

**Arastırma Makalesi**

**Türkiye Enerji Piyasasında Piyasa Takas Fiyatı Tahmini: Makine Öğrenimi Yöntemlerinin Karşılaştırılması**

*Market Clearing Price Prediction in the Turkish Energy Market: Comparison of Machine Learning Methods*

**Abdulkadir KESKİN**

Arş. Gör. Dr., İstanbul Medeniyet Üniversitesi

Siyasal Bilgiler Fakültesi

[abdulkadir.keskin@medeniyet.edu.tr](mailto:abdulkadir.keskin@medeniyet.edu.tr)

<https://orcid.org/0000-0002-4795-1028>

Makale Geliş Tarihi	Makale Kabul Tarihi
20.02.2025	30.04.2025

**Öz**

Enerji piyasalarının karmaşık yapısı ve bu piyasalarda oluşan fiyatların öngörülebilirliği hem ekonomik istikrar hem de sürdürülebilir kalkınma hedefleri açısından büyük önem taşımaktadır. Özellikle Türkiye gibi enerji talebinin hızla arttığı ülkelerde, piyasa takas fiyatının (PTF) doğru bir şekilde tahmin edilmesi, piyasa katılımcılarının etkin kararlar almasına olanak tanımakta ve enerji piyasasının şeffaflığını artırmaktadır. Bu çalışma, Türkiye enerji piyasasında PTF'nin tahmini için altı farklı makine öğrenimi algoritmasının (Doğrusal Regresyon, Karar Ağacı, Destek Vektör Makineleri, Gaussian Süreç Regresyonu, Çekirdek Tabanlı Regresyon ve Sinir Ağları) etkinliğini karşılaştırmalı olarak analiz etmektedir. Türkiye'nin Ocak 2012-Ocak 2023 dönemine ait enerji piyasası verilerinden yararlanılarak, sıcaklık, brüt elektrik tüketimi, toplam kurulu güç, döviz kuru ve Brent petrol fiyatları gibi faktörlerin PTF üzerindeki etkileri incelenmiştir. Sonuçlar, Gaussian Süreç Regresyonu (GPR) ve Karar Ağacı (DT) modellerinin PTF tahmininde diğer yöntemlere göre daha yüksek doğruluk sağladığını göstermektedir. **GPR modeli, eğitim ve test aşamalarında tutarlı bir performans sergileyerek en düşük RMSE ve en yüksek R<sup>2</sup> değerlerine ulaşmıştır. Ayrıca, DT modeli test aşamasında istikrarlı sonuçlar sunarak ikinci en iyi performansı göstermiştir.**

**Anahtar kelimeler:** Piyasa Takas Fiyatı (PTF), Enerji Fiyat Tahmini, Makine öğrenmesi, Türkiye Enerji Piyasası, Gaussian Süreç Regresyonu (GPR)

**Abstract**

The complex structure of energy markets and the predictability of prices in these markets hold great significance for both economic stability and sustainable development goals. Particularly in countries like Turkey, where energy demand is rapidly increasing, accurately forecasting the Market Clearing Price (MCP) enables market participants to make effective decisions and enhances the transparency of energy markets. This study comparatively analyzes the effectiveness of six different machine learning algorithms (Linear Regression, Decision Tree, Support Vector Machines, Gaussian Process Regression, Kernel Ridge Regression, and Neural Networks) for forecasting MCP in Turkey's energy market. Using energy market data from January 2012 to January 2023, the impacts of factors such as temperature, gross electricity consumption, total installed capacity, exchange rates, and Brent oil prices on MCP were examined. The results indicate that the Gaussian Process Regression (GPR) and Decision Tree (DT) models provide higher accuracy in MCP prediction compared to other methods. The GPR model demonstrated consistent performance in both training and testing phases, achieving the lowest RMSE and the highest R<sup>2</sup> values. Moreover, the DT model delivered stable results during the testing phase, ranking as the second-best performing model.

**Önerilen Atıf /Suggested Citation**

Keskin, A., 2025, Türkiye Enerji Piyasasında Piyasa Takas Fiyatı Tahmini: Makine Öğrenimi Yöntemlerinin Karşılaştırılması, *Üçüncü Sektör Sosyal Ekonomi Dergisi*, 60(2), 1707-1719.

**Keywords:** Market Clearing Price (MCP), Energy Price Forecasting, Machine Learning, Turkey's Energy Market, Gaussian Process Regression (GPR)

## 1. Giriş

Türkiye’de piyasa takas fiyatının (PTF) tahmini, enerji piyasasının etkin işleyişi, enerji arz güvenliği, sürdürülebilir kalkınma hedefleri ve ekonomik istikrar açısından önemli bir yere sahiptir. Enerji fiyatlarındaki ani dalgalanmalar hem ekonomik hem de sosyal açıdan geniş kapsamlı sonuçlara yol açmaktadır. PTF, enerji piyasasında arz ve talep dengesinin bir göstergesi olmakla birlikte, çeşitli faktörlerden etkilenmektedir. Bu nedenle, enerji piyasasında karar alıcılar için güvenilir bir tahmin modeli oluşturmak, fiyatların öngörülebilirliğini artırarak piyasa katılımcılarının karar alma süreçlerini destekleyecektir. Enerji arzının sürdürülebilirliği ve fiyatların istikrarı, enerji sektörüne yönelik yatırımlardan toplumun enerjiye erişimine kadar birçok farklı unsuru etkilemektedir (Kruyt ve ark., 2009: 2167). Türkiye özelinde PTF'nin tahmini, enerji piyasasındaki katılımcılara değerli bilgiler sunmanın yanı sıra, enerji arz güvenliğini artıracak stratejilerin belirlenmesi için de bir temel oluşturmaktadır.

Piyasa Takas Fiyatı, elektrik piyasasında arz ve talep dengesinin kesiştiği noktada oluşan ve tüm piyasa katılımcıları için referans fiyat olarak kullanılan bir göstergedir. PTF, özellikle gün öncesi ve gün içi piyasaları gibi organize piyasalarda belirlenir ve saatlik olarak değişkenlik gösterebilir. Elektrik üreticilerinin arz teklifleri ile tüketicilerin talep talepleri doğrultusunda oluşan bu fiyat, arz ve talep dengesi, yenilenebilir enerji kaynaklarının üretim kapasitesi, hava koşulları, ekonomik durumlar ve piyasa oyuncularının stratejik kararlarından etkilenmektedir. Özellikle talep dalgalanmaları ve arz kesintileri PTF’de yüksek volatiliteye neden olabilir. Türkiye’de PTF ve Enerji Piyasaları İşletme A.Ş. (EPIAŞ) tarafından yönetilen piyasalarda belirlenmektedir ve elektrik ticaretinin düzenlenmesi ve piyasa şeffaflığının sağlanmasında kritik bir rol oynamaktadır (EPIAŞ, 2024; Lago ve ark., 2018: 387).

Enerji piyasasında fiyat tahmini yapmak, enerji arz ve talep dengesinin sağlanmasında önemli bir rol oynamaktadır. Enerji piyasaları doğaları gereği oldukça değişken olması enerji üretim ve tüketiminde fiyat dalgalanmalarına yol açmaktadır. İklimsel koşullar, döviz kuru, petrol fiyatları gibi değişkenler, enerji fiyatlarında dalgalanmalara neden olan başlıca etkenler arasında yer almaktadır (Keskin ve Kara, 2021: 196). PTF, Türkiye’de elektrik enerjisinin ticaretinin yapıldığı serbest piyasada, arz ve talep dengesine göre belirlenmemektedir. Bu sebepten PTF enerji sektörünün önemli bir göstergesi olarak kabul edilmektedir. PTF’yi doğru bir şekilde tahmin etmek, enerji piyasasının etkin işleyişini sağlamak ve enerji fiyatlarındaki dalgalanmalardan kaynaklanan riskleri minimize etmek için önemlidir. Bu bağlamda, enerji fiyat tahminleri hem kamu hem de özel sektör tarafından, enerji arz güvenliğini sağlamak, enerji fiyat risklerini yönetmek ve enerji politikalarını belirlemek amacıyla yoğun olarak kullanılmaktadır (Rao, ve ark., 2024: 3292; Winzer, 2012: 36).

Geleneksel fiyat tahmin modelleri, geçmiş verilere dayanarak piyasa fiyatlarını tahmin etmeyi amaçlamaktadır. Bu yöntemler arasında istatistiksel modellerin yanı sıra ekonomik modeller de bulunmaktadır. Ancak enerji piyasalarındaki karmaşık ve doğrusal olmayan ilişkiler, geleneksel yöntemlerin sınırlarını ortaya çıkarmaktadır. Bu nedenle, günümüzde makine öğrenmesi tabanlı algoritmalar enerji piyasalarında giderek daha fazla kullanılmaktadır (Mohammadi, ve ark., 2020:18; Tschora, ve ark., 2022: 2; Yang, ve ark., 2022: 2). Makine öğrenmesi algoritmaları, büyük veri setleri üzerinde karmaşık ilişki yapılarını öğrenme yeteneği sayesinde enerji fiyatlarının daha doğru bir şekilde tahmin edilmesine olanak tanımaktadır. Makine öğrenmesi tabanlı algoritmalar, geçmiş verilerdeki karmaşık ilişkileri öğrenerek gelecekteki fiyat dalgalanmalarını daha başarılı bir şekilde tahmin edebilir. Bu çalışmada, doğrusal regresyon (LR), karar ağaçları (DT), destek vektör makineleri (SVM), Gaussian Süreç Regresyonu (GPR), Çekirdek Tabanlı Regresyon (KR) ve sinir ağları (NN) gibi farklı makine öğrenmesi yöntemleri kullanılarak Türkiye’deki PTF’nin tahmin edilmesi amaçlanmaktadır. Bu yöntemlerin her biri, enerji piyasasının farklı dinamiklerini modellemek ve tahmin doğruluğunu artırmak için çeşitli avantajlar sunmaktadır.

Elektrik enerjisine talebinin sürekli karşılanması gerektiği için arz talep değerinin piyasa koşullarında baz alarak tahmin ederek dengelenmesi gereklidir. Ancak, elektrik fiyatlarının volatilitesi nedeniyle bu tahminler zorlu hale gelmekte ve gibi birçok faktörden etkilenebilmektedir (Li, ve ark., 2019: 488) . Enerji piyasasında fiyat tahmini, günümüze kadar çeşitli yöntemlerle denenmiştir. Temel olarak klasik istatistiksel yaklaşımlar ve yapay zekâ tabanlı makine öğrenmesi yapay sinir ağları gibi yaklaşımlardan oluşmaktadır (Weron, 2014: 1031).

Klasik yöntemler arasında doğrusal regresyon veya otoregresif bütünleşik hareketli ortalama (ARIMA) yöntemleri sıklıkla kullanılmıştır. Örneğin, ARIMA modeli özellikle geçmiş verilerden doğrusal bir talep

yapısı varsayılarak tahmin yapılmasını sağlamakta ve Türkiye gibi enerji talebi sürekli artan ülkelerde sıklıkla tercih edilmektedir (Hamzaçebi ve ark., 2019: 2218). Bu yöntemin sınırlılığı, veri setinde doğrusal olmayan yapıların yer aldığı durumlarda yeterince doğru tahminler sunamamasıdır. Bu bağlamda, yapay sinir ağları (ANN), destek vektör regresyonu (SVR) ve adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) gibi yapay zekâ tabanlı yöntemler doğrusal olmayan ilişkileri modelleme yeteneği sayesinde son yıllarda daha fazla tercih edilmeye başlanmıştır (Bilgili ve ark., 2022: 15634; Demircioğlu ve Eşiyok., 2022: 1131). Bu çalışmanın temel amacı, Türkiye enerji piyasasında PTF'yi tahmin etmek üzere farklı makine öğrenimi algoritmalarının performanslarını karşılaştırmalı olarak analiz etmek ve en doğru tahmin sağlayan yöntemi belirlemektir.

## 2. Literatür Taraması

Demircioğlu ve Eşiyok (2022) , Türkiye'nin enerji tüketimini tahmin etmek için yapay sinir ağı (ANN) modelini kullanarak ve başarılı tahminler elde etmişlerdir. Hamzaçebi ve ark., (2019) ise ANN ve SARIMA modellerini bir arada kullanarak Türkiye'nin elektrik talebini tahmin etmiştir. Ayrıca Yunusova ve Kiran (2022), Türkiye'nin elektrik enerji talebini modellemek için Ağaç-Tohum Algoritması (Tree-Seed Algorithm, TSA) geliştirmiştir. Kalfa ve ark., (2021) elektrik piyasasını çoklu regresyon ve yapay sinir ağları ile tahmin etmiş yapay sinir ağlarının daha başarılı tahmin sonucu verdiğini tespit etmiştir. PTF üzerine yapılan diğer bir çalışmada Purlu ve ark., (2022) derin öğrenme yöntemlerinin başarılı tahmin performansı verdiğini tespit edilmiştir.

Rafiei, Niknam ve Khooban, (2016), önerdikleri modelde saatlik elektrik fiyatlarının olasılıksal yöntemlerle tahmin edilmesine yönelik bir yaklaşım sunarak Ontario ve Avustralya piyasalarında başarılı sonuçlar elde etmişlerdir. (2017) (Gao ve ark., (2017)ise dalgacık dönüşümü (WT) ve ARIMA ile yapay sinir ağları (ANN) modellerini birleştirerek Birleşik Krallık piyasasında gün öncesi fiyat tahmini gerçekleştirmiştir.

Neupane ve ark., (2017), saatlik bazda farklı algoritmalar arasında seçim yaparak fiyat tahminini geliştiren yeni yöntemler önermiştir. Benzer şekilde Singh ve ark., (2017) klasik yapay sinir ağı modelleri kullanarak kısa vadeli fiyat tahmini yaparken; Khajeh, ve ark., (2018), iki aşamalı özellik seçimi ve yinelemeli eğitim algoritması ile tahmin performansını artırmaya yönelik çalışmalar yapmıştır.

Derin öğrenme yaklaşımlarına odaklanan (Bento ve ark., 2018), dalgacık analizi ve korelasyon temelli hibrit yöntemler geliştirmiştir.(Kuo ve Huang (2018) ise RNN, LSTM, CNN ve SAE gibi derin öğrenme tekniklerinin kısa vadeli tahminlerdeki üstün performansını vurgulamış, özellikle CNN ve LSTM kombinasyonlarının elektrik fiyat tahmini için etkili olduğunu göstermiştir.

Lago ve ark., (2018), farklı derin öğrenme modellerini geleneksel yöntemlerle karşılaştırarak makine öğrenmesi yöntemlerinin istatistiksel modellere kıyasla genel olarak daha yüksek doğruluk sağladığını ortaya koymuşlardır. Aynı zamanda, Zahid ve ark., (2019), Cerjan ve ark., (2019) ile Polson ve Sokolov, (2020) de derin öğrenme yöntemlerinin diğer tekniklere göre üstünlüğünü destekleyen bulgular sunmuştur.

Türkiye enerji piyasasına yönelik çalışmalar ise sınırlı olmakla birlikte artış göstermektedir. Kölmek ve Navruz, (2015), ARIMA ve ANN modellerini karşılaştırmış ve yapay sinir ağlarının daha başarılı sonuçlar verdiğini göstermiştir. Gökgöz ve Filiz (2016), Türkiye gün öncesi elektrik piyasasında ANN tabanlı modellerin performansını analiz etmiş ve düşük hata oranları elde etmiştir. Yorulmuş ve ark., (2018), LSTM modellerinin geçmiş tüketim ve üretim verileriyle daha başarılı tahminler sunduğunu belirtmiştir. Ugurlu ve ark., (2018) ise çok katmanlı GRU yapılarının RNN ve klasik yöntemlere göre daha üstün performans sergilediğini göstermiştir. Yılmaz ve ark., (2018) ise ileriye dönük fiyatların spot fiyatların önyargısız bir göstergesi olabileceğini ortaya koymuştur.

Türkiye'de piyasa takas fiyatını (PTF) etkileyen faktörlerin doğru bir şekilde tahmin edilmesi, enerji piyasalarının etkin işleyişi ve politika yapıcıların karar alma süreçleri açısından oldukça önemlidir. Elektrik enerjisi arz ve talebi, piyasa takas fiyatları (PTF) üzerinde önemli etkiler yaratmakta ve fiyatlardaki dalgalanmalar ekonomi genelinde geniş çaplı sonuçlara neden olabilmektedir. Özellikle enerji piyasalarında yaşanan değişimlerin ardındaki temel unsurların anlaşılması, fiyat tahmin modellerinin geliştirilmesi ve piyasa değişkenlerinin belirleyici faktörlerinin doğru bir şekilde tespit edilmesi, bu alanda yapılan araştırmaların önemi artırmaktadır. Türkiye'nin enerji piyasası, iklimsel faktörler, döviz kuru, Brent petrol fiyatları ve toplam kurulu güç gibi çeşitli değişkenlerin etkisi altında şekillendiği için, bu değişkenlerin PTF üzerindeki etkilerini analiz etmek, gelecekteki fiyat dalgalanmalarının öngörülebilirliğini artırabilir.

Bu çalışmada, Türkiye enerji piyasasına özgü veriler kullanarak farklı makine öğrenmesi algoritmalarını karşılaştırmalı olarak analiz etmek ve Türkiye'deki enerji piyasası dinamiklerini modellemek üzerine kurulmaktadır. Elektrik fiyatlarının tahmininde, sıcaklık, brüt elektrik fiyatı, toplam kurulu güç, dolar kuru ve

Brent petrol fiyatları gibi çeşitli değişkenlerin etkileri dikkate alınarak enerji piyasasının daha şeffaf ve öngörülebilir hale getirilmesi hedeflenmektedir. Türkiye gibi gelişmekte olan ülkelerde enerji piyasası dinamikleri, makroekonomik ve küresel faktörlerden doğrudan etkilenmektedir. Dolar kurundaki dalgalanmalar, enerji maliyetlerinde ani artışlara yol açabilmekte; petrol fiyatları ise enerji üretim maliyetlerini doğrudan etkileyebilmektedir. Ayrıca, sıcaklık gibi iklimsel faktörler, elektrik talebinde önemli bir belirleyici olarak karşımıza çıkmakta ve elektrik talebindeki dalgalanmalar, PTF üzerinde doğrudan bir etkiye sahip olmaktadır. Bu bağlamda çalışma üç ana bölümden oluşmaktadır. Çalışmanın birinci bölümünde literatür incelemesi yapılmasının ardından ikinci bölümde çalışmanın veri seti ve yöntemi ifade edilmiştir. Çalışmanın son bölümünde ise analizden elde edilen sonuçlar verilmiş ve tartışılmıştır.


### 3. Veri Seti

Bu çalışmada piyasa takas fiyatını (PTF) tahmin etmek amacıyla aylık veriler kullanılarak altı makine öğrenmesi algoritmasıyla tahmin modeli ortaya konulmuştur. Araştırmada kullanılan veriler Ocak 2012'den Ocak 2023 dönemlerini kapsamaktadır. Modelde bağımlı değişken olarak piyasa takas fiyatı (PTF) yer alırken, bağımsız değişkenler beş ana faktörden oluşmaktadır: sıcaklık, brüt elektrik tüketimi, toplam kurulu güç, dolar kuru ve Brent petrol fiyatı. Bu değişkenler, enerji piyasasında fiyatları etkileyen çevresel ve ekonomik faktörlerden oluşmaktadır. Tablo 1'de araştırmada kullanılan değişkenlerin tanımlayıcı istatistikleri gösterilmiştir. İstatistikler; ortalama, medyan, maksimum ve minimum değerlerin yanı sıra standart sapma, çarpıklık, basıklık ve toplam gözlem sayısını göstermektedir.

**Tablo 1: Tanımlayıcı İstatistikler**

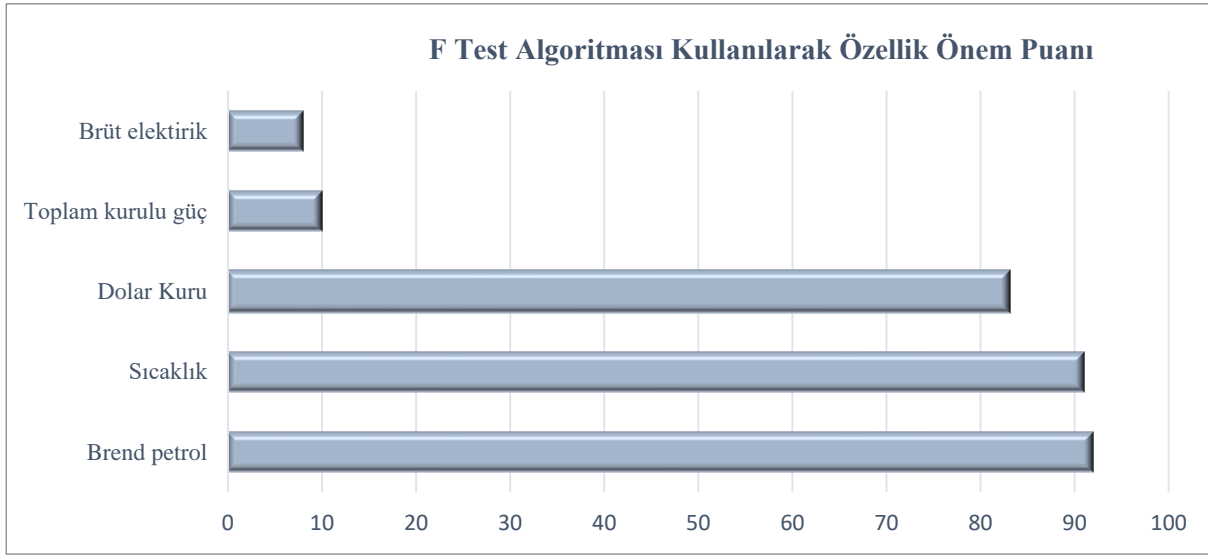
Değişken	Ortalama	Medyan	Maksimum	Minimum	Std. Sapma	Çarpıklık	Basıklık
PTF	498.525	178.509	3850.59	101.721	814.266	2.7666	9.7561
Sıcaklık	14.0796	14.3	26.4	0.3	7.8799	0.0243	1.6793
Brüt Elektrik Fiyatı	24031.23	24065.4	32783.8	18217.45	3054.34	0.281	2.5766
Toplam Kurulu Güç	81090.16	83524.35	104674.8	53256.79	15181.5	-0.2143	1.8533
Dolar Kuru	5.8002	3.6789	19.7195	1.7595	4.9311	1.6158	4.5718
Brent Petrol	427.0878	223.5018	1985.048	89.7082	461.161	2.0176	5.7124

Veri seti toplam 137 aylık gözlemden oluşmaktadır. Elde edilen verilere analiz yapmadan önce 0 ile 1 arasına normalize edilmiştir. Ayrıca verilerin %80 eğitim %20 si test aşamasında kullanılmıştır. Elde edilen değişkenler piyasa takas fiyatını tahmin etmek için özel olarak seçilmiştir. Çünkü her bir enerji piyasasında fiyat hareketleri üzerinde önemli bir etkiye sahiptir: **Sıcaklık:** Elektrik talebi genellikle sıcaklık değişimlerine bağlı olarak artmakta veya azalmaktadır. Yüksek sıcaklıklar, klima ve soğutma gibi enerji taleplerini artırırken, soğuk dönemlerde ısınma amaçlı enerji tüketimi yükselmektedir. Bu nedenle, sıcaklık değişimleri PTF üzerinde doğrudan etkili olabilecek bir faktördür. **Brüt Elektrik:** Elektrik tüketimi, ülkenin genel enerji talep seviyesini yansıtır. Talepteki artışlar, arz ve talep dengesi üzerinde baskı oluşturarak PTF'yi etkileyebilir. **Toplam Kurulu Güç:** Toplam kurulu güç, elektrik üretim kapasitesini temsil eder. Artan kapasite, piyasa fiyatları üzerinde istikrar sağlayıcı bir etki yaratırken, kapasitenin yetersizliği fiyatlarda dalgalanmaya neden olabilir. **Dolar Kuru:** Türkiye'de enerji sektörü için pek çok maliyet kalemi döviz kuru üzerinden belirlenmektedir. Dolar kurundaki dalgalanmalar, özellikle ithal enerji kaynaklarına bağımlı olan Türkiye'de PTF üzerinde doğrudan bir etki yapmaktadır. **Brent Petrol:** Petrol fiyatları enerji piyasasında maliyet belirleyici önemli bir etkidir. Brent petrol fiyatlarındaki değişiklikler, fosil yakıtlara dayalı enerji üretim maliyetlerini etkileyerek PTF'ye dolaylı bir etki sağlamaktadır. Analiz öncesinde veriler 0 ile 1 arasında çekilerek normalize işlemi yapılmıştır. Toplam kurulu güç 2012 yılı itibari ile bir istikrarlı olarak bir artış eğilimindedir. Piyasa takas fiyatı brüt elektrik talebi, Brent petrol ve döviz kuru birlikte eşanlı hareket etmektedir. Özellikle 2021 yılı sonrasında artış eğilimi göstermektedirler. Brüt elektrik talebi ve Brent petrol fiyatı Ağustos 2022 yılında düşüş eğilimi gösterirken dolar kurundaki artışın azaldığı görülmektedir. Bu değişimler Şekil 1'de detaylı olarak gösterilmektedir.



**Şekil 1: Değişkenlerin Analiz Dönemi Boyunca Aylık Değişimi**

Tanımlayıcı istatistikler, her bir değişkenin dağılım özelliklerini ve veri setinin genel yapısını yansıtarak modelin tahmin gücünü artıracak şekilde değerlendirilmiştir. Makine öğrenmesi modeli kurulmadan önce daha sağlıklı sonuçlar elde edebilmek için özellik seçimi (feature selection) uygulanarak hangi değişkenlerin PTF'yi tahmin ederken daha fazla öneme sahip olduğu gösterilmiştir. Özellik seçimi yaparken F test algoritması kullanılmıştır. Algoritma sonuçları Şekil 2'de gösterilmektedir.



**Şekil 2: ML Modelindeki Değişkenleri Özellik Seçimi**

#### 4. Yöntem

Bu çalışmada piyasa takas fiyatını tahmin etmek için esnek yapıları ve karmaşık veri setlerini modelleme yetenekleri nedeniyle yaygın olarak kullanılan altı makine öğrenmesi algoritması uygulanmıştır. Doğrusal Regresyon (Linear Regression, LR), bağımsız ve bağımlı değişkenler arasındaki doğrusal ilişkileri modelleyen basit bir algoritma olup temel eğilimleri anlamada avantaj sağlasa da doğrusal olmayan ilişkilerde yetersiz kalabilir (Bertsimas ve King, 2016: 2). Karar Ağacı (Decision Tree, DT), veriyi belirli kriterlere göre dallara ayırarak tahminler oluşturur; mevsimsellik veya hammadde fiyatları gibi faktörlere göre veriyi bölerek fiyat tahminine katkı sağlamaktadır. Ancak aşırı uyum riskine karşı budama gerektirir (Karim ve ark., 2021: 2; Song ve Lu, 2015: 134). Destek Vektör Makineleri (Support Vector Machines, SVM), veriyi en iyi ayıran hiperdüzlemi bularak doğrusal olmayan ilişkileri çekirdek (Kernel) fonksiyonları ile modelleyerek piyasa fiyatlarının öngörülmesinde başarılı bir performans sunar (Keskin ve ark., 2024: 1291). Gaussian Süreç Regresyonu (Gaussian Process Regression, GPR) ise veriyi olasılıksal bir bakış açısıyla modelleyerek her bir tahmin için güven aralıkları sağlamakta, bu da belirsizliğe sahip piyasalarda gerçekçi fiyat tahminleri sunmada değerli olmaktadır (Marrel ve Iooss, 2024: 110095). Çekirdek Yöntemleri (Kernel Methods, KR), doğrusal olmayan ilişkileri daha yüksek boyutlu bir uzaya yansıtarak veri analizinde etkili olmaktadır (Arenas-Garcia ve ark., 2013: 25; Keskin, 2025: 244). Son olarak, Sinir Ağları (Neural Networks, NN), çok katmanlı yapısı sayesinde doğrusal olmayan ilişkileri öğrenerek elektrik piyasası gibi karmaşık veri setlerinde başarılı tahminler sağla ve özellikle büyük veri setleri ile derin öğrenme teknikleri kullanıldığında güçlü sonuçlar elde edilebilir. Bu algoritmaların her biri, elektrik piyasasındaki fiyat tahmini için farklı veri yapılarına uygun esneklik ve doğruluk sağlamaktadır (Naskath ve ark., 2023: 2). Tüm analizler makine öğrenimi, simülasyon ve yapay zekâ gibi alanlarda yaygın olarak kullanılan güçlü bir yazılım aracı olan MATLAB 2024 ile gerçekleştirilmiştir (The MathWorks, 2024).

**Tablo 2: Kullanılan Makine Öğrenme Algoritmalarının Temel Parametreleri**

Algoritma	Parametre	Varsayılan Değer	Açıklama
<b>Linear Regression (LR)</b>	Fit Method	Linear	Regresyon modeli türü, doğrusal regresyonu ifade eder.
	Regularization	None	Varsayılan olarak düzenleme uygulanmaz.
	Robust	off	Aykırı değerlere duyarlı bir model oluşturur.
<b>Decision Tree (DT)</b>	MaxNumSplits	10	Karar ağacında yapılacak maksimum bölme sayısı.
	MinLeafSize	1	Her yaprak düğümde en az bulunacak örnek sayısı.
	SplitCriterion	gdi	Bölme kriteri olarak Gini saflığı kullanılır.
	Prune	on	Ağaç, aşırı uyumu önlemek için budanır.
<b>Support Vector Machine (SVM)</b>	KernelFunction	linear	Çekirdek fonksiyonu doğrusal olarak ayarlanır.
	BoxConstraint	1	C parametresi, ceza faktörü olarak kullanılır.
	Standardize	true	Verilerin standartlaştırılması aktif hale getirilir.
<b>Gaussian Process Regression (GPR)</b>	KernelFunction	squarexponential	Varsayılan olarak karesel üstel çekirdek fonksiyonu kullanılır.
	BasisFunction	constant	Temel fonksiyon, sabit olarak belirlenmiştir.
	Sigma	1	Gürültü parametresi varsayılan olarak 1'dir.
<b>Kernel Methods (KR)</b>	KernelFunction	rbf	Radyal tabanlı fonksiyon (RBF) varsayılan çekirdek olarak kullanılır.
	Scale	auto	Çekirdek ölçekleme otomatik ayarlanır.
	BoxConstraint	1	C ceza parametresi varsayılan olarak 1'dir.
<b>Neural Network (NN)</b>	HiddenLayerSize	[10]	Tek gizli katmanda 10 nöron bulunur.
	Activation Function	tansig	Gizli katmandaki aktivasyon fonksiyonu hiperbolik tanjanttır.
	Training Algorithm	trainscg	Scaled Conjugate Gradient algoritması ile eğitim yapılır.
	Epochs	1000	Maksimum eğitim döngü sayısı 1000 olarak ayarlanmıştır.
	Learning Rate	0.01	Öğrenme oranı varsayılan olarak 0.01'dir.

## 5. Sonuçlar

Makine öğrenmesi modellerinin performansları farklı değerlendirme metrikleri üzerinden karşılaştırılabilir. Burada, modellerin doğruluğunu ve hata oranlarını değerlendirmek için RMSE (Root Mean Square Error),

MSE (Mean Squared Error), R-squared (determinasyon katsayısı) ve MAE (Mean Absolute Error) kullanılmıştır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (1)$$

$$MSE = \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (2)$$

$$R^2 = \sum_{i=1}^n \left[ \frac{y_i - \tilde{y}_i}{y_i - \tilde{y}_i} \right]^2 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{n}} \quad (4)$$

Tablo 3, ML algoritmalarının hem eğitim hem de test veri setleri üzerindeki performansını RMSE, MSE, R<sup>2</sup> ve MAE ölçütleriyle karşılaştırmalı olarak göstermektedir. RMSE ve MSE, hata büyüklüğünü; MAE, ortalama mutlak hatayı; R<sup>2</sup> ise modelin açıklayıcılığını ifade etmektedir. GPR, hem eğitim hem de test aşamalarında en düşük hata değerleri ve en yüksek R<sup>2</sup> ile en başarılı model olarak öne çıkmıştır. DT, test aşamasında GPR'den sonra en istikrarlı performansı sergileyen model olmuştur. KR modeli test verisinde beklenenden daha yüksek bir doğruluk sağlamıştır. SVM ve LR modelleri, doğrusal ve karmaşık olmayan yapılarla sınırlı kaldığı için test verisinde daha düşük başarı göstermiştir. NN ise eğitim aşamasına göre testte daha iyi sonuçlar vererek dikkat çekmiştir. Bu bulgular, ML algoritmalarının PTF tahminindeki doğruluk düzeylerini karşılaştırmalı biçimde ortaya koymaktadır.

**Tablo 3: ML Modellerinin Ölçüm Performansının Değeri**

Model	Eğitim				Test			
	RMSE	MSE	R <sup>2</sup>	MAE	MAE	MSE	RMSE	R <sup>2</sup>
<b>Doğrusal Regresyon (LR)</b>	0.0958	0.0091	0.7963	0.0335	0.0528	0.0210	0.1451	0.6242
<b>Karar Ağaçları (DT)</b>	0.0909	0.0082	0.8168	0.0385	0.0393	0.0114	0.1070	0.7955
<b>Destek Vektör Makineleri (SVM)</b>	0.0868	0.0075	0.8327	0.0328	0.0514	0.0173	0.1315	0.6912
<b>Gaussian Süreç Regresyonu (GPR)</b>	0.0824	0.0068	0.8493	0.0349	0.0459	0.0140	0.1184	0.7498
<b>Çekirdek Tabanlı Regresyon (KR)</b>	0.1077	0.0116	0.7429	0.0415	0.0360	0.0086	0.0928	0.8463
<b>Sinir Ağları (NN)</b>	0.1001	0.0100	0.7778	0.0427	0.0446	0.0098	0.0990	0.8250

LR modeli, eğitim aşamasında 0.0958 RMSE, 0.0092 MSE, 0.0336 MAE ve 0.7963 R<sup>2</sup> değerlerine ulaşmıştır. Test aşamasında ise performansında belirgin bir düşüş göstermiş, 0.1452 RMSE ve 0.6242 R<sup>2</sup> değerleri elde edilmiştir. Bu sonuçlar, LR modelinin PTF tahmininde doğrusal ilişkilere duyarlı olduğunu, ancak karmaşık yapıları iyi temsil edemediğini göstermektedir. Karar Ağacı (DT) modeli, eğitim aşamasında 0.0909 RMSE, 0.0083 MSE, 0.0385 MAE ve 0.8168 R<sup>2</sup> ile tatmin edici bir performans sergilemiştir. Test aşamasında ise 0.1071 RMSE ve 0.7955 R<sup>2</sup> değerleri ile eğitim aşamasına yakın sonuçlar elde edilmiştir. DT modeli, özellikle test aşamasında diğer modellere göre daha istikrarlı bir performans göstermiştir. SVM modeli, eğitim aşamasında 0.0869 RMSE, 0.0075 MSE, 0.0328 MAE ve 0.8328 R<sup>2</sup> değerlerine ulaşmıştır. Ancak test aşamasında performansı düşmüş olup, 0.1316 RMSE ve 0.6913 R<sup>2</sup> değerleri elde edilmiştir. Bu düşüş, SVM modelinin veri setindeki karmaşık ilişkileri tam olarak öğrenemediğine işaret etmektedir. GPR, eğitim aşamasında en iyi sonuçları vererek 0.0825 RMSE, 0.0068 MSE, 0.0349 MAE ve 0.8493 R<sup>2</sup> değerlerine ulaşmıştır. Test aşamasında ise 0.1184 RMSE ve 0.7499 R<sup>2</sup> değerleri ile eğitim aşamasına yakın bir performans sergilemiştir. Bu model, veri setini oldukça iyi temsil etmiş ve en iyi genel performansı sağlamıştır. KR modeli, eğitim aşamasında 0.1077 RMSE, 0.0116 MSE, 0.0415 MAE ve 0.7429 R<sup>2</sup> ile görece daha düşük bir

performans göstermiştir. Test aşamasında ise performansı artmış ve 0.0983 RMSE ile 0.8463 R<sup>2</sup> değerlerine ulaşmıştır. Bu sonuçlar, KR modelinin test aşamasında beklenenden daha iyi sonuçlar verdiğini göstermektedir. Sinir Ağları NN modeli, eğitim aşamasında 0.1001 RMSE, 0.0100 MSE, 0.0428 MAE ve 0.7779 R<sup>2</sup> değerleri ile diğer modellere göre daha düşük bir performans sergilemiştir. Ancak, test aşamasında performansı artarak 0.0990 RMSE ve 0.8251 R<sup>2</sup> değerlerine ulaşmıştır. NN, test aşamasında eğitim aşamasına kıyasla daha başarılı sonuçlar vererek potansiyelini göstermiştir.

Genel olarak sonuçlar, GPR modelinin PTF tahmininde en yüksek doğruluğa sahip model olduğunu ve veriyi en iyi temsil ettiğini göstermektedir. KR ve DT modelleri de test aşamasında tatmin edici performans sergilemişlerdir. Bu bağlamda, enerji piyasasındaki fiyat tahminlerinin doğruluğunu artırmak adına, GPR ve DT gibi modellerin kullanımı elektrik piyasasındaki etkinliği daha fazla artıracaktır. Ayrıca, veri setinin daha geniş bir zaman aralığını kapsayacak şekilde genişletilmesi ve ek değişkenlerin dahil edilmesi, modellerin tahmin performansını daha da artırabilir.

## 6. Tartışma ve Öneriler

Bu çalışmada, Türkiye enerji piyasasında piyasa takas fiyatının PTF tahmini için farklı makine öğrenimi algoritmalarının etkinliği değerlendirilmiştir. Enerji fiyatlarının doğru bir şekilde tahmin edilmesi, piyasa katılımcılarının ve politika yapıcıların fiyat dalgalanmalarına karşı önceden önlem almalarını sağlamak ve enerji güvenliği açısından stratejik bir önem taşımaktadır. Çalışmada kullanılan altı makine öğrenimi algoritması arasında, özellikle GPR ve DT modelleri PTF tahmininde yüksek doğruluk oranları sağlamıştır. Literatürde enerji fiyat tahminleri üzerine yapılan çalışmalar, GPR'nin olasılıksal modelleme yeteneğiyle enerji piyasalarındaki belirsizliği yönetmede başarılı olduğu gözlemlenmiştir (Marrel ve Iooss, 2024: 110095). GPR modeli, her bir tahmin için güven aralıkları sağlamakta, bu da piyasa katılımcıları için belirsizliklerin yönetilmesini kolaylaştırmaktadır.

Bu çalışma, enerji piyasasındaki dalgalanmaların doğru tahmin edilmesi ve risklerin etkin yönetilmesi açısından önemli bir katkı sunmaktadır. Literatürde, enerji fiyat tahminlerinde klasik istatistiksel yöntemlerin yanı sıra makine öğrenimi yöntemlerinin de başarılı sonuçlar verdiği, özellikle karmaşık ve doğrusal olmayan veri setlerinde bu algoritmaların tahmin performansını artırdığı belirtilmektedir (Weron, 2014: 1031). Örneğin, geleneksel ARIMA modeli ile yapılan tahminlerde doğrusal ilişkiler esas alındığından, doğrusal olmayan yapıya sahip enerji piyasalarında sınırlı kalmaktadır. Bu bağlamda, çalışmamızda kullanılan sinir ağları NN, destek vektör regresyonu SVM gibi yöntemler, doğrusal olmayan ilişkileri modelleme yeteneği sayesinde enerji fiyatlarının öngörülebilirliğini artırmıştır.

Sonuç olarak, GPR ve DT modellerinin piyasa katılımcılarına daha güvenilir tahminler sunması, enerji piyasasındaki volatilitenin öngörülmesi adına önemlidir. Türkiye gibi gelişmekte olan ülkelerde enerji fiyatlarının yüksek volatilitite göstermesi, döviz kuru ve petrol fiyatları gibi dışsal faktörlerin etkisiyle piyasa tahminlerinde güçlük yaratmaktadır. Gelecek çalışmalarda, daha geniş veri setlerinin ve diğer ekonomik, çevresel değişkenlerin modele eklenmesiyle enerji fiyat tahminlerinin doğruluğunun artırılması mümkündür. Böylece enerji piyasasının şeffaflığı ve öngörülebilirliği artırılarak, enerji arz güvenliği daha etkin bir şekilde sağlanabilir.

## Kaynakça

- Arenas-Garcia, J., Petersen, K. B., Camps-Valls, G., & Hansen, L. K. (2013). Kernel Multivariate Analysis Framework for Supervised Subspace Learning: A Tutorial on Linear and Kernel Multivariate Methods. *IEEE Signal Processing Magazine*, 30(4), 16–29. <https://doi.org/10.1109/MSP.2013.2250591>
- Bento, P. M. R., Pombo, J. A. N., Calado, M. R. A., & Mariano, S. J. P. S. (2018). A bat optimized neural network and wavelet transform approach for short-term price forecasting. *Applied Energy*, 210, 88–97. <https://doi.org/10.1016/J.APENERGY.2017.10.058>
- Bertsimas, D., & King, A. (2016). OR Forum—An Algorithmic Approach to Linear Regression. *Operations Research*, 64(1), 2–16. <https://doi.org/10.1287/opre.2015.1436>
- Bilgili, M., İlhan, A., & Ünal, Ş. (2022). Time-series prediction of hourly atmospheric pressure using ANFIS and LSTM approaches. *Neural Computing and Applications*, 34(18), 15633–15648. <https://doi.org/10.1007/s00521-022-07275-5>
- Cerjan, M., Petričić, A., & Delimar, M. (2019). HIRA Model for Short-Term Electricity Price Forecasting. *Energies* 2019, Vol. 12, Page 568, 12(3), 568. <https://doi.org/10.3390/en12030568>



- Demircioğlu, M., & Eşlyok, S. (2022). Energy consumption forecast of Turkey using artificial neural networks from a sustainability perspective. *International Journal of Sustainable Energy*, 41(8), 1127–1141. <https://doi.org/10.1080/14786451.2022.2026357>
- EPIAŞ. (2024). Enerji Piyasaları İşletme A.Ş. Erişim adresi: <https://www.epias.com.tr>
- Gao, G., Lo, K., & Fan, F. (2010). Comparison of ARIMA and ANN Models Used in Electricity Price Forecasting for Power Market. 9, 120–126. <https://doi.org/10.4236/epe.2017.94B015>
- Hamzaçebi, C., Es, H. A., & Çakmak, R. (2019). Forecasting of Turkey's monthly electricity demand by seasonal artificial neural network. *Neural Computing and Applications*, 31(7), 2217–2231. <https://doi.org/10.1007/s00521-017-3183-5>
- Kalfa, V. R., Arslan, B., & Ertuğrul, İ. (2021). Determining the Factors Affecting the Market Clearing Price by Using Multiple Linear Regression Method. *Alphanumeric Journal*, 9(1), 35–48. <https://doi.org/10.17093/alphanumeric.882847>
- Karim, R., Alam, M. K., & Hossain, M. R. (2021). Stock market analysis using linear regression and decision tree regression. 2021 1st International Conference on Emerging Smart Technologies and Applications, ESmarTA 2021. <https://doi.org/10.1109/esmarta52612.2021.9515762>
- Kemal, M., Y., Kucukcolak, N. I., & Kucukcolak, R. A. (2018). Market efficiency and risk premium in the Turkish wholesale electricity market. *International Journal of Energy Economics and Policy*, 8(5), 76–88.
- Keskin, A., Ersin, I., & Atalan, A. (2024). Price Estimation Of Selected Grains Products Based On Machine Learning For Agricultural Economic Development In Türkiye. *The Journal of Animal and Plant Sciences*, (5), 1290–1302. <https://doi.org/10.36899/japs.2024.5.0811>
- Keskin, A., & Kara, B. (2021). The Relationship Between Electricity Generation, Electricity Consumption, and Economic Growth in Turkey 1975-2019. <https://doi.org/10.4018/978-1-7998-8335-7.ch012>
- Keskin, A. (2025). Predicting and Reducing Patient Waiting Times in Dental Clinics Using Machine Learning: A Case Study from Türkiye. *Black Sea Journal of Engineering and Science*, 8(1), 243–248. <https://doi.org/10.34248/bsengineering.1574470>
- Khajeh, M. G., Maleki, A., Rosen, M. A., & Ahmadi, M. H. (2018). Electricity price forecasting using neural networks with an improved iterative training algorithm. *International Journal of Ambient Energy*, 39(2), 147–158. <https://doi.org/10.1080/01430750.2016.1269674;wgroup:string:publication>
- Kölmek, M. A., & Navruz, I. (2015). Forecasting the day-ahead price in electricity balancing and settlement market of Turkey by using artificial neural networks. *Turkish Journal of Electrical Engineering and Computer Sciences*, 23(3), 841–852. <https://doi.org/10.3906/elk-1212-136>
- Kruyt, B., van Vuuren, D. P., de Vries, H. J. M., & Groenenberg, H. (2009). Indicators for energy security. *Energy Policy*, 37(6), 2166–2181. <https://doi.org/10.1016/j.enpol.2009.02.006>
- Kuo, P. H., & Huang, C. J. (2018). An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks. *Sustainability* 2018, Vol. 10, Page 1280, 10(4), 1280. <https://doi.org/10.3390/su10041280>
- Lago, J., De Ridder, F., & De Schutter, B. (2018). Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221, 386–405. <https://doi.org/10.1016/j.apenergy.2018.02.069>
- Li, K., Cursio, J. D., Jiang, M., & Liang, X. (2019). The significance of calendar effects in the electricity market. *Applied Energy*, 235, 487–494. <https://doi.org/10.1016/j.apenergy.2018.10.124>
- Marrel, A., & Iooss, B. (2024). Probabilistic surrogate modeling by Gaussian process: A review on recent insights in estimation and validation. *Reliability Engineering & System Safety*, 247, 110094. <https://doi.org/10.1016/j.ress.2024.110094>
- Mohammadi, S., Hesamzadeh, M. R., Vafamehr, A., & Ferdowsi, F. (2020). A Review of Machine Learning Applications in Electricity Market Studies. *Proceedings of 2020 3rd International Colloquium on Intelligent Grid Metrology*, smagrmet 2020, 15–22. <https://doi.org/10.23919/smagrmet48809.2020.9264022>

- Naskath, J., Sivakamasundari, G., & Begum, A. A. S. (2023). A Study on Different Deep Learning Algorithms Used in Deep Neural Nets: MLP SOM and DBN. *Wireless Personal Communications*, 128(4), 2913–2936. <https://doi.org/10.1007/S11277-022-10079-4/figures/7>
- Neupane, B., LeeWoon, W., & Aung, Z. (2017). Ensemble Prediction Model with Expert Selection for Electricity Price Forecasting. *Energies* 2017, Vol. 10, Page 77, 10(1), 77. <https://doi.org/10.3390/en10010077>
- Polson, M., & Sokolov, V. (2020). Deep learning for energy markets. *Applied Stochastic Models in Business and Industry*, 36(1), 195–209. <https://doi.org/10.1002/asm.2518>
- Purlu, M., Turkay, B. E., Andic, C., Aydin, E., Canol, B., & Kucukaslan, B. (2022). Market-Clearing Price Forecasting Using Keras in Turkish Day-Ahead Electricity Market. *Proceedings - 2022 IEEE 4th Global Power, Energy and Communication Conference, GPECOM 2022*, 517–522. <https://doi.org/10.1109/gpecom55404.2022.9815603>
- Rafiei, M., Niknam, T., & Khooban, M. H. (2017). Probabilistic Forecasting of Hourly Electricity Price by Generalization of ELM for Usage in Improved Wavelet Neural Network. *IEEE Transactions on Industrial Informatics*, 13(1), 71–79. <https://doi.org/10.1109/tii.2016.2585378>
- Rao, A., Tedeschi, M., Mohammed, K. S., & Shahzad, U. (2024). Role of Economic Policy Uncertainty in Energy Commodities Prices Forecasting: Evidence from a Hybrid Deep Learning Approach. *Computational Economics*, 64(6), 3295–3315. <https://doi.org/10.1007/S10614-024-10550-3/tables/4>
- Singh, N., Mohanty, S. R., & Dev Shukla, R. (2017). Short term electricity price forecast based on environmentally adapted generalized neuron. *Energy*, 125, 127–139. <https://doi.org/10.1016/j.energy.2017.02.094>
- Song, Y.-Y., & Lu, Y. (2015). Decision tree methods: applications for classification and prediction. *Shanghai Archives of Psychiatry*, 27(2), 130–135. <https://doi.org/10.11919/j.issn.1002-0829.215044>
- The MathWorks, Inc. (2024). *MATLAB and Statistics Toolbox Release [2024a], Regression Learner*. Massachusetts: The MathWorks, Inc.
- Tschora, L., Pierre, E., Plantevit, M., & Robardet, C. (2022). Electricity price forecasting on the day-ahead market using machine learning. *Applied Energy*, 313, 118752. <https://doi.org/10.1016/J.apenergy.2022.118752>
- Ugurlu, U., Oksuz, I., & Tas, O. (2018). Electricity Price Forecasting Using Recurrent Neural Networks. *Energies* 2018, Vol. 11, Page 1255, 11(5), 1255. <https://doi.org/10.3390/en11051255>
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030–1081. <https://doi.org/10.1016/j.ijforecast.2014.08.008>
- Winzer, C. (2012). Conceptualizing energy security. *Energy Policy*, 46, 36–48. <https://doi.org/10.1016/j.enpol.2012.02.067>
- Yang, W., Sun, S., Hao, Y., & Wang, S. (2022). A novel machine learning-based electricity price forecasting model based on optimal model selection strategy. *Energy*, 238, 121989. <https://doi.org/10.1016/J.ENERGY.2021.121989>
- Yorulmuş, H., Uğurlu, U., & Taş, O. (2018). A long short term memory application on the Turkish intraday electricity price forecasting. *PressAcademia Procedia*, 7(1), 126–130. <https://doi.org/10.17261/pressacademia.2018.867>
- Yunusova, P., & Kiran, M. S. (2022). Tree-Seed Programming for Modelling of Turkey Electricity Energy Demand. *International Journal of Intelligent Systems and Applications in Engineering*, 10(1), 142–152. <https://doi.org/10.18201/ijisae.2022.278>
- Zahid, M., Ahmed, F., Javaid, N., Abbasi, R. A., Kazmi, H. S. Z., Javaid, A., ... Ilahi, M. (2019). Electricity price and load forecasting using enhanced convolutional neural network and enhanced support vector regression in smart grids. *Electronics*, 8(2), 122. <https://doi.org/10.3390/electronics8020122>

**Research Article**

**Türkiye Enerji Piyasasında Piyasa Takas Fiyatı Tahmini: Makine Öğrenimi Yöntemlerinin Karşılaştırılması**

*Market Clearing Price Prediction in the Turkish Energy Market: Comparison of Machine Learning Methods*

**Abdulkadir KESKİN**

Arş. Gör. Dr., İstanbul Medeniyet Üniversitesi

Siyasal Bilgiler Fakültesi

[abdulkadir.keskin@medeniyet.edu.tr](mailto:abdulkadir.keskin@medeniyet.edu.tr)

<https://orcid.org/0000-0002-4795-1028>

**Extended Summary**

This study aims to forecast the Market Clearing Price (MCP) in Turkey's energy market using advanced machine learning algorithms and provides a comparative analysis of their effectiveness. Accurately predicting MCP is crucial for ensuring the efficient operation of energy markets, maintaining energy security, supporting sustainable development goals, and achieving economic stability. MCP serves as a critical indicator of the supply-demand balance in the energy market, influenced by various factors such as temperature, gross electricity consumption, total installed capacity, exchange rates, and Brent oil prices. By leveraging data from January 2012 to January 2023, this study offers valuable insights into the dynamics of the Turkish energy market and contributes to decision-making processes for policymakers and market participants.

**Introduction**

The volatility of energy prices poses significant challenges for energy markets and broader economic stability. Sudden fluctuations in MCP, driven by both external and internal factors, necessitate the development of reliable predictive models. Traditional statistical models often fail to capture the non-linear and complex relationships inherent in energy markets. Machine learning (ML) algorithms have emerged as powerful tools to address these limitations due to their ability to process large datasets and uncover intricate patterns. This study evaluates six ML algorithms: Linear Regression (LR), Decision Tree (DT), Support Vector Machines (SVM), Gaussian Process Regression (GPR), Kernel Ridge Regression (KR), and Neural Networks (NN), to identify the most effective method for MCP forecasting in Turkey.

**Data and Variables**

The analysis utilizes a comprehensive dataset spanning January 2012 to January 2023, containing monthly observations from Turkey's energy market. The dependent variable is MCP, while the independent variables include temperature, gross electricity consumption, total installed capacity, exchange rates, and Brent oil prices. These factors were selected based on their established impact on energy prices:

- **Temperature:** Influences electricity demand due to heating and cooling needs, affecting MCP directly.
- **Gross Electricity Consumption:** Reflects overall energy demand, with higher consumption exerting upward pressure on MCP.
- **Total Installed Capacity:** Represents the production potential of the energy sector; increased capacity generally stabilizes MCP.
- **Exchange Rates:** A critical factor for an energy-import-dependent country like Turkey, where fluctuations in exchange rates impact MCP significantly.

- **Brent Oil Prices:** A determinant of energy production costs, influencing MCP indirectly.

The dataset was normalized between 0 and 1 to enhance model performance. The data was split into training (80%) and testing (20%) sets to evaluate algorithm accuracy and generalizability.

## Methodology

Six ML algorithms were implemented to forecast MCP:

1. **Linear Regression (LR):** Models linear relationships between variables. While simple, it struggles with non-linear data patterns.
2. **Decision Tree (DT):** Segments data into branches based on criteria, making it effective for handling seasonal and categorical factors.
3. **Support Vector Machines (SVM):** Utilizes hyperplanes to classify data, excelling in non-linear data structures with kernel functions.
4. **Gaussian Process Regression (GPR):** Provides probabilistic modeling with confidence intervals, suitable for markets with high uncertainty.
5. **Kernel Ridge Regression (KR):** Projects non-linear relationships into higher-dimensional spaces for improved predictions.
6. **Neural Networks (NN):** Learns complex patterns through multi-layer structures, performing well with large and diverse datasets.

MATLAB 2024 was used for algorithm implementation and performance evaluation. Key performance metrics included Root Mean Squared Error (RMSE), Mean Squared Error (MSE), R-squared ( $R^2$ ), and Mean Absolute Error (MAE).

## Findings

The comparative analysis revealed significant differences in the performance of the six ML algorithms:

- **Gaussian Process Regression (GPR):** Demonstrated the highest accuracy, with the lowest RMSE and highest  $R^2$  values in both training and testing phases. GPR's probabilistic approach enabled it to manage uncertainty effectively, making it the best-performing model overall.
- **Decision Tree (DT):** Ranked as the second-best model, offering stable results during the testing phase. Its ability to segment data based on specific criteria contributed to its robustness.
- **Kernel Ridge Regression (KR):** Exhibited improved performance in the testing phase, suggesting its potential for capturing non-linear relationships.
- **Support Vector Machines (SVM):** Delivered satisfactory results but experienced performance drops during testing, indicating challenges in learning complex data patterns.
- **Neural Networks (NN):** Showed moderate performance; however, the results improved in the testing phase, highlighting the potential for further optimization.
- **Linear Regression (LR):** Performed adequately with linear relationships but struggled with non-linear dynamics, achieving the lowest accuracy among all models.

The findings underscore the superiority of GPR and DT models in MCP forecasting, making them ideal for applications requiring high accuracy and reliability.

## Discussion

The study's results highlight the value of incorporating advanced ML algorithms into energy market forecasting. GPR's success demonstrates the importance of probabilistic modeling in managing the inherent uncertainty of energy markets. Similarly, DT's performance underscores the utility of decision-making frameworks for handling categorical and seasonal data.

Comparing these findings with existing literature, the results align with previous studies that emphasize the limitations of traditional statistical models like ARIMA in non-linear contexts. For instance, ARIMA's reliance on linear assumptions often leads to suboptimal performance in dynamic and complex markets, whereas ML algorithms excel in capturing intricate patterns. Additionally, the study reinforces the relevance of considering macroeconomic and environmental factors such as exchange rates and temperature in MCP forecasting.

### **Policy Implications and Recommendations**

The study's insights have practical implications for energy market stakeholders:

1. **For Policymakers:** Leveraging GPR and DT models can enhance the predictability of energy prices, facilitating informed decision-making and the development of effective energy policies.
2. **For Market Participants:** Accurate MCP forecasts help mitigate risks associated with price volatility, enabling better planning and resource allocation.
3. **For Future Research:** Expanding the dataset to include additional variables (e.g., renewable energy production) and exploring hybrid models could further improve forecasting accuracy.

### **Conclusion**

This study provides a comprehensive evaluation of six ML algorithms for MCP forecasting in Turkey's energy market, demonstrating the superiority of GPR and DT models. By enhancing the predictability of energy prices, the findings contribute to the stability and efficiency of the energy market, supporting the broader goals of energy security and economic sustainability. Future research could build upon these results by incorporating larger datasets, alternative algorithms, and additional variables to refine forecasting models further.