Etkisi: Farklı Sektörlere Yönelik Bir Araştırma”, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(1): 129-145.
- Dickey, D. A., ve Fuller, W. A., (1979) “Distribution of the Estimators for Autoregressive Time Series with A Unit Root”, *Journal of the American Statistical Association*, 74(366):427.
- EPİAŞ (2020) <https://seffaflik.epias.com.tr/transparency/>, (31.12.2020).
- Ferreira, A. P., Gonçalves, R. J., ve Odete, F. P. (2019) “A Linear Regression Pattern for Electricity Price Forecasting in The Iberian Electricity Market”, *Revista Facultad De Ingeniería Universidad De Antioquia*, 93:117-127.
- Gershenson, C. (2003). “Artificial Neural Networks for Beginners”, University of Sussex. 1-8.
- Kalaycı, Ş. (2014). “SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri” (6. baskı), Ankara, Asil Yayın Dağıtım.
- Kalfa, V. R., Arslan, B. ve Ertuğrul, İ. (2021) “Determining the Factors Affecting the Market Clearing Price by Using Multiple Linear Regression Method”, *Alphanumeric Journal* , 9(1):35-48.
- Kaya vd. (2012) “Karışımli İkili Lojistik Regresyon Modeline İlişkin Bir Uygulama”, *DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 14(1):39-47.

- Khare, M. ve Nagendra, S. M. S. (2006) “Artificial Neural Networks in Vehicular Pollution Modelling”, *Studies in Computational Intelligence*, Poland.
- Kölmek, M. A. ve Navruz, İ. (2012) “Forecasting The Day-Ahead Price in Electricity Balancing and Settlement Market of Turkey by Using Artificial Neural Networks”, *Turkey Journal of Electrical Engineering & Computer Sciences*, 23:841–852.
- Kumar, S., ve Kaur, T. (2016) “Development of ANN Based Model for Solar Potential Assessment Using Various Meteorological Parameters”. *Energy Procedia*, 90:587-592.
- Mijwel, M. M. (2018) “Artificial neural networks advantages and disadvantages”. Retrieved from LinkedIn <https://www.linkedin.com/pulse/artificial-neuralnet-Work>.
- Onaiwu E. (2009) “How Does Bilateral Trading Differ from Electricity Pooling”, University of Dundee.
- Ozozen, A., Kayakutlu G., Ketterer M., ve Kayalica, O. (2016) “A Combined Seasonal ARIMA and ANN Model for Improved Results in Electricity Spot Price Forecasting: Case Study in Turkey”, 2016. *Proceedings of PICMET '16: Technology Management for Social Innovation*, 2681-2690.
- Öztemel, E. (2006) “Yapay Sinir Ağları”, İstanbul: Papatya Yayıncılık
- Peter, D. ve Silvia P. (2012) “ARIMA Vs. ARIMAX – Which Approach is Better to Analyze and Forecast Macroeconomic Time Series”, *Proceedings of 30th International Conference Mathematical Methods in Economics*, 136-140.
- Tabachnick, B. G. ve Fidell, L. S. (2013) “Using multivariate statistics” Boston:Pearson.
- Tutar, H., ve ALTINÖZ, M. (2010) “Örgütsel İklimin İşgören Performansı Üzerine Etkisi: OSTİM İmalat İşletmeleri Çalışanları Üzerine Bir Araştırma”, *Ankara Üniversitesi SBF Dergisi*, 65(02):196-218.
- Torró, H. (2007), “Forecasting Weekly Electricity Prices at Nord Pool”. Working Papers 2007.88, Fondazione Eni Enrico Mattei.
- Yıldırım, A. ve Kandemir, S. Y. (2018) “Yağış Miktarının Yapay Sinir Ağları ile Tahmini”, *BŞEÜ Fen Bilimleri Dergisi*, 5(2):97-104.
- Werbos, P. J. (1974) “Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences”, Phd. Thesis, Harvard University.

<b>KATKI ORANI / CONTRIBUTION RATE</b>	<b>AÇIKLAMA / EXPLANATION</b>	<b>KATKIDA BULUNANLAR / CONTRIBUTORS</b>
Fikir veya Kavram / <i>Idea or Notion</i>	Araştırma hipotezini veya fikirini oluşturmak / <i>Form the research hypothesis or idea</i>	Burak ARSLAN Prof. Dr. İrfan ERTUĞRUL
Tasarım / <i>Design</i>	Yöntemi, ölçeği ve deseni tasarlamak / <i>Designing method, scale and pattern</i>	Burak ARSLAN Prof. Dr. İrfan ERTUĞRUL
Veri Toplama ve İşleme / <i>Data Collecting and Processing</i>	Verileri toplamak, düzenlenmek ve raporlamak / <i>Collecting, organizing and reporting data</i>	Burak ARSLAN Prof. Dr. İrfan ERTUĞRUL
Tartışma ve Yorum / <i>Discussion and Interpretation</i>	Bulguların değerlendirilmesinde ve sonuçlandırılmasında sorumluluk almak / <i>Taking responsibility in evaluating and finalizing the findings</i>	Burak ARSLAN Prof. Dr. İrfan ERTUĞRUL
Literatür Taraması / <i>Literature Review</i>	Çalışma için gerekli literatürü taramak / <i>Review the literature required for the study</i>	Burak ARSLAN Prof. Dr. İrfan ERTUĞRUL

---

**Hakem Değerlendirmesi:** Dış bağımsız.

**Çıkar Çatışması:** Yazarlar çıkar çatışması bildirmemiştir.

**Finansal Destek:** Yazarlar bu çalışma için finansal destek almadığını beyan etmiştir.

**Teşekkür:** -

**Peer-review:** Externally peer-reviewed.

**Conflict of Interest:** The authors have no conflict of interest to declare.

**Grant Support:** The authors declared that this study has received no financial support.

**Acknowledgement:** -

---