

GAZİ

JOURNAL OF ENGINEERING SCIENCES

## Natural Gas Consumption Forecast in Kayseri with Box-Jenkins Methods, Grey Forecasting and Artificial Neural Networks

Betül Yılmaz<sup>a</sup>, Sinem Kulluk<sup>\*b</sup>

Submitted: 08.08.2023 Revised: 04.05.2024 Accepted: 09.05.2024 doi:10.30855/gmbd.0705A02

### ABSTRACT

**Keywords:** Natural gas consumption forecast, Box-Jenkins models, grey forecasting, artificial neural networks

<sup>a</sup> Erciyes University,  
Engineering Faculty,  
Dept. of Industrial Engineering  
38280 - Kayseri, Türkiye  
Orcid: 0000-0003-1419-4697  
e mail: iletisim.betulyilmaz@gmail.com

<sup>b\*</sup> Erciyes University,  
Engineering Faculty,  
Dept. of Industrial Engineering  
38280 - Kayseri, Türkiye  
Orcid: 0000-0002-0675-3113  
e mail: [skulluk@erciyes.edu.tr](mailto:skulluk@erciyes.edu.tr)

\*Corresponding author:  
[skulluk@erciyes.edu.tr](mailto:skulluk@erciyes.edu.tr)

In a world with growing environmental and energy concerns, effective energy use is crucial. Since our country largely imports natural gas, efficient usage is vital for the national economy. Accurate consumption estimates will enhance investment efficiency, optimize gas purchase agreements, and minimize economic losses from excess supply, thereby balancing future supply and demand. In this study, natural gas consumption data of Kayseri province on a monthly basis between the years 2015-2022, obtained from Republic of Türkiye Energy Market Regulatory Authority (EPDK), was used, and a consumption estimate was made for the year 2023. Auto Regressive Integrated Moving Average (ARIMA -Box-Jenkins), Gray Prediction and Artificial Neural Networks (ANNs) methods, which are widely accepted in the literature, were used as forecasting methods. The methods used were compared in terms of Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE) and  $R^2$  error performance measures, and it was seen that the multiplicative decomposition based grey GM(1,1) model, which gave the most successful result with an  $R^2$  value of 0.926, was suitable for estimation. With the appropriate multiplicative decomposition based GM(1,1) model, monthly natural gas consumption estimation of Kayseri province was made for the year 2023.

## Box-Jenkins Yöntemi, Gri Tahminleme ve Yapay Sinir Ağları ile Kayseri İli Doğal Gaz Tüketim Tahmini

### ÖZ

Çevresel ve enerji sorunlarının arttığı bir dünyada, enerjinin etkin kullanımı çok önemlidir. Ülkemiz büyük ölçüde doğal gaz ithal ettiğinden, doğal gazın verimli kullanımı ulusal ekonomi için hayati önem taşır. Doğru tüketim tahminleri, yatırım verimliliğini artıracak, gaz alım anlaşmalarını optimize edecek ve fazla arzdan kaynaklanan ekonomik kayıpları minimize ederek gelecekteki arz ve talep dengesini sağlayacaktır. Bu çalışmada T.C. Enerji Piyasası Düzenleme Kurumu'ndan (EPDK) alınan 2015-2022 yılları arası aylık bazda Kayseri iline ait doğalgaz tüketim verisi kullanılmış olup, 2023 yılı için tüketim tahmini gerçekleştirilmiştir. Tahminleme yöntemleri olarak literatürde de büyük ölçüde kabul gören Otoregresif Entegre Hareketli Ortalama (ARIMA -Box Jenkins) modelleri, Gri Tahminleme ve Yapay Sinir Ağları (YSA) yöntemleri kullanılmıştır. Kullanılan yöntemler Ortalama Mutlak Yüzde Hata (OMYH), Ortalama Mutlak Hata (OMH), Ortalama Kareli Hata (OKH), Ortalama Kareli Hata Kökü (OKHK) ve  $R^2$  hata ölçütleri bakımından karşılaştırılmış, 0.926  $R^2$  değeri ile en başarılı sonucu veren çarpımsal ayrıştırma tabanlı gri GM(1,1) modelinin tahminleme için uygun olduğu görülmüştür. Uygun bulunan çarpımsal ayrıştırma tabanlı GM(1,1) modeli ile 2023 yılı için Kayseri ili aylık doğal gaz tüketim tahminlemesi yapılmıştır.

**Anahtar Kelimeler:** Doğal gaz tüketim tahmini, Box-Jenkins yöntemi, gri tahmin, yapay sinir ağları

## 1. Giriş (Introduction)

Günümüzde artan enerji ihtiyacına karşı alternatif yakıtlar kullanılmaya başlanmıştır. Bunların başında fosil bir yakıt olan doğal gaz gelmektedir. Doğal gaz, sıcaklık ve basınç altında uzun yıllar boyunca kalan canlı artıklarının, yapısal değişime uğramasıyla günümüze kadar gelen enerji kaynaklarından biridir. Yanıcı bir gaz karışımı olup, aynı zamanda bir petrol türevidir [1]. Doğal gaz başlıca ulaşım, ısınma, pişirme, sıcak su, üretim tesisleri, fabrikalar ve elektrik üretimi gibi alanlarda kullanılmaktadır. Düşük maliyetli ve çevre dostu olması sebebiyle diğer yakıt türlerine göre daha fazla tercih edilmektedir.

Çevre sorunlarının ve enerjiye olan gereksinimin zamanla arttığı bir dünyada enerjinin verimli kullanılması büyük önem arz etmektedir. Ülkemizdeki doğal gaz ihtiyacı, büyük ölçüde ithal edilerek karşılanmaktadır. Bu nedenle doğal gazın verimli bir şekilde kullanılması, ülke ekonomisine katkıda bulunacaktır. Doğal gaz tüketimi miktarını etkileyen en önemli unsurlardan biri mevsimsel şartlar olup, yıllık toplam doğal gaz tüketimi her yıl değişmektedir. Yıllık ve aylık toplam tüketimler incelendiğinde benzer tüketim eğrilerinin olduğu görülmektedir. Enerji kaynaklarının yönetilmesi, doğal gaza olan talebin artmasıyla birlikte önemli bir konu haline gelmektedir. Bu nedenle gelecek dönemlere ait doğal gaz tüketimlerinin tahmin edilmesi ve modellenmesi, enerji kaynaklarının verimli kullanılmasında büyük önem taşımaktadır [2]. Doğal gaz tüketiminin doğru tahmin edilmesi enerji sektörüne yapılacak yatırımların ve uluslararası gaz alım anlaşmalarının etkinliğine katkıda bulunmakla beraber, ihtiyaç fazlası doğal gaz temini sonucunda oluşabilecek ekonomik kayıpları en aza indirebilecektir. Bu sayede de geleceğe yönelik doğal gaz arz ve talep arasındaki dengesizlikler ortadan kaldırılabilir [3].

Bu çalışmada, doğal gaz tüketiminin doğru ve etkin bir şekilde tahminlenmesi amaçlanmıştır. Kayseri ilinin 2015-2022 yılları arasında aylık bazda gerçekleşmiş olan doğal gaz tüketim serisi kullanılarak, Box Jenkins Yöntemi, Gri Tahminleme ve YSA yöntemleri ile tahminleme yapılmıştır. Tahminler sonucu hata etkinlik ölçütlerinden hareketle en uygun yöntem olarak çarpımsal ayrıştırma tabanlı GM(1,1) yöntemi belirlenmiş ve 2023 yılı için aylık bazda doğal gaz tüketim tahminlemesi bu yöntem ile gerçekleştirilmiştir.

## 2. Literatür İncelemesi (Literature Review)

Literatürde tahminleme alanında Box-Jenkins, Gri Tahminleme, Yapay Sinir Ağları yöntemleri ile gerçekleştirilen oldukça fazla çalışma mevcuttur. Kaya [4] Türkiye'nin yenilenebilir enerji kaynaklarını, 1990-2014 yılları tüketim verilerini kullanarak tahmin etmiştir. Yöntem olarak YSA, ARIMA ve Gri Tahmin yöntemlerini uygulamıştır. Yapmış olduğu analizler sonucunda YSA'nın en başarılı sonuçları verdiğini görmüştür. Çuhadar vd. [5] 1992-2005 yıllarında Antalya iline gelen aylık yabancı turist sayısı verilerine üstel düzeltme, Box-Jenkins ve YSA modellerini uygulamışlardır. Yaptıkları analizler ve kıyaslamalarla YSA yönteminin en iyi sonucu verdiğini görmüşler ve 2009 yılı için aylık dış turizm talebini tahminlemişlerdir. Kaynar vd. [6] çalışmalarında YSA ve ARIMA modelleri ile kısa dönemli doğal gaz tüketim tahmini yapmayı hedeflemişlerdir. Ankara iline ilişkin 1.5 yıllık, günlük ve haftalık doğal gaz tüketim verilerinden yararlanmışlardır. OKH değerlerini kıyaslamışlar ve YSA modelinin başarısının ARIMA modelinden daha yüksek olduğunu görmüşlerdir. Ayrıca yapılan tahminler içerisinde günlük veri tahmininin haftalık veri tahminine göre performansı daha yüksek çıkmıştır. Kırçıl [7], İzmir ilinin 2007-2012 yılları konut sektörü aylık doğal gaz tüketim verileriyle talep tahminlemesi gerçekleştirmiştir. Yöntem olarak mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modeli en uygun sonucu vermiş ve SARIMA modellerinden en uygun olanını hata ölçütleriyle değerlendirip, seçerek geleceğe yönelik tüketim tahminlemesi yapmıştır.

Çelik [8], Isparta ili 2010-2016 yılları konut sektörüne ait 76 aylık doğal gaz tüketim verilerini kullanarak doğal gaz ihtiyacını tahminlemeye çalışmıştır. Tahminleme yöntemi olarak Üstel Düzeltme, Box-Jenkins ve Gri Tahminleme yöntemlerini kullanmıştır. Başarı kriterleri açısından yöntemleri değerlendirerek, en iyi sonucu gri tahminleme yönteminin verdiğini gözlemlemiştir. Gelecek 20 ay için tüketim tahminlemesi gerçekleştirmiştir. Ekmekçi [9] çalışmasında, 1970-2013 yılları arası Türkiye'deki doğal gaz tüketimini

sektörel bazda incelemiştir. Birincil enerji arzı, çimento tüketimi, diğer sektörler tüketimi, ithalat tüketimi, konut tüketimi, sanayi tüketimi, sektörel toplam tüketimi olmak üzere toplamda 7 sektör için doğal gaz tüketim tahminlemesi gerçekleştirmiştir. Tahminleme yöntemi olarak ise ARIMA yöntemini uygulamış, uygulama için de Eviews ve SPSS paket programlarında yararlanmış. Eren[10], Türkiye İstatistik Kurumu'ndan (TÜİK) elde ettiği 2004-2016 yılları Türkiye yıllık doğal gaz tüketim ve nüfus serilerini kullanarak gri tahmin yöntemini kullanarak 2017 – 2030 yılları arası doğal gaz tüketim ve nüfus öngörüsü yapmıştır. Singh ve Yassine [11] çalışmalarında cihaz kullanımını, günün saati, günün periyodu, hafta içi, hafta, ay ve yılın mevsimi gibi zamanla ilişkilendirmelerin yanı sıra evdeki cihaz-cihaz ilişkilendirmeleri açısından anahtar faktörler olan cihaz kullanımını tanımlayarak tüketicilerin enerji tüketim davranışının ve enerji tahmin eğiliminin etkisini analiz etmişlerdir. Denetimsiz veri kümelemesi, enerji zaman serilerinde sık model madenciliği analizi ve enerji kullanımı tahmini için Bayes ağ tahmini önermişlerdir. Zengin akıllı sayaç veri kümelerini kullanarak kapsamlı deneyler gerçekleştirmişlerdir. Destek Vektör Makinesinin (DVM), Çok Katmanlı Algılayıcıdan (ÇKA) daha iyi performans gösterdiğini görmüşlerdir. Taşkınar [12] Ankara ilinde tüketilen doğal gaz miktarını öngörmeyi amaçlamıştır. YSA ile uygulama yapmıştır. Ağda girdi niteliği olarak nem, maksimum sıcaklık, minimum sıcaklık, ortalama sıcaklık, hissedilen maksimum sıcaklık, hissedilen en düşük sıcaklık, tüketim, bağımsız eleman sayısı ve ısı değer olmak üzere 9 tane nitelik kullanmıştır. En başarılı ağ yapısında 0.9772  $R^2$  değeri elde etmiştir. Akman vd. [13] elektrik yükü tahmin uygulamalarında sıklıkla kullanılan çeşitli tahmin yöntemlerini anlatmış, yeni yaklaşımlara değinmişlerdir. Destek vektör regresyonu ve melez yaklaşımların, elektrik yük tahmininde nispeten yeni ve rekabetçi bir yöntemler olduğunu vurgulamışlardır. Calp [14], işyerlerinde yapılan yemek ve ihtiyaç olunan personel miktarını içeren bir yapay sinir ağı tasarlamıştır. Model, gerçek verilerle test edilmiş ve YSA'nın oldukça başarılı tahminler gerçekleştirdiği izlenmiştir. Model oluşturulurken gizli tabakadaki nöron sayısı seçiminin ağın performansını etkilediği gözlemlenmiştir.

Erdem, [15] makine öğrenmesi teknikleri ile Türkiye'nin doğal gaz enerji tüketiminin tahminlenmesi üzerine çalışmıştır. YSA, Rastgele Orman (RO), zaman serileri gibi yöntemler ile tahminleme yapmış ve 2010 ile 2018 arası doğal gaz tüketim verilerini kullanmıştır. En başarılı tahminleri YSA üretmiştir. Tuna [16] Erzurum ili konut sektörü Ocak 2009- Kasım 2018 doğal gaz tüketim miktarlarıyla tahminleme yapmayı amaçlamıştır. Yöntem olarak ARIMA modellerini kullanmıştır. Aynı zamanda anket verileri oluşturularak hane halklarının doğal gazı tercih etme ve etmeme durumlarını detaylı bir şekilde incelemiştir. Akpınar [17] tez çalışmasında doğal gaz tüketim tahminlemesi yapmak amacıyla yıl öncesi ve gün öncesi aylık talep tahmini olmak üzere iki ayrı tahminleme yapmıştır. Ayrıştırma yöntemi, Winters üstel düzeltme ve Box-Jenkins yöntemlerini kullanmıştır. Uygulama sonucunda gün öncesi için öngörü gerçekleştirmiştir. Oruç ve Başağaoğlu [18] çalışmalarında bir sağlık merkezinde yatan hasta sayısının tahminini yapmışlardır. Model olarak gri tahminlemeyi tercih etmişlerdir. Ocak 2015-Ağustos 2019 tarihleri arasında yataklı hasta servisinde yatan hasta sayısı verilerini kullanmışlardır ve gelecek 28 ay için öngörü değerleri elde etmişlerdir. Demir ve Keskin [19] Samsun Mert Irmağı havzasında yükseklik modellemesi yapmışlardır. Tahmin yöntemleri olarak ÇKA ve regresyon analizi kullanmışlardır. Sonuç olarak ÇKA modellerinin tahminlemede daha iyi olduğunu gözlemlenmişlerdir. Aydın [2] Denizli ilindeki konut tüketicilerinin Ocak 2015- Haziran 2019 dönemi doğal gaz tüketim verilerini kullanarak tahminleme yapmıştır. ARIMA yöntemiyle Eviews programında uygulamalar gerçekleştirmiştir. Gelecek 2 yıl için aylık bazda öngörüler elde etmiştir. Konut doğal gaz kullanımını en fazla etkileyen parametrelerin tespitini yapmıştır [2].

Sayım [20] bir büyükşehir belediyesinin 2014-2018 yılları arası gelir bütçesi bilgilerini kullanarak, GM(1,1) yöntemi ile 2019-2023 yılları arası büyükşehir belediyesinin gelir ve giderlerinin öngörüsünü yapmıştır. Yapılan değerlendirmelerle gider kalemlerinin GM(1,1) yöntemine uygun olmadığını gözlemlenmiştir. Köse [21], Döviz kuru alış değerlerini öngörmek amacıyla 10 Temmuz 2019-7 Aralık 2020 dönemi döviz kurlarını kullanmıştır. Model olarak YSA ve GM(1,1) gri tahmin modelini uygulamıştır. Sonuç olarak YSA'da uzun kısa dönem hafıza (LSTM) katmanlarının daha başarılı sonuçlar verdiğini görmüştür. Panek ve Włodek [22] Polonya'nın orta ölçekli şehirlerinden birinde belediye tüketicilerinin geçici ve gelecekteki doğal gaz tüketiminin modellemesini gerçekleştirmişler. Bu amaçla makine öğrenme algoritmalarından YSA ve iki regresyon algoritması olan çoklu doğrusal regresyon (MLR) ve rasgele orman (RF) kullanmışlar. Doğal gaz

talebini tahmin etmede en iyi algoritmanın RO olduğunu göstermişlerdir. Safiyari vd [23] Mart 2019'un başından Şubat 2021'in sonuna kadar 24 ay boyunca Tahran eyaletinin konut sektöründeki aylık doğal gaz talebini tahmin etmek için ÇKA ve DVM yöntemlerini kullanmışlardır. En iyi sonucu en düşük hata ölçütü değeri ile ÇKA vermiştir.

### 3. Tahmin yöntemleri (Forecasting Methods)

#### 3.1. Box-Jenkins yöntemi (Box-Jenkins method)

Box-Jenkins diğer adıyla ARIMA modelleri 1970-1976 yıllarında George Box ve Gwilym Jenkins tarafından zaman serileri stokastik süreç özelliği sergiler varsayımından hareketle önerilmiştir [24]. Bu yöntemde tahminleme yapmak için serinin durağan olması veya durağan hale getirilmiş olması gerekmektedir. Box-Jenkins modelleri doğrusal durağan stokastik modeller, durağan olmayan doğrusal stokastik modeller ve mevsimsel modeller olarak sınıflandırılmaktadır [7]. Gerçek hayat uygulamalarında serilerin çoğunluğu, özellikle ekonomik zaman serileri durağan özellik sergilemez. Serilerin durağanlığını trend, mevsimsellik, döngüsellik ve rassallık gibi davranışlar bozar. Durağan olmayan zaman serilerinin modellenmesi için öncelikle serinin durağan hale getirilmesi gerekir. Serinin durağan hale getirilmesi için öncelikle ilgili davranışların ortaya konması, sonrasında da ortadan kaldırılması gerekir. Eğer zaman serisi, ortalama etrafında durağanlık göstermiyorsa, serinin durağanlığı uygun sayıda fark alınarak sağlanır. Serinin kaç kez farkı alınarak durağanlaştığı,  $d$  ile gösterilen fark alma derecesi parametresini ifade eder ve gerçek hayat uygulamalarında fark alma derecesi çoğunlukla 1 ya da en fazla 2 alınmaktadır. Orijinalinde durağan olmayan ama fark alma sonucu durağan hale getirilmiş serilere yönelik modellere entegre modeller ya da "durağan olmayan stokastik modeller" denir. Otoregresyon parametresi derecesi  $p$ , hareketli ortalama parametresi derecesi  $q$  ise ve  $d$  kez fark alma işlemi yapılmışsa, bu modele  $(p,d,q)$  dereceden otoregresif entegre hareketli ortalama modeli denir ve ARIMA  $(p,d,q)$  olarak gösterilir [25]. Genel ARIMA $(p,d,q)$  modelinin gösterimi Eş. 1 ve 2'de verilmiştir. Burada  $\nabla$  fark alma operatörü,  $d$  ise fark alma derecesidir.

$$Y_t = \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (1)$$

$$\phi(L)\nabla^d Y_t = \theta(L)\varepsilon_t \quad (2)$$

#### 3.2. Gri tahminleme yöntemi (grey forecasting method)

Gri tahminleme yöntemi, yapısı düzensiz, karmaşık ve belirsiz olan sistemler için 1982'de Deng Ju-long tarafından ortaya atılmış bir tahminleme tekniğidir [26]. Gri tahmin yönteminin, az sayıda veriyle çalışabilmesi ve yüksek tahmin güvenilirliği sağlaması açısından diğer tahmin yöntemleri ile karşılaştırıldığında avantajlı olabilmektedir [10]. Uygulamada en fazla kullanılan gri model, Birinci Mertebeden Bir Değişkenli Gri Model olarak adlandırılan GM (1,1) modelidir. GM (1,1) modeli aşağıdaki adımlar izlenerek kurulmaktadır [8].

**1.Adım:**  $n$  örneklem büyüklüğüne sahip  $x^{(0)}$  dizisinin gösterimi aşağıdaki gibidir:

$$X^{(0)} = (X^{(0)}(1), X^{(0)}(2), \dots, X^{(0)}(n)); n \geq 4 \quad (3)$$

**2.Adım:**  $X^{(0)}$  serisine Birikim Oluşturma İşlemi (BÜİ) uygulanarak  $X^{(1)}$  dizisi oluşturulur.

$$X^{(1)}(k) = (X^{(1)}(1), X^{(1)}(2), \dots, X^{(1)}(n)); n \geq 4 \quad (4)$$

**3. Adım:** Oluşturulan  $X^{(1)}$  dizisinden,  $Z^{(1)}$  serisi oluşturulur.

$$Z^{(1)} = (Z^{(1)}(1), Z^{(1)}(2), \dots, Z^{(1)}(n)) \quad (5)$$

$$Z^{(1)}(k) = 0.5 x^{(1)}(k) + 0.5 x^{(1)}(k - 1) \quad k = 2, 3, \dots, n \quad (6)$$

**4.Adım:** Modelin gri diferansiyel denklemi aşağıdaki gibidir:

$$x^{(0)}(k) + az^{(1)}(k) = b \quad k = 2, 3, \dots, n \quad (7)$$

Eş. 7'deki zaman noktaları  $k$ , gelişim katsayısı  $a$ , gri etki miktarı katsayısı ise  $b$  ile ifade edilmiştir.

**5.Adım:** Beyazlaştırma denklemi ise Eş. 8'deki gibi ifade edilir.

$$\frac{dx^{(1)}(k)}{dt} + \alpha x^{(1)}(k) = b \quad (8)$$

**6.Adım:** Eş. 7'deki gri diferansiyel denklemde yer alan  $a$  ve  $b$  parametrelerinin elde edilmesinde sıklıkla en küçük kareler yöntemi (EKK) ya da parametrik yöntem kullanılmaktadır. Önerilen ve en çok kullanılan en küçük kareler yöntemidir. Öncelikle denklemin parametreleri sağ tarafa alınarak aşağıdaki denklem elde edilir. Sonrasında seri matris formunda dönüştürülebilir.

$$X^{(0)}k = -\alpha z^{(1)}k + b \quad k = 2, 3, \dots, n \quad (9)$$

$$Y = \begin{bmatrix} x^{(0)}(1) \\ x^{(0)}(2) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad B = \begin{bmatrix} -z^{(1)}(1) & 1 \\ -z^{(1)}(2) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix} \quad \hat{a} = \begin{pmatrix} a \\ b \end{pmatrix} \quad (10)$$

$$Y = B\hat{a} \quad (11)$$

**7.Adım:** Eş. 11'in her iki tarafı  $B$  matrisinin devriği ile çarpıldığında Eş. 12 elde edilir. Bu işlemle  $B$  matrisi kare matrise dönüştürülmektedir.

$$B^T Y = B^T B \hat{a} \quad (12)$$

Eş. 12'in her iki tarafı  $B^T B$  matrisinin tersi  $(B^T B)^{-1}$  ile çarpılırsa,

$$(B^T B)^{-1} B^T Y = \hat{a} \quad (13)$$

$$\hat{a} = \begin{pmatrix} a \\ b \end{pmatrix} \text{ ise, } \begin{pmatrix} a \\ b \end{pmatrix} = (B^T B)^{-1} B^T Y \quad (14)$$

**8.Adım:** Eş. 8'deki beyazlaştırma denkleminde göre  $x^{(1)}(k)$  hesaplanabilir. Elde edilen  $a$  ve  $b$  değerleriyle Eş. 15 ve Eş. 16'daki gri modeller oluşturulabilir.

$$\left[ x_p^{(1)}(k+1) \right] = x^{(0)}(1) - \frac{b}{a} e^{-ak} + \frac{b}{a} \quad (15)$$

Burada  $x_p^{(1)}(k+1)$ ,  $k+1$  zamanında tahminlenen  $x$  değerinin kümülatif değerini ifade etmektedir.

**9.Adım:** Eş. 15 ile hesaplanan tahminlerin kümülatif yerine normal değeri hesaplanırsa denkleme Ters Birikim Oluşturma İşlemi (TBÜİ) uygulanabilir [8].

$$\hat{x}_p^{(0)}(k+1) = \left[ x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} - (1 - e^{-a}) \quad (16)$$



### 3.3. Yapay sinir ağları yöntemi (artificial neural network method)


Yapay sinir ağları, insan beyninin öğrenme yapısına benzer nitelikte olup, biyolojik nöron yapısından ve öğrenme biçimlerinden esinlenerek geliştirilmiştir [27]. YSA'nın en önemli özelliklerinden biri, doğrusal olmayan yapılarda iyi sonuçlar vermesidir. Doğrusal olmayan yapılar ile çalışmak zordur ancak YSA doğrusal olmayan yapılarda verdiği sonuçlarla bu zorluğu aşmaktadır. YSA'da yavaş bir birim, o sistemin hızını yavaşlatmaz. Geleneksel yöntemlerde ise sistemin yavaşlamasını sağlar. YSA'lar kendi kendine öğrenme yeteneğine sahiptirler. Veriyi, örnekler ile öğrenerek olay ile ilgili genelleme yapabilecek duruma gelirler. Genelleme ile görülmemiş örneklere bilgiler üretir. Ağda bazı yerlerdeki bozulmalar, ağın çalışmasına engel olmaz. Hatalara karşı toleransa sahip oldukları için ağ çalışmaya devam eder, sadece performansında düşüklük olabilir. Eksik verilerle çalışabilirler. Eksik bilginin olması durumunda çalışmayı engellemeyerek hatayı tolere etmeye çalışırlar. Sınırsız sayıda parametre değişken kullanılarak çalışabilmektedirler. Bu sınırsız sayıdaki parametre ve değişkenleri gerektiği anda kullanılacak şekilde eğitilirler. YSA'lar değişken ve parametrelerinde değişiklik olduğunda uygun çözümler için tekrar eğitilebilirler [28].

## 4. Kayseri İli Doğal gaz Tüketim Verileri (Natural Gas Consumption Data of Kayseri)

Çalışmada, Kayseri iline ait aylık doğal gaz tüketiminin tahminlemesi gerçekleştirilmiştir. Kullanılan veriler Kayseri ilinin 2015 Ocak - 2022 Aralık tarihleri arası 8 yıllık il genelinde tüketilen aylık doğal gaz miktarlarını içermekte olup, verilere EPDK [29] aracılığıyla erişim sağlanmıştır. İlk olarak veri üzerinde veri analizi gerçekleştirilmiş, daha sonra verilere Box-Jenkins yöntemi, gri tahminleme ve YSA olmak üzere üç yöntem tahminleme amacıyla uygulanmıştır. Yöntemler başarı kriterleri açısından değerlendirilip, en uygun çözümü veren yöntemle Kayseri ilinin gelecek aylara yönelik doğal gaz tüketim tahminlemesi yapılmıştır. Çalışmada kullanılan veriler Tablo 1'de, verilerin zaman yolu grafiği ise Şekil 1'de sunulmuştur.

Tablo 1. 2015-2022 Yılları Arası Aylık Bazda Kayseri İli Doğal Gaz Tüketim Miktarları (milyon Sm<sup>3</sup>) [29] (Natural Gas Consumption Amounts in Kayseri Province on a Monthly Basis Between 2015-2022 (million Sm<sup>3</sup>))

Aylar/Yıllar	2015	2016	2017	2018	2019	2020	2021	2022
Ocak	86.72	127.93	102.242	90.5	95.773	105.508	104.142	118.274
Şubat	71.5	82.38	101.976	95.259	104.586	117.066	104.767	130.319
Mart	63.96	59.94	78.188	72.984	83.433	91.472	98.086	107.343
Nisan	53.7	51.33	61.67	54.872	74.722	67.068	90.501	97.346
Mayıs	40.19	27.889	36.408	33.687	53.45	33.899	43.698	44.255
Haziran	23.68	25.566	20.255	21.434	17.956	27.406	30.754	31.884
Temmuz	21.23	15.528	28.146	36.279	35.77	25.643	26.274	25.292
Ağustos	35.76	31.347	22.904	20.552	23.899	27.057	29.903	25.809
Eylül	28.6	22.85	26.005	28.126	28.98	27.401	29.899	27.211
Ekim	30.43	36.881	32.731	33.829	35.721	34.203	40.043	33.351
Kasım	40.01	48.069	54.763	55.763	47.003	47.637	62.652	51.823
Aralık	43.71	78.517	85.226	89.9	83.31	91.953	93.3	82.455

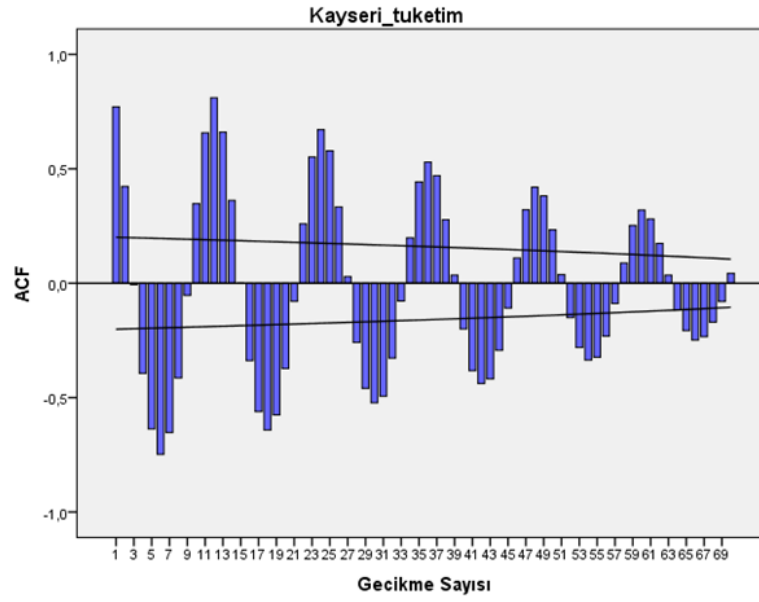


Şekil 1. 2015-2022 Yılları Arası Kayseri İli Doğal Gaz Tüketim Miktarları (milyon Sm<sup>3</sup>) Grafiği  
(The Graph of Natural Gas Consumption Amounts in Kayseri Province Between 2015-2022 (million Sm<sup>3</sup>))

## 5. Kayseri ili Doğal Gaz Tüketim Tahmini (Forecasting Natural Gas Consumption of Kayseri)

### 5.1. Box-Jenkins yöntemi ile doğal gaz tüketim tahminlemesi (Natural gas consumption estimation with Box-Jenkins method)

Box-Jenkins yöntemi ile tahminleme SPSS (26.0) istatistik paket programı üzerinde gerçekleştirilmiştir. İlk olarak Kayseri\_tuketim veri kümesinin analizini yapmak ve davranışını incelemek amacıyla serinin grafiği incelenmiştir. Şekil 1'de sunulan grafik değerlendirildiğinde, doğalgaz tüketiminin her yılın belirli mevsimlerinde artış ve azalış göstermesi verinin mevsimsel bileşen içerdiğine dair bir kanıt oluşturmaktadır. Serinin mevsimsellik içermesi sebebiyle seri durağan bir davranış sergilememektedir. Daha detaylı bir inceleme için serinin otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonları (PACF) incelenmiştir. Kayseri\_tuketim zaman serisinin ACF ve PACF grafikleri sırasıyla Şekil 2 ve Şekil 3'te, ilk 21 gecikme için Box-Ljung istatistikleri ile birlikte otokorelasyon tablosu ise Tablo 2'de verilmiştir.



Şekil 2. Kayseri\_tuketim Serisi ACF Grafiği  
(ACF Graph of Kayseri\_tuketim Series)

Şekilde verilen ACF grafiği incelendiğinde seride 12 aylık zaman periyotlarında önemli otokorelasyonların olduğu, dolayısıyla serinin mevsimsellik içerdiği ve durağan bir davranış sergilemediği net bir şekilde görülmektedir. ACF grafiğinden hareketle seride mevsimsellik olduğu ve mevsimselliğin periyodunun 12 olduğu sonucuna ulaşılmaktadır.

Tablo 2. Kayseri\_tuketim Serisi Otokorelasyon Tablosu (Autocorrelation Table of Kayseri\_tuketim Series)

Otokorelasyonlar					
Seri: Kayseri_tuketim					
Gecikme	Otokorelasyon	Std. Hata <sup>a</sup>	Box-Ljung İstatistiği Değer	Sd <sup>c</sup>	P <sup>b</sup>
1	0.77	0.1	58.773	1	.000
2	0.423	0.1	76.649	2	.000
3	-0.006	0.099	76.654	3	.000
4	-0.394	0.099	92.49	4	.000
5	-0.637	0.098	134.472	5	.000
6	-0.748	0.098	192.903	6	.000
7	-0.652	0.097	237.901	7	.000
8	-0.414	0.097	256.205	8	.000
9	-0.053	0.096	256.509	9	.000
10	0.347	0.096	269.702	10	.000
11	0.657	0.095	317.533	11	.000
12	0.81	0.094	391.025	12	.000
13	0.66	0.094	440.389	13	.000
14	0.362	0.093	455.434	14	.000
15	-0.001	0.093	455.434	15	.000
16	-0.338	0.092	468.907	16	.000
17	-0.561	0.092	506.434	17	.000
18	-0.642	0.091	556.083	18	.000
19	-0.575	0.09	596.497	19	.000
20	-0.372	0.09	613.672	20	.000
21	-0.079	0.089	614.452	21	.000


<sup>a</sup> sd: serbestlik derecesi

<sup>b</sup> Varsayılan süreç bağımsız (beyaz gürültü)

<sup>c</sup> Asimtotik ki-kare yaklaşımına dayalı



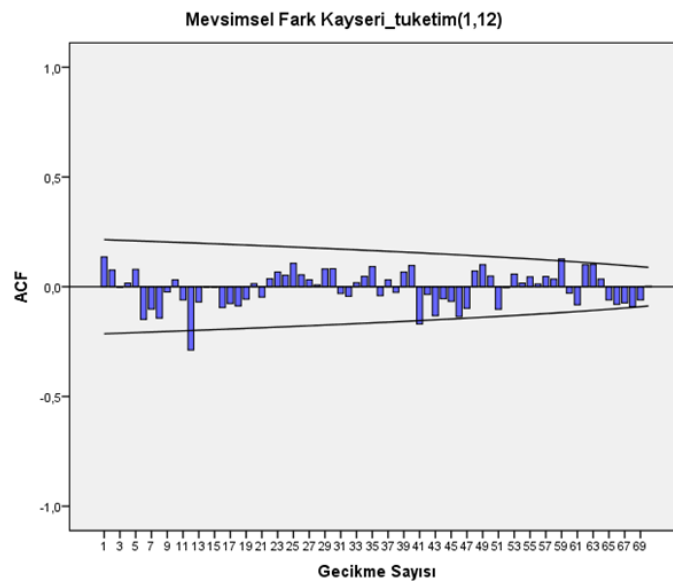
Tablo 2’de verilen Box-Ljung istatistikleri % 95 güven aralığında incelendiğinde, istatistiğin  $p$  değerlerinin tüm gecikmelerde 0.05’in altında değer aldığı görülmektedir. Bu ise serinin durağan olmadığını, gecikmelerde önemli otokorelasyonların mevcut olduğunu ifade etmektedir.



Şekil 3. Kayseri\_tuketim Serisi PACF Grafiği  
(PACF Graph of Kayseri\_tuketim Series)

Şekilde verilen kısmi otokorelasyonlar incelendiğinde bazı gecikmelerde önemli kısmi otokorelasyonların varlığı dikkat çekmektedir.

Seriye mevsimsellikten arındırıp, durağanlaştırabilmek için öncelikle serinin 1. dereceden mevsimsel farkını almak gerekir. Serinin mevsimsel farkı alındıktan sonraki otokorelasyon fonksiyonu (ACF) grafiği Şekil 4’te gösterilmiştir. ACF grafiği incelendiğinde serinin mevsimsellikten arındığı ve büyük ölçüde durağanlaştığı görülmektedir. Sadece 12. gecikmede önemli bir otokorelasyon görülmektedir, bunun durağanlığı bozup bozmadığını net olarak ortaya koymak için Box-Ljung istatistiği  $p$  değerlerine bakmakta fayda vardır. Mevsimsel farkı alınmış serinin 21 gecikme için ACF tablosu Tablo 3’te verilmiştir.



Şekil 4. Mevsimsel fark (Kayseri\_tuketim,1,12) Serisinin ACF Grafiği  
(ACF Graph of seasonal difference (Kayseri\_tuketim,1,12) Series)

Tablo 3. Mevsimsel fark (Kayseri\_tuketim,1,12) Serisinin ACF Tablosu (ACF Table of seasonal difference (Kayseri\_tuketim,1,12) Series)


Otokorelasyonlar					
Seri: Kayseri_tuketim					
Gecikme	Otokorelasyon	Std. Hata <sup>a</sup>	Box-Ljung İstatistiği Değer	Sd <sup>c</sup>	P <sup>b</sup>
1	0.136	0,107	1,603	1	0,205
2	0.076	0,107	2,111	2	0,348
3	-0.003	0,106	2,112	3	0,549
4	0.016	0,105	2,136	4	0,711
5	0.079	0,105	2,702	5	0,746
6	-0.149	0,104	4,746	6	0,577
7	-0.102	0,103	5,724	7	0,572
8	-0.143	0,103	7,671	8	0,466
9	-0.024	0,102	7,726	9	0,562
10	0.031	0,101	7,819	10	0,646
11	-0.061	0,101	8,183	11	0,697
12	-0.289	0,1	16,552	12	0,167
13	-0.07	0,099	17,049	13	0,197
14	-0.001	0,098	17,05	14	0,254
15	-0.004	0,098	17,051	15	0,316
16	-0.095	0,097	18,01	16	0,323
17	-0.077	0,096	18,645	17	0,349
18	-0.088	0,096	19,483	18	0,363
19	-0.057	0,095	19,839	19	0,404
20	0.014	0,094	19,86	20	0,467
21	-0.047	0,093	20,117	21	0,514

\* sd: serbestlik derecesi

<sup>a</sup>. Varsayılan süreç bağımsız (beyaz gürültü)

<sup>b</sup>. Asimtotik ki-kare yaklaşımına dayalı

Tablo 3 incelendiğinde % 95 güven aralığında Box-Ljung istatistiği  $p$  değerlerinin hepsinin 0.05'in üzerinde olduğu, dolayısıyla serinin durağanlaştığı görülmektedir. ACF grafiğinde 12. gecikmede sınır dışında görülen önemli otokorelasyon durağanlığı bozmamaktadır, Box-Ljung istatistiği  $p$  değeri bu gecikme için 0.167 değeriyle 0.05'in üzerindedir ve otokorelasyon önemli değildir. Mevsimsel fark alma işlemi sonucu seri mevsimsellikten arındırılmış, durağan hale gelmiştir. Böylece seri model belirleme aşaması için uygun duruma gelmiştir. Mevsimsel farkı alınmış serinin kısmi otokorelasyon fonksiyonu (PACF) grafiği Şekil 5'te verilmiştir.



Şekil 5. Mevsimsel fark (Kayseri\_tuketim,1,12) Serisinin PACF Grafiği  
(PACF Graph of seasonal difference (Kayseri\_tuketim,1,12) Series)

PACF grafiği incelendiğinde 12. gecikmede sınırları aşan önemli bir kısmi otokorelasyon görülmektedir. Ancak Tablo 3'te sunulan Box-Ljung istatistiği  $p$  değerlerine göre seride durağanlığı bozan önemli otokorelasyonlar bulunmamaktadır ve seri durağandır.

Seriye uygun modeli belirleyebilmek adına kullanılacak modelin mevsimsel olmayan otoregresif (AR) parametresi  $p$ , hareketli ortalama (MA) parametresi  $q$  ve mevsimsel otoregresif (AR)  $P$  parametresi, hareketli ortalama (MA) parametresi  $Q$  parametrelerinin tahminlerini yapmak gerekmektedir. Şekil 23 ve 24'teki ACF ve PACF grafiklerine bakıldığında periyot ( $s$ ) 12 olmak üzere, ilk gecikmelerde önemli otokorelasyonlar olmadığından mevsimsel olmayan AR parametresi  $p=0$ , mevsimsel olmayan MA parametresi  $q=0$ 'dır. Fark alınmadığından mevsimsel olmayan fark derecesi  $d=0$ 'dır. ACF grafiğinden hareketle 12. gecikme etrafındaki otokorelasyonların önemli olup olmadığı kabulüne göre mevsimsel MA parametresi  $Q=0$  veya  $Q=1$  alınabilir. PACF grafiğinden hareketle 12. gecikme etrafındaki kısmi otokorelasyonların önemli olup olmadığı kabulüne göre mevsimsel AR parametresi  $P=0$  veya  $P=1$  alınabilir. 1 kez mevsimsel fark alındığından mevsimsel fark derecesi  $D=1$ 'dir. Buna göre belirlenen alternatif modeller SARIMA(0,0,0)x(0,1,0)<sub>12</sub>, SARIMA(0,0,0)x(1,1,1)<sub>12</sub>, SARIMA(0,0,0)x(0,1,1)<sub>12</sub> ve SARIMA(0,0,0)x(1,1,0)<sub>12</sub> şeklindedir. Yapılan analizler sonucu SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modelinin seriyi modellemek için en uygun model olduğu görülmüştür. SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli uyum istatistikleri özet tablosu Tablo 4'te gösterilmiştir.

Tablo 4. SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli uyum istatistikleri özet tablosu (SARIMA(0,0,0)x(1,1,0)<sub>12</sub> model fit statistics summary table)

Uyum İstatistiği	Ortalama	Minimum	Maksimum	Yüzdeler						
				5	10	25	50	75	90	95
Durağan R2	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09
R2	0.897	0.897	0.897	0.897	0.897	0.897	0.897	0.897	0.897	0.897
OKHK	10.347	10.347	10.347	10.347	10.347	10.347	10.347	10.347	10.347	10.347
OMYH	15.941	15.941	15.941	15.941	15.941	15.941	15.941	15.941	15.941	15.941
MakMYH	61.704	61.704	61.704	61.704	61.704	61.704	61.704	61.704	61.704	61.704
OMH	7.642	7.642	7.642	7.642	7.642	7.642	7.642	7.642	7.642	7.642
MakMH	38.488	38.488	38.488	38.488	38.488	38.488	38.488	38.488	38.488	38.488
Norm BIC	4.779	4.779	4.779	4.779	4.779	4.779	4.779	4.779	4.779	4.779

$R^2$  belirleme katsayısı değeri 0.897 ile 1'e yakın bir değerdir ancak seride mevsimsellik olduğu için  $R^2$  değeri yerine *durağan*  $R^2$  ölçütünü dikkate almak daha doğru olacaktır. *Durağan*  $R^2$  değeri, çok düşük 0.09 değeriyle de olsa pozitif çıkmıştır. Dolayısıyla model, basit ortalama modelden az da olsa daha iyi sonuç vermiştir. Tablodan OMYH değerinin 15.941 olduğu görülmektedir. Maksimum mutlak yüzde hata ise (MakMYH) 61.704 olarak elde edilmiştir. Bu ölçütlerin biraz yüksek çıktığı söylenebilir. Diğer ölçütler ise tekil model değerlendirme için uygun değildir, ancak çoklu model karşılaştırmada kullanılacaktır. Tablo 5'te SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli istatistikleri gösterilmiştir. Tabloda verilen Ljung-Box Q istatistiği  $p$  değeri incelendiğinde, 0.353 değeriyle 0.05 değerinden yüksek değer almıştır ve model doğru şekilde belirlenmiştir.

Tablo 5. SARIMA(0,0,0)x(1,1,0)<sub>12</sub> Modeli İstatistikleri (SARIMA(0,0,0)x(1,1,0)<sub>12</sub> Model Statistics)

Model	Tahminleyici Sayısı	Model Uyum İstatistikleri Durağan R <sup>2</sup>	İstatistik	Ljung-Box Q(18) SD*	P	Aykırı Değer Sayısı
Kayseri_tuketim-Model_1	0	0.09	18.585	17	0.353	0

\* SD: Serbestlik Derecesi

Tablo 6'da SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli parametrelerine yönelik  $t$  istatistik sonuçları gösterilmektedir.


Tablo 6. SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli parametreleri (SARIMA(0,0,0)x(1,1,0)<sub>12</sub> Model Parameters)

			Tahmin	SH	t	p	
Kayseri_tuketim-Model_1	Dönüşüm yok	Sabit	2.722	0.807	3.372	0.001	
		AR, Mevsimsel	Gecikme 1	-0.416	0.106	-3.935	0.000
		Mevsimsel fark	1				

SH:Standart Hata

Tablodan modelin sabit terim parametresinin ve AR mevsimsel parametresinin  $t$  istatistiği  $p$  değerlerinin sırasıyla 0.001 ve 0.000 değerleriyle 0.05'ten küçük olduğu dolayısıyla her iki parametrenin de anlamlı olduğu anlaşılmaktadır.

Modelin uygunluğunu tespit etmekte bir başka kriter olan hataların beyaz gürültü olup olmadığının kontrolü öncelikle modelden elde edilen hatalara yönelik oluşturulan ACF grafiği aracılığıyla analiz edilmiştir. İlgili grafik Şekil 6'da sunulmuştur.



Şekil 6. SARIMA(0,0,0)x(1,1,0)<sub>2</sub>Modeli Hata Serisinin ACF Grafiği  
(ACF graph of the SARIMA(0,0,0)x(1,1,0)<sub>2</sub>model residual series)

Hataların ACF grafiğinden görüldüğü gibi birkaç gecikmede önemli otokorelasyon olabileceği izlenmektedir. Bu durumu kesinleştirmek ve modelin hata terimlerinin standart normal dağılımlı rasgele değişkenlerin dizininden oluşan bir beyaz gürültü süreci olup olmadığını test etmek için Box-Ljung testine bakmakta fayda vardır. Hata serisinin 21 gecikme için ACF tablosu, Box-Ljung test değerleriyle birlikte Tablo 7'de verilmiştir.

Tablo 7. HATA3 Serisinin ACF Tablosu (ACF Table of HATA3 Series)

Otokorelasyonlar					
Seri: HATA3					
Gecikme	Otokorelasyon	Std. Hata <sup>a</sup>	Box-Ljung İstatistiği		
			Değer	sd	P <sup>b</sup>
1	0.106	0.107	0.98	1	0.322
2	0.123	0.107	2.303	2	0.316
3	-0.002	0.106	2.303	3	0.512
4	-0.072	0.105	2.77	4	0.597
5	0.033	0.105	2.871	5	0.72
6	-0.284	0.104	10.362	6	0.11
7	-0.111	0.103	11.528	7	0.117
8	-0.167	0.103	14.164	8	0.078
9	-0.06	0.102	14.509	9	0.105
10	0.068	0.101	14.965	10	0.133
11	-0.023	0.101	15.019	11	0.182
12	0.058	0.1	15.355	12	0.223
13	-0.012	0.099	15.37	13	0.285
14	0.033	0.098	15.483	14	0.346
15	-0.012	0.098	15.498	15	0.416
16	-0.114	0.097	16.89	16	0.393
17	-0.02	0.096	16.932	17	0.459
18	-0.123	0.096	18.585	18	0.418
19	-0.106	0.095	19.827	19	0.405
20	-0.042	0.094	20.022	20	0.457
21	-0.045	0.093	20.25	21	0.505


\* sd: serbestlik derecesi

a. Varsayılan süreç bağımsız (beyaz gürültü).

b. Asimtotik ki-kare yaklaşımına dayalı.

Tabloda verilen Box-Ljung istatistiği  $p$  değerleri % 95 güven aralığında incelendiğinde tüm değerlerin 0.05 değerinden yüksek çıkmasından dolayı hataların rasgele bir davranış sergilediği ve beyaz gürültü olduğu sonucuna varılmaktadır.

Şekil 7'de gözlemlenen, SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli ile tahminlenen, tahminlenen değerlerin alt ve üst sınır değerleri grafik olarak gösterilmiştir. Şekilden de görüldüğü gibi modelce tahminlenen değerler gerçekleşen değerleri bazı hata değerleriyle birlikte tahmin etmektedir ve gerçekleşen değerler, tahminlenen değerlerin alt-üst sınır aralıklarında yer almaktadır. Buradan hareketle gelecekteki değerlerin de bu sınırlar içerisinde yer alacağı söylenebilir.



Şekil 7. Gerçekleşen ve SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli ile tahminlenen değerler grafiği  
(Actual and predicted values graph by the SARIMA(0,0,0)x(1,1,0)<sub>12</sub> model)

Bu analizler sonucunda modelin uygun olduğu, parametrelerinin anlamlı olduğu, hataların beyaz gürültü olduğu ve gelecekte gerçekleşecek değerlerin tahmin sınırları içerisinde yer alacağı söylenebilir. Analizlerde değerlendirilen 4 SARIMA modelinden SARIMA(0,0,0)x(1,1,0)<sub>12</sub> ve SARIMA(0,0,0)x(0,1,0)<sub>12</sub> modelleri uygun bulunmuş, bu modellerden de yukarıda detaylı analizleri verilen SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modeli Tablo 8’de verilen etkinlik ölçütlerine göre seçilmiştir. Model değerlendirmede en çok kullanılan ölçütlerden biri normalize Bayes bilgi kriteridir (*Norm BIC*). Bu ölçüt, model karmaşıklığını açıklamaya çalışan bir modelin genel uyumunun bir ölçüsüdür ve düşük olması beklenir. Tabloda verilen *Norm BIC* değerleri incelendiğinde SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modelinin daha iyi sonuç verdiği gözlemlenmektedir. Ayrıca bu model *MakMH* haricindeki diğer tüm hata etkinlik ölçütlerinde de daha iyi değer vermiştir ve SARIMA(0,0,0)x(0,1,0)<sub>12</sub> modelinin aksine *durağan R<sup>2</sup>* değeri negatif değil, pozitifdir.

Tablo 8. SARIMA(0,0,0)x(1,1,0)<sub>12</sub> ve SARIMA(0,0,0)x(0,1,0)<sub>12</sub> modelleri karşılaştırma tablosu (Comparison table of SARIMA(0,0,0)x(1,1,0)<sub>12</sub> and SARIMA(0,0,0)x(0,1,0)<sub>12</sub> models)

Model	R <sup>2</sup>	Durağan R <sup>2</sup>	OKHK	OMH	MakMH	Norm BIC
SARIMA(0,0,0)x(1,1,0) <sub>12</sub>	0.897	0.09	10.347	7.642	38.488	4.779
SARIMA(0,0,0)x(0,1,0) <sub>12</sub>	0.887	-2.60E-16	10.781	7.99	38.402	4.808

## 5.2. Gri tahmin yöntemi ile doğal gaz tüketim tahminlemesi (Natural gas consumption estimation with grey forecasting method)

Çalışmada birinci mertebeden tek değişkenli gri model olan GM(1,1) modeli ile tahminleme gerçekleştirilmiştir. Gri tahmin yönteminin uygulaması SPSS (26.0) paket programı ve Excel programından yararlanılarak yapılmıştır. Çalışmada Tablo 1’de sunulan 2015-2022 yılları arası aylık bazda gerçekleşen Kayseri ili doğal gaz tüketim miktarları kullanılmıştır. Daha önce de bahsedildiği ve Şekil 1’de de gösterildiği üzere veri kümesi mevsimsel bileşen içermektedir. Yapılan analizler ve literatür taraması sonucu benzer çalışmalara bakıldığında, gri modellerin serideki trend bileşenini yakalayıp doğru sonuçlar üretebilirken, mevsimsel bileşeni yakalayamadığı, doğru sonuçlar üretmediği görülmüştür. Bu nedenle, öncelikle serideki mevsimsel bileşeni seriden arındırmak için SPSS paket programı üzerinde ayrıştırma yöntemleri kullanılmıştır. Ayrıştırma yöntemlerinin hangisinin hangi tip seride daha etkin olduğunu tespit etmek adına herhangi bir ölçüt veya test olmaması nedeniyle hem toplamsal ayrıştırma hem de çarpımsal ayrıştırma yöntemlerinden faydalanılmıştır. Sonrasında toplamsal ayrıştırma ve çarpımsal ayrıştırma yöntemleriyle mevsimsel bileşenlerinden ayrılan serilere GM(1,1) modeli ayrı ayrı uygulanmıştır. Mevsimsel bileşenleri toplamsal ve çarpımsal ayrıştırma yöntemleriyle arındırılmış serilere GM(1,1) modeli uygulanarak edilen sonuçlar hata ölçütleri açısından karşılaştırılıp, uygun gri model belirlenmiştir. Toplamsal ve çarpımsal ayrıştırma kullanılarak elde edilen gri modellerin hata ölçütleri bakımından karşılaştırılması Tablo 9’da verilmiştir.

Tablo 9. Toplamsal ve çarpımsal GM(1,1) modellerinin hata ölçütleri (Error measures of additive and multiplicative GM(1,1) models)

Yöntemler	OMYH	OMH	OKH	OKHK	R <sup>2</sup>
Toplamsal GM(1,1)	14.5517984	6.869924	81.56573	9.031375	0.9141
Çarpımsal GM(1,1)	12.0785325	5.779011	70.29108	8.383978	0.926

Tablo incelendiğinde *OMYH*, *OMH*, *OKH*, *OKHK* etkinlik ölçüt değerlerinin en düşük olduğu ve *R<sup>2</sup>* değerinin en yüksek olduğu modelin çarpımsal ayrıştırma tabanlı GM(1,1) modeli olduğu görülmektedir. Gelecek ayları tahminlemek için kullanılacak en iyi gri model çarpımsal ayrıştırma tabanlı GM(1,1) modelidir. Model, SARIMA(0,0,0)(1,1,0)<sub>12</sub> modelinden daha iyi etkinlik ölçüt değerleri vermiştir. Çarpımsal ayrıştırma tabanlı GM(1,1) modeli uygulama adımları aşağıda anlatılmıştır.

**1. adım:** X<sup>(0)</sup> serisi, SPSS paket programı kullanılarak çarpımsal ayrıştırma yöntemi ile mevsimsel bileşenden ayrıştırılan seridir.



$$X^{(0)}(k) = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)); n=96$$

Matris formu;

$$Y = \begin{bmatrix} 47,91507 \\ 38,58574 \\ 42,32089 \\ 43,22456 \\ 60,42961 \\ \vdots \end{bmatrix} \text{şeklindedir.}$$

**2.adım:**  $X^{(0)}$  serisine Birikim Oluşturma İşlemi (BÜİ) uygulanarak  $X^{(1)}$  dizisi oluşturulmuştur.

$$X^{(1)}(k) = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)); n = 96$$

$$X(1) = \begin{bmatrix} 47,91507 \\ 86,50081 \\ 128,8217 \\ 172,04626 \\ 232,47587 \\ \vdots \end{bmatrix}$$

**3. Adım:**  $X^{(1)}$  dizisinden  $Z^{(1)}$  serisi oluşturulmuştur.

$$Z^{(1)} = (z^{(1)}(1), z^{(1)}(2), \dots, z^{(1)}(n))$$

$$Z^{(1)}(k) = 0.5 x^{(1)}(k) + 0.5 x^{(1)}(k-1) \quad k=2,3,\dots,96$$

$$Z(1) = \begin{bmatrix} -67,20794 \\ -107,661255 \\ -150,43398 \\ -202,261065 \\ -258,67341 \\ \vdots \end{bmatrix}$$

$Z^{(1)}$  matrisi B matrisine dönüştürülmüştür.

$$B = \begin{bmatrix} -67,20794 & 1 \\ -107,661255 & 1 \\ -150,43398 & 1 \\ -202,261065 & 1 \\ -258,67341 & 1 \\ \vdots & \vdots \end{bmatrix}$$

**4.Adım:** B matrisine devrik dönüşüm uygulanarak  $B^T$  matrisi elde edilmiştir.

$$B^T = \begin{bmatrix} -67,20794 & -107,661255 & \dots \\ 1 & 1 & \dots \end{bmatrix}$$

**5.Adım:**  $B^T$  matrisi ile B matrisi çarpılarak  $B^T * B$  matrisi elde edilmiştir.

$$B^T * B = \begin{bmatrix} 853595934,8 & -244429,0616 \\ -244429,0616 & 95 \end{bmatrix}$$

**6.Adım:** Dizey ters işlemi yapılarak  $B^T * B^{-1}$  matrisi elde edilmiştir.

$$B^T * B^{-1} = \begin{bmatrix} 4,45047E - 09 & 1,14508E - 05 \\ 1,14508E - 05 & 0,039988477 \end{bmatrix}$$

**7.Adım:**  $B^{T*}B^{-1*}$  matrisi ile  $B^T$  matrisi çarpılarak  $B^{T*}B^{-1*} B^T$  matrisi elde edilmiştir.

$$B^T * B^{-1} * B^T = \begin{bmatrix} 1,11517E - 05 & 1,09716E - 05 & \dots \\ 0,039218893 & 0,038755671 & \dots \end{bmatrix}$$

**8.Adım:**  $B^{T*}B^{-1*} B^T$  matrisi ile  $Y$  matrisi çarpılarak  $B^{T*}B^{-1*} B^T * Y$  matrisi elde edilmiştir.

$$B^T * B^{-1} * B^T * Y = \begin{bmatrix} -0,003053982 \\ 48,02203866 \end{bmatrix}$$

$$a = -0,003053982$$

$$b = 48,02203866$$

$$\frac{b}{a} = 15724,40022$$

**9.Adım:**  $a$  ve  $b$  değerleri kullanılarak gri model oluşturulmuştur.

$$\left[ \hat{x}_p^{(1)}(k+1) = x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} + \frac{b}{a}$$

Bu eşitlik ile elde edilen  $E$  matrisi;


$$E = \begin{bmatrix} 47,91507 \\ 96,15706804 \\ 144,5466215 \\ 193,0841816 \\ 241,7702012 \\ \vdots \end{bmatrix}$$

**10.Adım:**  $F$  matrisi elde edilmiştir.

$$F = \begin{bmatrix} 47,91507 \\ 48,24199804 \\ 48,38955344 \\ 48,53756017 \\ 48,68601959 \\ \vdots \end{bmatrix}$$

**11.Adım:**  $F$  matrisi (GM(1,1) modeli tahminleri) ile SPSS programında çarpımsal ayrıştırma yöntemi ile elde edilen mevsimsel endeks değerleri çarpılarak mevsimselliği dikkate alan tahmin değerleri bulunmuştur.

Çarpımsal ayrıştırma tabanlı GM(1,1) modelinin gerçekleşen ve tahmin değerleri grafiği Şekil 8'de verilmiştir. Şekilden de görüldüğü gibi tahminler gerçekleşen değerleri izlemektedir ve mevsimsel davranışı çok iyi düzeyde yakalamıştır. Çarpımsal ayrıştırma tabanlı GM(1,1) modeli ile  $0.926 R^2$  değerleri elde edilmiştir. Elde edilen  $R^2$  değeri oldukça 1'e yakındır ve SARIMA(0,0,0)(1,1,0)<sub>12</sub> modelinden elde edilen 0.897 değerinden daha yüksektir. Tablo 9'da sunulan OKHK ve OMH hata etkinlik ölçütlerinde de SARIMA(0,0,0)(1,1,0)<sub>12</sub> modelinden daha iyi yani daha düşük değerler elde edilmiştir.




Şekil 8. Çarpımsal ayrıştırma tabanlı GM(1,1) modelinin gerçekleşen ve tahmin değerleri grafiği  
(Actual and forecast values graph of multiplicative decomposition based GM(1,1) model)

### 5.3. Yapay sinir ağları yöntemi ile doğal gaz tüketim tahminlemesi (Natural gas consumption estimation with artificial neural networks)

YSA yöntemi uygulaması, WEKA paket programı 3.9.0 versiyonu üzerinde gerçekleştirilmiştir. Yapay sinir ağlarında tahminleme amacıyla Kayseri ili doğalgaz tüketim değerleri çıktı değişkeni olarak, yıl ve ay bilgileri ise girdi değişkenleri olarak ele alınmıştır. YSA modeli olarak sınıflandırma ve tahminlemede oldukça başarılı sonuçlar veren çok katmanlı algılayıcı (ÇKA) (Multilayer Perceptron -MLP) yöntemi kullanılmıştır. Yapay sinir ağ parametrelerini ve ağ mimarisini belirlemek için etkin bir yöntem olmadığı için pek çok farklı çok katmanlı algılayıcı modeli denenmiş, denemeler neticesinde sigmoid aktivasyon fonksiyonu kullanılarak, 3 gizli katman ve her katmanda 5 nöron olan ağ yapısı en iyi sonucu vermiştir. Veri eğitim ve test kümelerine ayrılırken %66-34 oranı kullanılmıştır. Bu doğrultuda verinin %66'sı modelin öğrenmesi için kullanılırken, kalan %34'lük kısmı ağı test edilmesi için kullanılmıştır. Model 500 iterasyon (epoch) çalıştırılmıştır.

Önerilen ağ mimarisinde giriş katmanında girdi niteliklerini ifade eden 2 nöron, her birinde 5'er adet nöron bulunan 3 gizli katman ve tüketim miktarı sürekli çıktı değişkenini ifade eden tek nöronlu çıkış katmanı bulunmaktadır. Önerilen ÇKA mimarisi Şekil 9'da gösterilmiştir.

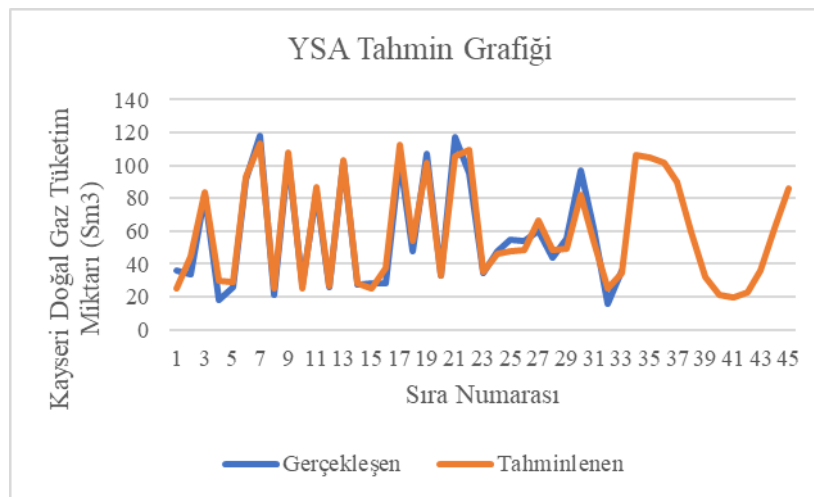


Şekil 9. Önerilen ÇKA Yapısı  
(Proposed MLP Structure)

Önerilen ÇKA modeli, test kümesinde 0.9773 korelasyon katsayısı ( $R$ ) değerine sahiptir, bu da değişkenler arasında pozitif yönlü yüksek düzeyde ilişki olduğunu ifade etmektedir. Model test kümesi üzerinde 5.5895  $OMH$ , 6.9347  $OKHK$ , % 20.1228 göreceli mutlak hata ve % 21.1757 göreceli kareli hata kökü değeri üretmiştir.

ÇKA modelinin etkinliğini artırmak adına modele yıl ve ay girdi değişkenlerinin yanı sıra veride aylık bazda mevsimsellik gözlemlendiğinden, sırayla geçmiş yılın aynı ayına ait veri (model1), geçmiş iki yılın aynı ayına ait veri (model2) ve geçmiş üç yılın aynı ayına ait veriler (model3) de girdi değişkeni olarak eklenmiştir. ÇKA modelinde sigmoid aktivasyon fonksiyonu, 3 gizli katman ve her katmanda 5 nöron olan bir yapı kullanılmıştır. Test kümesi üzerinde Model1 ile 0.9272  $R$ , 18.6229  $OMH$ , 20.3607  $OKHK$ , % 59.4784 görel mutlak hata ve % 56,6518 görel kareli hata kökü değeri elde edilmiştir. Model2 ile 0.9548  $R$  değeri, 7.8446  $OMH$ , 9.9887  $OKHK$ , % 28.7769 görel mutlak hata ve % 31.5288 görel kareli hata kökü değerleri; model3 ile ise 0.9546  $R$ , 9.2057  $OMH$ , 11.6586  $OKHK$ , % 29.799 görel mutlak hata ve % 35.662 görel mutlak hata kökü değerleri üretilmiştir. Ancak elde edilen bu sonuçlardan da görüldüğü gibi, geçmiş mevsimsel verilerin kullanımının yapay sinir ağının etkinliği üzerinde olumlu bir etkisi olmamıştır. Dolayısıyla girdi değişkeni olarak sadece yıl ve ayın kullanıldığı veri üzerinde elde edilen sonuçlar YSA'nın diğer yöntemlerle değerlendirilmesi aşamasında ele alınmıştır.

ÇKA modeli ile elde edilen sonuçların diğer yöntemlerle eşit şartlar altında karşılaştırılabilmesi için ÇKA modeli ile bütün veriler üzerinde elde edilen etkinlik ölçütleri de hesaplanmıştır. Bütün veriler üzerinde ÇKA ile 7.0642  $OMH$  değeri, 85.1353  $OKH$  değeri, 9.2269  $OKHK$  değeri, 15.167  $OMH$  değeri ve 0.91  $R^2$  değeri elde edilmiştir. ÇKA ile elde edilen tahminler ve gerçekleşen doğal gaz tüketim değerleri grafiği Şekil 10'da verilmiştir.



Şekil 10. Gerçekleşen ve Tahminlenen Doğal Gaz Tüketim Değerleri Grafiği  
(Observed and Forecasted Natural Gas Consumption Values Chart)

#### 5.4. Sonuçlar ve tartışma (Results and discussion)

Tablo 10, ARIMA modelleri, gri tahmin yöntemi ve yapay sinir ağları yöntemleri uygulanarak elde edilen Kayseri ili doğal gaz tüketimi tahmin sonuçlarının çeşitli performans ölçütleri açısından karşılaştırmasını göstermektedir. Tablo incelendiğinde en düşük  $OMYH$ ,  $OMH$ ,  $OKH$ ,  $OKHK$  değerlerine ve en yüksek  $R^2$  değerlerine sahip olan çarpımsal ayrıştırma tabanlı  $GM(1,1)$  yönteminin tahminlemede kullanılabilir en uygun yöntem olduğu görülmektedir. Çarpımsal ayrıştırma tabanlı  $GM(1,1)$  modelini sırasıyla toplamsal ayrıştırma tabanlı  $GM(1,1)$  yöntemi, YSA ve SARIMA modeli izlemektedir.

Tablo 10. Uygulanan yöntemlerin performans ölçütleri açısından karşılaştırması (Comparison of applied methods in terms of performance measures)

Hata Ölçütleri/Yöntemler	Toplamsal $GM(1,1)$	Çarpımsal $GM(1,1)$	SARIMA (0,0,0)(1,1,0) <sub>12</sub>	YSA
OMYH	14.5518	<b>12.0785</b>	15.941	15.167
OMH	6.8699	<b>5.779</b>	7.642	7.0642
OKH	81.5657	<b>70.2911</b>	107.0604	85.1353
OKHK	9.0314	<b>8.384</b>	10.347	9.2269
R2	0.9141	<b>0.926</b>	0.897	0.9104

Kayseri ili doğal gaz tüketimi aylık tahmini için en uygun yöntem olarak çarpımsal ayrıştırma tabanlı GM(1,1) yöntemi belirlendikten sonra, yöntem ile 2023 yılının 12 ayı için Kayseri ilinin doğal gaz tüketim tahmini yapılmıştır. Çarpımsal ayrıştırma tabanlı GM(1,1) modeli ile geleceğe yönelik tahmin değerleri Tablo 11'deki gibidir.

Tablo 11. 2023 Yılı Kayseri İli için Doğal Gaz Tüketimi Tahmin Değerleri (Forecast Values of Natural Gas Consumption for Kayseri Province in 2023)

Aylar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran
<b>Tüketim</b> (milyon Sm <sup>3</sup> )	116.701	119.849	98.047	80.844	43.411	29.59
Aylar	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
<b>Tüketim</b> (milyon Sm <sup>3</sup> )	31.661	32.181	32.551	40.921	59.667	99.239

## 6. Sonuçlar (Conclusions)

Çalışmada 2015-2022 yılları arasında aylık olarak gerçekleşen toplamda 96 aylık Kayseri iline ait doğal gaz tüketim verisi kullanılmış olup, 2023 yılı için tüketim tahmini gerçekleştirilmiştir. Tahminleme yöntemleri olarak literatürde de büyük ölçüde kabul gören Box-Jenkins, Gri Tahminleme ve Yapay Sinir Ağları yöntemleri kullanılmıştır. Tahminleme uygulamalarını yapmak ve analizleri gerçekleştirmek üzere SPSS istatistiksel yazılım, EXCEL ve WEKA makine öğrenimi paket programlarından faydalanılmıştır.

Tahminlemede ilk olarak Box-Jenkins yöntemi uygulanmıştır. Yöntem uygulanmadan önce doğal gaz tüketim serisinin davranışı incelenmiştir. Serinin mevsimsellik içermesi sebebiyle veriye mevsimsel fark alma işlemi uygulanarak durağanlık sağlanmıştır. Kullanılacak modeller için parametre tahmini yapılmıştır. Ardından dört alternatif modelin anlamlılıkları ve uygunlukları test edilmiştir ve model çıktıları başarı kriterleri açısından değerlendirilmiştir. Sonuç olarak ele alınan Box-Jenkins modellerinden SARIMA(0,0,0)x(1,1,0)<sub>12</sub> modelinin öngörü işlemi için en uygun model olduğu belirlenmiştir.

Kayseri doğal gaz tüketimi tahmininde ikinci olarak gri tahmin uygulanmıştır. Yapılan analizler ve literatür araştırması sonucunda gri tahmin yönteminin mevsimsellik içeren verilerde iyi sonuçlar vermediği anlaşılmıştır. Bu nedenle seri önce ayrıştırma yöntemleriyle mevsimsel bileşenden arındırılıp, daha sonra gri tahmin aşamasına geçilmiştir. Toplamsal ayrıştırma tabanlı GM(1,1) modeli ve çarpımsal ayrıştırma tabanlı GM(1,1) modeli olmak üzere iki gri model üzerinden tahminleme gerçekleştirilmiştir. Modeller hata ölçütleri açısından değerlendirilmiş ve ele alınan iki model arasından en iyi modelin çarpımsal ayrıştırma tabanlı GM(1,1) modeli olduğu belirlenmiştir.

Tahminlemede son yöntem olarak yapay sinir ağları (ÇKA) kullanılmıştır. Weka paket programında gerçekleştirilen analizler neticesinde yapay sinir ağlarının iyi bir çözüm sunduğu görülmüştür. Uygulamanın son aşamasında kullanılan üç yöntem *OMH*, *OKH*, *OKHK*, *OMYH* ve  $R^2$  hata ölçütleri bakımından karşılaştırılmış, 0,926  $R^2$  değeri ile en başarılı sonucu veren çarpımsal ayrıştırma tabanlı GM(1,1) yönteminin tahminleme için en uygun yöntem olduğu belirlenmiştir. Uygulamanın son aşamasında çarpımsal ayrıştırma tabanlı GM(1,1) yöntemi ile 2023 yılı için Kayseri ili aylık doğal gaz tüketim tahminlemesi yapılmıştır.

Bu çalışma ayrıştırma tabanlı gri tahmin yönteminin tahminleme yapmak üzere yöneticilerin ve uzmanların tercih edebileceği bir yöntem olduğunu verdiği başarılı sonuçla ortaya koymaktadır. Ele alınan diğer yöntemler de tahmin için uygun yöntemlerdir, ancak en uygun değildir. Gelecek çalışmalarda veri boyutu artırılarak daha da etkin tahminleme çalışmaları yapılabilir. Bu çalışmadan yola çıkılarak aynı zamanda Kayseri veya diğer illere yönelik sanayi, konut tüketimi gibi detaylı sektörel bazda enerji tüketimi tahminlemeleri de gerçekleştirilebilir.

## Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

## Kaynaklar (References)

- [1] Vikipedi, [Online]. <https://tr.wikipedia.org/wiki/Doğalgaz> [Erişim Tarihi: 18 Mart 2023].
- [2] M. Aydın, "Denizli ili için doğal gaz tüketim analizi ve tahmini," Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İşletme Ana Bilim Dalı Sayısal Yöntemler Programı, Denizli, Türkiye, 2022.
- [3] H. Aras, N. Aras, "Eskişehir'de konutsal doğal gaz talebine ekonomik göstergelerin ve dış ortam sıcaklığının etkileri," *Mühendis ve Makina Dergisi*, cilt 46., sayı 540, ss. 20- 27, 2005.
- [4] N. Kaya, "Zaman serilerine dayalı tahmin yöntemleri ile Türkiye'nin yenilenebilir enerji kaynakları talebinin tahmini," Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, Trabzon, Türkiye, 2005.
- [5] Y. Çuhadar, P. Güngör ve Y. Göksu, "Turizm talebinin yapay sinir ağları ile tahmini ve zaman serisi yöntemleri ile karşılaştırmalı analizi: Antalya iline yönelik bir uygulama," *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 14, sayı 1, ss. 99-114, 2009. <https://dergipark.org.tr/tr/pub/sduiibfd/issue/20831/223138>
- [6] O. Kaynar, S. Taştan, ve F. Demirkoparan, "Yapay sinir ağları ile doğalgaz tüketim tahmini," *Atatürk Üniversitesi, İktisadi ve İdari Bilimler Dergisi*, cilt 25, 2011.
- [7] M. Kırçıl, "Box- Jenkins yöntemi ile konut doğal gaz talebinin tahminlenmesi: İzmir ili örneği" Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Isparta, Türkiye, 2013.
- [8] K. Oruç, ve Ş. Çelik, "Isparta ili için doğal gaz talep tahmini," *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 22, sayı 1, ss. 31-42. 2016.
- [9] H. Ekmekçi, "Türkiye'deki doğal gaz kullanımının ARIMA metodu ile istatistiksel analizi," Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Karabük, Türkiye, 2016.
- [10] T. Eren, "Doğal gaz tüketim planlamasında gri tahmin yöntemi ve Türkiye uygulaması," İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, İstanbul, Türkiye, 2017.
- [11] S. Singh, and A. Yassine, "Big data mining of energy time series for behavioral analytics and energy consumption forecasting," *Energies*, vol. 11, no. 2, 452, 2018. doi:10.3390/en11020452
- [12] B. Taşkuner, "Ankara ili doğal gaz tüketiminin yapay sinir ağları ile öngörüsü," Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Enerji Enstitüsü Enerji Bilim ve Teknoloji Anabilim Dalı, 67, İstanbul, Türkiye, 2018.
- [13] T. Akman, C. Yılmaz, ve Y. Sönmez, "Elektrik yükü tahmin yöntemlerinin analizi," *Gazi Mühendislik Bilimleri Dergisi*, cilt 4, sayı 3, ss. 168-175, 2018. doi:10.30855/GJES.2018.04.03.003
- [14] M. H. Calp, "İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi," *Politeknik Dergisi*, cilt 22, sayı 3, ss. 675-686, 2019. doi:10.2339/politeknik.444380
- [15] O. E. Erdem, "Makine öğrenme teknikleri ile Türkiye'nin doğalgaz enerji tüketiminin tahminlenmesi," Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Konya, Türkiye, 2019.
- [16] Ç. Tuna, "Doğal gaz talep tahmini: Erzurum ili üzerine bir uygulama," Erzurum Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Ana Bilim Dalı, Yüksek Lisans Tezi, Erzurum, Türkiye, 2019.
- [17] M. Akpınar, ve N. Yumuşak, "Günlük temelli orta vadeli şehir doğal gaz talebinin tek değişkenli istatistik teknikleri ile tahmini," *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, cilt 35, sayı 2, ss. 725-742, 2020. doi: 10.17341/gazimmfd.494094
- [18] K., Oruç, ve A. Başağaoğlu Fındık, "Gri tahminleme ile Süleyman Demirel Üniversitesi Ağız Dış Sağlığı Merkezi'nde yatan hasta sayılarının tahmini," *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, cilt 37, ss. 193-212, 2020.
- [19] V. Demir, ve A. Ü. Keskin, "Yapay Sinir Ağları Yardımıyla Yükseklik Modellemesi Samsun-Mert Irmağı Havzası Örneği," *Gazi Mühendislik Bilimleri Dergisi*, cilt 6, sayı 1, ss. 54-61, 2020. doi:10.30855/gmbd.2020.01.05



- [20] S. Sayım, ve V. Ömürbek, "Gri tahmin GM (1, 1) modeli ile bir büyükşehir belediyesinde gelir tahmini," *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 8, sayı 3, ss. 1782-1805, 2021. doi:10.30798/makuiibf978524
- [21] Ü. B. Köse, "Yapay sinir ağları ve gri model ile döviz kuru tahmini," Marmara Üniversitesi Sosyal Bilimler Enstitüsü, Sayısal Yöntemler Ana Bilim Dalı, Yüksek Lisans Tezi, İstanbul, Türkiye, 2021.
- [22] W. Panek, and T. Włodek, "Natural gas consumption forecasting based on the variability of external meteorological factors using machine learning algorithms," *Energies*, vol. 15, 348, 2022. doi:10.3390/en15010348
- [23] M. H. Safiyari, S. Shavvalpour, and S. Tarighi, "From traditional to modern methods: comparing and introducing the most powerful model for forecasting the residential natural gas demand," *Energy Reports*, vol. 8, pp. 14699-14715, 2022. doi:10.1016/j.egy.2022.10.397
- [24] O. Çevik, "Zaman serileri analizinde Box-Jenkins Yöntemi ve turizm verileri üzerine bir uygulama," Kırıkkale Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Doktora Tezi, Kırıkkale, Türkiye, 1999.
- [25] Ö. Duru, "Zaman serileri analizinde arıma modelleri ve bir uygulama," İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonomi Bölümü Ekonometri Ana Bilim Dalı, Yüksek Lisans Tezi, İstanbul, Türkiye, 2007.
- [26] H. Yılmaz, "Türkiye'deki seragazi emisyon envanterinin geliştirilen gri tahmin yöntemi ile incelenmesi ve bir uygulama," Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, Erzurum, Türkiye, 2013.
- [27] B. Akın, "Yapay sinir ağlarıyla Konya bölgesinde kullanıcı doğal gaz tüketim öngörüsü," İstanbul Teknik Enstitüsü, Enerji Bilim ve Teknoloji Anabilim Dalı, Yüksek Lisans tezi, İstanbul, Türkiye, 2017.
- [28] B. Saltürk, "Yapay sinir ağları ile ürün satış miktarlarının tahmini: Mobilya sektöründe bir uygulama," Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Ana Bilim Dalı, Yüksek Lisans tezi, Sakarya, Türkiye, 2022.
- [29] Enerji Piyasası Düzenleme Kurumu, Doğal gaz aylık sektör raporları, [Online]. <https://www.epdk.gov.tr/Detay/Icerik/3-0-95-1007/dogal-gazaylik-sektor-raporu> [Erişim Tarihi: 20 Nisan 2023].

This is an open access article under the CC-BY license

