

# INTERNATIONAL JOURNAL OF ECONOMIC STUDIES



ULUSLARARASI  
EKONOMİK ARAŞTIRMALAR DERGİSİ

December 2023, Vol:9, Issue:3  
e-ISSN: 2149-8377  
journal homepage: <https://dergipark.org.tr/tr/pub/ead>

Aralık 2023, Cilt:9, Sayı:3  
p-ISSN: 2528-9942

INTERNATIONAL  
JOURNAL OF  
ECONOMIC STUDIES



## TR42 Bölgesi İçin Elektrik Enerjisi Talebinin Makine Öğrenimi Tabanlı Tahmini<sup>1</sup>

### Machine Learning Based Estimation of Electric Energy Demand For TR42 Region

**Burcu Nazlıcan DOĞRU**

Yüksek Lisans Öğrencisi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı İktisat Politikası, [nazlicandogru441@gmail.com](mailto:nazlicandogru441@gmail.com)

**Figen BÜYÜKAKIN**

Doç.Dr., Kocaeli Üniversitesi, Siyasal Bilgiler Fakültesi, İktisat Bölümü, [bfigen@kocaeli.edu.tr](mailto:bfigen@kocaeli.edu.tr)

MAKALE BİLGİSİ

ÖZET

Makale Geçmişi:  
Geliş 6 Aralık 2023  
Kabul 24 Aralık 2023

Anahtar Kelimeler:  
Elektrik Enerjisi, TR42 Bölgesi,  
Makine Öğrenmesi, Çoklu  
Doğrusal Regresyon, Talep.

© 2023 PESA Tüm hakları  
saklıdır

Elektrik enerjisinin depolanamama özelliği, piyasalarda arz-talep dengesinin sağlanamamasına neden olmaktadır. Söz konusu durum, elektrik enerjisinin talebine ilişkin tahmin çalışmalarını önemli bir hale getirmiştir. Piyasa dengesinin sağlanabilmesi için, gerçekleştirilen çalışmaların gerçeğe en yakın tahminleri sunması elzemdir. Küresel düzeyde elektrik enerjisinin üretimde kullanılan bir girdi halini alması, dünya nüfusunun hızla artması ve teknolojik gelişmelerin yaşanması gibi faktörler, elektrik talebinin hem dünyada hem de Türkiye’de artmasını tetiklemektedir. Ele alınan çalışma, Türkiye’nin Düzey 2 bölgelerinden biri olan TR42 bölgesi özelinde elektrik enerjisi talebinin gerçeğe yakın bir şekilde tahmin edilebilmesini amaçlamaktadır. Söz konusu bölgenin elektrik tüketim talebinin tahmini için makine öğrenmesi yöntemlerinden çoklu doğrusal regresyon analizinden yararlanılmıştır. Oluşturulan modelde elektrik fiyatı, dolar kuru, Tüketici Fiyat Endeksi (TÜFE), konut satışları, hava durumu, işgünü sayısı, kişi sayısı gibi değişkenler, dikkate alınmış ve her bir değişkenin aylık verileri kullanılmıştır. Değişkenler bölgede yer alan iller (Bolu, Düzce, Kocaeli, Sakarya ve Yalova) için ayrı ayrı değerlendirmeye tabi tutulmuş ve Yalova dışındaki diğer illerin tahmin değerlerinin iyi sonuçlar verdiği bulgusuna ulaşılmıştır.

ARTICLE INFO

ABSTRACT

Article History:  
Received 6 December 2022  
Accepted 24 December 2023

Keywords:  
Electrical Energy, TR42 Region,  
Machine Learning, Multiple  
Linear Regression, Demand.

© 2023 PESA All rights reserved

The non-storable nature of electrical energy causes the supply-demand balance in the markets not to be achieved. This situation has made forecasting studies regarding the demand for electrical energy important. In order to ensure market balance, it is essential that the studies carried out provide the closest estimates to reality. Factors such as electrical energy becoming an input used in production at the global level, the rapid increase in the world population and technological developments trigger the increase in electricity demand both in the world and in Turkey. The study aims to estimate the electrical energy demand realistically in the TR42 region, one of Turkey’s Level 2 regions. Multiple linear regression analysis, one of the machine learning methods, was used to estimate the electricity consumption demand of the region in question. In the created model, variables such as electricity price, dollar exchange rate, Consumer Price Index (CPI), housing sales, weather, number of working days, number of people were taken into account and monthly data of each variable was used. The variables were evaluated separately for the provinces in the region (Bolu, Düzce, Kocaeli, Sakarya and Yalova) and it was found that the prediction values of the provinces except Yalova gave good results.

## GİRİŞ

Dünya nüfusundaki hızlı artış, elektrik enerjisine ihtiyacın daha fazla artmasına neden olmuş ve söz konusu enerji, ikamesi bulunmayan bir enerji kaynağı haline gelmiştir. Günümüzde

<sup>1</sup> Bu çalışma, Kocaeli Üniversitesi, Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı İktisat Politikası Bilim Dalında hazırlanan yüksek lisans tezinden türetilmiştir.

üretilen elektrik enerjisi ağırlıklı olarak fosil yakıt kullanılarak üretilmektedir. Çünkü fosil yakıt, elektrik üretim santrallerinde düşük maliyetli üretimi mümkün kılmaktadır. Diğer fosil yakıtlar da elektrik üretimi için kullanılıyor olmasına rağmen söz konusu yakıtların dünya genelinde eşit bir dağılım sergilememesi var olan rezervlerin erimesine ve elektrik enerjisi piyasalarında fiyat dalgalanmalarının yaşanmasına neden olmaktadır.

Gelişmiş ekonomilerde ham maddeye erişim kolaylığı sayesinde yenilenebilir enerji temelli elektrik üretiminin yaygınlaştığı gözlemlense de gelişmekte olan ekonomilerde nüfus artış hızı ve gelir seviyesindeki artış dengesinin kurulamaması, ham maddeye erişimin zor olması enerji girdisi ile ilgili bir paradoksa neden olmaktadır. Söz konusu ülkeler, enerji üretiminde genellikle dışa bağımlı yapıdadırlar. Bu nedenle gelişmekte olan ekonomilerde elektrik enerjisi talebinin tahmin edilebilmesi amacıyla çalışmaların yürütülmesi ve politika araçlarının etkin kullanımı gerekmektedir. Sonuç itibarıyla ülkelerin gelişmişlik ve sosyo-ekonomik kalkınma düzeyindeki artış enerji kaynakları ile ilintili bulunmaktadır.

Elektrik enerjisinin ekonomik ve sosyal hayatta etkisi ve önemi yadsınamazdır. Her dönemde giderek artan elektrik talebi, ekonomik ve sosyal etkilerinin devamlılığının sağlanabilmesi adına, arz yönüyle karşılık bulmaya devam etmelidir. Talebin karşılanamadığı durumlarda bilinen en bariz sonuç, elektrik kesintilerinin sıklıkla yaşanmasıdır. Oluşan ya da oluşabilecek elektrik kesintileri sosyal yaşamı etkilediği gibi üretim süreçlerini de durma noktasına getiren bir sonuca sürükleyebilmektedir.

Enerji kaynaklarının üretimde girdi olarak kullanılması gelişmiş ve gelişmekte olan ekonomiler için verimlilik ve etkinlik üzerine politikalar geliştirilmesine neden olmaktadır. Maksimum elektrik enerjisi üretimine ve dağıtımına karşı minimum tüketimin gerçekleştirilmesi söz konusu politikaların temelini oluşturmaktadır. Diğer bir ifade ile ülkelerin elektrik enerjisine yönelik politikaları pareto optimumunu sağlamaya yöneliktir. Söz konusu politikalara karşın elektrik enerjisi depolanabilir bir enerji türü değildir. Gelişen teknolojik imkanlar dahilinde depolama çalışmaları söz konusu olsa da bu çalışmalar yüksek maliyet gerekmektedir. Depolanamama özelliği nedeniyle elektrik enerjisi yanında planlama gereksinimini de getirmektedir. Anında üretilen-anında tüketilen özelliği ile piyasalarda arz-talep dengesinin sağlanması ancak üretim miktarı planlamaları ile sağlanabilmektedir.

Uluslararası Enerji Ajansının (The International Energy Agency: IEA) 2020 yılı verilerine göre, dünyada en çok elektrik üretim ve tüketimine sahip olan ülke, dünyadaki toplam üretim ve tüketimin %28'i ile Çin olmaktadır (www.iea.org, 26.04.2022). Elektrik dağıtım kayıplarında ise Amerika Birleşik Devletleri (ABD) 212 milyar kWh ile ilk sırada yer almaktadır. Elektrik dağıtım kayıpları arz-talep dengesinin sağlanamamasından kaynaklanmakta ve piyasalardaki dengesizliği beraberinde getirmektedir. Aynı veriler ışığında, Türkiye ise 2020 yılında 291 milyar kWh elektrik üretmiş, buna rağmen 259 milyar kWh'te tüketmiştir (www.iea.org, 26.04.2022).

2020 yılında Türkiye'de tüketilen toplam elektrik miktarı 233.436.615 MWh'dır. Bunun %7,19'u TR42 bölgesi tarafından tüketilmektedir (www.epdk.gov.tr, 16.05.2022). Bölge, sanayi kuruluşları, üretim tesisleri ve mevcut jeopolitik konumu kapsamında sahip olduğu lojistik imkanları ile Türkiye için sanayinin omurgasını oluşturmaktadır.

Ele alınan çalışmanın amacı, 2016-2022 dönemi için TR42 bölgesinde gerçekleşen elektrik tüketiminin belirlenen değişkenler ile açıklanması ve bölgenin elektrik enerjisi talebinin tahmin edilmesidir. Gerek sanayi alanında önemli bir girdi olması gerekse literatürde TR42 bölgesinin elektrik enerjisi talep tahminine yönelik bir çalışmaya rastlanmaması mevcut çalışmanın sınırlarının belirlenmesinde önemli bir rol oynamıştır. Çalışmada öncelikle literatür taramasına yer verilmiş, ardından modelin tahminine yönelik yöntem ve veri seti oluşturulmuştur. Yapılan analizden elde edilen bulguların değerlendirilmesiyle çalışma sonlandırılmıştır.

## 1. Literatür Taraması

İlgili literatüre bakıldığında, elektrik enerjisi tüketimi ile ekonomik büyüme arasındaki

ilişkinin değerlendirildiği çalışmaların çoğunlukta olduğu ve genellikle klasik ekonometrik modellerin kullanımının tercih edildiği anlaşılmaktadır. Terzi 1998; Aktaş ve Yılmaz 2008; Acaravcı 2010; Yapraklı ve Yurttaş 2012; Shahbaz ve Lean 2012; Bayar ve Özel 2014; Saatçi ve Dumrul 2013; Lu 2017; Bayram ve Bozdağ 2018; Şengönül ve Koşaroğlu 2018; Akyol 2020; Barut ve Çelik 2021 söz konusu çalışmalara örnek gösterilebilirler. Bu açıdan değerlendirildiğinde, ele alınan çalışma elektrik enerjisi talebine yönelik tahmin yapmayı amaçladığından diğerlerinden farklılaşmaktadır. Ayrıca, elektrik enerjisi piyasasının etkin işleyişinin sağlanabilmesi için yapılan tahmin çalışmalarında ağırlıklı olarak geleneksel ekonometrik modellerinin kullanımı söz konusudur. Son yıllarda analiz için daha çok Yapay Sinir Ağları modelinin tercih edildiği gözlemlenmektedir. Bu çalışmada da klasik ekonometrik yöntemler yerine Yapay Sinir Ağları yöntemi tercih edildiğinden, bu da çalışmayı diğerlerinden ayıracı bir özellik olarak öne çıkarmaktadır.

Buradan hareketle aşağıda yer alan literatürün, iki açıdan ele alınarak düzenlenmesi daha uygun bulunmuştur. Buna göre öncelikle geleneksel modellerin (Tablo 1), sonrasında da makine öğrenimi modellerinin kullanıldığı çalışmalar (Tablo 2) derlenmiş ve tablolarda da gösterilmiştir.

**Tablo 1: Geleneksel Ekonometrik Modellerle Yapılan Çalışmalar**

Yazar	Çalışmanın Konusu	Yöntem	Sonuç
Houthakker (1951)	İngiltere'nin 42 ilinde 1937-1938 dönemi için fiyat ve gelir farklılıklarının elektrikli ev aletlerinin tüketim üzerindeki etkisi incelenmiştir.	EKK Yöntemi	Elektrik talebinin hem fiyat hem de gelir değişimlerine oldukça duyarlı olduğu gözlemlenmiştir.
Fisher ve Kaysen (1962)	Hanehalklarının elektrik talebi ile elektrikli ev aletleri stokları arasındaki ilişki kısa dönemli olarak analiz edilmiştir.	Çoklu Regresyon ve Kovaryans Analizi	Kısa vadede elektrikli ev aletleri stokları ile elektrik talebi arasında bir ilişkinin bulunduğu gözlemlenmiştir.
Wilson (1971)	Yıllık veriler kullanılarak elektrik talebini etkileyen faktörler ile bireylerin elektrik talebi tahmin edilmeye çalışılmıştır.	Eşbütünleşme ve Hata Düzeltme Modelleri	Hanehalklarının kullandığı elektrikli ev aletleri için modelde doğrusal ve logaritmik doğrusal formda tahmin gerçekleştirilmiş, tahmine göre fiyat esnekliği katsayısının değerinin (-)1,33 olduğu sonucuna ulaşılmıştır.
Al-Sahlawi (1990)	Suudi Arabistan için GSYİH, elektrik fiyatı ve ortalama gecikmeli talep arasındaki ilişki ele alınmıştır.	Eşbütünleşme Analizi	Uzun vadede elektrik fiyatının elektrik tüketimini belirlemede rol oynadığı ortaya çıkmıştır.
Şahin (1994)	Konut elektrik talebi fiyat elastikiyetini hesaplanmıştır.	En Küçük Kareler Yöntemi	Konut ve elektrik talebi fiyat elastikiyeti sıfır olarak saptanmış uzun dönem gelir esnekliğinin inelastik olduğu bulgusuna ulaşılmıştır.
Bakırtaş ve Diğerleri (2000)	Elektrik tüketimi ve milli gelir arasındaki ilişki analiz edilmiştir.	Johansen Eşbütünleşme Analizi	Uzun vadede gelir ve elektrik tüketimi arasında pozitif ilişkinin var olduğu tespit edilmiştir.
Erdoğan (2007)	1984-2004 dönemi için elektrik talebi tahmininde bulunulmuştur.	Otoregresif Hareketli Ortalamalar ve Eşbütünleşme Modelleri	Tüketicilerin fiyat-gelir farklılıklarına gösterdikleri tepkinin literatürdeki diğer çalışmalara kıyasla az sayıda olduğu ve söz konusu tahminlerin tutarlı politika uygulamalarını engellediği bulgularına ulaşılmıştır.
Güloğlu ve Akın (2014)	2008 yılı için Türkiye'deki hanehalklarının elektrik tüketimini etkileyen faktörler ele alınarak değerlendirilmiştir.	Sıralı Logit Modeli	Elektrikli ev aletlerinin kullanımı ile elektrik enerjisi tüketiminin hanehalkı yapıları arasında farklılık gösterdiği gözlemlenmiştir.

**Tablo 2: Makine Öğrenmesi Modelleri İle Gerçekleştirilen Çalışmalar**

Yazar	Çalışmanın Konusu	Yöntem	Sonuç
Ringwood ve diğerleri (2001)	İrlanda'nın elektrik talebi; GSYİH, nüfus, sıcaklık ve ortalama elektrik fiyatı ile tahmin edilmeye çalışılmıştır.	Yapay Sinir Ağları	Çalışma sonucunda Yapay Sinir Ağlarının doğrusal modellere nazaran daha gerçekçi sonuçlar sunduğu gözlemlenmiştir.
Canyurt Ve diğerleri (2004)	Türkiye'nin gelecekteki (2025 yılı) elektrik enerjisi talebi; GSYİH, nüfus, enerji talebi, ithalat ve ihracat değişkenlerinden yararlanılarak tahmini yapılmaya çalışılmıştır.	Genetik Algoritma Yöntemi	2025 yılında Türkiye'nin elektrik enerjisi talebinin 250 Mtep olacağı öngörülmüştür.
Sözen ve Arcaklıoğlu (2007)	Türkiye'nin enerji talebi; kurulu enerji güç enerji üretimi, enerji ihracatı ve ithalatı değişkenleri ile tahmin edilmiştir.	Yapay Sinir Ağları	Ekonomik değişkenlerin enerji talebindeki değişimleri daha doğru açıkladığı öngörülmüştür.
Ekonomou (2010)	Yunanistan'ın uzun dönemli elektrik enerjisi talebi hanehalkı ortalama elektrik tüketimi, elektrik üretimi, kurulu güç kapasitesi ve ortalama sıcaklık değeri değişkenleri ile tahmin edilmiştir.	Yapay Sinir Ağları	Modelin doğrusal regresyona oranla daha doğru tahminler gerçekleştirdiği gözlemlenmiştir.
Es ve Diğerleri (2014)	2011-2025 yılları arasında Türkiye'nin enerji talebi tahmin edilmiştir.	Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon	Yapay Sinir Ağlarının daha doğru sonuçlar verdiği öngörülmüştür.
Koç ve diğerleri (2018)	Elektrik enerjisi talep tahmini iki farklı makine öğrenmesi modeli ile gerçekleştirilmiştir.	Yerçekimi Arama Algoritması ve Yabani Ot Algoritması	Yerçekimi Arama Algoritması, Yabani Ot Algoritmasına göre daha iyi tahmin sonuçları sunmuştur.
Özkış (2020)	Türkiye'nin enerji talebi GSYİH, ithalat, ihracat ve nüfus girdileriyle tahmin edilmiştir.	Girdap Arama Algoritması	Girdap Arama Algoritmasının doğruluk payının yüksek olduğu gözlemlenmiştir.

İlgili literatür değerlendirildiğinde, makine öğrenmesi modellerinin geleneksel modellere göre daha gerçekçi tahminler sunduğu anlaşılmaktadır. Buradan çalışmalarda makine öğrenimi yönteminin kullanılmasının, geleceğe yönelik tahminlerin doğruluk payının artmasını sağlaması sayesinde hem piyasa dengesinin hem de politika yapıcıların etkinliklerinin artması mümkün olabilmektedir.

## 2. Çalışmanın Yöntemi Ve Veri Seti

Ele alınan çalışmada, Türkiye'nin en kalabalık ve üretimin en yoğun olarak yapıldığı, ayrıca en çok enerji ihtiyacının bulunduğu TR42 bölgesinin, elektrik enerjisi talep tahmininin doğru olarak yapılması amaçlanmaktadır. Böylelikle bölgeye yönelik uygun öngörü ve politikaların uygulanmasına zemin hazırlamak hedeflenmektedir.

Çünkü elde bulunan verilerden hareketle, gelecekte gerçekleşmesi olası değerlerin tahminlerinin yapılmasını amaçlayan çalışmalar, genellikle en doğru sonucu elde etmeyi hedeflemektedirler. Ne var ki yapılan değerlendirmeler içlerinde mutlaka bir hata payı barındırmakta ve hedefle gerçekleşen arasındaki doğruluk, ancak zamanı geldiğinde test edilebilmektedir. Mevcut hata payını minimize edilebilmek için ise ilk olarak analize seçilen girdilerin yani bağımsız değişkenlerin doğru yönde tercih edilmesi gerekmektedir. Öte yandan ele alınan veri setinin uzunluğu da yine tahmin sonuçlarının doğruluğunun sağlanması için önemli bir etkidir. Aynı zamanda veri setinin geçmişe dair daha fazla veri barındırması da tahmin sonuçlarının daha tutarlı olmasını güçlendirmektedir.

Bu bağlamda çalışmada yapılacak olan analiz için çoklu doğrusal regresyon yönteminin kullanımı tercih edilmiştir. Denetimli öğrenme yöntemlerinden biri olan çoklu doğrusal

regresyon, iki veya daha fazla (bağımsız) değişkenin bağımlı değişkendeki değişimi tahmin etmek veya açıklamak için kullanılan bir yöntemdir (Stanton, 2001: 2). Bu yöntemde bağımlı değişken, sayısal olarak sadece bir değişkenden ibaret olmak zorundadır. En küçük kareler yöntemine dayanan model, gözlenen ve tahmini yapılan değerlerin farklarının karelerinin toplamını minimize etmeyi sağlamaktadır. Ayrıca ele alınan çalışmada, durağanlık Genişletilmiş Dickey-Fuller (ADF) testi; otokorelasyon için ise Durbin-watson testi kullanılarak yapılmış ve geriye doğru eleme tekniğinden yararlanılmıştır.

Eletrik enerjisi talebinin tahminini yapabilmek için modele dahil edilen değişkenler, elektrik fiyatı, döviz kuru (\$), tüketici sayısı, TÜFE, TÜFE'nin bir önceki aya göre değişim oranı (%), konut satışı, hava durumu ve iş günü sayısı şeklinde sıralanmakta ve bu değişkenler girdi olarak ele alınmaktadır. Çıktı tarafından ise elektrik tüketim miktarı yer almaktadır. Söz konusu değişkenler Tablo 1'de gösterilmektedir.

**Tablo 3: Modelde Kullanılan Girdi ve Çıktı Değişkenleri**

GİRDİ	ÇIKTI
Elektrik Fiyatı (TL)	Elektrik Tüketim Miktarı (kWh)
Elektrik Fiyatı (\$)	
ABD Doları (Alış)	
Tüketici Sayısı	
TÜFE	
TÜFE Bir Önceki Aya Göre Değişim (%)	
Konut Satışı (Adet)	
Hava Durumu	
İş Günü Sayısı	

Tablo yer alan değişkenlerin elde edildiği kaynaklar ise farklı farklıdır. Şöyle ki, girdi olarak ele alınan elektrik fiyatı değişkeni, Enerji Piyasaları İşletmesi Anonim Şirketi Şeffaflık Platformu'ndan aylık ortalama olarak hesaplanmış ve dolar (\$) cinsinden ifade edilmiştir. Ayrıca elektrik fiyatı (TL/kWh) değişkeni, bölgesel düzeyde değil Türkiye geneli için geçerli olan fiyat düzeyinde ele alınmıştır. Bağımsız değişkenlere elektrik fiyatının (\$/kWh) eklenme nedeni ise veri setine dahil olan son 4 aylık periyotta elektrik fiyatının TL cinsinde öngörülemez artış yaşamasından kaynaklanmaktadır. Diğer bir değişken olan döviz kuru Amerikan doları (\$) olarak ele alınmış ve Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sisteminden (TCMB EVDS) temin edilmiştir. Girdi değişkenlerinden bir diğeri olan tüketici sayısı ise TR42 bölgesindeki illerin her birinde ikamet eden kişi sayısını belirtmekte ve Enerji Piyasası Düzenleme Kurumunun (EPDK) aylık sektör raporlarından derlenmiştir. Tüketici Fiyatları Endeksi (TÜFE) ve TÜFE'nin bir önceki aya göre değişim oranı (%) Türkiye İstatistik Kurumunun (TUİK) bölgesel sorgulamalarından elde edilmiştir. Konut satışı değişkenine ait veriler, her bir il için o ayda kaç konut satıldığını göstermektedir ve TCMB EVDS'den çekilmiştir. Hava durumu değişkeni, bir gün için gece ve gündüz hava sıcaklıklarının ve aylık ortalamalarının alınması ile hesaplanmıştır. Söz konusu verilerin Eylül 2021 tarihine kadarki Meteoroloji Genel Müdürlüğü'nden; Ağustos 2021–Şubat 2022 tarihleri arasındaki veriler ise Freemeteo'dan elde edilmiştir. İş günü sayısını ifade edilen değişken ise ele alınan aya ilişkin resmi ve dini tatiller çıkarıldıktan sonraki kaç iş günü çalışıldığını göstermektedir. Çıktı değişkeni olan elektrik tüketim miktarı verileri ise söz konusu ilin o ay içerisinde kaç kWh elektrik tükettiğini göstermektedir ve EPDK aylık sektör raporlarından temin edilmiştir. Söz konusu girdi ve çıktı değişkenleri, TR42 bölgesi için 2016-2022 dönemi kapsamında 74 adet aylık veriden yararlanılarak ulaşılmak istenen amaç doğrultusunda analize tabi tutulmaktadır.

Ancak çalışmanın ele alınan veri setinden kaynaklanan bazı kısıtları bulunmaktadır. Şöyle ki, ülkede elektrik piyasalarının özelleştirilmesi kapsamında hesaplama yöntemlerinin dönem dönem değişmesi, çalışmanın daha geri bir tarihten başlatılabilmesini olanaksızlaştırmıştır. Bununla birlikte bölgesel ya da il bazında aylık verilere her ay için ulaşılamamıştır. TR42 bölgesinde yer alan illerden Kocaeli, Sakarya, Bolu ve Düzce'nin perakende elektrik satış faaliyetleri Sakarya Elektrik Perakende Satış Anonim Şirketi tarafından gerçekleştirilirken Yalova'da ise bu görev Uludağ Elektrik Dağıtım Anonim Şirketi tarafından üstlenilmiştir. Ayrıca elektrik tüketim miktarı (kWh) ve tüketici sayısı gibi değişkenler ise bölgesel bazda ele alınmış ve EPDK sektör raporlarından derlenmiştir. Ancak söz konusu raporlar, 2016 yılından

itibaren aylık formatta paylaşıldığından çalışma bu tarihten başlatılmak zorunda kalınmıştır. Tüm bu faktörler, ele alınan çalışmanın kısıtları olarak değerlendirilmektedir.

### 3. Makine Öğrenmesi Algoritmasının Uygulaması

Çalışmada, internet tabanlı bir kodlama ara yüzü olan (Arslan, 2021: 25) Jupyter Notebook açık kaynak kodlu program kullanılmış ve Python programlama dilinden yararlanılmıştır. Genellikle veri analizi için dikkate alınan Jupyter Notebook, kod ile birlikte denklem, paragraf, şekil gibi niteliklere sahip olduğundan değişken çeşitliliğine izin vermektedir (Uğuz, 2021: 7). Aşağıda yer alan Tablo 4, Tablo 3'te belirtilen değişkenlerin veri setine ilişkin özniteliklerini göstermektedir. Söz konusu öznitelikler kullanılarak gerçekleştirilen regresyon analizi TR42 bölgesinde yer alan her il için ayrı ayrı gerçekleştirilmiştir.

**Tablo 4: Veri Setine Ait Öznitelikler**

Öznitelik	Açıklama
Elektrik_tuketimi	Tüketilen elektrik miktarı (kWh)
Fiyat_TL	TL cinsinden elektrik fiyatı (TL/kWh)
Fiyat_USD	ABD Doları cinsinden elektrik fiyatı (\$/kWh)
Dolar_kur	Aylık \$ alış fiyatı
Kisi_sayısı	Aylık tüketici sayısı
Tufe	Aylık TÜFE
Tufe_2	Aylık TÜFE'nin bir önceki aya göre değişim yüzdesi (%)
Konut_satis	Aylık konut satış adedi
Hava_durumu	Aylık ortalama sıcaklık değeri (°)
İs_gunu	Her bir ay için çalışılan gün sayısı

Elektrik talebinin makine öğrenimi tabanlı tahmin edilebilmesi için öncelikle hem bağımlı değişkenin hem de bağımsız değişkenlerin mevsimsellik ve trendlerden ayrıştırılarak durağan hale getirilmesi gerekmektedir. Bunun için yapılacak olan analize uygunluk göstermeyen hava durumu değişkenine ait ham veri setinde yer alan iki adet negatif değer, minimum pozitif değerlere çevrilerek veriler yeniden düzenlenmiştir. Aynı zamanda TÜFE'nin bir önceki aya göre değişimini ifade eden (%) değişkeni, TÜFE değişkeninin yüzdesinin alınması ile de oluşturulabildiği için analize dahil edilmemiştir. Bu kıstaslardan hareketle çalışmada, Pandas, Matplotlib, Numpy, Statsmodels ve Sklearn kütüphaneleri kullanılmıştır. Tablo 5 çalışma sürecinde kullanılan kütüphaneleri kodları ile birlikte yansıtmaktadır.

**Tablo 5: Çalışmada Kullanılan Kütüphanelerin Çağırılması**

```
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
from statsmodels.tsa.seasonal import seasonal_decompose
from statsmodels.tsa.stattools import adfuller
import scipy
from sklearn.linear_model import LinearRegression
import statsmodels.api as sm
from sklearn.model_selection import train_test_split
from sklearn.metrics import explained_variance_score, mean_absolute_error, mean_squared_error
```

Tablo 5'de yer alan kodlarla kütüphanelerin çağırılmasının ardından modelde çalışılmak istenen veri seti Jupyter Notebook'a dahil edilmiş (Tablo 6) ve söz konusu veri setine tarih de eklenmek suretiyle değişkenler yeniden yazdırılmıştır.

**Tablo 6: Veri Setinin Çağırılması**

```
raw_data=pd.read_csv("https://raw.githubusercontent.com/MutadisMutandis/datas2/main/Bolu.csv").dropna()
raw_data
raw_data["index"]=pd.date_range('2016-01-01', periods=74, freq='M')
raw_data=raw_data.set_index('index')
raw_data=raw_data[["Elec_Consumption", "Price_TL", "Price_USD", "Exc_Rate", "Noc", "Price_Index", "House_Sell", "Weather_Forecast", "Working_Day"]]
```

Başlangıçta Pandas kütüphanesinden veri seti çağırılmış (Tablo 6), ardından var olan değişkenlerin mevsimsellik ve trendlerden ayrıştırılması için ikinci adıma geçilmiştir. Bilindiği üzere mevsimsel etkiler, serilerde her yıl aynı zamanda tekrarlanan hareketleri yansıtmaktadırlar. Yapılan analizde hatalı sonuçlar elde etmemek için veri setinin mevsimsel etki ve trendlerden ayrıştırılması gerekmekte ve böylece serilerdeki gerçek değişimlerin seyri izlenip ekonomide anlamlı ve tutarlı yorumlar yapabilmek için kavuşturulmaktadır.

Ele alınan çalışmada serilerin mevsimsellikten arındırılması için Statsmodels kütüphanesinden yararlanılmıştır (Tablo 7). Bu işlemin ardından serilerin durağanlaştırılması gerektiğinden mevsimsellikten arındırılan veri setinin logaritması alınarak (Tablo 8) serilerde yer alan veriler arası farkların azaltılıp söz konusu seriler kısmen de olsa durağan hale getirilmeye çalışılmıştır.

#### **Tablo 7: Mevsimsellik ve Trendlerden Ayrıştırmak İçin Kullanılan Fonksiyon**

```
Def mevsim_ayristir(orijinal_veri_seti, donusturulen_veri_seti):
    columns=orijinal_veri_seti.columns
    for seri in columns:
        decompose=seasonal_decompose(orijinal_veri_seti[seri], model="multiplicative")
        donus_veri=decompose.observed/decompose.seasonal
        donusturulen_veri_seti[seri]=donus_veri
    return donusturulen_veri_seti
```

#### **Tablo 8: Veri Setinin Logaritmasının Alınması**

```
raw_data_s_l=np.log(raw_data_s)
raw_data_s_l.head()
```

Seçili değişkenler ile talep tahmini yapılmadan önce bağımlı ve bağımsız değişkenlerin de durağan olup olmadıklarının test edilmesi gerekmektedir (Tablo 9). Durağanlığın tespiti için ADF testinden yararlanılmıştır.

#### **Tablo 9: Durağanlık Testinde Kullanılan Fonksiyon**

```
Def stationary(x):
    result=adfuller(x)
    kv=result[0]
    p_value=result[1]
    lags=result[2]
    t_stats=result[4].values()
    print("-----")
    print("Kritik değer: {}\nP_Value: {}\nlags: {}\nt_stats: {}".format(kv,p_value,lags, t_stats))
    print("-----")
```

ADF testinden elde edilen p değerinin anlamlılık seviyesi eğer 0.05'den küçükse  $H_0$  hipotezi reddedilmekte ve verilerin durağan olduğu sonucuna ulaşılmaktadır. Analizde verilerin durağan olup olmadığı statsmodels.tsa.stattools'dan çağırılan adfuller niteliği ile test edilerek saptanmıştır. Buna göre, elektrik tüketimi, hem Türk Lirası hem de \$ cinsinden elektrik fiyatı değişkenleri, dolar kuru, kişi sayısı, TÜFE ve iş günü değişkenlerinin durağan olmadığı anlaşılmıştır. Bu nedenle verilerin farkları alınarak değişkenlerin durağanlaştırılması sağlanmıştır. Veri setinin farklarının alınması işlemi aşağıda yer alan Tablo 10'da gösterilmektedir.

#### **Tablo 10: Veri Setinin Farkının Alınması**

```
raw_data_s_l_diff=raw_data_s_l.diff().dropna()
raw_data_s_l_diff.head()
```

Ele alınan değişkenlerin farkları alındıktan sonra yeniden durağanlık testine tabi tutulması sonucunda tüm değişkenlerin durağanlaştığı gözlemlenmiştir. Böylece veri setinin birinci farkının durağanlaşması, başlangıç (rassal yürüyüş) serisinin, birinci dereceden bütünleşik (I1) olduğunun göstergesi olarak değerlendirilmiştir. Bundan sonra modelin kurulumuna geçilmiş ve veri setinin eğitim ve test verileri olarak ayrılması ile lineer regresyonun modele uyarlanması işlemleri Tablo 11'de gösterilmiştir.



**Tablo 11: Veri Setinin Eğitim ve Test Verileri Olarak Ayrılması**

```
X=raw_data_s_1_diff.iloc[:,1:].values
y=raw_data_s_1_diff.iloc[:,0].values
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.3, random_state = 0)
np.shape(X_train)
```

Buna göre, model için dikkate alınan veri setinin %30'unun test verisi ve %70'nin de eğitim verisi olarak ayrılması sağlanmıştır. Diğer bir deyişle, toplamda var olan 74 aylık veri setinin 52 ayı modelin eğitimi için 22 ayın verisi ise test aşamasında kullanılmıştır. Eğitim veri grubunda verilerin 2016 yılından başlaması, elektrik fiyatının görece daha istikrarlı olduğunu öğretmekte olup, test aşamasında yüksek fiyata (TL) karşı öğrenme kazandırılmamış olmasından kaynaklanmaktadır. Daha sonra söz konusu veri setinin lineer regresyona göre şekillendirilmesi için Sklearn Kütüphanesi çağrılmış, lineer regresyonun verilere uyarlanması Tablo 12'deki gibi gerçekleştirilmiştir.

**Tablo 12: Linear Regresyonun Modele Çağırılması**

```
Model_Regresyon = LinearRegression().fit(X_train, y_train)
y_pred = model_Regresyon.predict(X_test)
X = np.append(arr = np.ones((73,1)).astype(int), values = X, axis = 1)
X_yeni = X[:, [0,1,2,3,4,5,6,7,8]]
np.shape(X_yeni)
```

Tablo 12'de gösterilen uyumlanma işleminin ardından geriye doğru eleme tekniği ile bağımsız değişkenlerin seçimi yapılmış ve seçim süreci Tablo 13'te gösterilmiştir.

**Tablo 13: Modelden Elenecek Değişkenlerin Seçilmesi**

```
Model_regresyon_OLS = sm.OLS(endog = y, exog = X_yeni).fit()
print(model_regresyon_OLS.summary())
"""
X0: Tüketim miktarı
X1: Elektrik fiyatı (TL)
X2: Elektrik fiyatı (USD)
X3: Dolar kuru
X4: Kişi sayısı
X5: TÜFE
X6: Ev satışı
X7: Hava durumu
X8: İş günü
```

Yapılan seçim sonrasında Tablo 13'te gösterilen X sınıfı içinde yeni bir seri oluşturulmuş ve söz konusu seri, X\_yeni olarak adlandırılmıştır. Diğer taraftan Statsmodels kütüphanesinden OLS sınıfı kullanılmak suretiyle de model regresyon OLS oluşturulmuştur. Burada sıradan EKK olarak ifade edilen OLS, çoklu doğrusal regresyon analizinde verilerin ortasından geçen eğim değerine en az kare farkıyla yakınlaşmaya izin veren bir uygulamadır (veribilimcisi.com, 06.06.2022). ardından OLS sınıfına yeni değişkenler tanımlanarak model eğitilmiştir. Buna göre OLS'de belirtilen endog parametresi bağımlı değişkeni ve exog parametresi de intercept ve bağımsız değişkenleri modele dahil etmektedir (Uğuz, 2021: 136). Ardından OLS regresyonuna ait birinci iterasyon TR42 bölgesinde yer alan her il için ayrı ayrı yapılmıştır. Birinci iterasyon sonucunda anlamlı çıkmayan değerler, ikinci ve ihtiyaç duyulduğunda da üçüncü iterasyona başvurmak suretiyle modele anlamlılık kazandırılmaya çalışılmıştır. Söz konusu illere ilişkin iterasyon sonuçları, EK 1'de yer alan tablolarda yer almaktadır. Elde edilen iterasyon sonuçlarına göre, Kocaeli, Bolu, Düzce ve Yalova illerinin öznitelikleri ikinci iterasyondan sonra anlamlılık kazanırken, Sakarya'nın öznitelikleri ise üçüncü iterasyondan sonra anlamlı hale gelmiştir.

**Tablo 14: Performans Değerlendirme Ölçütlerinin Çağırılması**

```
print("MAE=%0.2f"%mean_absolute_error(y_test,y_pred))
print("MSE=%0.2f"%mean_squared_error(y_test,y_pred))
print("MedAE=%0.2f"%median_absolute_error(y_test,y_pred))
print("Belirleme Katsayısı(R2)=%0.2f"%r2_score(y_test,y_pred))
print("RMSE=%0.2f"%np.sqrt(mean_squared_error(y_test,y_pred)))
```



Geri eleme tekniğinin iterasyon işlemleri ile tamamlanmasından sonra dikkate alınan veri setinin performansının ölçümünün yapılması gerekmektedir. Bunun için Tablo 14’de yer alan kod dizimi kullanılmıştır. Tablo 14’deki performans değerlendirme ölçütlerinin çağırılmasıyla veri seti performansı ölçülmüş ve elde edilen performans sonuçları Tablo 15’de gösterilmektedir.

**Tablo 15: Test Veri Seti Performansı**

TR42 İlleri	MAE	MSE	RMSE	medAe
<b>Kocaeli</b>	0.11	0.05	0.22	0.06
<b>Sakarya</b>	0.09	0.04	0.20	0.04
<b>Bolu</b>	0.5	0.09	0.30	0.08
<b>Düzce</b>	0.18	0.13	0.35	0.09
<b>Yalova</b>	0.05	0.00	0.06	0.04

Söz konusu tabloda yer alan performans sonuçlarına göre, her bir il için en düşük değeri sağlayan ölçümler şu şekilde sıralanmaktadır: Kocaeli (0,05) ve Yalova’nın (0,00) en düşük ölçüm değerleri MSE’dir. Sakarya için en düşük iki ölçüm değeri vardır, bunlar MSE ve medAe ölçümleridir. Hem Bolu hem de Düzce için en düşük ölçüm değeri de olarak tespit edilmiştir.

#### 4. Analizden Elde Edilen Bulguların Değerlendirilmesi

Makine öğrenimi modellemesinden yararlanılarak yapılan analiz sonuçlarına göre, TR42 bölgesinde yer alan her bir il için ayrı ayrı yapılan değerlendirmelerden aşağıdaki bulgulara ulaşılmıştır:

Kocaeli’nde bağımsız değişkenlerin tahmin edilmesi istenen bağımlı değişkeni açıklama oranı %57 düzeyindedir. Bu oran Sakarya için %46, Bolu için %38, Düzce için %40, Yalova için ise %13 seviyelerindedir. Yalova’nın açıklama oranının düşük çıkması ildeki enerji dağıtım şirketinin diğer illerden farklı olmasına bağlanabilmektedir. Bolu ve Düzce’nin oranlarının birbirine yakın olması, her iki ilin coğrafi özellik olarak benzer olduklarını ortaya koymaktadır.

TR42 bölgesi içinde Kocaeli ile Yalova, iş günü değişkeninin anlamlı olduğu iki il olarak gözlemlenmiştir. Kocaeli’nin kalkınmasında en önemli rol oynayan sektörün sanayi olması, elektrik tüketimi ve aylık iş günü sayısı arasındaki ilişkinin anlamlılığını açıklayacak niteliktedir.

Ayrıca Kocaeli ve Bolu illeri bölgede hava durumu ile anlamlı ilişki sağlayan iki il olarak saptanmışlardır. Dolayısıyla hem Kocaeli hem de Bolu’da hava sıcaklıkları ile elektrik tüketimi arasındaki anlamlı ilişkinin, iklime bağlı olarak diğer illere kıyasla havalarda daha soğuk olmasından kaynaklanmaktadır.

TÜFE değişkeninin TR42 bölgesi içinde anlamlı olduğu tek ilin ise Sakarya olduğu belirlenmiştir. Bu da ilde elektrik tüketiminin fiyat hareketlerinden etkilenmediğini göstermektedir.


TR42 bölgesi için yapılan analizde, elektrik fiyatı (TL) ve elektrik fiyatı (\$), Yalova hariç tüm iller için anlamlı sonuçlar vermiştir. Ancak sonuçlara göre, elektrik fiyatı (TL) anlamlı ve pozitif bir etki gösterirken, elektrik fiyatı (\$) anlamlı ve negatif bir etkiye sahiptir. Bölgedeki tüm iller için konut satışı değişkeninin ise anlamlı sonuçlar verdiği gözlemlenmiştir. Diğer bir deyişle, gerçekleşen konut satışlarının, elektrik tüketim miktarını doğrudan doğruya etkilediği tespit edilmiştir. Sakarya için anlamlı sonuçlar veren TÜFE değişkeni diğer iller için anlamlı çıkmamıştır. Dolar kuru değişkeni ise Kocaeli, Sakarya, Bolu ve Düzce illerinde anlamlı sonuçlar verirken, Yalova için anlamlı bulunmamıştır. Diğer taraftan, elektrik tüketimi ile kişi sayısı değişkeni arasında ise TR42 bölgesindeki tüm iller için anlamlı ilişkiler bulunmadığı bulgusu elde edilmiştir.

Makine öğrenimi tabanlı tahmin yönteminden yararlanılarak TR42 bölgesi illeri için gerçekleştirilen bağımsız değişkenlerle bağımlı değişkenin tahminine yönelik analiz


sonuçları, aşağıda yer alan grafiklerde gösterilmektedir. Her bir ilin eğitim ve test verilerinin tahmini değeri ile gerçekleşen değerleri arasındaki değişimi yansıtan grafikler, aynı zamanda analiz sonuçlarının tutarlılığının bir yansıması olarak da kabul edilmektedirler. Grafiklerden de gözlendiği gibi, söz konusu bölgeye ait test verilerinin tahmini değerleri ile gerçek değerler paralel dalgalanmalar göstermektedirler. Tüm iller tek tek ele alındığında şu değerlendirmeler yapılabilmektedir.

Grafik 1 ve 2 Kocaeli için ele alınan veri setinin eğitim ve test değerlerinin tahmini ve gerçekleşen değerlerini yansıtmakta ve her iki değer birbirine paralel dalgalanmalar gösterdiği gözlemlenmektedir. Ayrıca Grafik 2'ye göre, tahmin değeri gerçekleşen değere kıyasla iyi bir performans sergilemektedir.


**Grafik 1: Kocaeli İli Eğitim Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırması**





**Grafik 2: Kocaeli İli Test Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırması**





**Grafik 3: Sakarya İli Eğitim Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırması**




Grafik 3 ve Grafik 4, Sakarya ilinin test verilerinin tahmini ile gerçekleşen değerlerini göstermektedir. Grafik 3'te tahmin değerlerinin gerçek değerlerin üstünde kaldığı; Grafik 4'te ise gerçek değerden sapmaların olduğu görülmektedir. Ancak modelin tahmin değerinin Sakarya için genel itibarıyla iyi bir performans sergilediği anlaşılmaktadır.

**Grafik 4: Sakarya İli Test Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırma****Grafik 5: Bolu İli Eğitim Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırma**



Bolu'nun gerçek ve tahmini değerlerinin gösterimleri de Grafik 5 ve Grafik 6'de yer almaktadır. Buna göre Grafik 5, tahmini ve gerçek değerlerin arasında bazı sapmaların olduğunu yansıtsa da genel itibarıyla iki veri setinin birbirine paralel seyrettiğini ortaya koymaktadır. Grafik 6 ise Bolu için yapılan tahmin değerlerinin modelde iyi performans sergilediğini yansıtmaktadır.

**Grafik 6: Bolu İli Test Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırması****Grafik 7: Düzce İli Eğitim Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırması**

Düzce'nin tahmini ve gerçek değerlerinin seyri de Grafik 7 ve Grafik 8'de yer almaktadır. Buna göre, Düzce'nin gerçek değeri ile tahmini değeri arasında tek bir sapmanın varlığı dışında birbirlerine paralel seyrettikleri, dolayısıyla da tahmin değerlerinin iyi bir performansa sahip oldukları görülmektedir.

**Grafik 8: Düzce İli Test Verisi İçin Gerçek Değer–Tahmini Değer Karşılaştırma**

Grafik 9 ve Grafik 10'da Yalova'nın test değerleri ile gerçek değerlerinin seyrini ortaya koymaktadır. Söz konusu grafiklerde Yalova için geçerli olan değerlerin birbirleriyle örtüşmediği, her iki değer birbirinden farklı gelişim gösterdikleri anlaşılmaktadır. Grafik 10 ise Yalova'nın test verilerinin tahmin edilen değerlerinden sapmalar olduğunu gösterse de peşine kırılmaların yakalanabildiğini de ortaya koymaktadır.

**Grafik 9: Yalova İli Eğitim Verisi İçin Gerçek Değer – Tahmini Değer Karşılaştırması****Grafik 10: Yalova İli Test Verisi İçin Gerçek Değer – Tahmini Değer Karşılaştırması**

## SONUÇ

Bir ülkenin gelişmişlik düzeyi ile tükettiği elektrik miktarı arasında pozitif yönlü bir ilişki bulunmaktadır. Şöyle ki, gelişmişlik düzeyi artan bir ülkede, geniş istihdam olanakları elde edilmekte, sanayi büyümekte, bunlarla birlikte de elektrik tüketimi yükselişe geçmektedir. Dolayısıyla, artan elektrik tüketiminin karşılanması için elektrik piyasasının bir yönünü oluşturan elektrik talebinin gerçeğe yakın bir şekilde tahmin edilmesi bir zorunluluk haline dönüşmektedir. Çünkü yapılacak olan doğru tahminlerle elde edilen sonuçların referans niteliği taşıması sayesinde piyasalarda yatırım kararlarının önü açılacaktır ve güven ortamı pekiştirilerek üretim, iletim ve dağıtım aşamalarında nasıl ve ne zaman elektrik arzı sağlanması gerektiği şeklindeki sorulara net yanıtlar verilebilecektir.

Ele alınan çalışmada, farklı değişkenlerden yararlanılarak sanayi üretiminin yoğun olarak yapıldığı TR42 bölgesi için elektrik enerjisi talebinin makine öğrenimi tabanlı tahmin yöntemlerinden çoklu doğrusal regresyon modeli kullanılarak tespit edilmesi hedeflenmiştir. Analiz yapılırken öncelikle değişkenler arası anlamlılık düzeyi değerlendirilmiş, eğitim ve test verileri ile model geliştirilmiş, ardından da elde edilen sonuçlar performans ölçüm yöntemleri

ile karşılaştırılmıştır. 2016-2022 dönemine ait toplam 74 aylık veri setinin %70'i eğitim ve %30'u da test aşamalarında kullanılmıştır.

Elde edilen sonuçlara göre, TR42 bölgesinde yer alan tüm illerde elektrik tüketim miktarı, konut satışı ile anlamlı, ancak kişi sayısı ile anlamsız ilişki sergilemektedir. Yalova dışındaki diğer illerin elektrik tüketiminin elektrik fiyatı (TL ve \$) ile aralarındaki ilişkinin anlamlı olduğu gözlemlenmiştir. Kocaeli'nin sanayi yoğun iş alanlarına sahip olması nedeniyle elektrik tüketimi ile iş günü arasında anlamlı; Bolu'nun soğuk bir iklime sahip olması nedeniyle de elektrik tüketimi ile hava durumu arasında yine anlamlı bir ilişkinin varlığı ortaya çıkmıştır.

Öte yandan Yalova dışındaki tüm illerin test verilerinin tahmini değerleri iyi bir performans sergilemektedir. Yalova'da ise söz konusu iki değer arasında sapmaların olduğu gözlemlenmiş ancak tahmin değerlerinin kırılmaları yakalayabildiği anlaşılmıştır. Performans ölçümlerine göre ise MAE, MSE, RMSE, MedAe ölçütleri illere göre farklılık göstermektedir.

İlgili literatüre bakıldığında, genellikle Türkiye için elektrik talebinin tahmin edilmesine yönelik çalışmaların ağırlığı dikkati çekmektedir. Ele alınan çalışma ise diğer çalışmalardan farklı olarak, sadece TR42 bölgesini temel almıştır. Bu bağlamda, girdilerin sağlanması ve veri setinin uzatılmasının mümkün olması halinde; saatlik/günlük frekansta tahminlerin gerçekleştirilmesi, sınıflandırma modellerinin uygulanabilir bir hal alması, sektörel olarak çeşitli değerlendirmelere tabi tutulması sağlanabilecektir. Böylece elde edilen tahminler gerçeğe daha yakın olabilecek ve yatırımcıların ilgili alanlara yatırım yapma kararlarını alırken hata yapma olasılıkları azaltılabilecektir. Çünkü elektrik talebinin olması gereken değerden yüksek tahmin edilmesi yatırım kararlarını olumsuz etkileyebilmekte ve bu durum kaynak dağılımının bozulmasına yol açmasının yanında görece gerekli alanlara yatırım yapılmasının ertelenmesine de neden olabilmektedir.

## KAYNAKÇA

- Acaravcı, Ali (2010). "Structural Breaks, Electricity Consumption and Economic Growth: Evidence from Turkey", *Romanian Journal of Economic Forecasting*, 2: 140-154.
- Aktaş, Cengiz & Yılmaz, Veysel (2008). "Causal Relationship Between Electricity Consumption and Economic Growth in Turkey", *Zonguldak Karaelmas Üniversitesi Sosyal Bilimler Dergisi*, 4(8): 45-54.
- Akyol, Mehmet (2020). "Elektrik Tüketimi Ve Ekonomik Büyüme Arasındaki İlişkinin Bölgesel Analizi: Türkiye Örneği". *Turkish Studies - Economy*, 15(3): 1123-1139.
- Al-Sahlawi, Mohammed (1990). "Forecasting the Demand for Electricity in Saudi Arabia", *Energy Journal*, 11(1): 119-125.
- Aydın, Bayram & Bozdağ, Emre Güneşer (2018). "Elektrik Tüketimi Ve Ekonomik Büyüme Arasındaki İlişki: Avrupa Birliği Ve Türkiye Örneği". *International Journal of Academic Value Studies*, 4(18): 70-80.
- Bakırtaş, Tahsin, Karbuz, Sohbet ve Bildirici, Melike (2000). "An Econometric Analysis of Electricity Demand in Turkey", *Sakarya University, Studies in Development*, 27(1-2): 22-34.
- Barut, Muhammed Emin & Çelik, Emine (2021). "Türkiye'de Sanayide Tüketilen Elektrik Enerjisi İle Ekonomik Büyüme Arasındaki İlişki: Granger Nedensellik Analizi". *Nicel Bilimler Dergisi*, 3(1): 43 – 58.
- Bayar, Yılmaz & Özel, Hasan Alp (2014). "Electricity Consumption and Economic Growth in Emerging Economies", *Journal of Knowledge Management, Economics and Information Technology*, 4(2): 1-18.
- Canyurt, Olcay Ersel, Ceylan, Halim, Öztürk, Harun Kemal ve Hepbaşı, Arif (2004). "Energy Demand Estimation Based on Two-Different Genetic Algorithm Approaches", *Energy Sources*, (26): 1313-1320.
- Coşkun, Hamzaçebi ve Kutay, Fevzi (2004). "Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3): 227-233.

- Ekonomou, Lambros (2010). "Greek Long-Term Energy Consumption Prediction Using Artificial Neural Network", *Energy*, (35): 512-517.
- Enerji Piyasası Denetleme ve Düzenleme Kurumu. (2021). <https://www.epdk.gov.tr/Detay/Icerik/3-0-24/yillik-sektor-raporu>, Erişim Tarihi: 16.05.2022.
- Erdoğan, Erkan (2007). "Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey", *Energy Policy*, (35): 1129-1146.
- Es, Hüseyin Avni, Kalender, Yeşim ve Hamzaçebi, Coşkun (2014). "Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 29(3): 495-504.
- Fisher, Franklin ve Kaysen, Carl (1962). *A Study in Econometrics: The Demand for Electricity in the United States*, Amsterdam.
- Güloğlu, Bülent ve Akın, Emre (2014). "Türkiye'de Hane Halkları Elektrik Talebinin Belirleyicileri: Sıralı Logit Yaklaşımı", *Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi*, 2(3): 1-20.
- Houthakker, Hendrick Samuel (1951). "Some Calculations of Electricity Consumption in Great Britain", *Journal of the Royal Statistical Society*, 114(3): 249-270.
- International Energy Agency (2020). *Capital Cost and Performance Characteristic Estimates for Utility Scale Electric Power Generating Technologies (SL-014940 | Project No. 13651.005)*. [https://www.eia.gov/analysis/studies/powerplants/capitalcost/pdf/capital\\_cost\\_AEO2020.pdf](https://www.eia.gov/analysis/studies/powerplants/capitalcost/pdf/capital_cost_AEO2020.pdf). Erişim Tarihi: 26.04.2022.
- Koç, İsmail, Nureddin, Refik ve Kahramanlı, Humar (2018). "Türkiye'de enerji talebini tahmin etmek için doğrusal form kullanarak GSA (Yerçekimi Arama Algoritması) ve IWO (Yabancı Ot Optimizasyon Algoritması) tekniklerinin uygulanması", *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, (6): 529-543.
- Lu, Wen-Cheng (2017). "Electricity Consumption and Economic Growth: Evidence from 17 Taiwanese Industries", *Sustainability, MDPI, Open Access Journal*, 9(1): 1-15.
- Özkış, Ahmet (2020). "Türkiye'nin Enerji Talebinin Tahmin Edilmesi Üzerine Girdap Arama Algoritması Temelli Yeni Bir Model", *Pamukkale Üniversitesi Mühendislik Bilim Dergisi*, 26(5): 959-965.
- Ringwood, John, Bofelli, D. and Murray, F.T. (2001). "Forecasting electricity demand on short, medium and long time scales using neural networks", *Journal of Intelligent and Robotic Systems*, (1)31: 129-147.
- Saatçi, Mustafa & Dumrul, Yasemin (2013). "Elektrik Tüketimi Ve Ekonomik Büyüme İlişkisinin Dinamik Bir Analizi: Türkiye Örneği", *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 32(2); 1-24.
- Shahbaz, Muhammad & Hooi Hooi Lean (2012), "The Dynamics of Electricity Consumption and Economic Growth: A Revisit Study of Their Causality in Pakistan", *Energy*, 39(1): 146-153.
- Sözen, Adnanu & Arcağlıoğlu, Erol (2007). "Türkiye'nin Temel Enerji Kaynakları için Projeksiyonlar", *Energy Sources*, (2): 183- 201.
- Stanton, Jeffrey (2001). "Galton, Pearson, and the Peas: A Brief History of Linear Regression for Statistics Instructors", *Journal of Statistics Education*, 9(3): 1- 13.
- Şengönül, Ahmet & Koşaroğlu, Şerife Merve (2018). "Elektrik Tüketimi Ve Ekonomik Büyüme Arasındaki İlişki: Brics Ülkeleri İçin Bir Uygulama". *Cumhuriyet Üniversitesi, İktisadi Ve İdari Bilimler Dergisi*, 19(2): 431-447.
- Terzi, Harun (1998). "Türkiye'de Elektrik Tüketimi Ve Ekonomik Büyüme İlişkisi: Sektörel Bir Karşılaştırma". *İktisat, İşletme ve Finans*, 13(144): 62-71.
- Türk Sanayiciler ve İş İnsanları Derneği (1994). *Enerji Sektöründe Geleceğe Bakış: Arz, Talep ve Politikalar*, İstanbul: TÜSİAD Yayınları.
- Uğuz, Sinan (2021). *Makine Öğrenmesi: Teorik Yönleri ve PYTHON Uygulamaları ile Bir Yapay Zeka Ekolü*, Ankara: Nobel Akademik Yayıncılık.
- Veri Bilimcisi. (2017). <https://veribilimcisi.com/2017/07/13/siradan-en-kucuk-kareler-yontemi/>. Erişim Tarihi: 06.06.2022.

- Wilson, Janie (1971). "Residential Demand for Electricity, Quarterly" Review of Economics and Business, 11(1): 7-22.
- Yapraklı, Sevda & Z. Çağlar Yurttançıkılmaz (2012), "Elektrik Tüketimi ile Ekonomik Büyüme Arasındaki Nedenellik: Türkiye Üzerine Ekonometrik Bir Analiz", Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Dergisi, 13(2): 195-215.

**EK 1:**

Kocaeli için yapılan birinci iterasyon sonuçları Tablo 16'da gösterildiği gibidir.

**Tablo 16: Kocaeli İli OLS Regresyonuna Ait Birinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.574			
Metot	EKK	F-istatistik	10.78			
Tarih	4 Haziran 2022	Prob (F-istatistik)	1.84e-09			
Saat	14:17:55	Log-Likelihood	81.629			
Gözlem	73	AIC	-145.3			
Hata Kalıntıları	64	BIC	-124.6			
Model Değişkeni	8					
	Coef	Std err	t	P >  t	[0.025	0.975]
X0	-0.0027	0.020	-0.137	0.891	-0.042	0.0
X1	1.9591	0.570	3.438	0.001	0.821	3.098
X2	-1.8159	0.570	-3.184	0.002	-2.955	-0.677
X3	-1.7959	0.636	-2.821	0.006	-3.066	-0.524
X4	2.4071	4.528	0.532	0.597	-6.639	11.453
X5	-0.3441	0.618	-0.557	0.579	-1.578	0.890
X6	0.0996	0.046	2.187	0.032	0.009	0.191
X7	0.2233	0.054	4.163	0.000	0.116	0.330
X8	0.3207	0.101	3.177	0.002	0.119	0.522
Omnibus	32.005	Durbin-watson	2.322			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	100.120			
Skew	1.290	Prob (JB)	1.82e-22			
Kurtosis	8.125	Cond. No	458			

Tablo 16'dan elde edilen sonuçlara göre, geriye doğru eleme tekniğinden yararlanmak suretiyle belirtilen anlamlılık düzeyinin ( $p=0.05$ , %5) üzerinde olan öznitelikler modelden çıkartılmıştır. Birinci iterasyonda modelden çıkartılan öznitelikler X0 (0.891), X4 (0.597) ve X5 (0.579) olarak sıralanmaktadır.

**Tablo 17: Kocaeli İli OLS Regresyonuna Ait İkinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.570			
Metot	En Küçük Kareler	F-istatistik	14.80			
Tarih	4 Haziran 2022	Prob (F-istatistik)	1.09e-10			
Saat	14:18:42	Log-Likelihood	81.234			
Gözlem	73	AIC	-150.5			
Hata Kalıntıları	67	BIC	-136.7			
Model Değişkeni	6					
	coef	Std err	t	P >  t	[0.025	0.975]
X1	1.9778	0.559	3.540	0.001	0.863	3.093
X2	-1.8296	0.557	-3.284	0.002	-2.942	-0.718
X3	-1.9048	0.590	-3.228	0.002	-3.083	-0.727
X4	0.0982	0.045	2.198	0.031	0.009	0.187
X5	0.2301	0.052	4.417	0.000	0.126	0.334
X6	0.3183	0.099	3.214	0.002	0.121	0.516
Omnibus	23.454	Durbin-watson	2.332			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	60.427			
Skew	0.964	Prob (JB)	7.56e-14			
Kurtosis	7.018	Cond. No	30.0			



Modelden Sabit, X4 ve X5'in çıkartılması ile aynı kod yine yazıldığında, Kocaeli için elde edilen sonuçlar Tablo 17'te gösterilmektedir. Kocaeli için X0, X4 ve X5 öznitelikleri çıkartılarak yapılan ikinci iterasyonda indis numaralandırması tekrarlanmış ve böylece modeldeki özniteliklerin anlamlılık düzeyi 0.05'den küçük bir sonuç elde edilerek modele anlamlılık kazandırılmıştır. Modelin anlamlı hale gelmesiyle geri eleme yöntemi bu noktada sonlandırılmıştır. Öte yandan Durbin-Watson test sonucuna (2.332) göre ise negatif korelasyonun varlığı ortaya çıkmıştır. Veri setinin normal dağılıma sahip olup olmadığına ilişkin yapılan değerlendirmede ise  $\alpha = 0.05$  anlamlılık düzeyinde Ki-kare kritik değeri  $\chi^2(0.05) = 5.99147$  iken  $JB = 60.427 > \chi^2 = 5.99147$  olduğundan sıfır hipotezi reddedilmektedir ve hataların normal dağılıma sahip olduğu anlaşılmıştır.

**Tablo 18: Sakarya İli OLS Regresyonuna Ait Birinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.448			
Metot	En Küçük Kareler	F-istatistik	8.301			
Tarih	4 Haziran 2022	Prob(F-istatistik)	1.21e-07			
Saat	14:23:51	Log-Likelihood	84.051			
Gözlem	73	AIC	-150.1			
Hata Kalıntıları	64	BIC	-129.5			
Model Değişkeni	8					
	coef	Std err	T	P >  t	[0.025	0.975]
X0	0.0213	0.019	1.138	0.259	-0.016	0.059
X1	1.7390	0.554	3.141	0.003	0.633	2.845
X2	-1.5999	0.555	-2.881	0.005	-2.709	-0.491
X3	-1.3694	0.619	-2.212	0.031	-2.606	-0.133
X4	-1.7369	3.411	-0.500	0.612	-8.551	5.078
X5	-1.5327	0.595	-2.578	0.012	-2.721	-0.345
X6	0.1319	0.041	3.189	0.002	0.049	0.215
X7	0.1042	0.057	1.812	0.075	-0.011	0.219
X8	0.1395	0.093	1.507	0.137	-0.045	0.324
Omnibus	19.345	Durbin-watson	2.556			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	64.144			
Skew	0.634	Prob (JB)	1.18e-14			
		Cond. No	357			
Kurtosis	7.414					

**Tablo 19: Sakarya İli OLS Regresyonuna Ait İkinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.443			
Metot	En Küçük Kareler	F-istatistik	10.81			
Tarih	4 Haziran 2022	Prob (F-istatistik)	1.13e-07			
Saat	14:25:00	Log-Likelihood	79.423			
Gözlem	73	AIC	-148.8			
Hata Kalıntıları	68	BIC	-137.4			
Model Değişkeni	5					
	coef	Std err	T	P >  t	[0.025	0.975]
X1	1.9275	0.568	3.395	0.001	0.795	3.060
X2	-1.8627	0.565	-3.298	0.002	-2.990	-0.736
X3	-1.9589	0.599	-3.268	0.002	-3.155	-0.763
X4	0.1655	0.036	4.633	0.000	0.094	0.237
X5	0.0987	0.058	1.699	0.094	-0.017	0.215
Omnibus	20.642	Durbin-watson	2.498			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	81.416			
Skew	-0.615	Prob (JB)	2.09e-18			
Kurtosis	8.025	Cond. No	30.6			

Sakarya için yapılan birinci iterasyonda Tablo 18'de de gösterildiği gibi anlamlılık düzeyinin ( $p=0.05$ , %5) üzerinde olan X0 (0.259), X4 (0.612), X5 (0.012) ve X8 (0.137) öznitelikleri modelden çıkartılmıştır. Modelden X0, X4, X5 ve X8'in çıkartılması ile kod yeniden çalıştırılmış ve ikinci iterasyon için indis

numaralandırılması tekrar yapıldığında X5 (0.094) özneliği de anlamlılık düzeyinin üzerinde çıktığından (Tablo 19); X5 özneliği de modelden çıkartılarak Sakarya için üçüncü iterasyonun yapılması gerekmiştir.

**Tablo 20: Sakarya İli OLS Regresyonuna Ait Üçüncü İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.459			
Metot	En Küçük Kareler	F-istatistik	0.419			
Tarih	4 Haziran 2022	Prob (F-istatistik)	11.53			
Saat	14:26:23	Log-Likelihood	4.43e-08			
Gözlem	73	AIC	80.477			
Hata Kalıntıları	68	BIC	-151.0			
Model Değişkeni	5					
	coef	Std err	T	P >  t	[0.025	0.975]
X1	1.0976	0.539	3.888	0.000	1.021	3.174
X2	-2.0283	0.532	-3.815	0.000	-3.089	-0.967
X3	-1.7515	0.609	-2.878	0.005	-2.966	-0.537
X4	-1.1832	0.531	-2.228	0.029	-2.243	-0.124
X5	0.1733	0.035	4.982	0.000	0.104	0.243
Omnibus	19.468	Durbin-watson	2.495			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	102.134			
Skew	0.375	Prob (JB)	6.64e-23			
Kurtosis	8.746	Cond. No	30.1			

Sakarya için yapılan üçüncü iterasyonda X5 = TÜFE değişkeni modele tekrar dahil edilmiş ve bu kez elde edilen sonuç anlamlı çıkmıştır. Modelde bu değişken X4 (0.029) değişkeni olarak yer almıştır. Sakarya'nın üçüncü iterasyonu sonucunda modelde sadece anlamlı öznelikler kaldığı için geri eleme yöntemi sonlandırılmıştır (Tablo 20). Durbin-watson test sonucunda ise (2.495) Kocaeli gibi Sakarya'da da negatif korelasyonun varlığı gözlemlenmiştir. Sakarya'nın verilerinden elde edilen Ki-kare kritik değeri  $\chi^2(0.05) = 5.99147$  iken  $JB = 102.134 > \chi^2 = 5.99147$  olduğundan sıfır hipotezi reddedilmiş ve hataların normal olarak dağılmadığı anlaşılmaktadır.

**Tablo 21: Bolu İli OLS Regresyonuna Ait Birinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.397			
Metot	En Küçük Kareler	F-istatistik	0.322			
Tarih	4 Haziran 2022	Prob (F-istatistik)	5.275			
Saat	13:31:06	Log-Likelihood	4.32e-05			
Gözlem	73	AIC	44.007			
Hata Kalıntıları	64	BIC	-70.01			
Model Değişkeni	8					
	Coef	Std err	T	P >  t	[0.025	0.975]
X0	0.0157	0.025	0.626	0.534	-0.034	0.066
X1	3.6057	0.916	3.937	0.000	1.776	5.436
X2	-3.5778	0.912	-3.922	0.000	-5.400	-1.755
X3	-3.3419	1.042	-3.208	0.002	-5.423	-1.261
X4	1.1826	5.695	0.208	0.836	-10.194	12.559
X5	-1.5481	1.033	-1.498	0.139	-3.613	0.516
X6	0.1350	0.067	2.008	0.049	0.001	0.269
X7	-0.1501	0.042	-3.536	0.001	-0.235	-0.065
X8	0.0598	0.159	0.376	0.708	-0.257	0.377
Omnibus	28.948	Durbin-watson	2.598			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	99.236			
Skew	1.096	Prob (JB)	2.83e-22			
Kurtosis	8.275	Cond. No	344			

Bolu'ya ait verilerden hareketle yapılan birinci iterasyon sonucunda modelden çıkartılan öznelikler X0 (0.534), X4 (0.836), X5 (0.139) ve X8 (0.708) olarak sıralanmaktadır (Tablo 21).

Modelden  $X_0$ ,  $X_4$ ,  $X_5$  ve  $X_8$ 'in çıkartılmasıyla aynı kod yeniden çalıştırıldığında, Bolu'nun ikinci iterasyon sonuçlarına ulaşılmıştır. Bolu'ya ait indis özellikleri yeniden yazılarak elde edilen ikinci iterasyon sonuçları Tablo 22'de gösterilmektedir. Buna göre özniteliklerin anlamlılık düzeyi, belirlenen düzeyin altında bulunduğundan modelin öznitelikleri anlamlı çıkmıştır. Böylece Bolu için geri eleme yöntemi sonlandırılmıştır. Durbin-watson test sonucunda da (2.646) diğer illerde olduğu gibi Bolu'nun da negatif korelasyona sahip olduğu anlaşılmaktadır. Aynı zamanda Ki-kare kritik değeri  $\chi^2(0.05) = 5.99147$  iken,  $JB = 62.836 > \chi^2 = 5.99147$  olduğundan sıfır hipotezi reddedilmiş ve hatalar normal olarak dağılmadığı bulgusuna ulaşılmıştır.

**Tablo 22: Bolu İli OLS Regresyonuna Ait İkinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.375			
Metot	En Küçük Kareler	F-istatistik	0.329			
Tarih	4 Haziran 2022	Prob (F-istatistik)	8.157			
Saat	13:32:25	Log-Likelihood	4.48e-06			
Gözlem	73	AIC	42.661			
Hata Kalıntıları	68	BIC	-75.32			
Model Değişkeni	5					
	Coef	Std err	T	P >  t	[0.025	0.975]
X1	3.7767	0.890	4.245	0.000	2.002	5.552
X2	-3.7963	0.878	-4.322	0.000	-5.549	-2.044
X3	-3.8954	0.943	-4.132	0.000	-5.777	-2.014
X4	0.1491	0.055	2.700	0.009	0.039	0.259
X5	-0.1591	0.041	-3.856	0.000	-0.241	-0.077
Omnibus	18.139	Durbin-watson	2.646			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	62.836			
Skew	0.545	Prob (JB)	2.27e-14			
Kurtosis	7.413	Cond. No	40.3			

Düzce ili için gerçekleştirilen birinci iterasyona göre,  $X_0$  (0.972),  $X_4$  (0.132),  $X_5$  (0.150),  $X_7$  (0.258) ve  $X_8$  (0.848) öznitelik değerleri anlamsız bulunmuş ve modelden çıkartılmıştır (Tablo 23). Çıkartılan özniteliklerin ardından kod yeniden çalıştırılmış ve ikinci iterasyon sonucunda Düzce'ye ait veri seti anlamlı hale gelmiştir (Tablo 24).

**Tablo 23: Düzce İli OLS Regresyonuna Ait Birinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.455			
Metot	En Küçük Kareler	F-istatistik	0.387			
Tarih	4 Haziran 2022	Prob (F-istatistik)	6.670			
Saat	13:31:06	Log-Likelihood	2.57e-06			
Gözlem	73	AIC	44.070			
Hata Kalıntıları	64	BIC	-70.14			
Model Değişkeni	8					
	Coef	Std err	T	P >  t	[0.025	0.975]
X0	0.0008	0.023	0.036	0.972	-0.044	0.046
X1	4.4827	0.960	4.668	0.000	2.564	6.401
X2	-4.3222	0.966	-4.475	0.000	-6.252	-2.393
X3	-4.0105	1.079	-3.715	0.000	-6.167	-1.854
X4	3.5546	2.332	1.524	0.132	-1.105	8.214
X5	-1.4978	1.028	-1.457	0.150	-3.552	0.556
X6	0.1670	0.089	1.871	0.066	-0.011	0.345
X7	0.0845	0.074	1.140	0.258	-0.064	0.233
X8	0.0323	0.168	0.193	0.848	-0.303	0.368
Omnibus	70.220	Durbin-watson	2.137			
rob (Omnibus)	0.000	Jarque-Bera (JB)	769.376			
Skew	2.624	Prob (JB)	8.55e-168			
Kurtosis	18.013	Cond. No	142			

Düzce için indis numaraları tekrar güncellenerek yapılan geri eleme yöntemi, kalan öznitelikler anlamlılık kazandığı için sonlandırılmıştır (Tablo24). Düzce'nin Durbin-Watson testi sonucunda da (2.226) negatif korelasyonun varlığı ortaya çıkmıştır. Ki-kare kritik değeri  $\chi^2(0.05) = 5.99147$  iken  $JB = 475.266 > \chi^2 = 5.99147$  olduğundan sıfır hipotezi reddedilmekte ve hataların normal dağıtılmadığı anlaşılmaktadır.

**Tablo 24: Düzce İli OLS Regresyonuna Ait İkinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.369			
Metot	En Küçük Kareler	F-istatistik	11.68			
Tarih	4 Haziran 2022	Prob (F-istatistik)	2.66e-07			
Saat	14:02:42	Log-Likelihood	40.793			
Gözlem	73	AIC	-73.59			
Hata Kalıntıları	69	BIC	-64.42			
Model Değişkeni	4					
	Coef	Std err	T	P >  t	[0.025	0.975]
X1	5.0279	0.929	5.410	0.000	3.174	6.882
X2	-4.9725	0.912	-5.454	0.000	-6.791	-3.154
X3	-5.0169	0.979	-5.125	0.000	-6.970	-3.064
X4	0.1974	0.071	2.792	0.007	0.056	0.338
Omnibus	47.556	Durbin-watson	2.226			
Prob (Omnibus)	0.000	Jarque-Bera (JB)	475.266			
Skew	1.481	Prob (JB)	6.27e-104			
Kurtosis	15.144	Cond. No	25.0			

Tablo 25'te yer alan Yalova'nın birinci iterasyon sonuçlarına göre anlamlılık düzeyi (0.05)'den büyük olan X<sub>0</sub> (0.571), X<sub>1</sub> (0.279), X<sub>2</sub> (0.298), X<sub>3</sub> (0.812), X<sub>4</sub> (0.116), X<sub>5</sub> (0.090) ve X<sub>7</sub> (0.634) öznelikleri modelden çıkartılmıştır.

**Tablo 25: Yalova İli OLS Regresyonuna Ait Birinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.069			
Metot	En Küçük Kareler	F-istatistik	1.667			
Tarih	4 Haziran 2022	Prob (F-istatistik)	0.124			
Saat	14:30:30	Log-Likelihood	97.791			
Gözlem	73	AIC	-177.6			
Hata Kalıntıları	64	BIC	-157.0			
	Coef	Std err	T	P >  t	[0.025	0.975]
X <sub>0</sub>	0.0037	0.010	0.336	0.716	-0.016	0.024
X <sub>1</sub>	0.4856	0.445	1.092	0.279	-0.403	1.374
X <sub>2</sub>	-0.4660	0.444	-1.050	0.298	-1.352	0.420
X <sub>3</sub>	-0.0513	0.505	-0.102	0.919	-1.061	0.958
X <sub>4</sub>	0.2901	0.969	0.299	0.766	-1.647	2.227
X <sub>5</sub>	-0.7708	0.489	-1.575	0.120	-1.748	0.207
X <sub>6</sub>	0.0718	0.036	2.015	0.048	0.001	0.143
X <sub>7</sub>	-0.0399	0.054	-0.736	0.464	-0.148	0.068
X <sub>8</sub>	-0.1788	0.082	-2.194	0.032	-0.342	-0.016
Omnibus	9.426	Durbin-watson	2.543			
Prob (Omnibus)	0.009	Jarque-Bera (JB)	14.055			
Skew	-0.461	Prob (JB)	0.000887			
Kurtosis	4.942	Cond. No	123			

Geri eleme yöntemi kapsamında iterasyona devam edildiğinde, indis numaraları güncellenerek ikinci iterasyon yapılmış ve tüm öznelıkların %5 düzeyinde anlamlı olduğu bulgusuna ulaşılmıştır (Tablo 26). Bu işlemin ardından geri eleme yöntemi sonlandırılmıştır. Durbin-Watson test sonucunda (2.501) negatif korelasyon ilişkisinin varlığı ortaya çıkmıştır. Ki-kare kritik değeri  $\chi^2(0.05) = 5.99147$  iken, JB = 15.144 >  $\chi^2 = 5.99147$  olduğundan sıfır hipotezi reddedilmiş ve hataların normal olarak dağıtılmadığı anlaşılmıştır.

**Tablo 26: Yalova İli OLS Regresyonuna Ait İkinci İterasyon OLS Regresyon Sonuçları**

Bölüm Değişkeni	y	R-squared				
Model	OLS	Adj. R-squared	0.051			
Metot	En Küçük Kareler	F-istatistik	2.961			
Tarih	4 Haziran 2022	Prob (F-istatistik)	0.0582			
Saat	14:31:28	Log-Likelihood	93.757			
Gözlem	73	AIC	-183.5			
Hata Kalıntıları	71	BIC	-178.9			
Model Değişkeni	2					
	Coef	Std err	T	P >  t	[0.025	0.975]
X1	0.719	0.034	2.139	0.036	0.005	0.139
X2	-0.1683	0.077	-2.175	0.033	-0.323	-0.014
Omnibus	10.903	Durbin-watson	2.501			
Prob (Omnibus)	0.004	Jarque-Bera (JB)	13.837			
Skew	-0.643	Prob (JB)	0.000989			
Kurtosis	4.702	Cond. No	3.00			