

Doğal Gaz Tesisat Firmalarının Gelecek İş Hacminin Tahmini: Mevsimsel ve Kısa Vadeli Dinamiklerin Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) Modeli ile Analizi

Selin SARAÇ GÜLERYÜZ^{1,a}, Fikri EGE^{1,b}

¹Toros Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Mersin, Türkiye

^aORCID: 0000-0002-4729-0637; ^bORCID: 0000-0002-9045-4975

Makale Bilgileri

Geliş : 10.09.2025

Kabul : 23.03.2026

DOI: 10.21605/cukurovaumfd.1781580

Sorumlu Yazar

Selin SARAÇ GÜLERYÜZ

selin.sarac@toros.edu.tr

Anahtar Kelimeler

Zaman serisi tahminleme

ARIMA

SARIMA

Doğal gaz

Atıf şekli: SARAÇ GÜLERYÜZ, S., EGE, F., (2026). Doğal Gaz Tesisat Firmalarının Gelecek İş Hacminin Tahmini: Mevsimsel ve Kısa Vadeli Dinamiklerin Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) Modeli ile Analizi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 41(1), 241-252.

ÖZ

Bu çalışmada Mersin ilindeki doğal gaz tesisat firmalarının gelecekteki iş hacimleri zaman serisi yöntemleri kullanılarak tahmin edilmiştir. Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) modeli, mevsimsel bileşenlerin ve kısa vadeli dinamiklerin modellenmesi için kullanılmıştır. 2011 yılından itibaren 10 yıl boyunca toplanan aylık yeni abone sayısı verisi analiz edilmiştir. Durağanlık ADF testi ile sınanmış, model parametreleri ACF ve PACF grafikleri incelenerek $(1,0,0)(0,1,2)_{[12]}$ olarak belirlenmiştir. Modelin doğruluğu MAPE ve R^2 kriterleri ile değerlendirilmiş; sırasıyla %16,51 ve 0,81 değerleri elde edilmiştir. Tahmin sonuçları, mevsimsel değişimlerin işletme planlamalarında belirleyici bir rol oynadığını göstermekte; firmaların insan kaynakları, stok yönetimi ve pazarlama stratejilerinde mevsimselliği esas almaları gerektiğini ortaya koymaktadır. Bu çalışma, doğal gaz tesisat sektöründeki işletmelere stratejik karar alma süreçlerinde uygulanabilir ve veri temelli bilgiler sunmaktadır.

Forecasting Future Business Volume of Natural Gas Installation Companies: Analysis of Seasonal and Short-Term Dynamics Using the Seasonal Autoregressive Integrated Moving Average (SARIMA) Model

Article Info

Received : 10.09.2025

Accepted : 23.03.2026

DOI: 10.21605/cukurovaumfd.1781580

Corresponding Author

Selin SARAÇ GÜLERYÜZ

selin.sarac@toros.edu.tr

Keywords

Time series forecasting

ARIMA

SARIMA

Natural gas

How to cite: SARAÇ GÜLERYÜZ, S., EGE, F., (2026). Forecasting Future Business Volume of Natural Gas Installation Companies: Analysis of Seasonal and Short-Term Dynamics Using the Seasonal Autoregressive Integrated Moving Average (SARIMA) Model. Çukurova University, Journal of the Faculty of Engineering, 41(1), 241-252.

ABSTRACT

This study forecasts the future business volume of natural gas installation companies in Mersin province using time series methods. The Seasonal Autoregressive Integrated Moving Average (SARIMA) model was employed to capture seasonal components and short-term dynamics. Monthly new subscriber data collected over a 10-year period starting from 2011 were analyzed. Stationarity was verified using the Augmented Dickey-Fuller (ADF) test, and model parameters were identified as $(1,0,0)(0,1,2)_{[12]}$ through ACF and PACF analysis. Model accuracy was assessed via MAPE and R^2 , yielding values of 16.51% and 0.81, respectively. The results reveal that seasonal fluctuations in natural gas demand play a decisive role in business planning, highlighting the need for companies to incorporate seasonality into human resources, inventory, and marketing decisions. This study provides actionable and data-driven insights for strategic decision-making in the natural gas installation sector.

1. GİRİŞ

Doğal gaz tüketimi, toplumun yaşam koşullarını ve ekonomik düzeylerini yansıtmak adına çok önemli bir belirtidir ve belirsiz faktörlerden etkilenmektedir.

Enerji tarih boyunca toplumların gelişimi ve sosyal yapısı açısından önemli bir faktör olmuştur. Günümüzde dünyanın enerji ihtiyacının %86'sı fosil enerji kaynaklarından kaynaklanmaktadır [1]. Petrol dünyadaki en yaygın enerji kaynağıdır ve onu kömür ve doğal gaz izlemektedir.

Ülkemize üç ayrı noktadan boru hatları aracılığıyla doğal gaz gelmektedir. Bunlardan Trakya ve Karadeniz üzerinden gelen hatlarla Rusya'dan, Doğu Anadolu hattı ile de İran'dan alınan gaz Türkiye'ye ulaşmaktadır. Ayrıca Tekirdağ Marmara Ereğli'de bulunan sıvılaştırılmış doğal gaz (LNG) santrali ile de aynı boru hattı sistemine Nijerya ve Cezayir'den sıvılaştırılmış olarak alınan doğal gaz verilmektedir.

Doğal gaz tüketiminin önceden tahmin edilmesi çeşitli nedenlerle önemlidir. Tahminlemenin doğruluğu yatırımları ve operasyonel işleri de doğrudan etkileyecektir. Bu nedenlerden dolayı, doğal gazın başarılı olarak yapılacak talep tahmini, doğal gaz yönetim süreçlerinin tüm yönleriyle ilgili önemli bir faktördür.

Bu çalışmada Mersin ilindeki doğal gaz firmalarının gelecekteki iş hacimleri zaman serisi yöntemleri kullanılarak tahminlenmiştir. Otoresgresif Entegre Hareketli Ortalama (ARIMA) modeli mevsimsel bileşenlerin ve kısa vadeli dinamiklerin modellenmesi için kullanılmıştır.

Bu çalışmanın literatüre katkısı şu şekilde özetlenebilir. Öncelikle Türkiye'de doğal gaz tesisat alanında tüketici sayısının ARIMA yöntemiyle tahminlenmesi üzerine bilenen ilk çalışmalardan birini oluşturmaktadır. Mevcut literatür büyük ölçüde doğal gaz tüketim miktarına odaklanırken, bu çalışma tesisat firmalarının iş hacmini doğrudan etkileyen yeni abone sayısını ele almakta ve bu alandaki eksikliği gidermektedir. Mevsimsel ARIMA yapısının bölgesel düzeyde aylık talep dinamiklerine uygulanması, operasyonel planlama açısından somut ve uygulanabilir sonuçlar ortaya koymaktadır. Elde edilen tahmin sonuçları, tesisat firmalarının stratejik insan kaynağı planlaması, envanter yönetimi ve pazarlama kararlarına yönelik ve doğrudan uygulanabilir öneriler sunmaktadır.

Doğal gaz tüketiminin ve talebinin tahminlenmesi, enerji planlaması, arz güvenliği ve işletme yönetimi açısından kritik bir araştırma alanı oluşturmaktadır; bu alanda istatistiksel zaman serisi yöntemlerinden makine öğrenmesine uzanan geniş bir yöntemsal yelpazede çalışmalar yürütülmektedir. Tahmin modelleri genel olarak tek ve birleşik modeller olarak sınıflandırılmakta; tek modeller ise istatistiksel modeller, makine öğrenmesi modelleri, gri modeller ve bulanık mantık başlıkları altında incelenmektedir [2].

İstatistiksel zaman serisi yöntemleri arasında ARIMA ve türevleri, yorumlanabilirliği, veri etkinliği ve yerleşik teorik altyapısı sayesinde doğal gaz talebinin modellenmesinde tarihsel olarak en yaygın kullanılan yaklaşımlar arasında yer almaktadır. Ediger ve Akar [3], Türkiye'nin birincil enerji talebini yakıt türlerine göre ARIMA modeliyle 2005-2020 dönemine ait öngörüler üretmiş; modelin trend içeren zaman serilerinde tatmin edici sonuçlar verdiğini ortaya koymuştur. Benzer bir yaklaşımla Akkurt ve arkadaşları [4], Türkiye'nin doğal gaz tüketimini aylık ve yıllık bazda Box-Jenkins yöntemleriyle modelleyerek SARIMA(0,0,2)(1,1,0) yapısının ARIMA'ya kıyasla daha iyi tahmin performansı sergilediğini göstermiştir. Tümse [5], ARIMA ve derin öğrenme yöntemlerini karşılaştırmalı olarak değerlendirdiği çalışmasında istatistiksel zaman serisi modellerinin özellikle kısa vadeli tahminlerde yorumlanabilirlik ve güvenilirlik açısından rekabetçi konumunu koruduğunu ortaya koymuştur.

Türkiye'nin hem enerji ithalatçısı bir ülke hem de bölgesel dağıtım piyasasına sahip olması, bölge ve şehir ölçeğindeki çalışmaları da ön plana çıkarmaktadır. Bu bağlamda Akpınar ve arkadaşları [6], Türkiye'nin Sakarya ilindeki konut ve düşük tüketimli ticari abonelere ait aylık doğal gaz verilerini zaman serisi ayrıştırma, Holt-Winters ve ARIMA yöntemleriyle modelleyerek ARIMA için rekabetçi bir performans sergilediğini raporlamıştır. Yine alanda bir başka çalışma yapan Akpınar ve arkadaşları [7] ise ARIMA modelini Türkiye'deki konut tüketicilerine uygulamış; zaman serisinden mevsimsel döngü bileşeninin çıkarılarak benzer ayların ayrı modeller halinde tahmin edilmesi yaklaşımının standart tek-model ARIMA'ya kıyasla MAPE değerini yaklaşık %2,2 oranında iyileştirdiğini göstermiştir. Tekin ve arkadaşları [8], Mersin iline ait enerji tüketim verilerini ARIMA yöntemiyle modelleyerek bölge ölçeğindeki istatistiksel tahmin yaklaşımlarının uygulanabilirliğini ortaya koymuştur. Türkiye

bağlamındaki en kapsamlı aylık ölçek çalışmalarından biri olan ve Bursa ile Kayseri illerini kapsayan araştırmada Alakent ve arkadaşları [9], 2014-2024 dönemi SOCAR verilerini kullanarak SARIMA ve üstel düzleştirme modelleri yanı sıra tam zamanında öğrenme tabanlı bir Gaussian süreç modelini karşılaştırmış; tüm Türkiye ölçeğinde de SARIMA yönteminin kabul edilebilir hata düzeylerinde kaldığını doğrulamıştır. Öte yandan Taşpınar ve arkadaşları [10], günlük bazda kısa vadeli doğal gaz tüketim tahminini çok katmanlı algılayıcı yapısındaki yapay sinir ağlarıyla ele almış; 4 yıllık enerji tüketimi ve meteoroloji verilerini kullanarak klasik istatistiksel yöntemlere alternatif bir modelleme çerçevesi sunmuştur.

Mevsimselliğin ve dışsal değişkenlerin modele dahil edilmesi, literatürde SARIMA-X ve SARIMAX modelleri üzerinden tartışılmaktadır. Manigandan ve arkadaşları [11], ABD'nin aylık doğal gaz üretim ve tüketim verilerini çapraz korelasyon fonksiyonu aracılığıyla modellemiş; sektörel değişkenleri bünyesinde barındıran SARIMAX modelinin en iyi performansı sergilediğini saptamıştır. Dışsal değişken yaklaşımını farklı bir metodoloji üzerinden ele alan Hussain ve arkadaşları [12], 2016-2030 dönemini kapsayan tahmin çalışmasında ARIMA ve Holt-Winters modellerini karşılaştırmış; sosyoekonomik göstergelerin gaz talebi üzerindeki belirleyiciliğini vurgulayarak ARIMA'nın uzun vadeli öngörülerde daha güvenilir sonuçlar ürettiğini ortaya koymuştur. Benzer biçimde Sen ve Günay [13], gelecekteki doğal gaz tüketimini tanımlayıcı değişken olarak sosyoekonomik göstergeler kullanan çeşitli çoklu regresyon modelleriyle modellemiş ve tahmin performansının kullanılan gösterge setine karşı duyarlılığını analiz etmiştir.

Doğal gaz tüketiminin yalnızca miktar değil; fiyat, piyasa yapısı ve arz güvenliğinin de dikkate alınarak modellenmesi giderek daha fazla ilgi görmektedir. Shaikh ve Ji [14], Çin'in doğal gaz tüketimini Gir Verhulst ve doğrusal olmayan gri Bernoulli modelleri aracılığıyla tahmin etmiş; gri model yaklaşımlarının sınırlı veri koşullarında dahi güvenilir sonuçlar ürettiğini göstermiştir. Benzer bir odakla Gascon ve Sanchez-Ubeda [15], eklenebilirlik varsayımlarına ve parçalı doğrusal regresyona dayalı modeller için otomatik belirleme prosedürü geliştirerek Monte Carlo simülasyonlarıyla model seçim sürecinin zayıf bağımlı veriler altında istikrarlı davrandığını doğrulamıştır.

İşletme ölçeğindeki çalışmalarda ise, Kovacic ve Dolenc [16] bir çelik fabrikasındaki gaz tüketim maliyetlerini minimize etmek amacıyla doğrusal regresyon ve genetik programlama yaklaşımlarını kombine etmiş; sipariş edilen ile tedarik edilen gaz miktarı arasındaki hatayı azaltmayı hedeflemiştir. Konut ve ticari tüketicilere odaklanan Fabbiani ve arkadaşları [17] ise sırt regresyonu, Gaussian süreci, k-en yakın komşu, yapay sinir ağı ve torus modellerini karşılaştırarak sıcaklık tahminlerinin mevsimsel rolüne dikkat çekmiştir. Benzer temada Gupta ve arkadaşları [18], Singapur'daki konut sektöründe şebeke akış verilerine dayalı matematiksel bir model oluşturmuş ve gaz ile elektrik yük profilleri arasındaki örüntüleri karşılaştırmalı biçimde incelemiştir. Oliver ve arkadaşları [19] ise gaz iletim operatörleri için zirvede talep yaşanan günün önceden tahminlenmesine yönelik bir metodoloji geliştirmiş; güneş radyasyonunun gaz tüketimi üzerindeki istatistiksel açıdan anlamlı etkisini ortaya koymuştur.

Ghana'nın günlük doğal gaz tüketimini ele alan yakın dönem çalışmasında Broni-Bediako ve arkadaşları [20], ARIMA ve SARIMA modellerini karşılaştırmış; SARIMA'nın 6,96 MAPE değeriyle ARIMA'ya (%7,29) kıyasla hafif bir üstünlük sergilediğini ortaya koymuş ve her iki modelin de kabul edilebilir doğruluk düzeyi sağladığını bildirmiştir.

Tüm bu bulgular ışığında, doğal gaz tüketiminin tahminlenmesinde ARIMA ve mevsimsel uzantısı SARIMA'nın özellikle veri yoğunluğunun sınırlı olduğu, yorumlanabilirliğin ve pratikliğin ön planda tutulduğu bölgesel ölçekli uygulamalarda güçlü ve güvenilir bir yöntem olmayı sürdürdüğü görülmektedir. Bununla birlikte, abone sayısı gibi talep yoğunluğunu dolaylı yoldan yansıtan değişkenlerin SARIMA çerçevesinde modellenmesine ilişkin çalışmalar literatürde oldukça sınırlı kalmaktadır; mevcut çalışma bu eksikliği gidermeye yönelik özgün bir katkı sunmaktadır.

2. YÖNTEM

ARIMA (Autoregressive Integrated Moving Average) modeli, zaman serisi analizinde sıklıkla kullanılan, hem kısa hem de uzun vadeli tahminlerde etkili olan güçlü bir yöntemdir [21]. Aylık yeni doğal gaz müşteri sayısının tahminlenmesi gibi mevsimsel özellikler taşıyan verilerde bu modelin kullanılması, istatistiksel açıdan tutarlı sonuçlar elde etmeye olanak tanır. ARIMA modeli özellikle trend ve mevsimsellik gibi bileşenleri zaman serisi verilerinden ayırıştırarak gelecekteki değerleri tahmin etmek için etkili bir yapı sunar. Model, verinin içinde var olan stokastik süreçleri de modelleyebilmesi sayesinde doğal gaz müşteri

sayılarında gözlemlenen dalgalanmaların ve ani değişimlerin yakalanabilmesine olanak tanır. Özellikle ekonomik ve politik faktörlerden etkilenen bu tür zaman serilerinde ARIMA modelinin esnek yapısı, dalgalanmaların öngörülmesi ve risklerin azaltılması açısından faydalıdır.

ARIMA modeli üç ana bileşenden oluşur: Otoregresif (AR), Entegre (I) ve Hareketli Ortalama (MA). Bu bileşenler zaman serisinin önceki gözlemleri ve artık terimlerle ilgili dinamiklerini açıklamaya olanak tanır. AR terimi, serinin geçmiş değerlerine dayalı olarak şimdiki değeri tahmin eder. AR(p) parametresi, serinin ne kadar önceki değerlerinin tahmine dahil edileceğini belirler. Doğal gaz müşteri sayısı verisinde AR terimi, geçmiş aylardaki müşteri sayılarına dayanarak gelecek dönem tahminlerinin yapılabilmesine olanak sağlar. Matematiksel olarak, Y_t değeri şu şekilde ifade edilir:

$$c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t \quad (1)$$

MA terimi, önceki tahmin hatalarının şimdiki değer üzerindeki etkisini dikkate alır. MA(q) parametresi, serinin ne kadar önceki hata terimlerinin şu anki tahmine dahil edileceğini belirler. Bu, tahmin edilen müşteri sayısının önceki dönemlerdeki öngörülemeyen şokların ya da düzensiz dalgalanmaların etkisinde olup olmadığını belirlemek için önemlidir. MA bileşeni şu şekilde ifade edilir. Burada $\theta_1, \theta_2, \dots, \theta_q$ MA katsayılarıdır ve ϵ_t beyaz gürültü terimidir.

$$c + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t \quad (2)$$

I (Entegrasyon) bileşeni, durağan olmayan bir serinin durağan hale getirilmesini ifade eder. d parametresi, serinin kaç kez farkının alındığını gösterir. Mevsimsel serilerde ek olarak mevsimsel fark alma işlemi de uygulanabilir; bu işlem D parametresiyle gösterilir ve seri, s dönem önceki değeriyle karşılaştırılarak mevsimsel etkiden arındırılır.

Bir ARIMA modeli, temel yapı (p,d,q)'nın yanı sıra mevsimsel yapı (P,D,Q)_[s] parametreleriyle ifade edilir. Burada P mevsimsel AR teriminin gecikme sayısını, D mevsimsel fark sayısını, Q mevsimsel MA teriminin gecikme sayısını, s ise mevsimsel periyodu (aylık veri için s=12) ifade etmektedir [22].

2.1. ARIMA Modeli Uygulama Adımları

ARIMA modelinin uygulanması dört temel adımdan oluşmaktadır.

Adım 1 Durağanlık Analizi: ARIMA modelinin uygulanabilmesinin temel ön koşulu zaman serisinin durağan olmasıdır. Durağanlık; serinin ortalama, varyans ve otokovaryans yapısının zaman içinde sabit kalması anlamına gelir [21]. Durağan olmayan seriler, fark alma işlemiyle durağan hale getirilir; kaç kez fark alındığı d parametresini belirler. Mevsimsel serilerde mevsimsel fark alma işlemi uygulanarak D parametresi elde edilir. Durağanlık Augmented Dickey-Fuller (ADF) testi ile sınanır [22]. ADF testinin sıfır hipotezi "seride birim kök vardır, seri durağan değildir" şeklindedir. p-değerinin 0,05'ten küçük çıkması sıfır hipotezinin reddedilmesi ve serinin durağan olduğunun kabul edilmesi anlamına gelir.

Adım 2 ACF ve PACF Analizi: Seri durağan hale getirildikten sonra uygun AR (p), MA (q) ve mevsimsel (P, Q) parametrelerinin belirlenmesi amacıyla Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF) grafikleri incelenir [22]. ACF, zaman serisinin kendisiyle farklı gecikme değerlerindeki doğrusal korelasyonunu ölçer; hesaplanan katsayılar güven bandıyla birlikte grafikleştirilir. ACF grafiğinde belirli bir gecikmeden sonra korelasyonun güven bandı içine ani şekilde girmesi (kesme) MA bileşeninin varlığına, geometrik ya da dalgalı biçimde yavaş azalması ise AR bileşeninin varlığına işaret eder. PACF ise ara gecikmelerin doğrusal etkisi arındırıldıktan sonra kalan kısmi korelasyonu ölçer; PACF grafiğinde belirgin bir kesme noktası AR bileşeninin derecesini (p) belirlemeye yarar. Mevsimsel yapının bulunduğu serilerde s, 2s ve 3s. gecikmelerde (aylık veriler için 12., 24. ve 36.) belirgin korelasyon değerleri gözlemlenir; bu değerler mevsimsel P ve Q parametrelerinin belirlenmesinde kullanılır.

Adım 3 Model Tanımlama ve Parametre Tahmini: Seri durağan hale getirildikten sonra uygun AR (p), MA (q) ve mevsimsel (P, Q) parametrelerinin belirlenmesi amacıyla Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF) grafikleri incelenir [22]. ACF, zaman serisinin kendisiyle farklı gecikme değerlerindeki doğrusal korelasyonunu ölçer; hesaplanan katsayılar güven bandıyla birlikte grafikleştirilir. ACF grafiğinde belirli bir gecikmeden sonra korelasyonun güven bandı içine ani şekilde

girmesi (kesme) MA bileşeninin varlığına, geometrik ya da dalgali biçimde yavaş azalması ise AR bileşeninin varlığına işaret eder. PACF ise ara gecikmelerin doğrusal etkisi arındırıldıktan sonra kalan kısmi korelasyonu ölçer; PACF grafiğinde belirgin bir kesme noktası AR bileşeninin derecesini (p) belirlemeye yarar. Mevsimsel yapının bulunduğu serilerde s, 2s ve 3s. gecikmelerde (aylık veriler için 12., 24. ve 36.) belirgin korelasyon değerleri gözlemlenir; bu değerler mevsimsel P ve Q parametrelerinin belirlenmesinde kullanılır. ACF ve PACF grafiklerinden elde edilen gecikme yapısı esas alınarak aday modeller oluşturulur. Parametreler RStudio (sürüm 4.1.2) ortamında maksimum olabilirlik (maximum likelihood) yöntemiyle tahmin edilir. Serinin kısa vadeli yapısı temel ARIMA bileşeni (p,d,q) ile; yıllık döngüsel yapısı ise mevsimsel bileşen (P,D,Q)[s] ile modellenir.

Adım 4 Model Doğrulama: Seçilen model tahmin edildikten sonra artık (residual) değerleri incelenir. Artıkların bağımsız ve rastsal dağılıp dağılmadığı Ljung-Box testi ile sınanır [25]; p-değerinin 0,05'ten büyük çıkması artıkların beyaz gürültü niteliği taşıdığını ve modelde açıklanmamış otokorelasyon kalmadığını gösterir. Son aşamada model performansı MAPE ve R² metrikleriyle değerlendirilir. Mean Absolute Percentage Error (MAPE), gerçek (y_i) ve tahmin edilen değerler (ŷ_i) arasındaki yüzde hatayı temsil eder [26]. MAPE ölçek bağımsız bir hata metriği olması nedeniyle farklı veri setleri ve büyüklüklerdeki seriler arasında karşılaştırma yapılmasına olanak tanır. İş dünyasında referans alınan MAPE yorumlama aralıkları şu şekildedir [27]: %10'dan küçük değerler çok iyi; %10–%20 arası iyi; %20–%50 arası kabul edilebilir; %50'nin üzerindeki değerler ise yanıltıcı tahmin kalitesine işaret eder.

$$\frac{100}{n} \sum_{i=1}^n \left| \frac{A_i - \hat{f}_i}{y_i} \right| \quad (3)$$

R² (R-kare), gerçek ve tahmin edilen değerler arasındaki ilişkinin benzerliği ve gücünü değerlendirmek amacıyla kullanılır [28]. R², 0-1 arası değer alır ve 1'e ne kadar yakınsa model uyumu o kadar yüksektir. y_i gerçek, ŷ_i tahmin edilen ve ȳ hesaplanan gerçek ortalama değer olmak üzere şu şekilde hesaplanır.

$$1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (4)$$

3. ARAŞTIRMA BULGULARI

Bu çalışmada 2011-2021 yılları arasında Mersin ilinde kaydedilen aylık yeni doğal gaz abone sayısı ele alınmıştır. Veri içeriğinde abonelerin kimlik bilgileri ve adresleri kişisel veri gizliliği nedeniyle filtrelenmiştir. Tüm işlemler 64 bit Windows 10 işletim sistemine sahip dizüstü bilgisayarda RStudio (sürüm 4.1.2) kullanılarak gerçekleştirilmiştir.


Veri setine ilişkin betimleyici istatistikler Çizelge 1'de sunulmuştur. 120 aylık gözlem süresince kaydedilen yeni doğal gaz abone sayısının ortalaması 423, standart sapması ise 234 olarak hesaplanmıştır. Ortalama ile medyan arasındaki belirgin fark, verinin simetrik dağılmadığına işaret etmektedir. Çarpıklık ve basıklık değerleri bir veri setinin değişkenliğini izlemek için kullanılan önemli kavramlardandır. -1.5 ile +1.5 değerleri arasında olması istenir. Çarpıklık ve basıklık değerlerine göre, kaydedilen aylık Çarpıklık ve basıklık değerlerinin -1.5 ile +1.5 sınırlarını aşması bu yorumu desteklemekte; serinin asimetrik bir yapı sergilediğini ve modellemede ek güçlükler doğurabileceğini göstermektedir.

Çizelge 1. Betimleyici istatistikler


Gözlem Sayısı	Ortalama	Medyan	Std Sapma	Çarpıklık	Basıklık
120	423	345	234	1.46	1.82

Şekil 1'de 2012 ile 2021 yılları arasındaki aylık yeni doğal gaz müşteri sayılarının zaman serisi gösterilmiştir ve doğal gaz sektöründe yeni müşteri kazanımında belirgin mevsimsel bir döngünün olduğunu ortaya koymaktadır. Her yılın özellikle son çeyreğinde veya ilk çeyreğinde zirve yapan müşteri sayıları, yılın diğer dönemlerinde daha düşük seyretmektedir. Bu durum, doğal gaz taleplerinin mevsimsel olarak yoğunlaştığını ve özellikle kış mevsiminde talebin arttığını göstermektedir. Şekil 1'de gözlemlenen zirve ve dip noktaları, verinin mevsimsel bir bileşene sahip olduğunu açıkça göstermektedir. Yılın aynı dönemlerinde düzenli artışlar ve azalmalar olması, doğal gaz kullanımı ve tesisat taleplerinin mevsimsel faktörlerden etkilendiğini kanıtlamaktadır. Kış aylarına denk gelen zirveler, soğuk hava koşullarının ve enerji gereksinimlerinin doğal gaz talebini doğrudan etkilediğini göstermektedir. Verinin genel seviyesine

bakıldığında, uzun dönemli bir trendin olmadığını veya çok belirgin olmadığını söylemek mümkündür. 2012 yılından itibaren müşteri sayılarında belirgin bir artış ya da azalış yönünde güçlü bir eğilim gözlemlenmemektedir. Ancak, 2016 yılından itibaren gözlemlenen dalgalanmalarda bir düşüş trendi dikkat çekmektedir. Bu dalgalanmalar, sektördeki kısa vadeli değişimlerin ve ekonomik ya da dışsal faktörlerin etkisini yansıtabilir. Özellikle 2015 yılından sonra görülen dalgalanmalarda keskin düşüşler, piyasadaki durgunluk veya ekonomik kriz gibi makroekonomik faktörlerden kaynaklanıyor olabilir. Bu tür düşüşler, doğal gaz sektörü için belirsiz dönemlerde müşteri sayılarında önemli bir azalma olabileceğini işaret etmektedir.




Şekil 1. Aylık yeni doğal gaz müşteri sayısının zaman serisi görselleştirilmesi



Şekil 2. Aylık doğal gaz yeni müşteri sayısının yılın ayları üzerindeki değişimi

Şekil 2, mevsimsellik etkilerini inceleyen bir zaman serisi analizini göstermektedir ve her bir ay için müşteri sayısındaki değişim, yıl içindeki doğal gaz taleplerindeki aylık değişkenlikleri ortaya koymaktadır. Şekil 2’de yılın ilk iki ayında, özellikle Ocak ayında yüksek bir müşteri sayısı gözlemlenmektedir. Ocak ayındaki zirve, soğuk kış aylarında doğal gaz talebinin artmasına bağlı olabilir. Şubat ayından itibaren müşteri sayısında ciddi bir düşüş yaşanmakta ve bu eğilim, özellikle Mart ve Nisan aylarında dip yaparak en düşük seviyelere ulaşmaktadır. Bu durum, havaların ısınmasıyla birlikte doğal gaz aboneliği ihtiyacının azaldığını gösterebilir. Bu azalma, doğal gaz tesisat firmalarının iş hacminin büyük oranda mevsimsel faktörlere bağlı olduğunu ve bu dönemlerde iş hacminde düşüş yaşanabileceğini işaret etmektedir. Özellikle yaz aylarında (Haziran, Temmuz ve Ağustos) müşteri sayısında bir stabilizasyon gözlemlenirken, sonbaharın gelmesiyle birlikte müşteri sayısında tekrar bir artış trendi başlamaktadır. Bu artış, kış mevsiminin yaklaşmasıyla birlikte artan doğal gaz talepleri ve yeni abonelik ihtiyaçlarından kaynaklanmaktadır. Kasım ve Aralık aylarında, özellikle Aralık ayında müşteri sayısı 800’ün üzerine çıkarak yıl içindeki ikinci zirvesine ulaşmaktadır. Bu, doğal gaz kullanımının artmasına ve yeni müşterilerin sisteme dahil olmasına yönelik güçlü bir talebin göstergesi olabilir. Bu tür bir mevsimsel analiz, ARIMA zaman serisi modelinin mevsimsel bileşenleriyle desteklenebilir. Yıl içindeki bu tür dalgalanmalar, doğru

modelleme yöntemleriyle tahmin edilebilir ve böylece firma yöneticileri, gelecekteki müşteri taleplerini daha etkin bir şekilde yönetebilir. Sezonluk etkilerin doğru bir şekilde modellenmesi, hem kısa vadeli hem de uzun vadeli iş hacmi planlaması açısından önemlidir.



Şekil 3. Trend ve bileşenler grafiği

Şekil 3'te üstte yer alan eğilim çizgisi, yıllar içindeki genel trendi temsil etmektedir. 2012 yılından 2020 yılına kadar müşteri sayısında belirgin bir azalma trendi gözlemlenmektedir. Bu düşüş eğilimi, doğal gaz sektöründe yeni müşteri kazanımında bir yavaşlama veya doyum noktasına ulaşma durumu olabileceğini işaret edebilir. Şekil 3'te altta yer alan grafikte ise, zaman serisinin mevsimsel bileşeni gözlemlenmektedir ve müşteri sayısındaki mevsimsel etkilerin her yıl düzenli olarak tekrar ettiğini ve belli aylar arasında belirgin zirveler ve dipler yaşandığını göstermektedir. Ocak ayı gibi kış dönemlerinde doğal gaz talebinin arttığını göstermektedir. Yılın bu dönemlerinde müşteri sayısında ani artışlar gözlemlenmektedir. Bu durum, kış aylarında ısınma ihtiyacının artması ve buna bağlı olarak doğal gaz aboneliğine olan talebin yükselmesi ile açıklanabilir. Yıllık bileşende görülen düşük seviyeler ise yaz aylarına denk gelmektedir. Özellikle Temmuz ve Ağustos aylarında müşteri sayısında belirgin bir azalma söz konusudur. Bu, sıcak hava koşulları nedeniyle doğal gaz kullanımına olan talebin azalmasıyla ilişkilendirilebilir.

3.1. ARIMA Modeli Uygulanması

3.1.1. Durağanlık Analizi

ARIMA modelinin uygulanmasına yönelik ilk adımda ham zaman serisi üzerinde ADF testi gerçekleştirilmiştir. Ham seri için ADF test istatistiği -6,29, p-değeri 0,01 olarak hesaplanmıştır. Bu sonuç, $p < 0,05$ olduğundan sıfır hipotezinin reddedildiğini ve serinin genel ortalaması bakımından durağan olduğunu göstermektedir. Bununla birlikte, standart ADF testi mevsimsel birim kökleri tespit etmemektedir [22]. Şekil 1-3'te açıkça gözlemlenen güçlü yıllık döngüsellik, mevsimsel bileşenin modellenmesi için birinci dereceden mevsimsel fark alma işleminin ($D=1$, $s=12$) gerekli olduğuna işaret etmektedir. Mevsimsel fark alınan seri üzerinde yeniden gerçekleştirilen ADF testinde istatistik -3,83, p-değeri 0,02 olarak hesaplanmış; serinin mevsimsel fark alma işleminin ardından durağan olduğu doğrulanmıştır.


3.1.2. ACF ve PACF Analizi

Durağanlaştırılmış seri üzerinde ACF ve PACF grafikleri incelenmiş; elde edilen sonuçlar sırasıyla Şekil 4 ve Şekil 5'te sunulmuştur.

Şekil 4'te verilen ACF grafiğinde 1. ve 2. gecikmelerde güven bandının dışında anlamlı korelasyon değerleri gözlemlenmiş; 3. gecikmeden itibaren değerler güven bandının içine girmiştir. 12. gecikmede belirgin negatif bir spike gözlemlenmiş, bu değer 24. gecikmede de kısmen sürmüştür; söz konusu örüntü mevsimsel MA bileşeninin modele ikinci dereceye kadar ($Q=2$) dahil edilmesi gerektiğine işaret etmektedir.


Şekil 5'te gösterilen PACF grafiğinde ise 1. gecikmede istatistiksel olarak anlamlı bir değer tespit edilmiş; bu bulgu serinin bir otoregresif terim içerdiğini ($p=1$) ortaya koymuştur. Mevsimsel gecikme olan 12. gecikmede ACF'de anlamlı korelasyon gözlemlenmiş ve bu değer 24. gecikmede de kısmen sürmüştür; söz konusu örüntü mevsimsel MA bileşeninin modele ikinci dereceye kadar ($Q=2$) dahil edilmesi gerektiğine işaret etmektedir. Mevsimsel PACF incelemesinde 12. gecikmede anlamlı bir değere rastlanmamış; mevsimsel AR bileşenine gerek olmadığı ($P=0$) kararına varılmıştır.

ACF - Mevsimsel Fark Alınmış Seri



Şekil 4. Mevsimsel fark alınmış seriye ait ACF grafiği

PACF - Mevsimsel Fark Alınmış Seri



Şekil 5. Mevsimsel fark alınmış seriye ait PACF grafiği

3.1.3. Model Tanımlama ve Parametre Tahmini

ACF ve PACF analizlerinden elde edilen bulgular doğrultusunda mevsimsel $(P,D,Q)[s]$ bileşeninin modele dahil edilmesiyle birlikte yapı, mevsimsel otoregresif entegre hareketli ortalama modeli olan $SARIMA(1,0,0)(0,1,2)_{[12]}$ 'ye dönüşmüştür.

Model katsayıları maksimum olabilirlik (ML) yöntemiyle tahmin edilmiştir. AR(1) katsayısı 0,62 (standart hata = 0,078) ve mevsimsel MA(1) katsayısı -0,56 (standart hata = 0,133) istatistiksel olarak anlamlıdır. Mevsimsel MA(2) katsayısı -0,21 (standart hata = 0,137) ise sınırda anlamlılık sergilemekle birlikte, ACF grafiğinde 24. gecikmede gözlemlenen korelasyon yapısı ve model artıklarının beyaz gürültü testini geçmesi bu terimin modelde tutulmasını desteklemektedir.

Temel bileşen (1,0,0); serinin bir dönem önceki değeriyle olan kısa vadeli otoregresif ilişkisini, $d=0$ ile serinin durağan olduğunu ve $q=0$ ile kısa vadeli MA etkisinin bulunmadığını ortaya koymaktadır. Mevsimsel bileşen $(0,1,2)_{[12]}$ ise yıllık döngüsellik modellemektir: $D=1$ ile uygulanan birinci dereceden mevsimsel fark alma işlemi her ayın değerini 12 ay öncesiyle karşılaştırarak döngüsel etkiyi dengelemiştir; $Q=2$ ise önceki iki mevsimsel dönemin hata terimlerinin modele dahil edildiğini ifade etmektedir. Modele ait AIC değeri 1333,26 olarak hesaplanmıştır.

3.1.4. Model Doğrulama


Seçilen $SARIMA(1,0,0)(0,1,2)_{[12]}$ modeline ait artık değerleri Ljung-Box testi ile sınanmıştır. Test istatistiği 20,41, p-değeri 0,67 olarak hesaplanmıştır. $p > 0,05$ olduğundan sıfır hipotezi reddedilememiştir; artıklarda istatistiksel olarak anlamlı bir otokorelasyon yapısının bulunduğu dair yeterli kanıt elde edilememiştir. Bu sonuç, artıkların beyaz gürültü davranışıyla uyumlu olduğunu ve modelin veri yapısını yeterince açıkladığını göstermektedir.

Model performansı MAPE ve R^2 metrikleriyle değerlendirilmiştir. MAPE %16,51, R^2 ise 0,81 olarak hesaplanmıştır. Bu değer, Lewis [25] tarafından önerilen yorumlama aralıklarına göre iyi düzeyde tahmin doğruluğuna karşılık gelmektedir. 0,81 R^2 değeri ise modelin gerçek değerlerdeki değişkenliğin %81'ini açıklayabildiğini göstermektedir. Bu sonuçlar, modelinin bu veri seti için güvenilir bir tahmin aracı niteliği taşıdığını ortaya koymaktadır.


Şekil 6'da gerçek abone sayıları ile $SARIMA(1,0,0)(0,1,2)_{[12]}$ modeli tarafından tahmin edilen değerler birlikte gösterilmektedir. İki serinin genel örtüşme derecesi, modelin mevsimsel döngüleri ve orta vadeli dalgalanmaları başarılı biçimde yakaladığına işaret etmektedir. Özellikle yaz aylarındaki dip noktaları ve sonbahar-kış geçişindeki artış eğilimleri model tarafından tutarlı biçimde tahmin edilmiştir.

Bununla birlikte, 2012-2013 ve 2015-2016 kış dönemlerinde gözlemlenen aşırı zirve değerlerinde tahmin değerlerinin gerçek değerlerin altında kaldığı görülmektedir. Bu sapma, söz konusu dönemlerdeki ani ve olağandışı talep artışlarının modelin öngörü kapasitesinin ötesinde olduğuna işaret etmekte; MAPE değerini olumsuz etkileyen başlıca gözlemler bu uç değerlere karşılık gelmektedir. 2016 sonrasında ise iki seri arasındaki uyumun belirgin biçimde arttığı gözlemlenmektedir; bu durum modelin düşen trend ve azalan volatilité koşullarında daha iyi performans sergilediğini ortaya koymaktadır.

Şekil 7'de $SARIMA(1,0,0)(0,1,2)_{[12]}$ modeli kullanılarak üretilen 24 aylık tahmin sunulmaktadır. Geçmiş gözlemler siyah çizgiyle, model tahmini mavi çizgiyle gösterilmiş; koyu gölgeli alan %80, açık gölgeli alan ise %95 tahmin güven aralığını temsil etmektedir. Kesik dikey çizgi, geçmiş gözlemler ile tahmin döneminin başlangıcını ayırmaktadır. Tahmin sonuçları, mevsimsel döngünün 2021-2022 döneminde de belirleyici olmaya devam ettiğini ortaya koymaktadır. Kış aylarında abone talebinin 600-700 bandına yükseleceği, yaz aylarında ise 200-250 bandına gerileyeceği öngörülmektedir. Güven aralıklarının tahmin ufku ilerledikçe genişlemesi, uzak dönem tahminlerindeki belirsizliğin arttığını göstermekte ve bu durum zaman serisi tahminlemede beklenen istatistiksel bir örüntüyü yansıtmaktadır.



Şekil 6. Gerçek ve tahmin edilen değerlerin karşılaştırılması



Şekil 7. Aylık doğal gaz yeni müşteri sayısının iki yıllık tahmini

4. SONUÇLAR

Bu çalışmada Mersin iline ait 10 yıl boyunca kaydedilen aylık yeni doğal gaz abone sayısı verisi kullanılarak tesisat firmalarının gelecekteki iş hacimlerinin tahminlenmesi amaçlanmıştır. Bu amaç doğrultusunda SARIMA(1,0,0)(0,1,2)_[12] modeli kurulmuş ve modelin geçerliliği MAPE ile R² performans kriterleriyle sınanmıştır. Analiz sonucunda elde edilen %16,51 MAPE değeri, Lewis [25] tarafından önerilen yorumlama çerçevesine göre iyi düzeyde tahmin doğruluğuna karşılık gelmektedir. 0,81 R² değeri ise modelin veri setindeki değişkenliğin %81'ini açıklayabildiğini ortaya koymaktadır. Ljung-Box testi sonucunda artıklarda istatistiksel olarak anlamlı bir otokorelasyon yapısının varlığına dair yeterli kanıt elde edilememiş; bu bulgu modelin zaman serisi varsayımlarını karşıladığını doğrulanmıştır. Bu sonuçlar, modelinin Mersin ili doğal gaz tesisat sektörüne ait aylık abone sayısı tahmininde güvenilir bir araç niteliği taşıdığını göstermektedir.

Literatür incelendiğinde, mevcut çalışmaların büyük çoğunluğunun doğal gaz tüketim miktarını bağımlı değişken olarak ele aldığı görülmektedir. Buna karşın yeni abone sayısı gibi iş hacmini doğrudan yansıtan bir değişkenin SARIMA çerçevesinde modellenmesi literatürde oldukça sınırlı kalmaktadır. Bu çalışma söz konusu boşluğu doldurarak tesisat sektörüne özgü bir tahmin yaklaşımı geliştirmektedir. Öte yandan elde edilen bulgular, mevsimsel yapılarının yalnızca enerji tüketim miktarı değil, sektörel iş hacmi göstergeleri üzerinde de başarıyla uygulanabileceğini ortaya koyması bakımından metodolojik bir katkı da sunmaktadır.

Verinin genel yapısına bakıldığında, yeni abone sayısının güçlü bir mevsimsel örüntü sergilediği görülmektedir. Ocak ayı yıl içindeki birinci zirveyi oluştururken, Kasım-Aralık dönemi ikinci zirve olarak öne çıkmaktadır. Mart-Nisan ayları ise yıllık dip noktasına karşılık gelmektedir. Bu döngünün tutarlı biçimde tekrar etmesi, tesisat talebinin büyük ölçüde hava koşulları ve ısınma ihtiyacına bağlı olduğunu ortaya koymaktadır. Öte yandan trend analizi, 2016 sonrasında yeni abone sayısında kademeli bir düşüş eğilimi bulunduğuna işaret etmektedir. Bu durum, doğal gaz yeni abone oranının belirli bir doyum noktasına yaklaşmakta olduğuna ya da alternatif enerji kaynaklarına yönelimin etkisine işaret edebilir.

Çalışma bulguları, doğal gaz tesisat firmalarına operasyonel ve stratejik düzeyde çeşitli kararlar için somut bir veri zemini sunmaktadır. Tahmin modeli, Ekim-Ocak döneminin yıllık en yüksek talep dönemi olduğunu net biçimde ortaya koymaktadır. Bu bilgi doğrultusunda firmalar söz konusu dönemden önce mevsimlik personel alımı süreçlerini başlatmalı; sözleşmeli ya da yarı zamanlı çalışanlardan oluşan esnek bir kapasite havuzu oluşturmalıdır. Böylece müşteri taleplerine yanıt süreleri kısaltılarak hizmet kalitesi korunabilir. Öte yandan Mart-Ağustos döneminde talep düşüşü yaşandığı bilindiğinden bu dönem, mevcut personelin teknik eğitim programlarına, sertifika yenileme süreçlerine ve bakım faaliyetlerine yönlendirilmesi için stratejik bir fırsat olarak değerlendirilebilir. Boru, vana, sayaç ve bağlantı elemanları gibi tesisat malzemelerinin temin sürelerinin uzun olabildiği göz önünde bulundurulduğunda, firmaların tahmin verilerine dayalı olarak Eylül-Ekim döneminde stok seviyelerini yükseltmesi kritik önem taşımaktadır. Yaz aylarına ait düşük talep öngörülleri ise satın alma miktarlarının kısıtlanması ve stok devir hızının optimize edilmesi için temel alınabilir. Bu yaklaşım hem depolama maliyetlerini düşürecek hem de

nakit akışı üzerindeki baskıyı azaltacaktır. Talep düşüşünün yaşandığı Mart-Ağustos döneminde firmalar, abone tabanını genişletmek amacıyla indirimli paket teklifleri, taksitli ödeme seçenekleri ve bakım-onarım hizmet sözleşmeleri gibi araçları devreye alabilir. Bu dönemlerde mevcut abonelere yönelik çapraz satış fırsatları (baca temizliği, cihaz servisi, periyodik kontrol) değerlendirilerek düşük sezon kayıplarının bir bölümü telafi edilebilir. Yüksek talep dönemlerinde ise yeni müşteri kazanımına yönelik yoğun pazarlama faaliyetleri yerine mevcut iş yükünün etkin yönetimine odaklanılması daha verimli bir yaklaşım olacaktır. Üretilen tahmin aralıkları, firmaların nakit akışı projeksiyonlarını ve bütçe planlamalarını daha gerçekçi bir zemine oturtmasına olanak tanımaktadır. Kış aylarında yoğunlaşan iş hacmine karşılık yaz aylarında yaşanan gelir düşüşü, firmalar için mevsimsel bir finansal dalgalanma riski yaratmaktadır. Bu riski yönetmek amacıyla kış döneminin yüksek gelirlerinden finansal rezerv ayrılması ve düşük talep dönemlerinde sabit giderlerin kontrol altında tutulması önerilebilir. Tahmin belirsizliğinin yüksek olduğu dönemlerde ise acil rezerv veya kredi limiti gibi mekanizmaların önceden hazır edilmesi, firmaları olası talep sapmalarına karşı koruyacaktır. Trend analizinin ortaya koyduğu uzun vadeli abone düşüşü, firmaların yalnızca yeni abone kazanımına dayanan iş modellerini sorgulamasını gerektirmektedir. Bu çerçevede firmalar; periyodik bakım, enerji verimliliği danışmanlığı ve doğal gaz tesisat güvenlik denetimleri gibi katma değerli hizmet alanlarına yatırım yaparak gelir kaynaklarını çeşitlendirebilir. Bunun yanı sıra mevcut abone tabanındaki sadakati artırıcı programlar geliştirmeleri ve yakıt dönüşümü, karma enerji sistemleri gibi komşu alanlarda etkinlik kazanarak sektördeki rekabet avantajlarını sürdürmeleri önerilmektedir. Özellikle doğal gazın yenilenebilir enerji sistemleriyle entegrasyonuna yönelik artan talep, tesisat firmalarına yeni iş kolları açma potansiyeli sunmaktadır.

5. KAYNAKLAR

1. BP, (2020). *Statistical review of world energy 2020*, (69th Edition), London.
2. Tian, N., Shao, B., Bian, G., Zeng, H., Li, X. & Zhao, W. (2023). Application of forecasting strategies and techniques to natural gas consumption: A comprehensive review and comparative study. *Engineering Applications of Artificial Intelligence*, 129(C), 1-31.
3. Ediger, V.Ş. & Akar, S. (2007). ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35(3), 1701-1708.
4. Akkurt, M., Demirel, Ö.F. & Zaim, S. (2010). Forecasting Turkey's natural gas consumption using time series methods. *European Journal of Economic and Political Studies*, 3, 1-21.
5. Tümse, S. (2025). Current status and future forecast of global CO2 concentration using statistical and deep learning time series methods. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 40(4), 875-888.
6. Akpınar, M. & Yumusak, N. (2016). Year ahead demand forecast of city natural gas using seasonal time series methods. *Energies*, 9, 727.
7. Akpınar, M. & Yumusak, N. (2013). Forecasting household natural gas consumption with ARIMA model: A case study of removing cycle. *7th International Conference on Application of Information and Communication Technologies*, Baku, 1-6.
8. Tekin, İ., Erat, S. ve Zeren, Y. (2016). Mersin İli'nin 2023 yılına kadar elektrik enerjisi ihtiyacının hesaplanması. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 31(1), 187-196.
9. Alakent, B., Işıklı, E., Kadaifci, C. & Taşpınar, T.S. (2025). Forecasting monthly residential natural gas demand in two cities of Turkey using just-in-time-learning modeling. *PLoS One* 20(6), e0325538.
10. Taşpınar, F., Celebi, N. & Tutkun, N. (2013). Forecasting of daily natural gas consumption on regional basis in Turkey using various computational methods. *Energy and Buildings*, 56, 23-31.
11. Manigandan, P., Alam, M.S., Alharthi, M., Khan, U., Alagirisamy, K., Pachiyappan, D. & Rehman, A. (2021). Forecasting natural gas production and consumption in United States-Evidence from SARIMA and SARIMAX models. *Energies*, 14(19), 6021.
12. Hussain, A., Memon, J.A., Murshed, M., Alam, M.S., Mehmood, U., Alam, M.N., Rahman M. & Hayat U. (2022). A time series forecasting analysis of overall and sector-based natural gas demand: A developing South Asian economy case. *Environmental Science and Pollution Research International*, 29(47), 71676-71687.
13. Sen, D. & Günay, M.E. (2019). Forecasting annual natural gas consumption using socio-economic indicators for making future policies. *Energy*, 173, 1106-1118.
14. Shaikh, F. & Ji, Q. (2016). Forecasting natural gas demand in China: Logistic modelling analysis. *International Journal of Electrical Power & Energy Systems*, 77, 25-32.
15. Gascon, A. & Sanchez-Ubeda, E.F. (2018). Automatic specification of piecewise linear additive models: application to forecasting natural gas demand. *Statistics and Computing*, 28, 201-217.

16. Kovacic, M. & Dolenc, F. (2016). Prediction of the natural gas consumption in chemical processing facilities with generic programming. *Genetic Programming and Evolvable Machines*, 17, 231-249.
17. Fabbiani, E., Marziali, A. & Nicolò, G.D. (2021). Forecasting residential gas demand: machine learning approaches and seasonal role of temperature forecasts. *International Journal of Oil, Gas and Coal Technology*, 26(2), 202-204.
18. Gupta, P., Zan, T.T.T., Dauwels, J. & Ukil, A. (2018). Flow-based estimation and comparative study of gas demand profile for residential units in Singapore. *IEEE Transactions on Sustainable Energy*, 10(3), 1120-1128.
19. Oliver, R., Duffy, A., Enright, B. & O'Connor, R. (2017). Forecasting peak-day consumption for year-ahead management of natural gas networks. *Utilities Policy*, 44, 1-11.
20. Broni-Bediako, E., Buabeng, A. & Allotey, P. (2024). Predicting Ghana's daily natural gas consumption using time series models. *Petroleum Science and Engineering*, 8(1), 27-37.
21. Box, G.E.P. & Jenkins, G.M. (1970). *Time series analysis: Forecasting and control*. Holden-Day, San Francisco, 553.
22. Box, G.E.P., Jenkins, G.M., Reinsel, G.C. & Ljung, G.M. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons, New Jersey, 712.
23. Chatfield, C. (2004). *The analysis of time series: An introduction*. Chapman & Hall/CRC, London, 352.
24. Said, S.E. & Dickey, D.A. (1984). Testing for unit roots in autoregressive-moving average models of unknown order. *Biometrika*, 71(3), 599-607.
25. Ljung, G.M. & Box, G.E.P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303.
26. Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., Newton, J., Parzen, E. & Winkler, R. (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of Forecasting*, 1, 111-153.
27. Lewis, C.D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and forecasting*. Butterworth-Heinemann, Oxford, 143.
28. Montgomery, D.C., Peck, E.A. & Vining, G.G. (2012). *Introduction to linear regression analysis*. Wiley, New Jersey, 672.