

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANA BİLİM DALI**

**YENİLENEBİLİR KAPASİTE ARTIŞININ ELEKTRİK
PİYASALARI ÜZERİNE ETKİSİ**

**Hazırlayan
Ömer POLAT**

**Danışman
Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU
Doç. Dr. Sibel ARSLAN**

Yüksek Lisans Tezi

**KASIM 2024
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANA BİLİM DALI**

**YENİLENEBİLİR KAPASİTE ARTIŞININ ELEKTRİK
PİYASALARI ÜZERİNE ETKİSİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Ömer POLAT**

**Danışman
Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU
Doç. Dr. Sibel ARSLAN**

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından ARDEB 3501 / 222M440 numaralı ve TÜBİTAK 2210-C Öncelikli Alanlara Yönelik Yurt İçi Yüksek Lisans Burs Programı 2022/2 Projeleri Birimi tarafından 1649B022214214 kodlu proje ile desteklenmiştir.

**KASIM 2024
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Ömer POLAT

İmza

“Yenilenebilir Kapasite Artışının Elektrik Piyasaları Üzerine Etkisi” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Hazırlayan

Ömer POLAT

Danışman

Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU

Enerji Sistemleri Mühendisliği ABD Başkanı

Prof. Dr. Gamze GENÇ

İmza

Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU danışmanlığında **Ömer POLAT** tarafından hazırlanan “**Yenilenebilir Kapasite Artışının Elektrik Piyasaları Üzerine Etkisi**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Enerji Sistemleri Mühendisliği Anabilim Dalında yüksek lisans tezi olarak kabul edilmiştir. **Enerji Sistemleri Mühendisliği** Anabilim Dalında **yüksek lisans** tezi olarak kabul edilmiştir.

04/11/2024

JÜRİ:

Danışman : Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU.....

Üye : Doç. Dr. Mehmet Fatih KAYA

Üye : Doç. Dr. Hatice Tekiner MOĞULKOÇ

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun tarih vesayılı kararı ile onaylanmıştır.

..... /...../

Prof. Dr. Emel KIZILKAYA AYDOĞAN

Enstitü Müdürü

TEŞEKKÜR

Yüksek lisans eğitim ve öğretim hayatım boyunca danıştığım her durumda değerli zamanlarını ayırarak kıymetli bilgilerini benimle paylaşan, her türlü desteği sağlayan ve yol gösteren danışman hocam Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU'ya bu süreç boyunca kazandırdığı her şey için en içten teşekkürlerimi sunuyorum.

Çalışmama olan katkı ve kıymetli görüşleri için danışman hocam Doç. Dr. Sibel ARSLAN'a çok teşekkür ederim.

Zor zamanlarımda beni hep cesaretlendirip motivasyonumu yükselten, her türlü yardım ve fedakarlığı sağlayarak hep yanımda olan sevgili arkadaşlarım Müh. Abdurrahman KIRAÇ'a ve Hakkı Can ERGÜN'e her şey için sonsuz teşekkür ederim.

Bu tez çalışmasına katkılarından dolayı, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 2210-C Öncelikli Alanlara Yönelik Yurt İçi Yüksek Lisans Burs Programı (Proje No: 1649B022214214) ve TÜBİTAK ARDEB 3501 Programı (Proje No: 222M440) kapsamında destek sağlayan kurumlara teşekkür ederim.

Yüksek lisans eğitimime başladığım günden itibaren çalışmalarım beni teşvik eden, cesaretlendiren, bana her zaman destek olup hiçbir zaman yalnız bırakmayan, her daim motive eden, hayatım boyunca üzerimde en büyük emeği olan babam Hasan POLAT'a, annem Ayşe POLAT'a, kardeşlerim Galip POLAT'a ve Numan POLAT'a en içten teşekkürlerimi sunarım.

Ömer POLAT

Kasım 2024, KAYSERİ

YENİLENEBİLİR KAPASİTE ARTIŞININ ELEKTRİK PİYASALARI ÜZERİNE ETKİSİ

Ömer POLAT

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Kasım 2024

Danışman: Dr. Öğr. Üyesi Saltuk Buğra SELÇUKLU, Doç. Dr. Sibel ARSLAN

ÖZET

Elektrik piyasaları, artan yenilenebilir enerji kaynaklarının (YEK) etkisiyle önemli bir dönüşüm sürecindedir. Özellikle rüzgâr ve güneş gibi düşük maliyetli enerji kaynaklarının piyasa dinamikleri ve fiyatlandırma üzerindeki etkileri araştırılmaktadır. YEK kapasitesindeki artış, elektrik piyasalarında fiyatları düşürme ve piyasa gücünü azaltma potansiyeline sahiptir. Bu çalışma, piyasa yapılarının yeniden tasarımı ve YEK entegrasyonuna yönelik öneriler sunmayı amaçlamaktadır. Modelleme, yenilenebilir enerjinin piyasa fiyatlarına etkisini belirleyerek politika yapıcıların bilinçli kararlar almasına katkı sağlamaktadır. Ayrıca, piyasa gücünü azaltmak ve adil rekabeti sağlamak için öneriler sunulmuştur. Türkiye’deki gün öncesi elektrik piyasası için yedi regresyon yöntemi kullanılarak elektrik fiyatları tahmin edilmiştir. Veriler Borsa İstanbul (EXIST) Şeffaflık Platformu’ndan alınmış, %80 eğitim ve %20 test olarak bölünmüştür. Python kullanılarak geliştirilen modellerin performansları değerlendirilmiştir. SHAP analizi, yenilenebilir enerjinin fiyatları düşürdüğünü, fosil yakıtların ise artırdığını göstermektedir. Bu çalışmada, öznitelik önemi ve PCA teknikleriyle bağımsız değişkenlerin fiyat tahminine katkısı analiz edilmiştir. Çalışmanın sonuçları, enerji politikalarının ve piyasa stratejilerinin geliştirilmesi için önemli bir referans kaynak olarak sunulmakta ve akademik literatür ile sektör uygulamalarına değerli katkılar sağlamaktadır.

Anahtar Kelimeler: Yenilenebilir Enerji, Açıklanabilir Makine Öğrenimi, Elektrik Piyasaları, Piyasa Takas Fiyatı, SHAP Analizi

IMPACT OF RENEWABLE CAPACITY INCREASE ON ELECTRICITY MARKETS

Ömer POLAT

Erciyes University, Graduate School of Natural and Applied Sciences

Master Thesis, November 2024

Supervisor: Asst. Prof. Dr. Saltuk Buğra SELÇUKLU, Assoc. Prof. Dr. Sibel

ARSLAN

ABSTRACT

Electricity markets are undergoing a significant transformation due to the increasing impact of renewable energy sources (RES). The expansion of low marginal cost energy sources like wind and solar is being studied for its potential to lower prices and reduce market power in electricity markets. This study aims to offer critical recommendations for the redesign of market structures and the integration of RES. By modeling the impact of renewable energy on market prices, the study helps policymakers make informed decisions. Additionally, it provides suggestions to reduce market power and ensure fair competition. Electricity prices in Türkiye's day-ahead market were predicted using seven regression methods. The data were obtained from the Transparency Platform of Energy Exchange Istanbul (EXIST) and split into 80% training and 20% testing sets. The models were developed using Python, and their performance was evaluated. SHAP analysis explains how various features influence the target variable, showing that renewable energy tends to lower prices while fossil fuels have the potential to increase them. This study also analyzes the contribution of independent variables to price forecasting using feature importance and PCA techniques. The findings serve as a valuable reference for the development of energy policies and market strategies, contributing significantly to both academic literature and industry practices.

Keywords: Renewable Energy, Explainable Machine Learning, Electricity Markets, Market Clearing Price, SHAP Analysis

İÇİNDEKİLER

YENİLENEBİLİR KAPASİTE ARTIŞININ ELEKTRİK PİYASALARI ÜZERİNE ETKİSİ

YÖNERGEYE UYGUNLUK.....	ii
KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	x
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiii
1. BÖLÜM.....	3
GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI.....	3
1.1. Problem Durumu	3
1.2. Elektrik Piyasaları	4
1.2.1. Piyasa Takas Fiyatı.....	5
1.2.2. Türkiye’de Enerji Piyasası.....	6
1.3. Elektrik Piyasasında Liyakat Sırası (Merit Order)	9
1.4. Literatür Çalışması	11
1.5. Araştırmanın Amacı	17
1.6. Araştırmanın Önemi.....	18
2. BÖLÜM.....	19
YÖNTEM VE MATERYAL.....	19
2.1. Tezin Yöntemi	20
2.2. Kullanılan Makine Öğrenimi Modelleri	21
2.3. Temel Bileşen Analizi ve Öznitelik Önemi	23

2.4. Model Performans Değerlendirme Metrikleri	24
2.5. Veri Seti ve Model Uygulama.....	25
2.5.1. Veri Ön İşleme Aşaması.....	28
2.5.2. Model Uygulama	30
2.5.2.1. Temel Bileşen Analizi Uygulaması	31
2.5.2.2. Öznitelik Önemi Uygulaması	32
2.5.3. Model Açıklanabilirliği.....	33
3. BÖLÜM.....	35
BULGULAR.....	35
3.1. Öznitelik Önemi ve Temel Bileşen Analizi Sonuçları	35
3.1.1. Temel Bileşen Analizi Kullanılarak Bağımsız Değişkenlerin Analizi	36
3.1.2. Öznitelik Önemi Kullanılarak Bağımsız Değişkenlerin Analizi.....	39
3.2. PCA ve Öznitelik Önemi Yöntemlerin Karşılaştırılması	43
3.3. Tüm Veri Seti Kullanılarak Elde Edilen Model Sonuçları	47
3.4. Piyasa Takas Fiyatına Etki Eden Parametrelerin Açıklanabilirliği	51
3.5. Yenilenebilir Enerji Kaynaklarının PTF üzerindeki Etkisi.....	65
4. BÖLÜM.....	67
TARTIŞMA, SONUÇ ve ÖNERİLER.....	67
4.1.Tartışma	67
4.2. Sonuç ve Öneriler	72
DESTEKLER	75
KAYNAKÇA	76
ÖZGEÇMİŞ.....	82

KISALTMALAR

PTF : Piyasa Takas Fiyatı
YEK : Yenilenebilir Enerji Kaynakları
GÖP : Gün Öncesi Piyasası
GİP : Gün İçi Piyasası
DGP : Dengeleme Güç Piyasası
TEİAŞ : Türkiye Elektrik İletim Anonim Şirketi
MW : MegaWatt
kW : kiloWatt
EPIAŞ : Enerji Piyasaları İşletme Anonim Şirketi
SURE : Seemingly Unrelated Regression
YSA : Yapay Sinir Ağı
LSTM : Uzun Kısa Süreli Bellek
CNN : Convolutional Neural Networks
SARIMA : Mevsimsel Otoresif Entegre Hareketli Ortalama
ARIMA : Otoresif Entegre Hareketli Ortalama
AR : Otoresif
CMARS : Konik Çok Değişkenli Uyarlanabilir Regresyon
ML : Makine Öğrenimi
AI : Yapay Zeka
LightGBM : Light Gradient Boosted Machine
XGBoost : Extreme Gradient Boosting
RF : Rassal Orman Regresyonu
SVM : Destek vektör makineleri
CBT : Catboost Regresyon
DT : Karar Ağacı Regresyonu
MSE : Ortalama Kare Hatası
MAE : Ortalama Mutlak Hata
RMSE : Kök Ortalama Kare Hata
MAPE : Ortalama Mutlak Yüzde Hata
EXIST : Enerji Borsası İstanbul

BOTAŞ : Petrol Boru Hatları İşletme AŞ

SHAP : Shapley Katkısal Açıklamalar

ACF : Otokorelasyon

PACF : Kısmi Otokorelasyon

PCA : Principal Component Analysis

RFECV : Recursive Feature Elimination with Cross-Validation



TABLÖLER LİSTESİ

Tablo 1. Türkiye Gün Öncesi Piyasasında PTF Tahmini Yapan Çalışmalar.....	14
Tablo 2. Veri Seti	26
Tablo 3. Veri Seti Örnek	27
Tablo 4. PCA için Eğitim ve Test kümesi.....	45
Tablo 5. Öznitelik Önemi için Eğitim ve Test kümesi.....	45
Tablo 6. Eğitim ve Test Kümesi	49
Tablo 7. GridSearch ve SHAP Analizi Çalışma Süreleri.....	71

ŞEKİLLER LİSTESİ

Şekil 1. Piyasa Takas Fiyatı.....	5
Şekil 2. Gün Öncesi Piyasa Süreci	6
Şekil 3. 2022 Türkiye Gün Öncesi Piyasa Elektrik Fiyatlarının Ortalaması - Hafta Sonları ve Resmi Tatiller	7
Şekil 4. 2022 Türkiye Gün Öncesi Piyasa Elektrik Fiyatlarının Aylık ve Mevsimsel Ortalamaları.....	8
Şekil 5. Türkiye Gün Öncesi Piyasa Elektrik Fiyatlarının Günlük ve Haftalık Ortalamaları	8
Şekil 6. Orijinal, Trend, Mevsimsellik, Artık.....	9
Şekil 7. Liyakat Sırası Etkisi	10
Şekil 8. Makine Öğrenimi Modelleri.....	20
Şekil 9. Korelasyon Isı Haritası.....	29
Şekil 10. PTF'yi etkileyen bağımsız değişkenler	29
Şekil 11. PCA ile Açıklanan Varyans Oranı	32
Şekil 12. Değişkenlerin PCA Bileşenlerine Katkısı	38
Şekil 13. Bağımsız Değişkenlerin Toplam PCA Katkısı.....	39
Şekil 14. Makine öğrenimi Modellerin Öznitelik Önemi Analizi: (a) LightGBM, (b) CatBoost, (c) XGBoost, (d) Sequential, (e) SVR, (f) RF, (g) DT.....	42
Şekil 15. Modellerin Hata Metrik Performanslarının Karşılaştırılması: (a) R^2 , (b) RMSE, (c) MSE, (d) MAE, (e) MAPE	47
Şekil 16. Model Tahmin Hatası: (a) XGBoost, (b) RF, (c) SVR, (d) Sequential, (e) DTR, (f) CatBoost, (g) LightGBM	50
Şekil 17. Modellerin sonuçları	51
Şekil 18. LightGBM Shap Değeri	53
Şekil 19. Otokorelasyon (ACF) ve Kısmi Otokorelasyon (PACF) Analizi	55
Şekil 20. Türkiye'de 2022 Yılı İtibariyle Elektrik Üretim Payları	57
Şekil 21. Modellerin Shap Value Analizi: (a) CatBoost, (b) XGBoost.....	58
Şekil 22. Modellerin Shap Value Analiz: (a) SVR, (b) Sequential, (c) RF, (d) DT	61

GİRİŞ

Günümüzde, enerji kaynaklarının sürdürülebilirliği ve çevresel etkilerinin önemi giderek artmaktadır. Enerji sektöründe yenilenebilir enerji kaynakları kilit bir rol üstlenmektedir. Yenilenebilir enerji kaynakları, sürdürülebilirlik ve çevresel sorumluluk açısından önemli avantajlar sağlarken enerji piyasaları üzerinde de dikkate değer etkiler oluşturabilir. Bu çalışma, yenilenebilir enerji kapasitesindeki artışın elektrik piyasalarında özellikle fiyat üzerindeki etkilerini analiz etmeyi hedeflemektedir.

Elektrik piyasası, genellikle finansal veya zorunlu değiş tokuş şeklinde satın alımlara, satışlara ve kısa dönemli ticaretlere olanak tanıyan bir sistemdir. Piyasada, arz ve talep miktarlarına ve verilen fiyat tekliflerine bağlı olarak piyasa takas fiyatı (PTF) oluşmaktadır. Elektrik talebini karşılamada fosil yakıt üretiminin oranı her geçen yıl azalmakta ve yenilenebilir enerji kaynakları giderek daha fazla değer görmektedir.

Elektrik piyasalarının dinamikleri, özellikle yenilenebilir enerji kaynaklarının (YEK) hızla artan katkısıyla, son yıllarda önemli değişiklikler göstermektedir. Bu dönüşüm, enerji üretim ve tüketim süreçlerinde yeni fırsatlar ve zorluklar ortaya çıkarırken geleneksel fosil yakıtlı enerji üretim sistemlerinin yerini almaya başlayan rüzgâr ve güneş enerjisi gibi düşük marjinal maliyetli yenilenebilir enerji kaynakları, piyasa fiyatlandırma mekanizmalarını ve arz-talep dengelerini köklü bir şekilde etkilemektedir. Yenilenebilir enerji kaynaklarının artan kullanımı, enerji piyasalarında daha rekabetçi bir ortam yaratmakta ve fiyat dinamiklerini yeniden şekillendirmektedir. YEK kapasite artışı, piyasa fiyatlarını düşürme ve piyasa gücünün kullanımını azaltma potansiyeline sahipken piyasa katılımcılarının stratejik karar alma süreçlerinde de önemli değişikliklere yol açmaktadır. Elektrik piyasalarının bu yeni dinamiklerini anlamak ve bu değişimlere uygun stratejiler geliştirmek, enerji politikaları ve piyasa düzenlemeleri açısından büyük önem taşımaktadır. Yenilenebilir enerji kaynaklarının kesintili doğası ve düşük marjinal maliyetleri, piyasa oyuncularının üretim ve tüketim stratejilerini yeniden gözden geçirmesini gerektirmektedir. Bu tez çalışması, Türkiye'nin gün öncesi elektrik piyasasında piyasa takas fiyatının (PTF) tahmin edilmesi ve yenilenebilir enerji

kaynaklarının piyasa dinamikleri üzerindeki etkilerinin incelenmesini amaçlamaktadır. Bölüm 1’de, elektrik enerjisi sektöründeki yeniden yapılanma çalışmaları ve elektrik piyasalarının modellenmesine yönelik literatür taranmış, yenilenebilir enerji kaynaklarının belirsiz ve kesintili doğasının planlama süreçlerinde ortaya çıkardığı zorluklar vurgulanmıştır. Bölüm 2’de, EPIAŞ’ın şeffaflık platformundan elde edilen 2018-2023 dönemi verileri kullanılarak makine öğrenimi algoritmalarıyla PTF tahmini yapılmış, modellerin hiperparametre optimizasyonu ve SHAP yöntemi ile model açıklanabilirliği artırılmıştır. Ayrıca, öznitelik önemi ve Temel Bileşen Analizi (PCA) teknikleri kullanılarak bağımsız değişkenlerin elektrik fiyat tahminine katkısı analiz edilmiştir, bu sayede model doğruluğu artırılmış ve veri boyutu azaltılmıştır. Bölüm 3’te, çeşitli makine öğrenimi modellerinin performansı sık kullanılan hata ölçütleriyle değerlendirilmiş, yenilenebilir enerji kapasitesindeki artışın elektrik fiyatları üzerindeki düşürücü etkisi ve fosil yakıtların fiyatlar üzerindeki etkileri analiz edilmiştir. Son olarak, Bölüm 4’te, enerji piyasasında yer alan aktörlere yüksek performanslı tahmin modelleri sunulmuş, gelecekteki araştırmalar için açık erişim veri ve kod paylaşımının önemi vurgulanmış ve yenilenebilir enerji kaynaklarının artan entegrasyonunun piyasa dinamiklerini nasıl şekillendirdiği detaylı bir şekilde ortaya konmuştur.

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

1.1. Problem Durumu

Elektrik enerjisi sektöründe yapılan yeniden yapılanma çalışmaları son 20 yılda hız kazanmıştır ve buna paralel olarak akademik alandaki elektrik piyasalarının modellenmesi ile ilgili çalışmalar da son 10 yılda hızla artmıştır. Koltsaklis ve Dagoumas'un [1] ele aldığı elektrik üretim kapasite planlama modelleri üzerine yapılan derleme çalışmasına göre, sektörün karmaşık doğası nedeniyle geleneksel maliyet temelli yaklaşımların kapsamlı bir şekilde değiştirilip güncellendiği belirtilmektedir. Özellikle, yenilenebilir enerji kaynaklarının (YEK) belirsiz ve kesintili doğası planlama süreçlerinde yeni zorluklar ortaya çıkarmaktadır. Bu bağlamda, yeni modellerin YEK kapasitesindeki artışı dikkate alarak analizlerde bulunması önem arz etmektedir. YEK'in payının artması ve enerji sisteminin elektrifikasyonunun artmasıyla birlikte, uzun vadeli çalışmalarda kısa vadeli değişkenliklerin nasıl temsil edileceği, iklim değişikliğinin etkisinin nasıl dahil edileceği ve modelleme süreçlerinde açıklık ve şeffaflığın nasıl sağlanacağı gibi bazı zorluklara dikkat çekilmektedir. Bu zorluklardan biri de pazar gücünün YEK kapasitesi ile nasıl değiştiğidir. Gallo [2], piyasalara giderek daha fazla değişken üretimin girmesiyle birlikte piyasa katılımcılarının nasıl tepki verdiğinin ve uyum sağladığının araştırılması gerekliliğine işaret etmektedir. Piyasa davranışının genellikle yenilenebilir enerjinin şebeke entegrasyonu ile ilgili çalışmalarda ele alınmadığını ve bireysel piyasa katılımcılarının fiyatları etkilemek ve kârlarını artırmak için aldığı stratejik kararların etkisini gerekliliğini belirtmektedir. Bu noktada, piyasa gücünün etkilerine ve piyasa katılımcılarının piyasaları manipüle etme yeteneklerine yeterince dikkat edilmediği özellikle vurgulanmaktadır. Selçuklu ve Elmahi [3], pazar gücünün azaltılması için özgün bir model sunmuşlardır. YEK'in piyasalarda pazar gücü açısından etkileri incelenmiştir.

1.2. Elektrik Piyasaları

Elektrik piyasaları, elektrik enerjisinin alım satımının yapıldığı ve fiyatlarının belirlendiği platformlardır. Bu piyasalarda, arz ve talep dengesine bağlı olarak elektrik fiyatları belirlenir ve enerji tedarikçileri ile tüketiciler arasında ticari ilişkiler gerçekleşir. Elektrik piyasaları, enerji verimliliği, sürdürülebilirlik ve rekabetçi fiyatlandırma gibi konularda önemli bir rol oynamaktadır [4].

Enerji piyasaları, alıcı ve satıcıların bir aracı piyasa işletmecisi aracılığıyla işlem yaptığı gün öncesi ve gün içi gibi piyasalardır [5]. Bu piyasalarda, alıcı ile satıcı birbirini tanımaz; işlemler aracı kurum aracılığıyla gerçekleşir ve bir takas merkezi işlemleri takas eder. Takas merkezi, hem alıcılar hem de satıcılar için karşı tarafı oluşturur [6]. Dolayısıyla, aracı kurum alıcının yerine satıcı, satıcının yerine de alıcı gibi davranır. Enerji piyasaları, işlemlerin gerçekleşme zamanına göre spot ve vadeli olmak üzere ikiye ayrılır. Spot piyasalar, takasın yapıldığı gün malın veya kıymetin el değiştirdiği piyasalar olarak tanımlanırken vadeli piyasalar, ileriki bir tarihte teslimatı veya nakit uzlaşması yapılmak üzere belirlenen fiyat ve miktardan alım satımın yapıldığı piyasalar şeklinde tanımlanır [7].


Türev piyasalar, alıcı ve satıcılar arasında bugünden yapılan anlaşma sonucu gelecekte belirli bir tarihte ve önceden belirlenmiş fiyat üzerinden teslim edilmek üzere alım satım sözleşmelerinin yapıldığı piyasalardır [8]. Elektrik ticareti yapanlar, ihtiyaçlarını uzun vadede ikili anlaşmalar ve vadeli işlemler piyasalarında kontratlar ile karşılayabilirler. Ancak elektriğin teslim tarihi yaklaştığında, spot piyasa devreye girer. Spot piyasa, teslimatın ve ödemenin iki iş günü içerisinde gerçekleştiği piyasadır. İki iş gününün üzerinde bir teslimat veya ödeme süresi mevcutsa, bu piyasalar vadeli piyasa olarak adlandırılır [9]. Organize toptan elektrik piyasaları (spot piyasalar), Gün Öncesi Piyasası (GÖP), Gün İçi Piyasası (GİP), Dengeleme Güç Piyasası (DGP) ve Yan Hizmetler Piyasası'dır [10].

GÖP, her bir piyasa katılımcısının bir sonraki günün her bir saatine ilişkin olarak alış-satış miktar ve fiyat tekliflerini verdiği, oluşan arz-talep eğrilerinin kesiştirilmesiyle gün öncesi fiyatının belirlendiği piyasadır [10]. Bu fiyat, diğer piyasalar için referans fiyat olarak kabul edilir ve elektrik ilk kez tahmin edilen ihtiyaçlar doğrultusunda dengelenmiş olur, gerçek zamanlı sistem işletmesini kolaylaştırır. GİP, genellikle sürekli ticaret

yöntemiyle çalışan bir piyasadır. Genellikle gün öncesi piyasası kapandıktan sonra açılır ve ilgili saat için ticaret yapılabilir [10]. DGP ise, sistem işletmecisinin sistemi dengede tutmak için işlettiği piyasadır. Bu piyasada asıl amaç ticaret değil, sistemin dengelenmesi ve güvenliğinin sağlanmasıdır. Sistem işletmecisi (TEİAŞ), sistemin dengesini sağlamak için gerekli tüm işlemleri talimatlar ile yerine getirir [10].

1.2.1. Piyasa Takas Fiyatı

Piyasa Takas Fiyatı (PTF), günlük elektrik piyasalarında arzı ve talebi dengelemek için temel bir öneme sahiptir. Toplam elektrik arzının talebi karşıladığı fiyatı yansıtan toptan piyasa temizlemesi yoluyla, genellikle saatlik olarak belirlenir. Üreticiler ve perakendeciler gibi piyasa katılımcıları, elektrik miktarlarını ve fiyatlarını detaylandıran teklifler sunarlar. Düşük teklifler dağıtımı sağlayarak şebekeye elektrik üretirken yüksek teklifler bunu yapmayabilir. PTF, üretici gelirlerini ve perakendeci/tüketici maliyetlerini doğrudan etkiler. Üreticiler sağladıkları elektrik için PTF'ye dayalı ödemeler alırken kullanıcılar tükettikleri elektrik için aynı tutarı öderler (Şekil 1).




Şekil 1. Piyasa Takas Fiyatı

PTF, arz-talep dengesini sağlayarak fiyatlandırmayı ve piyasa hareketlerini yönlendirir ve yatırım tercihlerini şekillendirir. Her aya, her güne ve her saate göre değişkenlik gösteren PTF'nin doğru tahmini, piyasada teklif vermede ve fiyatlama stratejilerinde başarı için kritik öneme sahiptir. Geçmiş piyasa verileri ve uygun modeller kullanılarak doğru PTF tahminleri yapılmalıdır.

Elektrik fiyatı tahmini, bilinçli karar verme, risk yönetimi, piyasa verimliliği, talep tepkisi, politika değerlendirmesi ve yenilenebilir enerjinin başarılı entegrasyonu için hayati öneme sahiptir. Bu tahminler, piyasa katılımcılarının stratejilerini optimize etmelerini, riskleri yönetmelerini ve fiyat sinyallerine yanıt vermelerini sağlayarak elektrik piyasalarının etkili ve güvenilir işleyişine katkıda bulunur.

1.2.2. Türkiye’de Enerji Piyasası

Türkiye’de Enerji Piyasaları İşletme Anonim Şirketi (EPIAŞ), 18 Mart 2015 tarihinde kurulmuştur ve enerji piyasalarının etkin, şeffaf, güvenilir ve sürdürülebilir biçimde işletilmesi ve geliştirilmesi için çalışmaktadır. EPIAŞ bünyesinde Gün Öncesi Piyasası (GÖP), Gün İçi Piyasası (GİP), Dengeleme Güç Piyasası (DGP), Spot Doğal Gaz Piyasası, Vadeli Elektrik Piyasası, Vadeli Doğal Gaz Piyasası ve Yenilebilir Enerji Kaynak Garanti Sistemi ve Piyasası bulunmaktadır. GÖP, elektriğin teslimat gününden bir gün öncesinde, elektrik ticareti ve dengeleme faaliyetleri için kullanılır ve bu piyasada elektrik enerjisi referans fiyatı yani piyasa takas fiyatı (PTF) belirlenir. İşlemler günlük olarak saatlik bazda gerçekleştirilir. Gün öncesi piyasası süreci *Şekil 2*’de görülmektedir. Piyasadaki katılımcılar, piyasada beklenen referans fiyatına göre kendi portföylerini dengelemeyi amaçlar.




Şekil 2. Gün Öncesi Piyasa Süreci


Türkiye’nin 2022 yılında elektrik üretiminin %60.37’si termik santrallerden, %39.63’ü ise yenilenebilir enerji kaynaklarından elde edilmiştir. Yenilenebilir enerji kaynakları arasında hidroelektrik %50.49, rüzgâr enerjisi %23.14 ve güneş enerjisi %11.84 oranında yer almaktadır. 2023 yılında Türkiye’deki elektrik üretiminin %36.3’ü kömürden, %21.4’ü doğal gazdan ve %42,26’sı yenilenebilir enerji kaynaklarından sağlanmıştır. Bu

yenilenebilir kaynaklar arasında hidroelektrik %19.6, rüzgâr enerjisi %10.4, güneş enerjisi %5.7, jeotermal enerji %3.4 ve biyogaz enerjisi %2.99 oranında paya sahiptir. 2024 yılının ilk altı ayında ise Türkiye’de fosil yakıtlı elektrik üretimi %46.76, yenilenebilir enerji kaynaklı üretim ise %53.53 olarak gerçekleşmiştir [11,12].

Türkiye Gün Öncesi Piyasası’ndaki elektrik fiyatları, saatlik, günlük ve mevsimsel faktörlere bağlı olarak değişmektedir. Elektrik fiyatları, yüksek talep saatlerinde artar, hafta sonları ve tatil günlerinde ise talep düştüğü için düşer (*Şekil 3*). Mevsimsel olarak, *Şekil 4*’de görüldüğü gibi kış aylarında ısıtma ihtiyacı, yaz aylarında ise soğutma ihtiyacı nedeniyle fiyatlar yüksek olur. Ancak, hidroelektrik santrallerinin yüksek payı nedeniyle ilkbaharda fiyatlar düşer.




Şekil 3. 2022 Türkiye Gün Öncesi Piyasa Elektrik Fiyatlarının Ortalaması - Hafta Sonları ve Resmi Tatiller



Şekil 4. 2022 Türkiye Gün Öncesi Piyasa Elektrik Fiyatlarının Aylık ve Mevsimsel Ortalamaları


Şekil 5’de günlük ve haftalık ortalama PTF değerlerini gösteren iki zaman serisi vardır. Mavi çizgi günlük ortalamaları, kırmızı çizgi ise haftalık ortalamaları temsil eder. Günlük verilerin daha fazla dalgalanma gösterdiği, haftalık verilerin ise bu dalgalanmaları yumuşattığı ve daha genel eğilimleri yansıttığı görülmektedir. 2018’den 2023’e doğru genel bir yükseliş eğilimi göstermektedir. Bu eğilim, gün öncesi elektrik piyasasında fiyatların bu dönemde arttığını göstermektedir.



Şekil 5. Türkiye Gün Öncesi Piyasa Elektrik Fiyatlarının Günlük ve Haftalık Ortalamaları

Şekil 6’da zaman serisi bileşenleri, trend, mevsimsellik ve artıklar olmak üzere üç bileşene ayrıştırılmıştır. Trend bileşeni, verilerdeki uzun vadeli eğilimi gösterir ve bu

bileşende zaman içinde yavaş yavaş artan bir eğilim görülmektedir. Mevsimsellik bileşeni, belirgin bir yıllık desen olmasa da yıl içinde düzenli dalgalanmalar göstermektedir. Artıklar bileşeni ise trend ve mevsimsellik tarafından açıklanamayan varyasyonları gösterir. Bu varyasyonlar genellikle rastgele ve düzensizdir.



Şekil 6. Orijinal, Trend, Mevsimsellik, Artık


Son dönemde Türkiye’de uygulanan enerji politikaları, yönetmelikler ve hükümet destekleri gibi faktörler, yenilenebilir enerjilerdeki artışın ana sebepleri arasında yer almaktadır. Yenilenebilir enerjilerin artışı, düşük marjinal maliyetler ve liyakat sıralaması ilkesi gibi nedenlerle, spot piyasa fiyatlarında belirsizliklere ve fiyat değişkenliğine neden olabilmektedir.

1.3. Elektrik Piyasasında Liyakat Sırası (Merit Order)

Yenilenebilir enerji kaynaklarının geleneksel fosil yakıtlı enerji üretim sistemlerinin yerini alması, düşük marjinal maliyetleri ve kesintili doğasıyla piyasa fiyatlandırma mekanizmalarını ve arz-talep dengelerini etkilemektedir. Özellikle rüzgâr ve güneş enerjisi gibi YEK’ler, piyasa takas fiyatlarını düşürme ve piyasa gücünün kullanımını azaltma potansiyeline sahiptir. Liyakat Sırası Etkisi (Merit Order Effect), elektrik piyasasında marjinal üretim maliyeti en düşük olan kaynakların ilk olarak devreye alındığı bir sistemdir. Liyakat sırası etkisi, YEK’lerin sıfıra yakın marjinal maliyetleri

nedeniyle elektrik üretiminde öncelikli hale gelmelerini ifade eder, bu da fosil yakıtlı santrallerin devreye girme sıklığını azaltarak toplam üretim maliyetlerini ve dolayısıyla piyasa fiyatlarını düşürür. YEK'lerin artan entegrasyonu, enerji piyasalarında daha rekabetçi bir ortam yaratırken aynı zamanda piyasa katılımcılarının üretim ve tüketim stratejilerini yeniden gözden geçirmelerini gerektirir. Bu dönüşüm, enerji sektöründe yeni fırsatlar ve zorluklar ortaya çıkararak, gelecekteki enerji piyasalarının şekillenmesinde önemli bir rol oynayacaktır.

Şekil 7'de yenilenebilir enerjinin elektrik piyasasına girişinin fiyat üzerindeki etkisini göstermektedir. Grafikte, yatay eksen enerji miktarını (MWh) ve dikey eksen ise fiyatını (\$/MWh) göstermektedir. Elektrik piyasasında arz ve talep dengesi, üretim maliyetleri doğrultusunda belirlenmektedir. Bu grafik, arz eğrisinin (yeşil, siyah ve gri renklerle gösterilen) ve talep eğrisinin (turuncu) etkileşimini göstermektedir. Arz eğrisi, yenilenebilir enerji kaynakları (rüzgâr gücü, güneş enerji vb.), fosil yakıtlar ve diğer enerji kaynaklarını içermektedir. Grafik, yenilenebilir enerjilerin düşük marjinal maliyetle arz eğrisinde en düşük seviyede yer aldığını ve fosil yakıtların daha yüksek maliyetle arz eğrisinde üst sıralarda bulunduğunu göstermektedir. Bu durumda, yenilenebilir enerjide artan kullanımı genellikle arz eğrisini sola kaydırmakta ve bu da piyasa takas fiyatının düşmesine neden olmaktadır. Grafikte PTF, başlangıçta P_0 seviyesinde iken rüzgâr enerjisinin entegrasyonu ile P_1 seviyesine düşmektedir. Bu durum, Liyakat Sırası Etkisi olarak bilinen etkiyi yansıtmaktadır.



Şekil 7. Liyakat Sırası Etkisi

Diğer taraftan PTF, arz-talep dengesini sağlayarak fiyatlandırmayı yönlendirir, piyasa hareketlerini şekillendirir ve yatırım tercihlerini belirler. PTF, her aya, her güne ve her saate göre değişkenlik göstermektedir. Piyasada teklif vermede ve fiyatlama stratejilerinde iyi sonuçlar alabilmek için geçmiş piyasa verileri ve uygun modeller kullanılarak doğru PTF tahminleri yapılmalıdır.

1.4. Literatür Çalışması

Son yıllarda elektrik sektöründe yeniden yapılanmalar sonucunda, birçok ülkede, serbest ve rekabete dayalı elektrik piyasaları kurulmuştur. Bir elektrik piyasasının pazar hedefi, tüketicilerin elektrik talebini, üretim kaynaklarının doğru miktarda yatırım yaparak minimum maliyetle karşılamaktır. Elektrik üretiminde verimlilik artışını sağlamak ve elektrik fiyatlarını düşürmek amacıyla pek çok ülkede olduğu gibi Türkiye’de de serbest elektrik piyasasına geçilmiştir. Hem dünyada hem de ülkemizde enerjiye olan ihtiyacın çoğu fosil yakıtlı enerji kaynaklarından karşılanmaktadır fakat son yıllarda fosil yakıtların elektrik üretimindeki payı azalmakta ve yenilenebilir kapasite hızla artmaktadır. Bu dönüşümün elektrik piyasaları üzerine etkisi önemli bir araştırma alanıdır.

Yenilenebilir elektrik kaynakları üzerine yapılan çeşitli çalışmalar, metodolojileri, veri kaynaklarını ve hedefleri farklılık gösterse de genellikle sistem kapasite sınırlarına yaklaştığında özellikle maliyet sıralama etkisi aracılığıyla spot piyasa fiyatlarını düşürdüğünü kabul etmektedir. Liyakat Sırası Etkisinin tahmin edilmesi için kullanılan veri frekansının seçimi, rapor edilen sonuçları etkileyebilir. Rüzgârın elektrik fiyatları üzerindeki etkisi, özellikle Almanya, Hindistan, İspanya, İtalya ve Avustralya gibi yüksek rüzgâr penetrasyonuna sahip ülkelerde önemli rol oynamaktadır. Rüzgâr analizlerinin güneş çalışmalarından daha fazla olduğu göz önüne alındığında, bu çalışma, Türkiye elektrik piyasasının özel koşulları nedeniyle güneş, rüzgâr, jeotermal ve hidroelektrik üretimi alanlarına odaklanmaktadır.

Abban ve Hasan [13], Avustralya elektrik piyasalarında yüksek güneş enerjisi girişinin elektrik fiyatları üzerindeki etkisini ölçmeyi amaçlamaktadır. Çalışmanın amacına ulaşmak için tek değişkenli ve çok değişkenli genelleştirilmiş otoregresif koşullu değişen varyans modeli kullanılmıştır. Artan güneş penetrasyonunun Queensland, Güney Avustralya ve Tazmanya’nın bölgesel elektrik piyasalarında elektrik fiyatlarını azalttığı görülmektedir.

Benhmad ve Percebois [14], liyakat sırası etkisini saatlik olarak araştırmak ve Almanya’da 2012- 2015 yılları arasında elektrik piyasası için saatlik geçmiş verilere dayalı ampirik bir analiz yapmak için *Seemingly Unrelated Regression* metodolojisini kullanmıştır. Temel bulgularda rüzgâr ve güneş üretimi arttıkça elektrik spot fiyatlarında keskin bir düşüş olduğu görülmektedir.

Odeh ve Watts [15], yenilenebilir enerji kaynaklarının (güneş, rüzgâr, jeotermal, hidroelektrik vb.) kullanımını ve potansiyelini inceleyerek, bunların ekonomik, çevresel ve sosyal sürdürülebilirliğini değerlendirmektedir. Çalışma, yenilenebilir enerji entegrasyonunu etkileyen teknik, ekonomik, politik ve sosyal faktörleri analiz etmektedir. Yenilenebilir enerji teknolojilerinde kayda değer ilerlemeler olmasına rağmen, güneş ve rüzgâr kaynaklarının yüksek değişkenliği ve sınırlı öngörülebilirliği nedeniyle entegrasyonları hâlâ zordur. Entegrasyonu kolaylaştırmak için coğrafi çeşitlendirme gibi önlemler alınabilir. Şili’deki rüzgâr ve güneş enerjisinin piyasa değeri üzerindeki mekansal çeşitlendirme etkilerini incelemekte ve bu çeşitlendirmenin yenilenebilir enerjinin piyasa değeri üzerinde olumlu etkisi olduğunu ortaya koymaktadır. Sonuçlar, rüzgâr ve güneş enerjisi piyasa değerinin çeşitlendirme düzeyine bağlı olarak artabileceğini göstermektedir. Çalışmanın bulguları, yenilenebilir enerjinin daha sürdürülebilir ve çevre dostu bir enerji sistemine geçiş için önemli ipuçları sunmakta ve enerji depolama, akıllı şebekeler ve talep yönetimi gibi teknolojilerin geliştirilmesinin önemini vurgulamaktadır. Enerji politikaları, teşvikler ve düzenleyici çerçeveler yenilenebilir enerjinin daha hızlı benimsenmesini desteklerken toplumsal farkındalık ve kabul de kritik öneme sahiptir. Gelecekteki araştırmalar, teknolojik yenilikler ve uluslararası işbirliği, yenilenebilir enerjinin sürdürülebilir bir şekilde yaygınlaşmasına katkı sağlayacaktır.

Nibedita ve Irfan [16], Hindistan elektrik piyasası için yenilenebilir kaynaklardan elektrik üretiminin toptan elektrik fiyatları üzerindeki asimetric etkilerini araştırmışlardır. Doğrusal olmayan bir eş bütünleşmenin varlığı ve yenilenebilir kaynakların toptan elektrik fiyatı üzerindeki asimetric etkileri, doğrusal olmayan bir otoregresif dağıtılmış gecikme modelleme çerçevesi kullanarak incelemişlerdir. Çalışma, toptan elektrik fiyatı ile yenilenebilir kaynaklardan elektrik üretimi ve toptan elektrik fiyatı ile rüzgâr ve güneş kaynaklarından elektrik üretimi arasında doğrusal bir eş bütünleşme ilişkisini ortaya

koymaktadır. Rüzgâr ve güneş elektrik üretimindeki pozitif ve negatif etkileri nedeniyle toptan elektrik fiyatına verilen tepkilerin asimetrik olduğunu göstermişlerdir.

Csereklyei vd. [17], Avustralya’da 2010-2018 yılları arasında rüzgâr ve güneş enerjisi üretiminin toptan elektrik fiyatları üzerindeki etkisini araştırmaktadır. Avustralya Ulusal Elektrik Piyasası için günlük veri setlerini kullanmaktadırlar. Rüzgâr ve güneş üretiminin liyakat sırası etkisini ayırtırmak için otoregresif dağıtılmış gecikme modelleri ile tahmin yöntemi kullanılmıştır. Çalışmada, yenilenebilir enerji kaynaklarına yönelim arttıkça elektrik fiyatlarında düşüş olduğu sonucu çıkarılmaktadır.

Cieplinski vd. [18], liberalleşmiş piyasaların düşük marjinal maliyeti dolayısıyla rüzgâr ve güneş enerjisine yapılan yeni yatırımların kârını düşürme eğiliminde olduğunu belirtmektedir. Çalışmada, İtalyan ekonomisine (2015-2040) yeni bir hibrit dinamik makro simülasyon modeli uygulanmaktadır. Fiyat sübvansiyon politikasının ilk on yıldaki (2021-2030) etkisizliğine rağmen 2040 yılına kadar değişken yenilenebilir enerji kaynaklarının çok yüksek nüfuzuna ulaşmak hâlâ çok önemlidir.

Concettini vd. [19], yenilenebilir üretimdeki piyasa dengesini incelemek için İtalya’nın gün öncesi piyasasının saatlik fiyat-miktar dengesini simüle eden bir İtalyan Gün Öncesi Piyasa Çözücüsü algoritması geliştirmişlerdir. Analizlerin sonucunda yenilenebilir kapasitenin artışının elektrik piyasalarında fiyatları azalttığı görülmektedir.

Coester vd. [20], Alman elektrik piyasası verilerine dayanarak yapılan bir çalışmada, serbest piyasa koşullarında yenilenebilir enerjinin enerji arz güvenliği üzerindeki etkileri incelenmiştir. Yenilenebilir enerji kapasitesinin genişleme hedefleri tarafından değil, ekonomik faktörler tarafından yönlendirildiği bir model kullanılarak, yenilenebilir enerjiyi bir yatırım seçeneği olarak dinamik olarak modellemişlerdir. Araştırma, sabit bir ödeme garantisi mekanizmasının, yenilenebilir enerji genişlemesini ve kesintisiz enerji arzını sağlamak için uygun bir araç olduğunu ortaya koymaktadırlar. Ancak, elektrik üretiminin dış maliyetlerini içselleştirme durumunda, konvansiyonel santraller için teşviklerle birlikte serbest piyasa senaryosunun, yenilenebilir enerji için en uygun maliyetli seçenek olduğu belirtmektedirler.

Sánchez de la Nieta ve Contreras [21] sıfıra eşit bir marjinal maliyetle yenilenebilir enerji kaynaklarının dahil edilmesinin, gün öncesi elektrik piyasasının marjinal fiyatları

üzerinde aşağı yönlü bir etki yaratabileceğinden yola çıkarak enerji tekliflerine daha yüksek bir yenilenebilir enerji katılımı ile gün öncesi elektrik piyasası fiyatları üzerindeki aşağı yönlü etkinin sayısallaştırılması üzerine çalışma yapmışlardır. Çeşitli simülasyon sonuçları sunarak yenilenebilir üretim katılımının İspanyol elektrik piyasası fiyatları üzerindeki etkisini analiz etmek ve ölçmek için bir algoritmik model göstermişlerdir. Yenilenebilir üretimin marjinal maliyeti konvansiyonel üretime göre daha düşük olduğu ve yenilenebilir üretimin piyasaya katılımı nedeniyle piyasa fiyatı üzerinde aşağı yönlü bir etki yarattığı, yenilenebilir üretimin elektrik piyasasına katılımı ne kadar fazla olursa, fiyatlar üzerindeki aşağı yönlü etkisinin de o kadar büyük olacağı sonucu çıkarılmıştır.

Elektrik piyasaları, teknik yapısı itibarıyla diğer finansal piyasalardan oldukça farklıdır. Elektrik piyasalarındaki fiyat hareketliliği büyük ölçüde kısıtlamalardan etkilenmektedir. Arz tarafında, sistem yapısı gereği her bir noktada üretimin tüketimi karşılaması gereklidir. Talep tarafında ise tüketim, tedarikçilerin davranışlarından ve mevsimsellikten etkilenir. Elektrik tüketimi ve fiyatları aylık, günlük ve saatlik olarak değişkenlik göstermektedir. Elektrik piyasalarındaki bu fiyat hareketliliğini hedef alınan piyasa verileri doğrultusunda uygun metot ve modeller ile doğru tahminlere dayandırarak, piyasada teklif verme ve fiyatlama stratejilerinde optimum bir çıkar sağlanabilir.

Bu kapsamda, elektrik piyasalarının son dönemlerdeki davranışları hakkında yapılan çalışmalarda çeşitli modeller önerilmektedir [22]. Gün öncesi piyasasında PTF tahmini yapmak, piyasada kazanç elde etmek için önemlidir. Literatürde PTF tahmini ile ilgili çok sayıda çalışma bulunmaktadır. Türkiye gün öncesi piyasasında yapılan PTF tahmini çalışmaları Tablo 1’de verilmiştir.

Tablo 1. Türkiye Gün Öncesi Piyasasında PTF Tahmini Yapan Çalışmalar

YAZAR	Kullanılan Metot	Kullanılan Değişkenler
Şenocak ve Kahveci [23]	Yapay Sinir Ağı (YSA)	Doğal Gaz üretim miktarı, Linyit üretim miktarı, Sıvı yakıtlar üretim miktarı
Demirezen ve Çetin [24]	Rassal Orman Regresyonu, Destek Vektör Regresyonu	PTF, Bir gün önceki fiyat, Bir ay önceki fiyat, Hafta sonu ve Hafta içi günler, Bir saat önceki fiyat, İki saat önceki fiyat, Üç saat önceki fiyat, İşlem hacmi

Ertaylan vd. [25]	YSA	Tarih, Saat, Bir gün önceki fiyat, Bir hafta önceki fiyat, Toplam tüketim miktarı, Gaz referans fiyatı, Tatil günleri
Akay vd. [26]	Uzun Kısa Süreli Bellek (LSTM), Destek Vektör Regresyonu	Sistem Marjinal Fiyatı
Arslan ve Ertuğrul [27]	Çoklu regresyon, YSA	Enerji üretim miktarı, Talep miktarı
Karatekin ve Başaran [28]	Lineer Regresyon, Polinom Regresyon, YSA, Xgboost	Gün öncesi saatlik takas fiyatı, Her bir elektrik üretim kaynağı için saatlik üretim
Şirin ve Yılmaz [29]	Quantile Regresyon	Talep miktarı, PTF, Rüzgâr üretim miktarı, Nehir Hidro miktarı üretim, Gaz üretim miktarı
Avcı vd. [30]	Zaman serisi, YSA, Mevsimsel model	Tahmini talep, Marj, Güne-özüğü değişken Tatil değişkeni
Tayşi vd. [31]	SARIMA, YSA	Bir gün önceki aynı saatteki PTF, Bir hafta önceki aynı saatteki PTF, Son 24 saatteki ortalama PTF
Uğurlu vd. [32]	Markov zinciri, CNN, SARIMA, LSTM, Navie Bayes, Kendi kendini Uyarıcı Eşik Otoregresif	24 saat gecikmeli fiyat, 168 saat gecikmeli fiyat, 1 saat gecikmeli fiyat, 48 saat gecikmeli fiyat, 23 saat gecikmeli fiyat, 72 saat gecikmeli fiyat, 336 saat gecikmeli fiyat, Talep tahmini, Sıcaklık, 24 saat gecikme ile gerçekleşen talep/arz, 24 saat gecikmeli piyasa fiyatının dengelenmesi
Özyıldırım ve Beyazıt [33]	Lineer Regresyon, Radyal tabanlı fonksiyon	PTF gecikme, Sıcaklık, Sıcaklığın karesi, Günlük, Aylık, Tatil değişkeni
Kölmek ve Navruz [34]	YSA, Otoregresif (AR)	Tarihsel gün öncesi fiyat, Talep tahmini, Ortalama sıcaklık, Tüketim tahmini, İkili sözleşme tutarı, Gün kodu
Avni Özözen vd. [35]	SARIMA, YSA	Gün öncesi saatlik PTF, Talep/Arz
Arifoğlu ve Kandemir [36]	Çok katmanlı Algılayıcı, CNN, LSTM	Haftanın günleri ve resmi tatiller, Gerçek zamanlı

		tüketim, Hidroelektrik elektrik üretimi, Sistem marjinal fiyatı, Yük tahmin planı, Rüzgâr hızı, Sıcaklık
--	--	--

Türkiye'nin elektrik fiyatlarının tahmini konusunda sunulan çalışmaların başında Yıldırım vd. [37], Özyıldırım and Beyazıt [33], Hayfavi and Talaslı [38] vardır. Türkiye spot elektrik piyasa fiyat tahmini için ilk sinir ağı yaklaşımını kullanarak literatüre öncü bir çalışma sunan Kölmek and Navruz [34], gün öncesi fiyat tahmini için YSA ve AR modellerini kullanmışlardır. Farklı olarak Yıldırım vd. [37] elektrik fiyat tahmini için konik çok değişkenli uyarlanabilir regresyon çizgileri (CMARS), dinamik regresyon ve Robust CMARS yöntemlerini kullanmışlardır. Yönteme bağlı olarak veri sınırlaması nedeniyle sonuçların kesinliği belirsizdir. Elektrik fiyat tahmini için ortalama spot fiyatı kullanarak çok faktörlü bir model oluşturan Hayfavi and Talaslı [38], bu modeli tahminlemeye alternatif olarak önermişlerdir. Modelde kullanılan parametreler ve varsayımlar, Türkiye'nin piyasa dinamiklerini tam olarak ele almamaktadır. Bu nedenle, Türkiye'nin gün öncesi elektrik piyasası için daha spesifik ve uygun olan diğer modellerin kullanılması önerilmiştir. Uğurlu vd. [32], doğrusal regresyon ve radyal tabanlı fonksiyon kapsamında fiyat tahminlemesinde sıcaklığın karesi, sıcaklık, tatil günleri, saatlik, günlük ve aylık fiyatlar gibi değişkenler kullanmış ve radyal tabanlı fonksiyonun daha iyi sonuç verdiğini belirtmiştir. SARIMA ve YSA yöntemleri kullanarak elektrik fiyat tahmini yapan Avcı vd. [30] değişken olarak çeşitli varyasyonlardaki PTF'yi kullanmışlardır. Taysi vd. [31] Türkiye Elektrik Piyasası için fiyat tahmin sistemlerinin değerlendirilmesini amaçlamıştır. ARIMA modeli ve ileri beslemeli yapay sinir ağı (YSA) olmak üzere iki farklı sistem oluşturmuşlardır. Her iki sistem de takvim bilgisi ve geçmiş fiyat verilerini kullanarak elektrik fiyatlarını tahmin etmektedir. Sonuçlara göre, her iki sistem de haftalık olarak elektrik fiyatlarını ortalama %8.5 hata oranıyla tahmin edebilmektedir. Ozozen vd. [35], Türkiye gün öncesi elektrik piyasası için birleşik bir metodoloji olan ARIMA ve YSA zaman serisi kullanmışlardır. Bu çalışma, verilerin eksik olabileceği ve geçmiş verilere büyük ölçüde bağımlı olunan piyasalarda zaman serisi tahmini için SARIMA ve geri yayılım (back-propagation) öğrenmeli YSA'dan oluşan yeni bir hibrit model önermektedir. Türkiye elektrik piyasasında tamamen serbestleşmemiş elektrik ticaretinde uyguladıkları model ile tahminindeki hataların ortalama %4 azaldığını ve %30'luk bir iyileşme sağladığını savunmaktadırlar [35].

Türkiye elektrik piyasasına ilişkin literatür incelendiğinde, araştırma makalelerinin az olduğu ve çalışmaların çoğunluğunun doktora tezleri veya konferans tutanakları düzeyinde olduğu ve birçoğunun gün öncesi piyasası kurulmadan önceki dönemi temsil ettiği ve bu çalışmalarda da yeterli veri setlerinin kullanılmadığı gözlemlenmiştir. Mevcut piyasa koşullarını ve son dönem veri zenginliğini tam yansıtan ve doğru elektrik fiyat tahmini yapan çalışmaların eksikliği görülmektedir. Başlıca eksikler, yenilenebilir enerji kaynaklarının artışından sonraki incelemelerin yetersizliği, kullanılan verilerin ve yöntemlerin açık kaynak olarak ulaşılamaması, elektrik fiyatına etkileyen değişken parametrelerin net olarak belirlenmemesi, her bir parametrenin etki düzeylerinin belirtilmemesi ve model açıklanabilirliğinin göz ardı edilmesi gibi hususlardır.

Literatür taramasında görüldüğü gibi çalışmaların çoğu YEK kapasitesinin piyasadaki fiyatlara etkisini incelemektedir ve YEK kapasitesindeki artışların elektrik piyasalarında fiyatları genellikle azalttığı gözlemlenmiştir. Bu tezde, elektrik piyasasında yenilenebilir kapasite artışının piyasa takas fiyatı üzerindeki etkisi incelenecektir. Çalışmamız, literatürdeki YEK ve elektrik piyasalarında piyasa takas fiyatı tahmini ile ilgili mevcut boşlukları ele almayı hedeflemektedir.

1.5. Araştırmanın Amacı

Günümüzde artan enerji talebi ve çevresel kaygılar, sürdürülebilir ve yenilenebilir enerji kaynaklarına olan ilgiyi her zamankinden daha fazla artırmaktadır. Fosil yakıtların tükenebilir ve çevreye zarar verici özellikleri, temiz ve yenilenebilir enerji kaynaklarının önemini daha da pekiştirmektedir. Rüzgâr, güneş, hidroelektrik ve biyokütle gibi yenilenebilir enerji kaynakları, karbon ayak izini azaltmanın yanı sıra enerji arz güvenliğini sağlamada da büyük bir rol oynamaktadır.

Bu çalışmanın amacı, yenilenebilir enerji kapasitesinin artışının elektrik piyasaları ve fiyatı üzerindeki etkilerini incelemektir. Özellikle yenilenebilir enerji kaynaklarının yaygınlaşmasının elektrik fiyatlarına nasıl yansıdığı ve arz güvenliği açısından ne gibi değişikliklere yol açtığı değerlendirilmiştir.

Yenilenebilir enerji kapasitesinin elektrik piyasasındaki miktar ve oranının artmasının piyasa üzerindeki etkileri, makine öğrenmesi algoritmaları ve SHAP analizi ile incelenmiştir. Yenilenebilir enerji kaynaklarının, özellikle rüzgâr ve güneş enerjisi gibi

çok düşük marjinal maliyetlere sahip olduđu göz önünde bulundurulduğunda, elektrik fiyatlarının düşürülmesinde etkin bir rol oynayacağı düşünülmektedir. Çalışma kapsamında, yenilenebilir enerji kaynaklarının farklı türlerinin (güneş, rüzgâr, hidroelektrik, biyokütle, vb.) piyasa üzerindeki etkileri ayrı ayrı ele alınacak ve bu etkilerin genel enerji sistemine katkıları analiz edilecektir. Ayrıca, piyasa takas fiyatı tahmininde değişkenlerin etkilerinin de detaylı analizleri yapılmıştır.


1.6. Araştırmanın Önemi

Elektrik enerjisi sektöründe yaşanan yeniden yapılanma çalışmalarının hız kazanması ve akademik alandaki elektrik piyasalarının modellenmesi ile ilgili çalışmaların artması, enerji sektörünün gelecekteki yönelimleri ve kararlarının belirlenmesinde büyük önem taşımaktadır. Özellikle YEK kullanımının artmasıyla birlikte, enerji piyasalarında karşılaşılan zorluklar ve değişen dinamikler üzerine yapılan araştırmalar, sektördeki paydaşların daha bilinçli ve etkili stratejiler geliştirmesine yardımcı olmaktadır. Bu nedenle, elektrik piyasalarının modellenmesi ve yenilenebilir enerji entegrasyonu üzerine yapılan bu tür çalışmalar, sadece akademik bir merak değil, aynı zamanda sektördeki uygulayıcılar ve politika yapıcılar için de büyük önem taşımaktadır. YEK payının artması ve enerji sisteminin elektrifikasyonunun hızlanması gibi önemli dönüm noktaları ile karşı karşıya olan sektör, bu tür araştırmaların sonuçlarına dayanarak daha sürdürülebilir ve rekabetçi bir enerji geleceği inşa etmek için kritik kararlar alabilir. Bu çalışmaların sonuçları, enerji politikalarının şekillendirilmesinde ve sektördeki aktörlerin stratejik planlamalarında önemli bir rehberlik sağlamaktadır.

2. BÖLÜM

YÖNTEM VE MATERYAL

Makine Öğrenimi (Machine Learning, ML), bilgisayarları açıkça programlamadan öğrenmeye ve tahminlerde bulunmaya veya kararlar almaya yeten algoritmalar ve modeller geliştirmeye adanmış yapay zekâ tekniklerinin bir alt kümesidir. ML, algoritmaları eğitmek için veri kullanmayı içerir, böylece desenleri tanıyabilir, çıkarımlar yapabilir ve performanslarını artırabilirler. Temel olarak ML, deneyimden öğrenip adapte olabilen sistemler oluşturur, bu da onu görüntü tanıma ve doğal dil işlemeden öneri sistemlerine ve otonom araçlara kadar çeşitli uygulamalar için değerli kılar. ML, veriden öğrenme konusuna odaklanan çeşitli alt alanlardan oluşur (*Şekil 8*). Bu alt alanlar genellikle örtüşür ve birindeki ilerlemeler diğerlerine fayda sağlayabilir. Alt alan ve teknik seçimi, belirli bir probleme ve veri türüne bağlıdır.



Şekil 8. Makine Öğrenimi Modelleri

2.1. Tezin Yöntemi

Bu tez kapsamında, EPİAŞ platformunda bulunan Gün Öncesi Piyasası (GÖP) verileri kullanılarak elektrik fiyatlarının tahmin edilmesi ve fiyata etkileyen faktörlerin detaylı incelenmesi amacıyla çeşitli yöntemler ve modeller karşılaştırılmıştır. Çalışmada, EPİAŞ'ın şeffaflık platformunda¹ yer alan ve 1 Ocak 2018 ile 01 Ocak 2023 tarihleri arasında toplanan 5 yıllık veri seti değerlendirilmiştir. Rassal orman, karar ağacı, destek vektör makinesi, CatBoost, XGBoost, LightGBM ve ayrıca Keras ile sıralı (sequential) yapay sinir ağları modelleri kullanılmıştır. Modellerin hiperparametre optimizasyonu ise GridSearch yöntemi ile yapılmıştır. Ayrıca, piyasa elektrik fiyatına etki eden faktörleri anlama ve yenilenebilir enerji kapasitesindeki artışın elektrik piyasalarına etkisini belirlemek için SHAP analizi yöntemi kullanılmıştır.

¹ <https://seffaflik.epias.com.tr>

Bununla birlikte, elektrik fiyat tahmini sürecinde hem tüm değişkenler kullanılarak hem de Temel Bileşen Analizi (PCA) ile boyut indirgeme yöntemi uygulanarak modellerin performansları karşılaştırılmıştır. Özellikle, PCA ile veri setindeki varyansın büyük kısmını açıklayan bileşenler seçilmiş ve bu bileşenlerle tahmin modelleri yeniden oluşturulmuştur. Ek olarak, Rassal Orman modelinin öznelik önemi (*feature importances*) yöntemi kullanılarak, modelde yer alan değişkenlerin elektrik fiyatına etkisi analiz edilmiştir. Bu sayede, model performansını iyileştirmek ve yorumlanabilirliği artırmak için hangi özelliklerin daha önemli olduğu belirlenmiştir.

2.2. Kullanılan Makine Öğrenimi Modelleri

Light Gradient Boosted Machine (LightGBM), gradyan artırma algoritmasının verimli ve etkili bir şekilde uygulanmasını sağlayan açık kaynaklı bir kütüphanedir. LightGBM, gradyan artırma algoritmasını daha büyük gradyanlı örnekler üzerine odaklanarak ve otomatik özellik seçimi ekleyerek geliştirir. Bu, eğitim sürecinde hızlı ve daha iyi tahmin performansı sağlayabilir [83].

Extreme Gradient Boosting (XGBoost), gradyan artırma algoritmasının verimli ve etkili bir şekilde uygulanmasını sağlayan açık kaynaklı bir kütüphanedir. XGBoost, regresyon modelleme için doğrudan kullanılabilir. Gradient boosting, sınıflandırma veya regresyon tahmine dayalı modelleme problemleri için kullanılabilen bir grup makine öğrenimi algoritması sınıfını ifade eder. Topluluklar, karar ağacı modellerinden oluşturulur [81]. XGBoost'ta son tahmin oluşturulurken rassal ormandan farklı olarak tüm ağaçların doğrusal toplamı alınmaktadır ve her ağacın amacı kendinden önceki ağaçların artık hatasını en aza indirmektir [83].

Derin öğrenmede yaygın olarak kullanılan Keras, yapay sinir ağları için yüksek seviye bir uygulama programlama arayüzüdür ve model oluşturma ve eğitim için arka planda TensorFlow'u kullanan bir araçtır. Keras kullanılarak ardışık katmanlardan sinir ağı oluşturulurken ilgili model için bir sarıcı sınıf kullanılır. Eğitim ve modeli çalıştırma işlemleri için kullanılan compile, fit ve evaluate gibi yöntemler Keras arayüzüne uygulanır. Keras'taki model yapısı, derleme aşamasında TensorFlow kütüphanesini kullanır. Keras ardışık sınıfı, önemli Keras ardışık modellerin bir parçası olan sınıflardan biridir ve büyük miktarda bilgi dizisi ile modelleri eğitmek için bir dizi algoritmayı kullanır.

Rassal Orman Regresyonu (RF), denetimli makine öğrenmesi yöntemlerinden birisidir. Boosting yöntemine alternatif olması için geliştirilmiştir [76,77]. RF hem regresyon hem de sınıflandırma problemlerine uygulanması, diğer yöntemlere göre daha hızlı eğitilmesi ve tahmin hızının daha yüksek olması, düzenleme parametre sayısının daha az olması, çok boyutlu problemlere doğrudan uygulanabilmesi gibi özelliklerinden dolayı dikkat çekmektedir [78]. RF, karar ağaçlarının en önemli dezavantajı olarak görülen eğitim verilerini aşırı öğrenme eğiliminde olması problemine bir çözüm yolu olma özelliği taşımaktadır [77].

Destek vektör makineleri (SVR), Vapnik-Chervonenkis teorisine dayanan denetimli bir makine öğrenmesi yöntemidir. SVR hem sınıflandırma hem de regresyon problemlerine uygulanabilmektedir [79]. SVR mantığı, doğrusal olmayan bir fonksiyon üzerinden girdi verilerinin eşlendiği daha yüksek boyutlu girdi uzayında bir doğrusal regresyon fonksiyonunun hesaplanmasına dayanmaktadır [80].

Karar Ağacı, sınıflandırma ve regresyon amacıyla kullanılan makine öğrenimi tekniklerinden biridir. Özellik değerleri ağaç benzeri bir modelden geçer ve dallar, if-else koşullarını andıran kurallarla nihai bir karara yönlendirir. Eğitim verisi işleme sürecinin bir sonucu olan Karar Ağacı modelinde, ID3 gibi ünlü algoritmalar birkaç aşamada çalışır. İlk olarak, her özelliğin entropisi hesaplanır. Entropi, çeşitlilik değeridir ve maksimum değeri 1'dir. Daha sonra, bilgi kazancı değeri hesaplanır ve bu değer, hangi özelliğin çıktıyı en çok etkilediğini gösterir. Son aşamada, ağaç her özelliğin bilgi kazancı ve entropi değerlerine göre düzenlenir. Model, toplanmış ve çıktıya sahip olan test verileri ile test edilir. Performans, test verilerinin çıktısını gerçek çıktılarla karşılaştırarak doğruluk üzerinden ölçülür. Karar ağacı aracılığıyla elde edilen hiyerarşik segmentasyon, n sayıda istatistiksel birim kümesini, optimizasyon kriterine göre homojen alt gruplara ayırır. Diğer modelleme tekniklerine kıyasla, Karar Ağacı modellemenin avantajı, sonuçların yorumlanabilirliğinin if-else karar kuralları ile basit olmasıdır [39,40].

CatBoost, son derece etkili bir makine öğrenimi yöntemi olarak öne çıkmaktadır, çünkü gradient tabanlı metodolojilere getirdiği yeniliklerle dikkat çekmektedir [41]. Özellikle kategorik ve sıralı niteliklerin yönetiminde Bayesian tahminciler kullanarak aşırı uyumu azaltma yeteneği ile bilinmektedir. CatBoost içinde, özellik önceliklendirmesi ise tahmin değeri değişikliği veya kayıp fonksiyonu değişikliği gibi yöntemlerle gerçekleştirilir. Bu

regresyon modeli, Gradient Boosting Decision Tree (GBDT) yöntemini temel alarak sürekli bir hedef değişkenini tahmin etmek üzere tasarlanmıştır. Özellikle kategorik değişkenlerin yoğun olduğu veri setlerinde, kompleks ilişkileri anlama ve doğrusal olmayan yapıları modelleme yeteneği ön plandadır. CatBoost'un ağaç tabanlı yapısı, veri setindeki etkileşimleri ve değişken ilişkilerini yakalamak için optimize edilmiştir. Bu da büyük veri setlerinde bile yüksek doğruluk ve performans sağlamasını sağlar [42,43].

2.3. Temel Bileşen Analizi ve Öznitelik Önemi

Temel bileşen analizi (Principal Component Analysis, PCA), çok boyutlu veri setlerindeki varyansı koruyarak boyut azaltma işlemi yapan etkili bir yöntemdir. PCA, yüksek boyutlu verileri daha anlaşılabilir ve yönetilebilir hale getirmek amacıyla, orijinal özniteliklerin doğrusal kombinasyonlarından oluşan yeni değişkenler (ana bileşenler) üretir. Bu ana bileşenler, veri setindeki en büyük varyansı açıklayan doğrultulara göre sıralanır. İlk bileşen, en yüksek varyansı temsil ederken, sonraki bileşenler daha az varyans açıklayarak veriyi özetler. Boyutun fazla olduğu veri setlerinde hesaplama maliyetleri ve analiz süreçleri zorlaşırken, PCA gereksiz boyutları ortadan kaldırarak daha hızlı ve verimli modellerin oluşturulmasına olanak tanır. Sonuç olarak, PCA hem veri analizini sadeleştirir hem de makine öğrenmesi algoritmalarının performansını optimize eder [44,45].

Öznitelik önemi (*feature importance*), makine öğrenimi modellerinde her bir özneliğin sonuç değişkeni üzerindeki etkisini değerlendiren önemli bir yöntemdir. Bu analiz, hangi özniteliklerin modele daha fazla katkı sağladığını belirleyerek tahminlerin açıklanabilirliğini artırır ve modelin performansını iyileştirir. Ağaç tabanlı modellerde bilgi kazancı veya öznitelik kullanım sıklığına göre sıralamalar yapılırken, lineer modellerde katsayılar özniteliklerin etkisini gösterir. Ayrıca SHAP gibi daha karmaşık yöntemler de kullanılarak özniteliklerin katkıları analiz edilebilir. Bu sayede, hedef değişkene en çok katkı sağlayan öznitelikler ön plana çıkarılarak modelin optimizasyonu yapılabilir ve veri setinin boyutu azaltılarak daha hızlı, basit ve etkili modeller oluşturulabilir [46,47].

2.4. Model Performans Değerlendirme Metrikleri

Bu tez çalışmasında model performansını değerlendirmek için 5 hata ölçüsü kullanılmıştır. Bunlar R^2 , MSE, MAE, RMSE ve MAPE'dir. R-kare (R^2), korelasyon katsayısının karesidir ve modeldeki bağımsız değişkenlere göre bağımlı değişkenin varyasyon oranını yani bağımlı değişkendeki değişkenliğin ne kadarının model tarafından açıklanabileceğini ölçer. Bağımsız değişkenle bağımlı değişken arasındaki ilişkinin gücünü 0-1 aralığında gösterir. R^2 değeri 1 ise tam korelasyon vardır. Yani R^2 değeri 1'e yaklaştıkça model doğruluğu artmaktadır. R^2 aşırı uyum (overfitting) sorununu dikkate almaz. $SS_{Residual}$ hata karelerinin toplamı ve SS_{Total} ortalama farkların toplamı olmak üzere R^2 şöyle hesaplanır:

$$R^2 = 1 - \frac{SS_{Residual}}{SS_{Total}} \quad (1)$$

Ortalama Kare Hatası (Mean Squared Error, MSE), bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu gösterir. MSE, bir makine öğrenmesi modelinin performansını ölçer ve her zaman pozitif değerlidir. MSE değeri sıfıra yakın olan modelin daha iyi bir performans gösterdiği söylenebilir. Y_i gerçek değerler, $\hat{y}_i$ tahmin edilen değerler ve N örnek sayısı olmak üzere MSE şöyle hesaplanır:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2)$$

Ortalama Mutlak Hata (Mean Absolute Error, MAE), iki sürekli değişken arasındaki farkın ölçüsüdür. MAE, veri kümesinin tüm örneğinde, o örnek için gerçek değer ile öngörülen değer arasındaki her bir farkın mutlak değerinin ortalamasıdır. MAE, regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır ve şöyle hesaplanır;

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3)$$

Kök Ortalama Kare Hata (Root Mean Square Error, RMSE), bir makine öğrenmesi modelinin tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan ve hatanın büyüklüğünü ölçen ikinci dereceden bir metriktir. RMSE, tahmin hatalarının (kalıntıların) standart sapmasıdır. Kalıntılar, regresyon hattının veri

noktalarından ne kadar uzakta olduğunun bir ölçüsüdür. RMSE ise bu kalıntıların ne kadar yayıldığıнын bir ölçüsüdür. Verilere en iyi uyan çizgi etrafında o verilerin ne kadar yoğun olduğunu söyler. RMSE değeri sıfırdan sonsuza kadar değişebilir. Düşük değerlere sahip tahminleyiciler daha iyi performans gösterir. RMSE değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir. RMSE, MSE'nin kareköküdür ve şöyle hesaplanır;

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{n}} \quad (4)$$

Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error, MAPE), pozitif ve negatif hataların birbirini götürmesini önlemek için mutlak değerleri kullanan ve zaman serisi modelleri arasında tahmin doğruluğunu karşılaştıran bir hata ölçüsüdür. MAPE değeri %10 altında olan tahmin modelleri yüksek doğruluk derecesine sahiptir. MAPE değeri %10 ile %20 arasında olan modeller ise doğru tahmin modelleri olarak sınıflanabilir. MAPE şöyle hesaplanır:

$$MAPE = \frac{\sum_{j=1}^N \frac{|y_j|}{\hat{y}_j}}{N} \quad (5)$$

Bu, makine öğreniminde modellerin performansını değerlendirmek için kullanılan yaygın değerlendirme metrikleridir, özellikle regresyon problemleri bağlamında. Her metrik farklı bir amaca hizmet eder ve hangi metriğin kullanılacağı, problemimizin özel karakteristiklerine ve değerlendirmenin vurgusuna bağlıdır. R^2 , uyumun ne kadar iyi olduğunu anlamak için kullanılır. MSE ve RMSE, hata büyüklüğünü ölçmek için kullanılır; RMSE, hedef değişkenle aynı birimlerde hata ölçüsü sağlar. MAE, basit ve açıklanabilir bir hata ölçüsü istendiğinde, özellikle aykırı değerlere daha az duyarlıdır. MAPE, yüzde olarak tahmin doğruluğunu değerlendirmek için kullanılır, genellikle tahmin senaryolarında. Bu metriklerin hepsini uyguladık, böylece ihtiyaç duyulduğunda diğer çalışmalarla karşılaştırmalar yapılabilir.

2.5. Veri Seti ve Model Uygulama

Bu tez çalışmasında öncelikle, Türkiye Gün Öncesi Piyasası (GÖP) piyasa takas fiyatı (PTF) için tahmin yöntemlerinin karşılaştırılması sunulmaktadır. Algoritmalar, Enerji Borsası İstanbul (EXIST) Şeffaflık Platformu, Petrol Boru Hatları İşletme AŞ (BOTAŞ)

ve Meteoroloji Genel Müdürlüğü tarafından sağlanan verileri kullanarak her gün için saatlik PTF tahmini oluşturur. Veri seti, 1 Ocak 2018'ten 31 Aralık 2022'ye kadar olan süreyi kapsamaktadır. Tablo 2'deki MCP özelliği, saat başı gözlemlenen PTF'yi temsil eder ve algoritmaların bağımlı değişkenidir. Diğer özellikler ise modellerin eğitiminde kullanılan bağımsız değişkenlerdir.

Türkiye gün öncesi piyasası elektrik fiyat tahmini için 1 Ocak 2015 ile 1 Ocak 2023 yılları arası veri seti EPIAŞ platformundan alınmıştır. Tablo 2'de veri setindeki değişkenlerin özellikleri ayrıntılı bir şekilde verilmektedir. Tablo 3'te ise veri setine bir örnek gösterilmektedir. Türkiye gün öncesi piyasa fiyatını tahmininde en doğru modeli oluşturmak için şu prosedürler uygulanmıştır ve alt bölümlerde detayları verilecektir:

- Hedef değişkenin ve ihtiyaç duyan modeller (SVR ve Sequential model) için girdi değişkenlerinin normalleştirilmesi,
- Verilerin ön işleme (veri setindeki eksik veriyi tamamlama, tekrarlanan ve aykırı verileri kaldırma, dönüştürme, temizleme, normalleştirme ve boyut indirgeme işlemlerine) tabi tutularak eğitim ve test seti olmak üzere ayrılması,
- Seçilen modellerin hiperparametre optimizasyonu,
- Sonuçlarda hataların incelenmesi ve hataları azaltmak için en iyi modeli etkileyen önemli bağımsız değişkenler seçilerek incelenmesi.

Tablo 2. Veri Seti

Özellik	Açıklama	Mean	Std	Min	Max
MCP	Piyasa Takas Fiyatı	67.44	49.87	0.000	66.63
HOLY	Haftaiçi/Haftasonu	0.69	0.462	0.000	1.000
MCP-24	Bir gün önceki fiyat	67.38	49.81	0.000	66.305
MCP-168	Bir hafta önceki fiyat	66.79	46.66	0.000	65.23
MCP-672	Bir ay önceki fiyat	65.01	46.66	0.000	62.08
PISO	Fiyattan Bağımsız Satış Emri	11334.9	2856.4	3721.1	23000.6
PIBO	Fiyattan Bağımsız Teklif Emri	18811.5	4594.1	3721.3	43135.4
SSOV	Gönderilen Satış Sipariş Hacmi	29642.2	4767.8	10444.2	44737.7
SBOV	Gönderilen Teklif Sipariş Hacmi	24578.5	4623.18	10715.2	47542.8
MO	Eşleşen Teklifler Miktarı	19744.9	3776.73	9640.1	32222.5
MB	Eşleşen Teklif Miktarı	19745.1	3776.62	9640.2	32223.7
TV	Ticari Değer	1364707	1074959	0.000	6442106
DER	Günlük Döviz Kuru	8.593	4.398	3.732	18.703

TG	Toplam Üretim	34207.7	5208.5	15333.3	51285.6
NG	Doğal Gazdan Üretim	8954.022	3999.599	496.66	19453.6
HYD	Hidro Barajdan Üretim	5727.2	2921	296.6	15891.7
LIG	Linyit Kömüründen Üretim	4953	614.35	2189.1	6984.1
RHYD	Hidro Nehirden Üretim	2217.5	1324.9	379.9	6103.5
ICOAL	İthal Kömürden Üretim	6913.3	1771.4	956.3	10138.8
WIND	Rüzgârdan Üretim	2992.83	1824.53	42.53	9327.7
SOL	Güneş Enerjisinden Üretim	114.06	245.31	-1.70	1289.82
FUEL	Fuel Oil'den Üretim	84.48	59.37	0.000	237.6
GEO	Jeotermalden Üretim	1021.9	177.328	525.11	1357.3
ASPH	Asfaltit Kömürden Üretim	246.67	84.61	0.000	368.72
BCOAL	Kara Kömürden Üretim	403.43	116.19	77.5	692.63
BIO	Biyokütleden Üretim	523.18	219.35	202.58	1011.2
IMEX	İthalat-İhracat Elektrik Hacmi	-27.01	315.92	-3130	1648.5
WAS	Atık Isıdan Üretim	82.85	13.63	30.69	127.76
GASP	Doğal Gaz Fiyatı	377.06	303.5	162.85	1444.5
ANK	Ankara'nın saatlik ortalama sıcaklığı	13.7	9.29	-13	38.6
IST	İstanbul'un saatlik ortalama sıcaklığı	16.39	7.57	-2.6	35.9

Tablo 3. Veri Seti Örnek

Değişkenler - Endeks	20496	69110	56528	54275	33239
Date (MM/DD/YYYY)	05/4/2018	11/9/2022	06/3/2021	03/1/2022	1/16/2018
Hour	12:00AM	02:00PM	08:00AM	11:00AM	11:00PM
HOLY	1	0	0	1	1
PTF	38.32	204.35	37.85	44.31	50.49
PTF-24	46.11	228.28	42.96	44.47	50.15
PTF-168	41.84	177.62	31.10	45.03	47.62
PTF-672	40.79	188.49	41.17	40.11	47.91
PISO	3821.1	13325.0	11511.10	11934.3	6,321.4
PIBO	4154.5	22089.8	21836.60	26197.7	13331.0
SSOV	24599.60	27573.5	28817.80	29369.5	26748.2
SBOV	10887.6	27545.5	27273.20	32147.1	21645.3
MO	9645.1	22449.9	22319.40	26441.4	13991.3
MB	9768.4	22449.9	22319.40	26441.40	13991.3
TV	575271.5	4830462	995033.5	1170308	724016.6
DER	3.52	18.59	8.42	7.60	5.87
TG	29623.56	38461.7	31989.97	39657.47	31303.91
NG	9080.66	6632.21	14911.33	12108.81	10738.83
HYD	6663.42	2742.24	2553.60	10652.92	3093.80
LIG	3143.93	5571.35	4901.77	4566.95	5219.39
RHYD	4354.49	907.82	1267.23	1622.79	692.85
ICOAL	3401.76	10024.07	4390.8	6434.91	8049.09
WIND	1312.45	8159.26	748.78	1440.92	1671.00


SOL	0.00	542.27	447.82	355.96	0.00
FUEL	170.50	69.70	41.90	37.70	140.40
GEO	523.10	1130.19	1173.97	1183.59	851.95
ASPH	264.95	97.15	340.01	282.70	348.85
BCOAL	446.5	540.12	465.35	441.66	181.50
BIO	182.00	903.05	701.90	633.47	265.05
IMEX	0.00	1052.24	-41.22	-196.60	0.00
WAS	79.80	90.03	86.73	91.69	51.20
GASP	165.87	1053.96	206.91	173.89	276.68
ANK	12.00	18.10	21.90	7.80	16.20
IST	14.30	20.40	22.60	6.60	18.40

2.5.1. Veri Ön İşleme Aşaması


Veri ön işleme, veri setlerindeki hataları veya yanlış verileri düzeltmek, eksik verileri doldurmak, veri normalleştirme ve veri boyutunu azaltmak için kullanılır. Ayrıca, veri özelliklerini ölçeklendirir ve makine öğrenimi modellerinin performansını artırır. Standardizasyon, verileri ortalama 0 ve standart sapması 1 olacak şekilde ölçeklendirir. K-en yakın komşular ve destek vektör makineleri gibi mesafe ölçümlerine dayanan algoritmalar için özellikle yararlıdır. Normalleştirme, verileri 0 ile 1 arasında bir aralığa ölçeklendirir. Bu teknik, sınır ağları ve kümeleme algoritmaları gibi ağırlığa duyarlı modellere dayanan algoritmalar için faydalıdır.

Veri ölçeklendirme, makine öğrenimi modellerini eğitirken çok önemlidir. Çünkü çoğu algoritma hem girdi hem de çıktı verilerinin önceden hazırlanmasını gerektirir. Bu amaçla, veri özelliklerini ve hedef değişkenleri uygun hale getirmek için basit veri işleme süreçleri uygulanmıştır. Giriş verilerini düzenlemek için kullanılan "ölçekleyici" ve modelin tahmin ettiği değerleri düzenlemek için kullanılan "dönüştürücü" birbirinden farklıdır. Her iki işlev de performansı optimize etmeye yardımcı olan dört farklı hiperparametre seçeneği ile ayrı ayrı değerlendirilir.

Korelasyon, veri setindeki değişkenler arasında doğrusal ilişkinin yönünü ve etkisini göstermektedir. Böylece veri setinde mantıksal çıkarım yaparak tahminlemeye etkisi olmayan değişkenler belirlenebilmektedir. Değişkenler arasındaki doğrusal ilişkiler *Şekil 9*'da verilmektedir. Piyasa kapanış fiyatını etkileyen parametrelerin pozitif ve negatif yönlü etkisi de *Şekil 10*'da gösterilmektedir.



Şekil 9. Korelasyon Isı Haritası



Şekil 10. PTF'yi etkileyen bağımsız değişkenler

2.5.2. Model Uygulama

Veri ön işleme aşamasının ardından, makine öğrenimi ve yapay sinir ağları modelleri oluşturulmuştur. Veri seti, %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Min-Max ölçeklendirme yöntemiyle veri ölçeklendirme işlemi uygulanarak, modelleme süreci iyileştirilmiş ve özellikler arasındaki büyüklük farkları ortadan kaldırılmıştır. Bu işlem, özellikle SVR ve YSA modellerinde, veri değerlerini 0 ile 1 arasında normalize ederek gerçekleştirilmiştir. Buna karşın, RF, XGBoost, CatBoost, LightGBM ve Karar Ağaçları gibi ağaç tabanlı modeller, özelliklerin göreceli sıralamalarını temel alarak çalıştıkları için verilerin ölçeklenmesine ihtiyaç duymazlar. Bu modellerin performansı, özelliklerin mutlak değerleri yerine bölünme noktalarının belirlenmesiyle etkilendiğinden, özellikler arasındaki büyüklük farklarının bu tür modellerin karar verme süreçlerine etkisi olmaz. Bu durum, veri hazırlık süreçlerini sadeleştirir ve söz konusu modellerin çeşitli veri setlerine esnek bir şekilde uygulanabilmesine olanak tanır.

Çalışmada 7 farklı model uygulanmıştır. Bütün modellerde, öncelikle temel (vanilla) bir model oluşturulmuştur. Ardından, eğitim ve test verileri üzerinde aşırı uyma (overfitting) olup olmadığını ve eğitim hatasını (underfitting) kontrol etmek için çapraz doğrulama (cross-validation) uygulanmıştır. Çapraz doğrulama, bir modelin performansını değerlendirmek ve genelleme yeteneğini ölçmek amacıyla veri setini belirli parçalara böler. Model, bu parçalardan birini test etmek ve diğerleriyle eğitmek için tekrarlanarak kullanılır. Bu yöntem, daha güvenilir performans ölçümleri elde etmenin yanı sıra overfitting veya underfitting gibi problemleri tespit etme konusunda da etkilidir.

Hiperparametreleri optimize etmek amacıyla GridSearch gibi teknikler kullanılarak en iyi tahminleme modeli geliştirilmiştir. GridSearch, bir modelin hiperparametrelerini belirlemek için kullanılan bir optimizasyon yöntemidir. Belirli bir hiperparametre kombinasyon seti oluşturulur, bu kombinasyonlarla model eğitilir ve performans metrikleri değerlendirilir. Sistemli bir hiperparametre araştırması yaparak, en iyi kombinasyonu otomatik olarak bulma sürecini gerçekleştirir.

Ek olarak, özellikler arasındaki bağımlılık ve ilişkiyi daha iyi anlayabilmek ve modelin daha az sayıda bileşenle yüksek performans göstermesini sağlamak amacıyla Temel Bileşen Analizi uygulanmıştır. PCA, veri setindeki orijinal değişkenler arasındaki korelasyonu azaltarak boyut indirgeme için kullanılmış ve modellerin performansları hem


tüm değişkenlerle hem de PCA ile elde edilen bileşenlerle karşılaştırılmıştır. Bu sayede, tahmin modellerinin boyut indirgeme ile nasıl iyileştirildiği incelenmiştir.

2.5.2.1. Temel Bileşen Analizi Uygulaması

PCA (Principal Component Analysis), veri setindeki çok boyutluluğu azaltarak, değişkenler arasındaki korelasyonu ortadan kaldıran ve varyansın büyük kısmını koruyan etkili bir yöntemdir. Bu yöntemle, orijinal değişkenlerin doğrusal birleşimlerinden oluşan yeni bileşenler elde edilerek, veri daha sade ve yorumlanabilir hale getirilir. PCA analizi sırasında, farklı varyans yüzdelere açıklayacak bileşen sayıları incelenmiştir. Yapılan analizler sonucunda, %85 varyansı açıklamak için yaklaşık 10 bileşenin, %90 varyansı için 12 bileşenin ve %95 varyansı için ise yaklaşık 15 bileşenin yeterli olduğu belirlenmiştir. Bu değerlendirmeler, verideki bilgiyi en az bileşenle açıklayarak modelin karmaşıklığını azaltmayı ve performansını optimize etmeyi hedeflemiştir. Bu şekilde, PCA analizi, veri setindeki kritik bilgiyi kaybetmeden boyutluluğun düşürülmesini sağlamaktadır.

Şekil 11'de, PCA ile kümülatif olarak açıklanan varyans oranı bileşen sayısına göre grafikte görülmektedir. *Şekil 11* incelendiğinde, bileşen sayısının artmasıyla açıklanan varyansın hızla arttığı ve yaklaşık 12 bileşenden sonra bu artış hızının azaldığı görülmektedir. Bu noktada toplam varyansın %90'dan fazlası açıklanmıştır. Şekil üzerinde bir diz bükülme noktası (elbow point) gözlenmekte olup, bu nokta yaklaşık olarak 5 ila 10 bileşen arasında bulunmaktadır. Diz bükülme noktası, daha az sayıda bileşenle en fazla varyansın açıklanabildiği yeri temsil eder.

Bu doğrultuda, 12 bileşen seçmek, verideki toplam varyansın %90'dan fazlasını açıklamak için yeterli olabilir. Bu seçim, daha az sayıda bileşenle veri setinin büyük bir kısmındaki varyansı açıklama amacına hizmet ederken, aynı zamanda modelin karmaşıklığını da kontrol altında tutar.



Şekil 11. PCA ile Açıklanan Varyans Oranı

2.5.2.2. Öznitelik Önemi Uygulaması

Öznitelik önemi, makine öğrenmesi modellerinin performansını artırmak ve bağımsız değişkenlerin hedef değişken üzerindeki etkilerini daha net değerlendirebilmek amacıyla sıklıkla kullanılan bir analiz tekniğidir. Bu çalışma kapsamında, yedi farklı makine öğrenmesi modeli (Random Forest, XGBoost, LightGBM, CatBoost, Decision Tree, Sequential Model ve SVR) kullanılarak öznitelik önemleri hesaplanmış ve modellerin performansını optimize etmek için Recursive Feature Elimination with Cross-Validation (RFECV) ve permutation_importance teknikleri uygulanmıştır. LightGBM, XGBoost, CatBoost, Random Forest, Decision Tree ve SVR modellerinde RFECV yöntemi kullanılarak her iterasyonda modelin tahmin gücüne düşük katkı sağlayan öznitelikler sistematik olarak elenmiş, bu şekilde modelin tahmin gücünü en üst düzeye çıkaracak alt öznitelik kümesi elde edilmiştir. RFECV sürecinde model, her adımda çapraz doğrulama katmanlarıyla test edilerek, model performansına en fazla katkıyı sağlayan özellikler korunmuş ve gereksiz ya da düşük önem taşıyan özellikler çıkarılmıştır. Derin öğrenme tabanlı Sequential Model'de ise öznitelik önemleri permutation_importance yöntemi ile belirlenmiş, modelin tahmin gücüne düşük katkıda bulunan öznitelikler elenerek modelin

daha sade, geliştirilebilir ve aşırı öğrenmeye karşı daha dayanıklı bir yapıya ulaşmasını sağlamaktadır.

2.5.3. Model Açıklanabilirliği

SHAP (SHapley Additive Explanations) değeri, bir modelin farklı özelliklerinin bir hedef değişkeni üzerindeki etkisini açıklayan bir yöntemdir [48]. Makine öğrenmesi modellerinin karar verme süreçlerini anlamayı ve yorumlamayı kolaylaştırır. Bu sayede modelin karmaşıklığı ve karar verme mekanizması anlaşılabilir, özelliklerin önemi ve etkisi değerlendirilebilir ve modelin önyargılarını ve açıklanabilirliğini analiz etmemizi sağlar.

Elektrik piyasası fiyat tahmininde kullanılan modeller karmaşık ve yorumlanması zor olabilir. SHAP değerleri, bu modellerin hangi özelliklere dayalı olarak fiyat tahmini yaptığını ve her bir özelliğin tahmindeki etkisini açıklar. Bu bilgiler, modelin güvenilirliğini ve açıklanabilirliğini artırır. SHAP değerleri, her bir özellik için pozitif veya negatif bir değer üretir. Pozitif değerler, özelliğin fiyat tahminini artırdığını, negatif değerler ise azalttığını gösterir.

Bu çalışmada, model açıklanabilirliğini daha da artırmak için Rassal Orman modelinin önemlilik önemi (feature_importances_) yöntemi kullanılarak, her bir özelliğin elektrik fiyat tahminine olan katkısı analiz edilmiştir. Bu yöntem, modelin hangi özelliklere daha fazla ağırlık verdiğini ve bu özelliklerin elektrik fiyatları üzerindeki etkisini anlamamızı sağlar. Özelliklerin önem sırası belirlenerek, elektrik piyasasındaki kritik değişkenler tespit edilmiş ve modelin performansını artırmak amacıyla bu bilgiler kullanılmıştır. Ayrıca, PCA analizinden elde edilen temel bileşenler ile SHAP değerleri birleştirilerek, boyut indirgeme sonrası açıklanabilirliğin nasıl etkilendiği değerlendirilmiştir.

Bu tezde, makine öğrenmesi modellerinin karar verme süreçlerini açıklamak ve yenilenebilir enerji kapasitesinin artışının elektrik piyasalarına etkisini daha iyi anlamak amacıyla SHAP yöntemi kullanılmıştır. SHAP yöntemi, yenilenebilir enerji kaynaklarının (rüzgâr ve güneş enerjisi gibi) elektrik fiyatları üzerindeki etkisini değerlendirmede kritik bir rol oynamıştır. Bu yöntem, modelin açıklanabilirliğini artırarak farklı özelliklerin hedef değişken üzerindeki etkisini anlamamıza olanak tanır. Özellikle, yenilenebilir enerji kaynaklarının marjinal maliyetlerinin düşüklüğünün piyasa

fiyatlarını nasıl etkilediğini ve bu kaynakların artışının piyasa dinamiklerini nasıl değiştirdiğini daha net bir şekilde açıklamak için SHAP değerleri kullanılmıştır. Bu sayede, yenilenebilir enerji kapasitesindeki artışın elektrik piyasalarındaki fiyatlandırma mekanizmalarına olan etkisi daha ayrıntılı ve anlaşılır bir biçimde ortaya konulmuştur.



3. BÖLÜM

BULGULAR

Bu çalışma, Türkiye'nin gün öncesi elektrik piyasalarında yenilenebilir enerji tüketiminin piyasası takas fiyatı (PTF) üzerindeki etkisini kapsamlı bir şekilde incelemektedir. EPİAŞ, Meteoroloji Genel Müdürlüğü ve BOTAŞ'tan elde edilen 2018-2023 verileri kullanılarak, çeşitli makine öğrenimi modelleri (RF, DT, SVR, XGBoost, CatBoost, LightGBM ve Sequential Model) ile Türkiye gün öncesi elektrik piyasası takas fiyatı tahmin edilmiştir. Bunun yanı sıra, Temel Bileşen Analizi (PCA) kullanılarak boyut indirgeme yöntemi uygulanmış ve verideki temel bileşenler çıkarılarak modellerin performansı bu bileşenler üzerinden de değerlendirilmiştir. PCA, veri setindeki değişkenlerin birbirleriyle olan ilişkisini azaltarak modelin daha verimli çalışmasını sağlamıştır.

Ayrıca, öznitelik önemi yöntemi kullanılarak, modelin fiyat tahminlerinde hangi değişkenlerin daha etkili olduğu belirlenmiş ve piyasa fiyatlarına en fazla etki eden faktörler tespit edilmiştir. Bu analiz, modelin açıklanabilirliğini artırarak hangi özelliklerin daha kritik olduğunu ortaya koymuştur. SHAP değerleri ile birlikte, özellik önem sıralamaları ve yenilenebilir enerji üretimindeki artışın elektrik piyasalarındaki fiyatlandırmaya etkisini daha detaylı ve anlaşılabilir bir şekilde ortaya koymaktadır.

3.1. Öznitelik Önemi ve Temel Bileşen Analizi Sonuçları

Bu bölümde, elektrik fiyat tahmini için kullanılan çeşitli makine öğrenimi modellerinin performansları, Temel Bileşen Analizi (PCA) ve Öznitelik Önemi (Feature Importance) yöntemleriyle kapsamlı bir şekilde değerlendirilmiştir.

3.1.1. Temel Bileşen Analizi Kullanılarak Bağımsız Değişkenlerin Analizi

Bu çalışmada, 30 bağımsız değişkenden oluşan veri setine PCA uygulanarak değişkenlerin bileşenlere katkıları ve açıklanan varyans oranları incelenmiştir. Analizin amacı, veri setinin açıklayıcı gücünü en iyi temsil eden bileşen sayısını belirlemektir. Bu kapsamda, verinin %85, %90 ve %95'ini açıklayan bileşen sayıları dikkate alınarak analizler gerçekleştirilmiş, %85 varyans oranını açıklamak için 10 bileşen, %90 varyans oranını açıklamak için 12 bileşen ve %95 varyans oranını açıklamak için 15 bileşen kullanılmıştır.

Yapılan analizler sonucunda, %90 varyansı açıklayan 12 bileşenin verinin en anlamlı özetini sunarak en iyi tahmin sonuçlarını verdiği gözlemlenmiştir. Bu nedenle, modelleme sürecinde %90 varyansı açıklayan 12 bileşenli yapı tercih edilmiştir. Bu seçim, veri setindeki değişkenlerin açıklayıcı gücünü en iyi şekilde temsil ederken, aynı zamanda bilgi kaybını en aza indirmeyi ve modelin sadeliğini korumayı amaçlamıştır.

Şekil 12'de, her bir bağımsız değişkenin 12 PCA bileşeni üzerindeki yüklemeleri görselleştirilmiştir. Bu grafik, her bir değişkenin hangi PCA bileşenine ne ölçüde katkı sağladığını göstermektedir. Yüksek pozitif ve negatif yüklemelere sahip değişkenler, ilgili bileşenler üzerinde önemli bir açıklayıcı güce sahip olup, bu durum bileşenlerin yorumlanabilirliğini artırmaktadır. Örneğin, *Şekil 12*'de PCA-8 bileşeninin Haftaici/Haftasonu (HOLY) değişkeni üzerinde önemli bir etkiye sahip olduğu görülmektedir. HOLY, bu bileşende yüksek bir pozitif yükleme ile yer almakta olup, bileşenin varyansının büyük ölçüde bu değişken tarafından açıklandığını göstermektedir. Aynı şekilde, PCA-11 bileşeni üzerinde Asfaltit Kömürden Üretim (ASPH) değişkeni güçlü bir etkiye sahip olup, bu bileşenin varyansının önemli bir kısmı ASPH tarafından açıklanmaktadır. Ayrıca, PCA-12 bileşeni, İthalat-İhracat Elektrik Hacmi (IMEX) ve Atık Isıdan Üretim (WAS) değişkenleri arasındaki anlamlı ilişkileri ortaya koyarak, bu iki değişkenin PCA-12 üzerindeki açıklayıcı rolünü vurgulamaktadır.

Aynı zamanda, negatif yüklemeler de önemli bilgi sağlamaktadır. Yüksek negatif yüklemeler, ilgili değişkenlerin bileşenler üzerinde ters yönlü bir etkide bulunduğunu göstermektedir. Örneğin, İthal Kömürden Üretim (ICOAL) ve Güneş Enerjisinden Üretim (SOL) değişkenleri, belirli bileşenler üzerinde negatif yönlü etkiye sahip olup, bu bileşenlerin varyansını azaltıcı yönde etkilemektedir. Bu tür analizler, hangi bileşenlerin

daha fazla açıklayıcı güce sahip olduğunu ve hangi değişkenlerin bu bileşenlere nasıl etki ettiğini açıkça ortaya koymaktadır.


Bu analizler, PCA'nın veri boyutunu azaltmadaki etkinliğini göstermekte ve orijinal değişkenlerin çok boyutlu yapısını daha iyi anlamamıza yardımcı olmaktadır. 12 bileşenle yapılan analizlerde, veri setinin büyük bir kısmının anlamlı şekilde özetlenebildiği, dolayısıyla modelin performansının artarak karmaşıklığın kontrol altına alınabildiği gözlemlenmiştir. Bu bağlamda, %90 varyansı açıklayan 12 bileşen seçimi hem modelin açıklayıcılığını optimize etmekte hem de sadelik ile performans arasındaki dengeyi sağlamaktadır.

Şekil 13'te, bağımsız değişkenlerin tüm PCA bileşenlerine olan toplam katkıları, yüklemelerinin karelerinin toplamı üzerinden görselleştirilmiştir. Bu grafik, hangi değişkenlerin PCA analizi sonucunda veri setinin toplam varyansını açıklamada en etkili olduğunu göstermektedir.


Öne çıkan bulgulara göre, HOLY, ASPH ve Linyit Kömüründen Üretim (LIG) değişkenleri, PCA bileşenlerine en yüksek katkıyı sağlayarak, veri setindeki toplam varyansın büyük bir kısmını açıklamaktadır. *Şekil 13*'te görüldüğü üzere, HOLY 0.992, ASPH 0.974 ve LIG 0.865 değerleriyle en dikkat çekici katkıları sunmakta, bu da söz konusu değişkenlerin PCA modelinde baskın bir rol oynadığını göstermektedir. Bu değişkenler, modelleme sürecinde önemli bir etkiye sahip olup, verinin temel yapılarının PCA ile doğru bir şekilde yakalanmasına katkıda bulunur. IMEX, WAS ve Rüzgârdan Üretim (WIND) gibi orta düzeyde katkı sağlayan değişkenler de PCA bileşenleri üzerinde dikkate değer bir rol oynasa da IMEX'in 0.803 değerindeki katkısı gibi, bu etkiler HOLY, ASPH ve LIG ile karşılaştırıldığında daha sınırlı kalmaktadır. Bunun yanında, Bir ay önceki fiyat (MCP_672) ve Günlük Döviz Kuru (DER) gibi değişkenler, sırasıyla 0.150 ve 0.138 gibi düşük katkı değerleriyle PCA'nın veri setindeki varyansı açıklamada daha az önem verdiği değişkenler arasında yer almakta ve bu tür değişkenler boyut azaltma süreçlerinde göz ardı edilebilir olarak değerlendirilmektedir.

Yüksek katkı sağlayan değişkenler, özellikle HOLY, PCA bileşenlerinin oluşturulmasında veri setinin büyük bir kısmını açıklayan temel yapıları temsil etmektedir. Bu değişkenler, verideki toplam varyansla güçlü bir ilişki içinde olup, modelleme sürecinde ihmal edilmeleri durumunda modelin öngörü gücünde önemli bir

kayba yol açabileceği görülmektedir. HOLY gibi değişkenler, modelin performansını büyük ölçüde artırırken, veri setindeki yapısal bilgiyi doğru bir şekilde özetlerler. Öte yandan, düşük katkı sağlayan değişkenler, örneğin GASP ve DER, PCA bileşenlerinde daha az bilgi taşımakta ve veri setinin boyutunun azaltılması söz konusu olduğunda göz ardı edilebilecek unsurlar olarak değerlendirilmektedir. Bu değişkenler, PCA'nın açıkladığı varyansın küçük bir bölümünü temsil ettikleri için modelin genel performansına sınırlı katkı sağlarlar. Sonuç olarak, bu grafik, PCA'nın veri setindeki hangi değişkenlerin daha fazla önem taşıdığını ve veri boyutunun nasıl etkili bir şekilde azaltılabileceğini görselleştirir. Yüksek yüklemelere sahip değişkenler, modelin temel yapı taşlarını oluştururken, düşük katkıya sahip olanlar daha az önem arz etmektedir. Bu da modelleme süreçlerinde hangi değişkenlerin odak noktası olması gerektiğini ve hangi değişkenlerin veri boyutunu düşürürken göz ardı edilebileceğini anlamamıza dair önemli ipuçları sunmaktadır.



Şekil 12. Değişkenlerin PCA Bileşenlerine Katkısı



Şekil 13. Bağımsız Değişkenlerin Toplam PCA Katkısı

3.1.2. Öznitelik Önemi Kullanılarak Bağımsız Değişkenlerin Analizi

Öznitelik önemi, makine öğrenmesi modellerinin başarımını artırmak ve modeldeki bağımsız değişkenlerin hedef değişkene olan etkilerini daha iyi anlamak için yaygın olarak kullanılan bir analiz yöntemidir. Bu çalışmada, farklı makine öğrenmesi algoritmaları ile öznitelik önemleri hesaplanmış ve her model için RFECV yöntemi uygulanmıştır. Amaç, model performansını en üst düzeye çıkarmak için en etkili bağımsız değişkenleri belirlemek ve düşük öneme sahip değişkenleri elemek olmuştur. RFECV, modelin tahmin gücüne katkı sağlamayan öznitelikleri iteratif olarak çıkararak, en iyi performansı sağlayacak özellik alt kümesini oluşturmayı hedefler. Özellikle geniş ve karmaşık veri setlerinde, bu yöntem daha sade ve genellenebilir modeller elde edilmesine yardımcı olmaktadır.

Bu çalışmada, 30 bağımsız değişkenden oluşan veri setinde öznitelik önemleri hesaplanmış ve bu değişkenlerin hedef değişken üzerindeki etkileri detaylı bir şekilde analiz edilmiştir. Şekil 14'teki görselleştirmeler kullanılarak öznitelik öneminin değerlendirilmesi yapılmış ve bağımsız değişkenlerin tahmin gücüne olan katkıları ile bu katkıların dereceleri analiz edilmiştir.

Şekil 14.a'da sunulan LightGBM modeline göre, 25 bağımsız değişken seçilmiş ve bu değişkenlerin büyük bir kısmı modele önemli katkılar sağlamıştır. Özellikle MCP_168, GASP, MCP_672, DER ve MCP_24 gibi değişkenlerin model performansına en yüksek


katkısı sunduğu görülmektedir. LightGBM, geniş çaplı değişken setlerini etkin bir şekilde işleyebilmesi ile bilinir ve burada da büyük oranda değişkenin modelin açıklayıcılığına önemli katkılar sağladığı gözlemlenmiştir. Diğer modellere kıyasla LightGBM’de seçilen değişkenlerin çoğunun öznitelik değerleri daha yüksektir, bu da modelin geniş bir değişken setine dayalı olarak güçlü bir tahmin performansı sunduğunu göstermektedir.

Şekil 14.b’deki CatBoost ve Şekil 14.d’deki Sequential model için yapılan analizler de genel olarak bağımsız değişkenlerin yüksek katkılar sağladığını ortaya koymaktadır. Bir gün önceki fiyat (MCP_24) ve bir hafta önceki fiyat (MCP_168) her iki modelde de öne çıkarken, diğer önemli değişkenlerin de modele kayda değer katkılar sunduğu görülmektedir. Bu modellerde özellikle öznitelik önem dağılımının daha dengeli olduğu gözlemlenmiştir. CatBoost, özellikle kategorik veriler üzerinde etkili olduğu için birçok değişkenin model açıklayıcılığına katkıda bulunduğu fark edilirken Sequential modelde ise MCP_24 ve MCP_168 gibi değişkenlerin önemi daha baskın bir şekilde öne çıkmaktadır. Bu modellerin genel performansı, bağımsız değişkenlerin geniş bir kısmının modele anlamlı katkılar sunmasından kaynaklanmaktadır.

Şekil 14.c’de sunulan XGBoost ve Şekil 14.e’de sunulan SVR modellerinde, MCP_24, MCP_168, Doğal Gaz Fiyatı (GASP) ve Bir ay önceki fiyat (MCP_672) gibi değişkenlerin öznitelik önemleri diğer değişkenlere kıyasla çok daha yüksektir. Bu modellerde, özellikle bu dört değişkenin model performansında merkezi bir rol oynadığı, diğer değişkenlerin ise daha düşük katkılar sunduğu gözlemlenmektedir. XGBoost, performans odaklı bir model olarak bilinir ve burada da tahmin gücünün büyük bir kısmının bu anahtar değişkenler tarafından sağlandığı anlaşılmaktadır. Benzer şekilde, SVR modeli de bu dört değişkene büyük ölçüde dayanmakta ve diğer değişkenler modelin performansına sınırlı katkı sunmaktadır.

Şekil 14.f’deki RF ve Şekil 14.g’deki DT modellerinde ise MCP_24 ve MCP_168 gibi değişkenlerin öznitelik önemlerinin öne çıktığı görülmektedir. Bununla birlikte, diğer bağımsız değişkenlerin öznitelik önemleri bu iki modelde oldukça düşüktür. Özellikle, GASP ve MCP_672 gibi değişkenlerin öznitelik değerleri, XGBoost ve SVR modellerine kıyasla daha düşük seviyelerde kalmaktadır. RF ve DT modellerinde, sadece birkaç anahtar değişkenin modele anlamlı katkı sunduğu, geri kalan değişkenlerin ise modelin tahmin performansında daha az etkili olduğu anlaşılmaktadır.

Sonuç olarak, yapılan analizler, Bir gün önceki fiyat (MCP_24), Bir hafta önceki fiyat (MCP_168), Doğal Gaz Fiyatı (GASP) ve Bir ay önceki fiyat (MCP_672) gibi değişkenlerin modellerin performansına en büyük katkıyı sağladığını göstermektedir. Bu değişkenler, özellikle hedef değişkenin tahmininde merkezi bir rol oynamaktadır. Bununla birlikte, Fuel Oil'den Üretim (FUEL), Ankara'nın saatlik ortalama sıcaklığı (ANK), Asfaltit Kömürden Üretim (ASPH) ve Atık Isıdan Üretim (WAS) gibi değişkenler, genel olarak modellerde düşük öznitelik değerlerine sahip olup, model performansını iyileştirme sürecinde göz ardı edilebilir. Bu sonuçlar, veri setindeki önemli değişkenlerin belirlenmesi ve model sadeleştirme süreçlerinde hangi değişkenlerin öncelikli olarak ele alınması gerektiğine dair değerli bilgiler sunmaktadır.



Şekil 14. Makine öğrenimi Modellerin Öznitelik Önemi Analizi: (a) LightGBM, (b) CatBoost, (c) XGBoost, (d) Sequential, (e) SVR, (f) RF, (g) DT

3.2. PCA ve Öznitelik Önemi Yöntemlerin Karşılaştırılması

PCA, veri setinin boyutunu azaltmak ve modellerin hesaplama yükünü hafifletmek amacıyla kullanılmış, öznitelik önemi analizi ise modellerin tahminlerde hangi özelliklere öncelik verdiğini belirlemek üzerine yoğunlaşmıştır. Her iki yöntem de boyut indirgeme ve öznitelik seçiminin model performansı üzerindeki etkilerini incelemek için uygulanmıştır. Tüm tahmin modellerinin hata metriklerine göre hata oranları, test ve eğitim olarak **Hata! Başvuru kaynağı bulunamadı.** ve **Hata! Başvuru kaynağı bulunamadı.**'te verilmiştir. *Şekil 15*'teki grafikte, sonuçların güvenilirliğini sağlamak ve overfitting veya underfitting gibi durumları değerlendirmek açısından önem taşımaktadır. Bu tablo ve grafiklerin birlikte değerlendirilmesi, modellerin performansını kapsamlı bir şekilde analiz etmemize olanak tanımaktadır.

PCA yöntemi, modellerdeki değişken sayısını azaltarak hesaplama yükünü hafifletmek ve modelin daha hızlı çalışmasını sağlamak amacıyla uygulanmıştır. PCA ile, veri setindeki değişkenlerin korelasyon yapıları incelenmiş ve verinin %90'ini açıklayan optimal bileşen sayısı belirlenmiştir. Aşağıda, PCA uygulanarak elde edilen model sonuçları ve bu sonuçların hata metrikleri verilmiştir.

PCA sonrası en iyi model, CatBoost olmuştur. CatBoost modelinde, %90 varyansı açıklayan 12 bileşen ile yapılan tahminlerde R^2 skorları eğitim setinde 0.998, test setinde ise 0.947 olarak ölçülmüştür. CatBoost ve SVR modelleri, testte yüksek (R^2 : 0.947 ve 0.946) doğruluk ile en iyi sonuçları sunmaktadır. LightGBM ve XGBoost modeli de aynı yüksek doğruluk (R^2 : 0.941) ve düşük hata oranları sırasıyla (MAE: 6.84, RMSE: 12.12, MAE: 6.48, RMSE: 12.07) ile dikkate değer bir performans sergilemektedir. Random Forest ve Sequential modelleri belirli metriklerde iyi sonuçlar verse de genel olarak daha yüksek hata oranlarına sahiptir. Karar Ağaçları modeli ise, en düşük doğruluk (R^2 : 0.889) ve en yüksek hata oranları (MAE: 9.52, RMSE: 16.71) ile diğer modellere kıyasla daha zayıf bir performans göstermektedir. Bu değerlendirme, CatBoost ve SVR modellerinin genel performans açısından en iyi seçenekler olduğunu, ancak model seçiminde performans metriklerinin dikkatlice analiz edilmesi gerektiğini vurgulamaktadır.

Öznitelik önemi yöntemiyle yapılan analizlerde, modellerin hangi değişkenlere daha fazla ağırlık verdiği belirlenmiştir. Yapılan öznitelik önemi analizi, her bir modelin tahmin performansını etkileyen kritik özellikleri belirlemekte ve model optimizasyon sürecini

desteklemekte önemli bir rol oynamıştır. Bu analiz sonucunda, çeşitli modeller için önemli özellikler seçilerek gereksiz özelliklerin çıkartılması suretiyle model performansı iyileştirilmiştir. Özellikle LightGBM modelinde 25 önemli özellik belirlenmiş ve bu özelliklerle optimize edilen model, test setinde 0.953 R^2 değeri elde ederek en iyi performansı göstermiştir. CatBoost modeli ise 27 önemli özellik kullanılarak optimize edilmiş ve test setinde 0.952 R^2 değeri elde edilmiştir. Benzer şekilde, XGBoost modelinde 29 önemli özellik kullanılarak 0.948 R^2 değeri elde edilmiş, SVR modelinde ise 30 özellik kullanılarak 0.936 R^2 değerine ulaşılmıştır. Random Forest modelinde ise 29 önemli özellik kullanılarak 0.934 R^2 değeri elde edilmiş, son olarak Sequence modeli 30 özellik kullanılarak optimize edilmiş ve bu modelde 0.917 R^2 değeri elde edilmiştir. Bu bulgular, optimize edilmiş modellerin varsayılan modellere göre daha başarılı olduğunu ve özellikle LightGBM ve CatBoost modellerinin öznitelik seçimi sonrasında elde edilen önemli performans artışını ortaya koymaktadır.

PCA ve öznitelik önemi yöntemleri sonucunda elde edilen bulgular, her iki yöntemin de modellerin performansını artırmada önemli katkılar sağladığını göstermektedir. PCA kullanılarak gerçekleştirilen boyut indirgeme sonucunda en iyi modeller CatBoost ve SVR modelleri olarak öne çıkarken, en düşük performansı Karar Ağacı (DT) modeli sergilemiştir. Benzer şekilde, öznitelik önemi yöntemiyle gerçekleştirilen analizlerde de en iyi sonuçlar LightGBM ve CatBoost modelleri ile elde edilmiştir; en kötü performans ise yine Karar Ağacı modeli tarafından gösterilmiştir. Bu bulgu, her iki yöntemde de CatBoost modelinin tutarlı bir şekilde en iyi performansı sergilediğini ortaya koymaktadır. Öznitelik önemi yönteminde elde edilen sonuçlar, PCA'ya göre daha yüksek doğruluk oranlarına ve daha optimize edilmiş bir model performansına işaret etmektedir. Öznitelik önemi yönteminin, değişkenler arası ilişkileri daha iyi analiz ederek modelin etkinliğini artırdığı gözlemlenmiştir.


Sonuç olarak, CatBoost modeli hem PCA ile boyut indirgeme hem de öznitelik önemi yöntemleriyle optimize edilen modeller arasında tutarlı bir şekilde en iyi sonuçları vermiştir. Aynı zamanda LightGBM modeli de öznitelik önemi yöntemiyle yapılan analizlerde en iyi performans gösteren modellerden biri olmuştur. Bu durum, CatBoost ve LightGBM modellerinin, özellikle öznitelik seçimi ve boyut indirgeme süreçlerine duyarlı olarak, elektrik fiyat tahmini için en uygun modeller olarak öne çıktığını göstermektedir.

Tablo 4. PCA için Eğitim ve Test kümesi


	Kriter									
	R ²		MAE		MSE		RMSE		MAPE	
Model	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
RF	0.990	0.934	23.7	162.2	2.59	6.91	4.87	12.73	25.41	56.53
SVR	0.981	0.946	2.42	5.78	47.6	134.2	6.90	11.58	13.71	24.29
XGBT	0.999	0.941	0.74	6.48	1.05	145.7	1.02	12.07	4.23	39.89
YSA	0.998	0.940	1.55	7.42	4.88	148.3	2.21	12.18	10.51	32.52
CBT	0.998	0.947	1.16	6.23	2.74	130.4	1.65	11.42	6.76	31.78
LGBM	0.998	0.941	1.51	6.84	4.63	146.9	2.15	12.12	9.16	36.99
DT	0.941	0.889	7.37	9.52	145.60	279.2	12.06	16.71	53.45	106.7

Tablo 5. Öznitelik Önemi için Eğitim ve Test kümesi


		Kriter									
		R ²		MAE		MSE		RMSE		MAPE	
Model	Değişken Sayısı	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
RF	29	0.989	0.934	2.9	6.5	26.5	163	5.15	12.7	24.3	40
SVR	30	0.994	0.944	3.4	6.6	14.6	138	3.82	11.7	24.4	33.9
XGBT	29	0.988	0.948	3.7	6.2	29.1	128	5.38	11.3	25.9	32.1
YSA	30	0.982	0.942	3.5	6.1	42.5	143	6.52	11.9	11.8	18.9
CBT	27	0.989	0.950	3.4	6	27.2	122	5.22	11	24.1	28.6
LGBM	25	0.990	0.953	3.3	5.8	24.5	116	4.95	10.7	14.6	33.8
DT	28	0.938	0.896	6.3	8.4	153	257	12.38	16	57	58.8




(a)




(b)



(c)



(d)



(e)

Şekil 15. Modellerin Hata Metrik Performanslarının Karşılaştırılması: (a) R^2 , (b) RMSE, (c) MSE, (d) MAE, (e) MAPE

3.3. Tüm Veri Seti Kullanılarak Elde Edilen Model Sonuçları

Bu bölümde yedi farklı modelin tahmin sonuçlarına yer verilmiştir. Tüm tahmin modellerinin hata metriklerine göre hata oranları test ve eğitim olarak verilmiştir. Tablo 6 ve Şekil 16'daki grafik, sonuçların güvenilirliğini sağlamak ve *overfitting* veya *underfitting* gibi durumları değerlendirmek için önemlidir.

Tablo 6 ve diğer şekillerin (Şekil 16 - Şekil 17) birlikte değerlendirilmesi, modellerin performansını kapsamlı bir şekilde analiz etmemizi sağlar. XGBoost ve LightGBM modelleri, eğitimde mükemmel (R^2 : 0.996) ve testte yüksek (R^2 : 0.93 ve 0.95) doğruluk ile en iyi sonuçları sunmaktadır. Random Forest modeli de yüksek doğruluk (R^2 : 0.93) ve düşük hata oranları (MAE: 6.61, RMSE: 12.9) ile dikkate değer bir performans sergilemektedir. Destek Vektör Regresyonu, Yapay Sinir Ağları ve CatBoost (CBT) modelleri belirli metriklerde iyi sonuçlar verse de genel olarak daha yüksek hata oranlarına sahiptir. Karar Ağaçları modeli ise, en düşük doğruluk (R^2 : 0.89) ve en yüksek hata oranları (MAE: 8.36, RMSE: 16.2) ile diğer modellere kıyasla daha zayıf bir performans göstermektedir. Bu değerlendirme, XGBoost ve LightGBM modellerinin genel performans açısından en iyi seçenekler olduğunu, ancak model seçiminde performans metriklerinin dikkatlice analiz edilmesi gerektiğini vurgulamaktadır.

Modellerin tahmin hatası grafiklerinde (Şekil 16) gerçek değerler x ekseninde, modellerin tahmin ettiği değerler ise y ekseninde gösterilir. Yeşil noktalar, modelin her bir veri noktası için yaptığı tahmini temsil eder. Kırmızı çizgi, modelin mükemmel bir tahmin yapacağı ideal bir durumu gösterir. Siyah çizgi ise modelin eğitim verisi üzerinde en iyi


uyumu saęlayan eğriyi temsil eder. Siyah ve kırmızı çizgiler ne kadar yakın olursa, modelin tahminleri o kadar doğrudur.

Elektrik fiyat tahmini için kullanılan farklı modellerin görsel karşılaştırmaları incelenerek çeşitli makine öğrenimi modellerinin performansının kapsamlı bir karşılaştırması yapılmıştır. Bu analizde, LightGBM modeli (*Şekil 16.g*), gerçek değerler ve tahminler arasında mükemmel bir uyum sergileyerek diğer tüm modelleri geride bırakan en iyi performans gösteren model olarak belirlenmiştir. XGBoost (*Şekil 16.a*) ve CatBoost (*Şekil 16.f*) modelleri de LightGBM'e yakın ancak biraz gerisinde yüksek performanslarıyla öne çıkmıştır ve elektrik fiyat tahmini için güçlü alternatifler olarak kabul edilebilir. Sequential model (*Şekil 16.d*) ve SVR (*Şekil 16.c***Hata! Başvuru kaynağı bulunamadı.**) ortalama performans göstermiş, yüksek performanslı modellerin gerisinde kalmış ancak yine de tatmin edici sonuçlar vermiştir. Ancak, Rastgele Orman modeli (*Şekil 16.b*) bu iki modelden daha düşük performans sergilemiştir. En düşük performans ise Karar Ağacı modeli (*Şekil 16.e*) tarafından gösterilmiştir. Bu sonuçlar, LightGBM modelinin elektrik fiyat tahmini için en uygun seçenek olduğunu, diğer modellerin ise çeşitli performans düzeylerine göre belirli durumlar ve ihtiyaçlar için değerlendirilebileceğini göstermektedir. LightGBM modelinin *Şekil 16.g*'de görülen siyah ve kırmızı çizgilerinin örtüşmesi, bu modelin elektrik fiyat tahmininde (PTF) en iyi performansı gösteren model olduğunu açıkça ortaya koymaktadır. Bu örtüşme, modelin tahminlerinin gerçek değerlerle mükemmel bir uyum içinde olduğunu ve PTF'yi en iyi şekilde açıklayan yöntem olduğunu gösterir. LightGBM modeli, diğer modellere kıyasla daha doğru tahminler yapmaktadır. Bu durum, modelin PTF'yi etkileyen faktörleri daha iyi yakaladığını ve daha sağlam bir tahminleme gerçekleştirdiğini gösterir.


Tüm tahmin modellerinin R^2 , MSE, MAE, RMSE ve MAPE metriğine göre hata oranları *Şekil 17*'de verilmiştir. DT modelinde 2018-2022 yılları arasında hata metriklerine göre bu modelin diğer modellere göre daha başarısız tahmin yaptığı sonucuna varılmıştır. Bunun yanı sıra CatBoost ve XGBoost modelleri daha iyi sonuçlar ortaya koysalar da *Şekil 17*'de hata oranları ve grafik incelemeleri sonucunda en başarılı tahminlerin LightGBM modeli ile yapıldığı görülmektedir.

Tablo 6. Eğitim ve Test Kümesi


	Kriter									
	R ²		MAE		MSE		RMSE		MAPE	
Model	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
RF	0.99	0.93	2.88	6.61	24.95	166	4.99	12.9	20.65	64.8
SVR	0.956	0.94	6.08	6.92	108.7	145	10.42	12	43.63	8
XGBT	0.996	0.93	2.23	6.45	10.74	124	3.27	11.1	13.82	6.45
YSA	0.957	0.94	5.88	6.16	106.7	154	10.33	12.4	5.86	6.86
CBT	0.983	0.94	4.31	6.51	41.26	131	6.42	11.4	30.21	48.7
LGBM	0.996	0.95	2.26	5.98	10.94	126	3.31	11.2	14.62	49.6
DT	0.950	0.89	6.36	8.36	125.3	269	11.19	16.2	16.42	97.7




(a)




(b)




(c)




(d)



(e)




(f)



(g)

Şekil 16. Model Tahmin Hatası: (a) XGBoost, (b) RF, (c) SVR, (d) Sequential, (e) DTR, (f) CatBoost, (g) LightGBM




Şekil 17. Modellerin sonuçları

3.4. Piyasa Takas Fiyatına Etki Eden Parametrelerin Açıklanabilirliği

SHAP (SHapley Additive Explanations), Lloyd Shapley tarafından oyun teorisi temelli geliştirilen bir kavram olup her bir özelliğin model tahminlerine katkısını nicel olarak belirleyerek kompleks makine öğrenimi modellerinin yorumlanabilirliğini artırır [48]. SHAP değeri, bir modelin farklı özelliklerinin bir hedef değişkeni üzerindeki etkisini açıklayan bir yöntemdir. Makine öğrenmesi modellerinin karar verme süreçlerini anlamayı ve yorumlamayı kolaylaştırır. Bu sayede modelin karmaşıklığı ve karar verme mekanizması anlaşılabilir, özelliklerin önemi ve etkisi değerlendirilebilir ve modelin önyargılarını ve açıklanabilirliğini analiz etmemizi sağlar.

Elektrik piyasası fiyat tahmininde kullanılan modeller karmaşık olup, yorumlanmaları zor olabilir. SHAP değerleri, bu modellerin fiyat tahminlerini hangi özelliklere dayandığını ve her bir özelliğin tahmin üzerindeki etkisini açıklar. Bu bilgiler, modelin güvenilirliğini ve açıklanabilirliğini artırmaktadır. SHAP değerleri, her bir özellik için pozitif veya negatif bir değer üretir. Enerji piyasası tahmin modelinde kullanılan özelliklerin model çıktıları üzerindeki etkisi, SHAP özet grafiği aracılığıyla yorumlanabilir. SHAP değerleri, her bir özelliğin modelin karar verme sürecine katkısını ortaya koyarak, enerji piyasası analistlerine ve karar vericilere değerli bilgiler sağlar. Bu analiz, enerji piyasalarında gelecekteki fiyat dinamiklerini daha iyi anlamak ve tahmin etmek için kritik öneme sahiptir.

SHAP grafiğinde (örneğin *Şekil 18*), x-ekseni boyunca noktaların dağılımı, her bir özelliğin tahmin edilen değişken (MCP) üzerindeki etkisinin büyüklüğünü ve yönünü nicel olarak belirleyen SHAP değerlerini yansıtır. Y-ekseni, fiyat tahminini etkileme açısından özelliklerin genel önemine göre sıralar. Kırmızı noktalar yüksek özellik değerlerini, mavi noktalar ise düşük özellik değerlerini temsil eder. Örneğin, *Şekil 18*'de MCP-24 değişkeninin en yüksek değeri olan \$264, açık kırmızı bir nokta ile gösterilmiş olup, buna karşılık gelen SHAP değeri x ekseninde +98'dir ve bu, fiyat üzerinde önemli bir pozitif etkiyi ifade eder. Buna karşılık, MCP-24'ün en düşük değeri olan \$0, açık mavi bir nokta ile gösterilmiş olup, SHAP değeri -30'dur ve bu, fiyat üzerinde belirgin bir negatif etkiyi belirtir.




Şekil 18. LightGBM Shap Değeri

Pozitif SHAP değerlerine sahip kırmızı noktaların varlığı, ilgili özelliğin MCP tahminlerini artırma eğiliminde olduğunu, negatif SHAP değerlerine sahip mavi noktalar MCP tahminlerini düşürme eğiliminde olduğunu gösterir. Sıfır eksenini etrafındaki noktaların yoğunluğu, özelliğin MCP üzerinde önemsiz bir etkisi olduğunu ima eder. Bu görselleştirmeleri analiz ederek, girdi özellikleri ile çıktı (MCP) arasındaki karmaşık ilişkiler hakkında değerli içgörüler elde edebiliriz. Bu bölümde, bireysel girdi özelliklerinin fiyat üzerindeki etkisini açıklamak için SHAP (SHapley Additive Explanations) analizi kullanılmıştır. İlk olarak en etkili özellikleri önceliklendiriyor, ardından enerji kaynaklarının elektrik fiyatları üzerindeki etkilerini kapsamlı bir şekilde incelendi. Son olarak, piyasa ile ilgili ve finansal özelliklerin fiyata katkısını derinlemesine ele alıyoruz. Bu sistematik yaklaşım, çeşitli faktörler arasındaki karmaşık etkileşimlerin ve bunların elektrik piyasasındaki fiyat belirlemesine olan toplu etkilerinin kapsamlı bir şekilde anlaşılmasını sağlar.

LightGBM modeline ilişkin SHAP değerleri *Şekil 18*'de ve diğer modeller için *Şekil 21-Şekil 22*'de sunulmuştur. SHAP değerleri, MCP-24 değişkenini, yani bir önceki günün fiyatını, sonraki gün fiyat tahmininde en etkili öngörücülerden biri olarak sürekli bir şekilde tanımlamaktadır. SHAP analizi, MCP-24'ün düşük değerlerinin tahmin edilen fiyat üzerinde belirgin bir negatif etki, yüksek değerlerinin ise güçlü bir pozitif etki oluşturduğunu açıkça ortaya koymaktadır. İncelenen tüm özellikler arasında, MCP-24'ün yüksek değerleri, fiyat üzerinde en büyük pozitif etkiye sahip değişken olarak öne çıkmaktadır. Bu, yüksek MCP-24 değerinin ertesi gün daha yüksek bir fiyat olasılığını anlamlı bir şekilde artırdığını işaret etmektedir. Buna karşılık, düşük MCP-24 değeri, ertesi gün daha düşük bir fiyat olasılığını göstermektedir. Koyu mavi, mor veya koyu kırmızı noktalarla sıfır SHAP değerleri etrafında kümelenmiş ara değerler göz ardı edilebilir bir etkiye sahiptir.

Benzer bulgular, sırasıyla geçen haftanın ve geçen ayın piyasa takas fiyatını temsil eden MCP-168 ve MCP-672 için de genişletilebilir. LightGBM modelinde MCP-24'ün etkisi kadar belirgin olmasa da genel eğilim tutarlılığını korumaktadır. SHAP grafiklerinde açık mavi noktalarla temsil edilen MCP-168 ve MCP-672'nin düşük değerleri, tahmin edilen fiyat üzerinde negatif bir etki yaratarak, ertesi gün daha düşük fiyatlar olasılığını işaret etmektedir. Buna karşın, bu değişkenlerin yüksek değerleri, daha yüksek fiyatların olasılığını artırmaktadır. Sıfıra yakın SHAP değerleri ile gösterilen edilen orta değerler, tahmin fiyatı üzerinde ihmal edilebilir bir etkiye sahiptir. Düşük değerler sergilediklerinde, MCP-24 ve MCP-168, gün türü (HOLY) ve kömürden enerji üretimi (ICOAL) ile birlikte fiyatı azaltmada en etkili değişkenler olarak öne çıkmaktadır.

Bu sonuçlar, otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) analizleri ile desteklenmektedir. ACF ve PACF, piyasadaki ortalama elektrik fiyatlarının zamansal davranışını değerlendirmektedir (*Şekil 19*). Bu analizler, PTF'nin geçmiş değerlerinin mevcut değerler üzerindeki etkisini belirlemede önemli bir rol oynamaktadır.



Şekil 19. Otokorelasyon (ACF) ve Kısmi Otokorelasyon (PACF) Analizi

ACF grafiğinin analizi, PTF verileri içindeki içsel ilişkiler hakkında önemli bilgiler sunmaktadır. Grafikte gözlemlenen başlangıçtaki yüksek değerler, PTF'nin kısa vadeli geçmiş verileri ile güçlü bir pozitif korelasyon göstererek, geçmiş değerlerin mevcut fiyat tahminlerinde kritik bir referans olabileceğini düşündürmektedir. Özellikle, birkaç saat veya bir gün öncesine ait kısa vadeli tarihsel veriler, mevcut fiyat değerlerini belirlemede önemli bir rol oynamaktadır.


PACF grafiği analizi, PTF ile geçmiş değerler arasındaki kısmi korelasyonları ortaya koymaktadır. Grafiğin başlangıç kısmındaki belirgin yüksek değerler, kısa vadeli geçmiş değerlerin PTF değerleri üzerinde önemli bir etkiye sahip olduğunu göstermektedir. Ancak, bu yüksek değerlerin hızla azalması, geçmiş değerlerin zamanla etkisinin azaldığına işaret etmektedir. Özellikle, ilk birkaç gecikme için yüksek PACF değerleri, mevcut MCP değerlerini tahmin etmede erken gecikmelerin kritik önemini vurgulamakta ve yakın geçmiş değerlerle daha güçlü bir ilişki olduğunu belirtmektedir. Bu bulgu, tarihsel verilerin, özellikle ilk birkaç saat veya günden gelen verilerin, mevcut MCP değerlerini tahmin etmede daha fazla dikkate alınması gerektiğini ortaya koymaktadır.

HOLY değişkeninin ikili (binary) yapısı, hafta içi günleri (HOLY=1) ve hafta sonları/tatiller (HOLY=0) temsil ederek bağımsız değerlendirme sürecini zorlaştırmaktadır. Bu değişkenin sınırlı değer aralığı ve model üzerindeki tutarsız etkileri, analiz sürecini karmaşıktırmaktadır. Sıfır SHAP değerlerine yakın yoğun kırmızı noktaların kümelenmesi, hafta içi günlerinin MCP zerinde küçük bir yukarı yönlü etki oluşturduğunu öne sürerken, hafta sonları/tatillerle ilişkilendirilen mavi noktaların x-ekseni boyunca daha geniş dağılımı, daha belirgin ancak oldukça değişken bir aşağı yönlü

etkiyi göstermektedir. Bu durum, tüm hafta sonları ve tatillerin fiyatların düşmesine neden olmadığını ima etmektedir. Dolayısıyla, HOLY değişkeninin fiyat üzerindeki etkisi izole bir şekilde kesin olarak belirlenememektedir. Bu değişkenin etkisinin, modeldeki diğer değişkenlerle olan etkileşimlere bağlı olduğu ve fiyat dalgalanmalarını doğru bir şekilde değerlendirmek için birden çok faktörün etkileşimini dikkate alan kapsamlı bir analiz gerektiği anlaşılmaktadır.


Günlük döviz kuru (DER) ile ilgili olarak, SHAP grafiğinin pozitif tarafında yoğun kırmızı noktaların dağılımı, yüksek DER değerleri ile fiyat artışı arasında güçlü bir pozitif korelasyon olduğunu ortaya koymaktadır. Bu durum, yüksek döviz kurunun ertesi gün elektrik fiyatlarını etkili bir şekilde artırdığını ifade etmektedir. Bu ilişki, Türkiye'nin elektrik üretiminin önemli bir kısmının ithal yakıtlara, özellikle doğalgaz (%22) ve kömüre (%17) olan büyük bağımlılığına atfedilebilir. Bu yakıtlar, toplam üretimin yaklaşık %40'ını oluşturmaktadır. DER arttıkça, bu yakıtların ithalat maliyeti yükselir ve bu da üretim maliyetlerinin artmasına ve dolayısıyla elektrik fiyatlarının yükselmesine neden olur. Buna karşılık, düşük DER değerlerini temsil eden mavi noktaların azlığı ve sıfır SHAP değerleri etrafında kümelenmeleri, düşük döviz kurlarının fiyat üzerinde ihmal edilebilir bir etkisi olduğunu göstermektedir. Bu durum, döviz kuru düşük olduğunda bile, elektrik fiyatlarını düşürmede önemli bir katkı sağlamadığını işaret etmektedir. Bu gözlem, yüksek döviz kurlarının fiyatlar üzerinde önemli bir yukarı yönlü baskı oluştururken, düşük döviz kurlarının sınırlı bir aşağı yönlü etkiye sahip olduğunu ve DER'in fiyat üzerindeki asimetric etkisini vurgulamaktadır.

Enerji üretim kaynaklarının incelenmesi hem yenilenebilir hem de fosil yakıtlardan üretilen elektrik miktarının fiyat üzerinde önemli bir etkisi olduğunu ortaya koymaktadır. Bu etkinin daha iyi anlaşılabilmesi için, bu kaynakların toplam elektrik üretimindeki paylarının dikkate alınması gerekmektedir. *Şekil 20*, 2022 yılı itibarıyla elektrik üretim paylarını göstermekte olup, her bir kaynağın fiyat üzerindeki etkisini yorumlamak için değerli bir bağlam sunmaktadır. Bu analiz, elektrik piyasasındaki fiyat dalgalanmalarını incelerken enerji karışımının bileşiminin dikkate alınmasının önemini vurgulamaktadır.




Şekil 20. Türkiye'de 2022 Yılı İtibariyle Elektrik Üretim Payları

Beklenin aksine, SHAP analizi, yüksek hidroelektrik üretiminin (HYD) fiyat ile pozitif bir ilişki gösterdiğini ortaya koymaktadır; bununla birlikte, bu etkinin LightGBM modelinde nispeten küçük olduğu saptanmıştır. Bu gözlem, tüm modellerde tutarlı bir şekilde tekrarlanmakta olup, CatBoost (Şekil 21.a) ve XGBoost (Şekil 21.b) modellerinde benzer etki büyüklükleri gözlemlenerek bu beklenmedik bulguya daha fazla güven sağlamaktadır. Bu karşı sezgisel sonuç, Türkiye elektrik piyasasındaki hidroelektrik santrallerin belirli piyasa dinamiklerine ve operasyonel stratejilerine atfedilebilir. Yüksek hidroelektrik üretimi, fiyatın doğal olarak arttığı sınırlı arz için rekabetin yüksek olduğu talep zirvesi (pik) dönemleri ile çakışabilir. Alternatif olarak, hidroelektrik santralleri, yüksek fiyat dönemlerinde gelirlerini maksimize etmek için üretimlerini stratejik olarak ayarlayabilirler ve bu da gözlemlenen pozitif korelasyona katkıda bulunur. Hidroelektrik üretimi ile fiyat dinamikleri arasındaki ilişkinin altında yatan mekanizmaları tam olarak anlamak için daha fazla araştırma gereklidir.




(a)




(b)

Şekil 21. Modellerin Shap Value Analizi: (a) CatBoost, (b) XGBoost


Güneş enerjisi (SOL) üretiminin analizine ilişkin bulgular, MCP üzerindeki karmaşık etkilerini ortaya koymaktadır. Sıfır SHAP değerleri etrafında yoğunlaşan mavi noktalarla temsil edilen düşük güneş enerjisi üretimi, MCP üzerinde önemsiz bir etki göstermektedir. Ancak, güneş enerjisi üretimi arttıkça, SHAP grafiğinin negatif kısmında yoğunlaşan kırmızı noktalarla belirginleşen negatif bir etki ortaya çıkmaktadır. Bu durum, yüksek güneş enerjisi üretiminin fiyat üzerinde genellikle aşağı yönlü bir baskı oluşturduğunu ve artan yenilenebilir enerji arzının daha pahalı üretim kaynaklarının yerini alarak fiyatları düşürdüğünü göstermektedir. Bu gözlem, CatBoost, XGBoost, SVR (Şekil 22.a), RF (Şekil 22.c) ve DT (Şekil 22.d) gibi çeşitli modeller tarafından doğrulanmakta olup, yüksek güneş enerjisi üretimi ile fiyat arasında tutarlı bir negatif korelasyon ortaya koymaktadır. Ancak, Sequential model (Şekil 22.b), diğer modellerden saparak güneş enerjisi üretimini önemli bir öngörücü olarak değerlendirmemektedir. Bu tutarsızlık, model mimarisindeki farklılıklara atfedilebilir. Genel olarak, elde edilen kanıtlar, özellikle yüksek seviyelerde güneş enerjisi üretiminin elektrik fiyatını azaltmada anlamlı bir rol oynadığını ortaya koymaktadır. Bu bulgu, güneş enerjisinin elektrik fiyatlarını düşürme potansiyelini ve daha sürdürülebilir bir enerji karışımını teşvik etme kapasitesini vurgulamaktadır.




(a)



(b)



(c)



(d)

Şekil 22. Modellerin Shap Value Analiz: (a) SVR, (b) Sequential, (c) RF, (d) DT

Biyokütleden enerji üretiminin (BIO) analizi, düşük seviyelerdeki biyokütle üretiminin ertesi günün fiyatı üzerinde ihmal edilebilir bir etkiye sahip olduğunu, sıfır SHAP değerlerinde yoğunlaşan mavi noktalar aracılığıyla göstermektedir. Ancak, SHAP grafiğinde hem negatif hem de pozitif tarafta kırmızı noktalar gözlemlenmekte olup, pozitif tarafta daha yüksek SHAP değerleri yer almaktadır. Bu durum, yüksek biyokütle üretiminin fiyatı bir miktar artırabileceğini ima etmektedir. Bu gözlem, biyokütle enerjisinin diğer yenilenebilir enerji kaynaklarına kıyasla nispeten daha yüksek marjinal maliyetlerine atfedilebilir; zira daha yüksek üretim maliyetleri, elektrik piyasasında artan fiyatlara dönüşebilmektedir. Bu model, RF modelinin biyokütle üretimini önemli bir öngörücü olarak değerlendirmemesi dışında, çoğu modelde tutarlılık göstermektedir.

Doğalgaz fiyatı (GASP), elektrik fiyatının belirlenmesinde kilit bir faktör olarak öne çıkmakta ve tüm modellerde güçlü bir pozitif ilişki sergilemektedir. Yüksek doğalgaz fiyatları, sürekli olarak elektrik fiyatında önemli bir artış öngörmekte olup, elektrik üretiminde temel yakıt kaynağı olarak doğalgazın kritik rolünü yansıtmaktadır. Ancak,

düşük doğalgaz fiyatlarının etkisi daha az belirgin olup, genellikle PTF üzerinde ihmal edilebilir bir aşağı yönlü etki göstermektedir. Bu asimetri, doğalgazdan enerji üretimi (NG) ile PTF arasındaki ilişkide de görülmektedir. Düşük NG, yüksek NG'nin oluşturduğu hafif yukarı yönlü baskıya kıyasla PTF üzerinde daha güçlü bir aşağı yönlü baskı uygulamaktadır. Bu gözlem, LightGBM, CatBoost ve XGBoost modellerinde tutarlı olup, elektrik üretiminde doğalgaza bağımlılığın azaltılmasının, özellikle alternatif kaynakların mevcut olduğu durumlarda, daha düşük fiyatlara katkıda bulunabileceğini göstermektedir. Ancak, bu etkinin tüm modellerde aynı olmadığını ve model spesifik farklılıkların olabileceğini belirtmek önemlidir. Ayrıca, analiz, doğalgaz fiyatları ve üretim seviyeleri arasındaki karmaşık etkileşimi ortaya koymaktadır. Yüksek doğalgaz fiyatları güvenilir bir şekilde yüksek PTF'yi öngörürken, düşük doğalgaz fiyatları ile düşük NG kombinasyonu mutlaka daha düşük bir PTF garantilememektedir.

Nehirden hidroelektrik üretiminin (RHYD) yüksek seviyeleri, tüm modellerde tutarlı bir şekilde fiyat üzerinde düşürücü bir etki yaratmaktadır; ancak, düşük RHYD'nin etkisi önemsiz kalmaktadır. Bununla birlikte, RHYD değişkeni, tüm modellerde sürekli olarak önemli bir öngörücü olarak ortaya çıkmamaktadır ve hem yüksek hem de düşük üretim seviyeleri için SHAP değerleri önemli ölçüde değişkenlik göstermektedir. Dolayısıyla, RHYD ile PTF arasındaki ilişkiye dair sonuçlar güvenilir değildir ve dikkatle değerlendirilmelidir.

Linyit kömürü, Türkiye'nin toplam elektrik üretiminde %15 paya sahip önemli bir enerji kaynağı olmasına rağmen, yalnızca LightGBM, CatBoost ve RF modelleri linyitten elektrik üretimini (LIG) önemli bir değişken olarak değerlendirmektedir. LightGBM ve CatBoost modellerine göre, yüksek LIG fiyatı güçlü bir şekilde azaltmakta, düşük üretim ise fiyatı artırmaktadır. Jeotermal (GEO) üretimi için de benzer değerlendirmeler yapılabilir, ancak PTF üzerindeki etkisi daha sınırlıdır. Yalnızca SVR modeli, jeotermal üretimini daha kritik bir değişken olarak değerlendirerek ters bir etki göstermektedir; yani, yüksek jeotermal üretimi fiyatı belirgin şekilde artırmakta, düşük üretim ise fiyatı düşürmektedir.

LightGBM modeline göre ilginç ve beklenmedik bir diğer bulgu, yüksek rüzgâr (WIND) üretiminin fiyatı artırdığı ve düşük üretimin fiyatı azalttığı yönündedir; ancak bu etkinin çok büyük olmadığı vurgulanmaktadır. CatBoost, SVR ve XGBoost modelleri, WIND

değişkeninin etkisini dikkate almamaktadır. Sequential model, bu etkinin nedenine dair net bir açıklama sunmamaktadır. Sadece DT modeli, yüksek rüzgâr (WIND) üretiminin fiyatı azalttığını ve düşük üretimin fiyatı artırdığını öne sürmektedir.

İthal kömürden (ICOAL) yüksek üretimin PTF üzerinde hiçbir etkisi olmazken, düşük üretim fiyatı belirgin bir şekilde düşürmektedir ve negatif tarafta yaklaşık -30 SHAP değeri ile LightGBM ve RF modellerine göre tüm parametreler arasında en etkili olanıdır. XGBoost modeli de düşük üretim için benzer sonuçlar sunmakta, ancak bu modele göre, ithal kömürden (ICOAL) yüksek üretim fiyatı düşürmektedir. CatBoost ve SVR modelleri, ICOAL'ı anlamlı bir değişken olarak değerlendirmemekte ve Sequential ile DT modelleri bu etkileri yeterince açıklamamaktadır.

Taş kömüründen (BCOAL) üretimin PTF üzerindeki etkisinin analizi, farklı modeller arasında karmaşık sonuçlar ortaya koymaktadır. LightGBM modeli, fiyatı tahmin ederken BCOAL değişkenini önemli bir faktör olarak görmemektedir. Buna karşılık, diğer tüm modeller BCOAL'ı tahminlere dahil ederek, onun potansiyel önemini vurgulamaktadır. Ancak, etkisinin yönü ve büyüklüğü modeller arasında değişkenlik göstermektedir. CatBoost modeli, bu konuda en tutarlı açıklamayı sunmaktadır. Bu model, yüksek seviyelerde BCOAL üretiminin fiyatı önemli ölçüde azalttığını öne sürmekte olup, daha düşük maliyetli kaynaklardan artan arzın fiyatları düşüreceği beklentisiyle uyumludur. İlginç bir şekilde, bu modele göre, taş kömüründen düşük üretim senaryosu fiyat üzerinde kayda değer bir etki oluşturmamaktadır.

Fuel-oilden enerji üretimi (FUEL), Türkiye'nin elektrik üretiminde çok düşük bir paya sahiptir (<%1), bu nedenle FUEL değişkeni çoğu modelde önemli bir faktör olarak değerlendirilmemektedir. LightGBM, CatBoost ve Sequential modeller bu değişkeni tahminlerine dahil etmemekte olup, diğer modellerde ise değişkenin etkisi dikkate değer değildir.

Enerji kaynakları, tarihsel PTF ve gaz fiyatlarının yanı sıra çeşitli piyasa ve iklim değişkenleri de fiyat tahmininde etkili olmaktadır. Bu değişkenler arasında ticaret hacmi (TV), verilen satış siparişi hacmi (SSOV), verilen teklif siparişi hacmi (SBOV), eşleşen teklifler miktarı (MO), fiyat bağımsız satış siparişi (PISO), fiyat bağımsız teklif siparişi (PIBO) ve Ankara ile İstanbul'un saatlik ortalama sıcaklıkları yer almaktadır. Ancak, LightGBM modeli yalnızca SSOV, SBOV ve İstanbul'un saatlik ortalama sıcaklığını

(IST) seçici bir şekilde dahil ederken, diğer değişkenleri göz ardı etmektedir. MO değişkeni ise yalnızca CatBoost modeli tarafından düşük bir etki ile dikkate alınmaktadır.

Maksimum piyasa fiyatı adımında piyasaya sunulan elektrik arzı teklif miktarını temsil eden Verilen Satış Siparişi Hacmi (SSOV), artan arzın genellikle daha düşük fiyatlara yol açması nedeniyle fiyat üzerinde aşağı yönlü bir baskı oluşturması beklenir. Bu ilişki, SSOV değerlerinin düşük olduğu durumlarda daha yüksek fiyat ile ilişkilendirildiğini sürekli olarak gösteren LightGBM, CatBoost, SVR ve Sıralı modellerin SHAP analizi ile doğrulanmaktadır. Ancak, yüksek SSOV'nin fiyatı önemli ölçüde düşürdüğü ters etki bu modeller tarafından güçlü bir şekilde desteklenmemektedir. Buna karşılık, fiyat bağımsız satış siparişi (PISO), piyasaya herhangi bir fiyat adımı olmaksızın sunulan elektrik arzı teklif miktarını temsil ederek, arz ve fiyat arasındaki ilişkiye tamamlayıcı bilgiler sunar. LightGBM modeline dahil edilmemiş olmasına rağmen, diğer tüm modellerin SHAP analizi, PISO ile fiyat arasında negatif bir korelasyon olduğunu sürekli olarak ortaya koymakta olup, daha yüksek PISO değerlerinin daha düşük PTF ile ilişkilendirildiğini göstermektedir. Dolayısıyla, PTF üzerindeki arz tarafı etkisinin kapsamlı bir analizi, hem SSOV hem de PISO değişkenlerinin birlikte değerlendirilmesini gerektirmektedir.

Fiyat bağımsız teklif siparişi (PIBO) ve verilen teklif siparişi hacmi (SBOV), sırasıyla piyasaya herhangi bir fiyat adımı olmadan ve 0 \$/MWh fiyat adımında sunulan elektrik talep teklif miktarını temsil ederek paralel bir analiz yapılabilir. Ancak, şaşırtıcı bir şekilde, bu talep tarafı değişkenlerinin fiyat üzerindeki etkisi, arz tarafı karşıtları olan SSOV ve PISO'nun etkisi kadar belirgin değildir. LightGBM, SVR, Sequential ve DT modellerinde SBOV'nin SHAP değerleri, düşük SBOV değerlerinin azalmış fiyat ile ilişkilendirildiğini sürekli olarak göstermekte olup, azalan talebin daha düşük fiyatlara yol açabileceğini düşündürmektedir. Buna karşılık, PIBO'nun etkisi daha belirsizdir, çünkü sadece SVR modelinde temsil edilmekte ve burada daha yüksek PIBO değerleri artan PTF ile ilişkilendirilmektedir. Talep tarafı değişkenlerinin gözlemlenen etkisindeki bu farklılık, arz tarafı değişkenlerine kıyasla daha fazla araştırmayı gerektirmektedir. Talebin fiyat esnekliği gibi diğer faktörlerin, talep ve fiyat arasındaki ilişkiyi etkileyebileceği mümkündür.

Piyasadaki eşleşen tekliflerin saatlik toplam finansal hacmini temsil eden ticaret havmi (TV), LightGBM tarafından dikkate alınmamasına rağmen, birçok modelde PTF'nin

önemli bir öngörücüsü olarak öne çıkmaktadır. Özellikle CatBoost, XGBoost ve Sequential modeller, yüksek TV değerleri ile fiyat arasında güçlü bir pozitif korelasyon olduğunu göstermekte, artan ticaret aktivitesi ve finansal hacmin fiyatları yukarı yönlü etkilediğini ileri sürmektedir. Ancak, düşük TV değerlerinin fiyat üzerindeki düşüş yönlü etkisi bu modellerde daha az belirgindir. TV değişkeni, SVR, RF ve DT modellerine de dahil edilmiş, ancak etkisi daha az önemli ve daha az net bir şekilde tanımlanmıştır. TV'nin LightGBM modelinden çıkarılması, önceki saatin fiyatını temsil eden MCP-24 değişkeninin yüksek etkisine bağlanabilir. Saatlik toplam finansal hacim ve PTF arasındaki doğal ilişki göz önüne alındığında, MCP-24 değişkeninin LightGBM çerçevesinde TV'nin etkisini dolaylı olarak yakaladığı düşünülebilir.

İstanbul'un saatlik ortalama sıcaklığı (IST), CatBoost, Sequential, SVR ve RF modellerinde fiyatı etkileyen bir faktör olarak belirlenmiştir. Ancak, bu ilişkinin kesin doğası belirsizliğini korumaktadır. Özellikle, CatBoost modeli, İstanbul'daki daha düşük sıcaklıkların fiyatta hafif bir artış ile ilişkilendirildiği, daha yüksek sıcaklıkların ise fiyatta azalma ile ilişkilendirildiği bir model sunmaktadır. Bu gözlem, özellikle ısınma amaçlı elektrik talebindeki mevsimsel değişikliklere atfedilebilir. Daha soğuk aylarda, genellikle doğalgaz ile sağlanan ısınma ihtiyacının artması, elektrik talebini artırarak fiyat üzerinde yukarı yönlü bir baskı oluşturur. Buna karşılık, daha yüksek sıcaklıklar ısınma ihtiyacını azaltarak elektrik talebini ve dolayısıyla fiyatı düşürür. Ankara'nın (ANK) saatlik ortalama sıcaklığı ise, yalnızca SVR ve DT modellerinde nispeten düşük bir önemle yer alarak PTF üzerinde daha az belirgin ve tutarsız bir etki göstermektedir.

3.5. Yenilenebilir Enerji Kaynaklarının PTF üzerindeki Etkisi

Fosil yakıtlı üretim genellikle PTF üzerinde daha tahmin edilebilir ve güçlü etkilere sahiptir. Doğal gaz ve kömür gibi kaynaklar, üretim arttığında PTF fiyatlarını yükseltirken üretim azaldığında düşürür. Ayrıca, bu kaynakların yüksek maliyetleri de fiyatlar üzerinde önemli ölçüde etki yapar. Ancak, fosil yakıtlı olduğu halde, linyit (LIG) üretiminin PTF fiyatını düşürücü etkisi vardır. Bu durum, Türkiye'de yerli üretim olarak en çok kullanılan kömür çeşidinin linyit olması ve enerji ihtiyacında önemli bir rol oynamasından kaynaklanmaktadır.

Yenilenebilir enerji üretimi ise PTF üzerinde daha değişken ve belirsiz etkilere sahiptir. Güneş enerjisi, düşük üretim durumunda fiyatları pek etkilemezken yüksek üretim

durumunda fiyatları düşürür. Rüzgâr enerjisi, üretim arttığında fiyatları düşürür ve üretim azaldığında fiyatları yükseltir. Hidroelektrik enerji, baraj tipi yüksek üretim durumunda fiyatları artırırken nehir tipi yüksek üretim durumunda fiyatları düşürür. Jeotermal enerji, yüksek üretim seviyelerinde fiyatları düşürürken düşük üretimde fiyatlara etkisi yoktur. Biyokütle enerjisi ise yüksek üretim durumunda fiyatları artırırken düşük üretimde etkisi yoktur.

Yenilenebilir enerjinin üretim kapasitesi ve maliyetleri, fosil yakıtlara kıyasla daha düşük ve değişkendir. Bu durum, yenilenebilir enerjinin PTF üzerindeki etkilerini daha belirsiz ve dalgalı hale getirir. Bu belirsizlik, yenilenebilir enerji kaynaklarının üretimindeki doğal değişkenlik ve belirsizliklerden kaynaklanmaktadır.

Genel olarak, yenilenebilir enerji üretimi Piyasa Takas Fiyatı (PTF) üzerinde düşürücü bir etkiye sahiptir. Güneş ve rüzgâr enerjisi gibi yenilenebilir kaynaklar, üretim arttığında PTF fiyatlarını düşürür. Bu durum, yenilenebilir enerji kaynaklarının marjinal maliyetlerinin düşük olmasından kaynaklanır. Özellikle güneş enerjisi, yüksek üretim dönemlerinde PTF'yi belirgin bir şekilde düşürürken rüzgâr enerjisi üretimi de benzer şekilde fiyatları düşürür. Hidroelektrik enerji, nehir tipi yüksek üretim durumlarında fiyatları düşürürken baraj tipi hidroelektrik enerji üretimi de su seviyelerine bağlı olarak fiyatları etkiler.

Jeotermal enerji, sabit ve düşük maliyetli bir üretim kaynağı olarak, yüksek üretim dönemlerinde PTF'yi düşürür. Biyokütle enerjisi ise diğer yenilenebilir kaynaklara kıyasla daha maliyetli olmasına rağmen, yüksek üretim durumlarında fiyatları düşürebilir. Genel olarak, yenilenebilir enerji kaynaklarının artan üretimi, fosil yakıtlara olan talebi azaltarak PTF fiyatlarını düşürme eğilimindedir. Bu, enerji piyasasında daha sürdürülebilir ve maliyet etkin bir yapı oluşturmaktadır.

4. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

4.1.Tartışma

Elektrik piyasaları serbestleştikçe ve rekabet arttıkça, farklı vadelerdeki elektrik fiyatlarının doğru tahmin edilmesi, ticari faaliyetlerin kârlılığı ve sürdürülebilirliği için kritik hale gelmektedir. Elektrik fiyatının tahmin edilmesi, enerji piyasalarında yer alan üreticiler, tüketiciler, toptan ve perakende ticaret şirketleri ile yerli ve yabancı potansiyel yatırımcılar için kritik bir öneme sahiptir. Bu nedenle, günün piyasa koşullarına uygun yüksek performanslı modellere ihtiyaç duyulmaktadır.

Bu tezde öncelikle, gün öncesi piyasa takas fiyatının tahminleme çalışması yapılmıştır. Tahminleme çalışmasında RF, DT, SVR, XGBoost, CatBoost, LightGBM ve Sequential modelleri kullanılmıştır. Python programlama ile tahmin modelleri oluşturulmuştur. Çalışma kapsamında kullanılan/toplanan veriler, EPIAŞ Şeffaflık Platformu, Meteoroloji Genel Müdürlüğü ve BOTAŞ Genel Müdürlüğü sağlanmış gerçek veriler olup 2018-2023 yılları arası gün öncesi piyasasında her saatin değerlerini kapsamaktadır. Veri seti ön işleminden geçirilmiş daha sonrasında eğitim ve test olmak üzere iki parçaya ayrılmıştır. Tüm modellerde optimum hiperparametreler kullanılarak ve modele uygun şekilde ayarlanarak doğrulukları önemli ölçüde artırılmıştır. Çalışmada performans kistası olarak R^2 , MSE, MAE, RMSE ve MAPE kullanılmıştır. Modelleme ve optimizasyon süreçlerinin ardından, modelin hangi özelliklere daha fazla ağırlık verdiğini ve hangi özelliklerin tahminler üzerinde daha büyük bir etkiye sahip olduğunu belirlemek amacıyla SHAP kullanılmıştır. Önerilen tahmin modeli, Türkiye elektrik piyasasındaki aktörler tarafından kolayca kullanılabilir.

Elektrik fiyat tahmininde kullanılan makine öğrenme modellerinin performansında, veri seçimi, ön işleme ve hiperparametre optimizasyonunun kritik bir rol oynadığı bu

çalışmada ortaya konulmuştur. Özellikle, öznitelik önemi analizi, karar ağaçları tabanlı modellerde fiyat tahminine etki eden en belirleyici değişkenleri saptayarak model doğruluğunu artırmaya yönelik önemli bilgiler sağlamıştır. Yapılan öznitelik önemi analizine göre, Eşleşen Teklifler Miktarı (MO), Eşleşen Teklif Miktarı (MB), Fiyattan Bağımsız Teklif Emri (PIBO) ve Gönderilen Satış Sipariş Hacmi (SSOV) gibi değişkenlerin bazı modellerde düşük öznitelik önemine sahip olmaları nedeniyle çıkarıldığı, Fuel Oil'den Üretim (FUEL) ve Jeotermal Üretim (GEO) gibi değişkenlerin de yine düşük katkı değerleri nedeniyle bazı modellerde göz ardı edildiği gözlemlenmiştir. Bunun yanında, yalnızca öznitelik seçiminin değil, boyut indirgeme yöntemlerinin de model performansını iyileştirdiği görülmüştür.

Özellikle PCA ile yapılan boyut indirgeme işlemi, CatBoost ve SVR modellerinde tahmin doğruluğunu artırmış ve modelin hızını önemli ölçüde yükseltmiştir. PCA bulgularına göre, Haftaiçi/Haftasonu (HOLY), Asfaltit Kömürden Üretim (ASPH) ve Linyit Kömüründen Üretim (LIG) değişkenleri, PCA bileşenlerine en yüksek katkıyı sağlayarak veri setindeki toplam varyansın büyük bir kısmını açıklamışlardır. HOLY (0.992), ASPH (0.974) ve LIG (0.865) değerleriyle en yüksek katkıları sunarak, PCA modelinde baskın bir rol oynamış ve verinin temel yapılarının doğru bir şekilde yakalanmasına katkıda bulunmuştur. Öte yandan, Bir ay önceki fiyat (MCP_672) ve Günlük Döviz Kuru (DER) gibi düşük katkı sağlayan değişkenler, PCA'nın veri setindeki varyansı açıklamada daha az önem verdiği ve boyut azaltma süreçlerinde göz ardı edilebilecek unsurlar olarak değerlendirilmiştir. Bu bulgular, PCA'nın modelleme süreçlerinde hangi değişkenlerin temel yapı taşlarını oluşturduğunu ve hangilerinin daha az bilgi taşıdığını ortaya koymaktadır.

Öznitelik önemi analizinde ise, LightGBM, CatBoost ve Sequential modellerinde özellikle Bir gün önceki fiyat (MCP_24) ve Bir hafta önceki fiyat (MCP_168) gibi değişkenlerin yüksek katkı sağladığı ve bu değişkenlerin model performansına merkezi bir rol oynadığı tespit edilmiştir. Diğer yandan, Fuel Oil'den Üretim (FUEL), Ankara'nın saatlik ortalama sıcaklığı (ANK), Asfaltit Kömürden Üretim (ASPH) ve Atık Isıdan Üretim (WAS) gibi değişkenlerin daha düşük öznitelik önemine sahip olduğu ve tahmin gücüne sınırlı katkı sunduğu gözlemlenmiştir. Bu bulgular, öznitelik öneminin belirlenmesi ve boyut indirgeme tekniklerinin dikkatli bir şekilde bir arada kullanılmasının, elektrik fiyat tahmini gibi karmaşık problemler için model doğruluğunu

artırmada kritik olduğunu göstermektedir. Sonuç olarak, CatBoost ve LightGBM modelleri, öznitelik seçimi ve boyut indirgeme süreçlerine olan duyarlılıkları sayesinde elektrik fiyat tahmini için en uygun modeller olarak öne çıkmaktadır.

Bu çalışma, gün öncesi piyasa takas fiyatlarının tahminine yönelik çeşitli yöntemlerin kapsamlı bir değerlendirmesini sunarak, elektrik fiyat tahminleri için etkili ve güvenilir modellerin geliştirilmesini amaçlamaktadır. Elde edilen bulgular, veri seçimi ve ön işlemenin yanı sıra hiperparametre optimizasyonunun tahmin doğruluğu üzerindeki kritik etkilerini açıkça ortaya koymaktadır. Ayrıca, açık erişim ve model açıklanabilirliği gibi temel prensiplerin araştırma süreçleri üzerindeki olumlu katkıları vurgulanmış, modelin güvenilirliği ve şeffaflığı açısından SHAP değerlerinin rolü detaylandırılmıştır. Bu bağlamda, model optimizasyon süreçlerinin zaman, maliyet ve performans dengesi üzerindeki etkileri de göz önünde bulundurulmuştur. Bu çalışma, elektrik fiyat tahmininde kullanılan yöntemlerin etkinliğini artırma ve verimliliğini sağlama amacıyla gerekli stratejik yönetim yaklaşımlarını önermektedir.

Açık Erişimin Önemi: Elektrik piyasası fiyat tahmini alanında araştırmaların ilerlemesi için açık erişim çok önemlidir. Ne yazık ki bu alandaki araştırmalarda kullanılan birçok veri seti ve kodlar kamuya açık değildir. Bu durum, elektrik piyasası araştırmalarının tekrarlanabilirliğini ve ilerlemesini engeller. Veri eksikliği nedeniyle Elektrik Fiyatı Tahmini (EFT) çalışmaları tekrarlanamaz. Bu, bilimin temel ilkelerine aykırıdır ve araştırma bulgularının güvenilirliğini zedeler. Hangi metodolojilerin iyi çalıştığını belirlemek zorlaşır ve araştırmacılar daha önce değerlendirilmiş metodolojileri yeniden değerlendirerek zaman kaybeder, EFT araştırmalarının ilerlemesi yavaşlar. Yeni yöntemleri yayınlardaki yöntemlerle karşılaştırmak zorlaşır ve en son yöntemlerle karşılaştırmalar genellikle kaçınılır. Bu durum, EFT araştırmalarında yeniliği kısıtlar. Yeni yöntemler, yayınlanmış yöntemlerle aynı koşullar altında karşılaştırılamaz. Bu, farklı koşullar altında yapılan karşılaştırmaların orijinal yöntemlerin yanlış uygulanmasına ve hatalı sonuçlara yol açar. Bu nedenle, EFT araştırmalarında açık erişimi teşvik etmek için bu çalışmada, toplanan ve ön işleme tabi tutulan verileri ve geliştirilen kodları paylaşıyoruz².

² <https://github.com/TheEmgame/EPF-Turkish-Day-Ahead-Market>

Veri Seçimi ve Ön İşlemenin Önemi: Bu çalışmada, modelleme başlangıçta 2015-2022 yılları arasındaki tüm veri kümesi kullanılarak gerçekleştirilmiştir. Ancak sonuçlar tatmin edici olmamıştır. Detaylı analizlerle PISO, PIBO, SSOV, SBOV, MO, MB, SOL, ASPH ve IMEX gibi değişkenlerde hatalar tespit edilmiştir. Bu hatalı veriler modelin öğrenme sürecini engelleyerek düşük doğruluk sonuçlarına yol açmıştır. Bu sorunu çözmek için veri kümesi, 2018-2022 yılları arasındaki temiz verileri içerecek şekilde sınırlandırılmıştır. Bu yaklaşım, hatalı verilerin etkisini ortadan kaldırarak modelin öğrenme kapasitesini artırmıştır. Düzeltilmiş veri kümesiyle yapılan modelleme, önceki modele göre önemli ölçüde daha yüksek doğruluk sağlamıştır. Bu çalışma, EPF’de veri seçimi ve ön işlemenin önemini vurgulamaktadır. Kusurlu veya eksik veriler, modelin performansını olumsuz etkileyerek hatalı sonuçlara yol açabilir. Bu nedenle, modellemeyen önce verilerin titizlikle incelenmesi ve hataların düzeltilmesi büyük önem taşır.

Hiperparametrelerin Etkisi ve Önemi: Elektrik fiyat tahmininin doğruluğunu artırmada, veri seçimi ve ön işlemenin yanı sıra hiperparametre optimizasyonu büyük önem taşır. Hiperparametreler, modelin öğrenme sürecini ve performansını etkileyen değişkenlerdir. Bu parametrelerin en uygun değerlerinin belirlenmesi, modelin en doğru tahminleri yapmasını sağlar. Farklı modeller ve parametrelerle yapılan denemeler, en iyi sonuçları üreten model ve parametre setini belirlemeyi amaçlar. Çeşitli model yapıları ve parametre kombinasyonları deneyerek, en uygun elektrik fiyatı tahmin modeline ulaşmak hedeflenir. Hiperparametre optimizasyonu, modelin daha doğru ve tutarlı tahminler yapmasını sağlar, modelin genelleme yeteneğini artırır ve modelin aşırı uyumunu önler. Hiperparametre optimizasyonu, elektrik fiyat tahmini ve diğer birçok makine öğrenme probleminde kritik öneme sahiptir. Doğru hiperparametre seçimiyle, modelin performansı önemli ölçüde artırılabilir ve daha doğru tahminler elde edilebilir.

Model Açıklanabilirliğinin Önemi: Modelleme ve optimizasyondan sonra, modelin hangi özelliklere daha fazla vurgu yaptığını ve hangi özelliklerin tahminler üzerinde daha fazla etkiye sahip olduğunu anlamak amacıyla SHAP değerleri kullanılmıştır. SHAP değerleri, her bir özelliğin modelin tahminlerine katkısını gösteren bir dizi sayıdır. Bu değerler, modelin hangi özelliklere öncelik verdiğini ve tahminler üzerinde hangi özelliklerin daha büyük bir etkisi olduğunu görmemizi sağlar. SHAP değerlerinin analizi, modelin içsel çalışma prensiplerini ve karar verme süreçlerini anlamamıza olanak tanır.

Bu sayede, modelin güvenilirliği ve şeffaflığı artırılarak, tahminlerin dayandığı temel faktörler açıkça belirlenir. Elektrik fiyat tahmininde SHAP değerlerinin kullanılması, modelin hangi değişkenlere daha fazla önem verdiğini ve bu değişkenlerin tahmin sonuçları üzerindeki etkilerini kapsamlı bir şekilde değerlendirmemizi sağlar. Bu analiz, modelin öngörü performansını iyileştirme ve karar destek süreçlerini optimize etme açısından kritik öneme sahiptir.

Zaman, Maliyet ve Performans Dengesi: Model Optimizasyon Süreçlerinin Elektrik Fiyat Tahminleri Üzerindeki Etkisi: Bu çalışmada, elektrik fiyat tahmininde kullanılan çeşitli makine öğrenme modellerinin performans ve eğitim süreleri Tablo 7’te sunulmaktadır. Çalışma, model hiperparametrelerinin optimize edilmesi sürecinde karşılaşılan zorlukları ve zaman alıcı doğasını gözlemlemiştir. Özellikle, GridSearch gibi otomatik hiperparametre ayarlama yöntemlerinin bazı durumlarda günler alabilen pratik olmayan yönleri, manuel ayarlamamanın etkinliği ve verimliliğinin önemini vurgular. Bu gözlemler, model optimizasyon süreçlerinde zaman, maliyet ve performans dengesinin stratejik yönetiminin kritik önemini ortaya koymaktadır.

Tablo 7. GridSearch ve SHAP Analizi Çalışma Süreleri

Modeller	Shap çalışma süresi	Grid Search çalışma süresi
LightGBM	50 seconds	2 seconds
CatBoost	7 seconds	4 seconds
XGBoost	5 minutes	10 seconds
Sequential	6 minutes	20 minutes
SVR	3154 minutes	13 minutes
RF	10 seconds	10 minutes
DT	10 seconds	3 seconds

Bu tezdeki analizler sadece Türkiye Gün Öncesi Piyasasına odaklanmıştır. Gelecekteki araştırmalar daha büyük bir veri setiyle çalışabilir ve makine öğrenimi modellerinin tahmin doğruluğunu ve çalışma süresini çeşitli pazarlarda karşılaştırabilir.

Tahmin yöntemlerinin performanslarının analiz edilmesi ile diğer çalışmalara da referans sağlanması öngörülmüştür. Girdi değişkenleri çeşitlendirilerek, tahmin yöntemi için farklı zaman dönemi sınıflandırılması yapılarak ve hibrit tahmin yöntemleri uygulanarak ileriki çalışmalarda daha iyi performans gösteren analizler gerçekleştirilebilir. Ayrıca elektrik piyasa sisteminin dinamik bir yapıya sahip olması bu alanda yapılan çalışmaların

güncel tutulmasını gerektirmekte ve farklı araştırma fırsatlarına açık olduğunu göstermektedir.

Türkiye’de rüzgâr ve güneş enerjisine dayalı santrallerin şebeke bağlantılarının artmasıyla yenilenebilir enerji profili değişecek ve toplam yenilenebilir enerji üretiminin belirsizliği artacaktır. Bu nedenle fiyat tahmini modellemelerinde bu etkilerin dahil edilmesi gerekecektir.

Elektrik enerjisi piyasası fiyat tahmini alanındaki araştırmaların ilerlemesi için açık erişim büyük önem taşımaktadır. Maalesef, bu alandaki birçok araştırmada kullanılan veri setleri ve kodlar kamuya açık hale getirilmemektedir. Bu durum, elektrik piyasasında araştırmalarının tekrarlanabilirliğini ve ilerlemesini engellemektedir. Bu çalışmada, EPF araştırmalarında açık erişimi teşvik etmek için EPIAŞ’tan topladığımız verileri ve açık kaynak kodlu olarak geliştirdiğimiz kodları kamuya açık hale getiriyoruz. Ayrıca, EPF araştırmacılarını kodlarını ve veri setlerini paylaşmaya veya açık erişimli veri setleri kullanmaya teşvik ediyoruz.

4.2. Sonuç ve Öneriler

Bu çalışmada kullanılan hem öznitelik önemi hem de PCA yöntemleri, tahmin modellerinin performansını artırma amacıyla uygulanmış ve her iki yöntemin de farklı modellerde önemli katkılar sağladığı görülmüştür. Öznitelik önemi analizi, özellikle LightGBM, XGBoost ve CatBoost modellerinde, etkisi az olan değişkenlerin çıkarılmasıyla daha verimli ve doğru tahminler yapılmasını sağlamıştır. PCA yöntemi ise, modellerin daha az bileşenle benzer veya daha iyi sonuçlar üretmesini mümkün kılmıştır.

Sonuç olarak, PCA ile en iyi performansı gösteren model CatBoost olurken, onu Sequential modeli takip etmiştir. Öznitelik önemine dayalı optimizasyonlarda ise en başarılı model LightGBM olmuş, ardından CatBoost gelmiştir. CatBoost modeli hem PCA hem de öznitelik seçimi yöntemleriyle genel olarak yüksek performans sergilemiştir. XGBoost iyi performans göstermiş olsa da LightGBM ve CatBoost’un gerisinde kalmıştır. Sequential ve SVM modelleri ise genel olarak daha düşük performans sergilemiş, ancak yine de tatmin edici sonuçlar vermiştir. Sonuç olarak, model seçiminde performans metriklerine ve modelin açıklanabilirliğine odaklanmak, tahmin doğruluğunu ve güvenilirliğini artırmak için kritik bir öneme sahiptir. LightGBM ve CatBoost

modelleri, özellikle karmaşık veri setlerinde yüksek performans gösteren, güçlü alternatifler olarak öne çıkmaktadır.

Araştırmalarda model seçimi ve hiperparametre ayarlama süreçlerinin önemi, XGBoost, LightGBM ve CatBoost gibi hafif *gradient boosting* modellerinin hızlı ve yüksek performans yetenekleriyle vurgulanmaktadır. Bu modeller, büyük veri setleriyle çalışan araştırmacılara önemli zaman ve maliyet tasarrufları sağlar. Aynı zamanda, eğitim süresi ve kaynak tüketimi gibi faktörleri dikkate alarak hız ve performans arasında bir denge kurulmasını gerektirir. Özellikle hesaplama kaynaklarının sınırlı olduğu senaryolarda, bu dengeyi stratejik olarak yönetmek araştırma tasarımı ve yöntem seçimi açısından kritik bir rol oynar. Bu bağlamda, araştırmacıların uzun eğitim sürelerinin finansal ve zaman baskılarına yol açabileceği senaryoları öngörmeleri ve mümkün olduğunca paralel hesaplama teknikleri ve daha verimli algoritmaları tercih etmeleri önerilir.

Elektrik fiyat tahmini için kullanılan makine öğrenme modellerinde hiperparametre ayarlarının ve model seçimi süreçlerinin optimizasyonu, karşılaşılan pratik zorluklara odaklanarak tartışılmaktadır. Bu süreçlerin maliyetler, zamanlama ve araştırmanın sürdürülebilirliği üzerindeki potansiyel etkilerine dair elde edilen değerli bilgiler, enerji piyasası tahminleri üzerinde çalışan diğer araştırmacıların model optimizasyonu ve seçimi süreçlerinde dikkate alması gereken önemli faktörler sunmaktadır. Bu çalışma, hiperparametre ayarlama ve model seçimi süreçlerinin etkin yönetiminin, enerji piyasasında tahminlerin doğruluğunu ve verimliliğini artırmada kritik olduğunu vurgulamaktadır.

Elektrik fiyat tahmini üzerine yapılan çalışmalarda kullanılan çeşitli modellerin performans ve hesaplama sürelerinin değerlendirilmesi, araştırmanın kritik bir bileşeni olarak gözlemlenmiştir. Bu bağlamda, XGBoost regresyon, Destek Vektör Regresyonu (SVR), Sıralı model, Rastgele Orman Regresyonu, LightGBM regresyon ve Karar Ağacı Regresyonu gibi modellerin uygulanması ve SHAP değerlerinin hesaplanması, model yorumlama ve özelliklerin önemini anlama açısından önemli bir rol oynamaktadır. Özellikle, Destek Vektör Regresyonu modeli için SHAP değerlerinin hesaplanmasının 3154 dakika sürmesi, hesaplama süresinin model seçimi ve optimizasyon süreçlerinde kritik bir faktör olduğunu vurgulamaktadır.

Araştırmacılar için tahmin doğruluğunun yanı sıra hesaplama verimliliği ve maliyet etkinliği de model seçiminde önemlidir. Uzun hesaplama sürelerine sahip modeller, büyük veri setleriyle çalışırken önemli zaman ve maliyet gereksinimleri doğurabilir, bu da özellikle sınırlı bütçeler veya zaman kısıtlamaları altında çalışan araştırma projeleri için büyük bir engel oluşturabilir. Bu nedenle, bir modelin tahmin performansının yanı sıra hesaplama süresi ve maliyeti de göz önünde bulundurulmalıdır. Kısa hesaplama sürelerine sahip modeller, zaman ve kaynakların kritik olduğu durumlarda avantaj sağlayabilir. Ayrıca, paralel işlem ve bulut bilişim gibi teknolojilerin kullanılması, araştırma sürecini hızlandırırken maliyetleri optimize edebilir. Sonuç olarak, elektrik fiyat tahmini gibi karmaşık problemleri modellemek için kullanılan çeşitli makine öğrenme teknikleri, yalnızca performans açısından değil, aynı zamanda hesaplama süresi ve maliyet açısından da değerlendirilmelidir. Bu yaklaşım, model seçim sürecini daha kapsamlı ve dengeli hale getirerek hem maliyet etkinliğini hem de araştırma verimliliğini artırabilir ve enerji gibi hızlı ve doğru kararların kritik olduğu sektörlerde araştırmacılara değerli yaklaşımlar sunabilir.

Elektrik fiyat tahmininin doğruluğunu artırmak için veri seçiminin ve ön işlemenin yanında hiperparametre optimizasyonu da büyük önem taşımaktadır. Hiperparametreler, modelin öğrenme sürecini ve performansını etkileyen değişkenlerdir. Bu parametrelerin optimal değerlerinin belirlenmesi, modelin en doğru tahminleri yapmasını sağlar. Model hiperparametrelerinin optimize edilmesinin zaman alıcı olduğu ve GridSearch gibi otomatik ayarlama yöntemlerinin günler sürebildiği gözlemlenmiştir. XGBoost, LightGBM ve CatBoost gibi *gradient boosting* modelleri, büyük veri setleriyle çalışan araştırmacılara zaman ve maliyet tasarrufu sağlarken eğitim süresi ve kaynak tüketimi arasında bir denge gerektirir. Hiperparametre ayarlarının ve model seçimi süreçlerinin optimizasyonunda karşılaşılan zorluklar, maliyetler, zamanlama ve araştırmanın sürdürülebilirliği üzerindeki etkiler dikkate alınmalıdır. Bu çalışmada önerilen tahmin modelleri, Türkiye elektrik piyasasındaki aktörler tarafından kolayca kullanılabilir.

Bu tezde, yenilenebilir enerji kaynakları ile fosil yakıtlı enerji üretiminin piyasa takas fiyatı (PTF) üzerindeki etkileri karşılaştırılmıştır. Analizler, enerji piyasasındaki fiyat dalgalanmalarını anlamak ve tahmin etmek için farklı enerji türlerinin PTF üzerindeki etkilerini ortaya koymuştur.

Yenilenebilir enerji kaynaklarının, özellikle güneş ve rüzgâr enerjisinin, PTF fiyatı üzerinde genellikle düşürücü bir etkiye sahip olduğu görülmektedir. Güneş enerjisi, yüksek üretim dönemlerinde PTF'yi belirgin şekilde azaltırken rüzgâr enerjisi de benzer şekilde fiyatları düşürmektedir. Hidroelektrik enerji, nehir tipi üretimin yüksek olduğu dönemlerde PTF'yi düşürürken jeotermal enerji ise sabit ve düşük maliyetli bir üretim kaynağı olarak bu etkiyi pekiştirmektedir. Biyokütle enerjisi, diğer yenilenebilir kaynaklara kıyasla daha maliyetli olmasına rağmen, yüksek üretim dönemlerinde PTF üzerinde düşürücü bir etki gösterebilmektedir. Buna karşın, fosil yakıtlı enerji üretimi, PTF üzerinde daha tahmin edilebilir ve güçlü etkilere sahiptir. Doğal gaz ve kömür gibi fosil yakıtlar, üretim arttığında PTF'yi yükseltirken üretim azaldığında fiyatları düşürmektedir. Fosil yakıtların yüksek maliyetleri enerji piyasasında belirgin fiyat dalgalanmalarına yol açmaktadır. Öte yandan, Türkiye'de yerli üretim olarak en çok kullanılan kömür çeşidi olan linyit üretiminin PTF fiyatını düşürücü bir etkisi vardır ve enerji ihtiyacında önemli bir rol oynamaktadır.

Sonuç olarak, yenilenebilir enerji kaynaklarının artan üretimi, fosil yakıtlara olan talebi azaltarak PTF üzerinde düşürücü bir etkiye sahiptir. Bu durum, enerji piyasasında daha sürdürülebilir ve maliyet etkin bir yapının oluşmasına katkı sağlamaktadır. Yenilenebilir enerji kaynaklarının entegrasyonu ve kullanımının artırılması, enerji piyasasında fiyat istikrarını sağlamak ve çevresel sürdürülebilirliği desteklemek açısından büyük önem taşımaktadır. Gelecekte enerji politikalarının, yenilenebilir enerji üretimini teşvik edecek şekilde düzenlenmesi hem ekonomik hem de çevresel faydalar sağlayacaktır. Bu çalışma, yenilenebilir enerji kaynaklarının Türkiye elektrik piyasasında fiyatları düşürmeye katkıda bulunduğunu ve enerji politikalarının bu doğrultuda şekillendirilmesinin önemini ortaya koymaktadır.

DESTEKLER

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) ARDEB 3501 Programı tarafından 222M440 numaralı proje ve 2210/C Yurt İçi Öncelikli Alanlar Yüksek Lisans Burs Programı kapsamında 1649B022214214 numaralı program ile desteklenmiştir. Çalışmamıza verdiği destekten ötürü TÜBİTAK'a teşekkürlerimizi sunarız.

KAYNAKÇA

1. Koltsaklis, N. E., Dagoumas, A. S. 2018. State-of-the-art generation expansion planning: A review. **Applied Energy**, **230**, 563-589. <https://doi.org/https://doi.org/10.1016/j.apenergy.2018.08.087>
2. Gallo, G. 2016. Electricity market games: How agent-based modeling can help under high penetrations of variable generation. **The Electricity Journal**, **29**(2), 39-46. <https://doi.org/https://doi.org/10.1016/J.TEJ.2016.02.001>
3. Selcuklu, S. B., Elmahi, A. I. E. 2021. Generation Expansion Planning Considering Competition and Market Power. **European Journal of Sustainable Development Research** **6**(1), em0176. <https://doi.org/https://doi.org/10.21601/ejosdr/11409>
4. TEİAŞ. Türkiye Elektirik Piyasaları. Mart 2023. (Web sayfası: <https://www.teias.gov.tr/>), (Erişim Tarihi: 01.01.2024)
5. EPDK. (2013). *6446 Sayılı Elektrik Piyasası Kanunu*. Ankara: Resmi Gazete
6. (MEB), T. C. M. E. B. 2011. Muhasebe ve Finansman, Sermaye Piyasası Faaliyetleri ve Ankara, 16 pp.
7. Canbaş, S., Doğukanlı, H. 2007. Finansal pazarlar: finansal kurumlar ve sermaye pazarı analizleri Karahan Kitabevi ve Adana, 13 pp.
8. Piyasası, V. İ. v. O. 2017. Türev Piyasa ne demektir? ve İstanbul, 8 pp.
9. Bankası, T. C. M., 2018. Terimler Sözlüğü.(Web sayfası: <https://www.tcmb.gov.tr/wps/wcm/connect/TR/TCMB+TR/Main+Menu/Banka+Hakkinda/Egitim-Akademik/Terimler+Sozlugu/>), (Erişim Tarihi: 01.01.2024)
10. DUY. (2009). *Dengeleme ve Uzlaştırma Yönetmeliği*. Ankara

11. Elder. 2022. 2022 Yılı Cumhurbaşkanlığı Yıllık programı Enerji Sektörü Özet Raporu.(Web sayfası: <https://www.elder.org.tr/Content/files/a4cfa306-6d2a-44ff-920d-2f2b55741b18.pdf>.), (Erişim Tarihi: Haziran 2023)
12. Atlası, E., 2024. Türkiye Elektrik Üretimi.(Web sayfası: <https://www.enerjiatlasi.com/elektrik-uretimi/>.), (Erişim Tarihi: Haziran 2024)
13. Abban, A. R., Hasan, M. Z. 2021. Solar energy penetration and volatility transmission to electricity markets—An Australian perspective. **Economic Analysis and Policy**, **69**, 434-449. <https://doi.org/https://doi.org/10.1016/j.eap.2020.12.022>
14. Benhmad, F., Percebois, J. 2018. Photovoltaic and wind power feed-in impact on electricity prices: The case of Germany. **Energy Policy**, **119**, 317-326. <https://doi.org/https://doi.org/10.1016/j.enpol.2018.04.042>
15. Odeh, R. P., Watts, D. 2019. Impacts of wind and solar spatial diversification on its market value: A case study of the Chilean electricity market. **Renewable and Sustainable Energy Reviews**, **111**, 442-461. <https://doi.org/https://doi.org/10.1016/j.rser.2019.01.015>
16. Nibedita, B., Irfan, M. 2022. Analyzing the asymmetric impacts of renewables on wholesale electricity price: Empirical evidence from the Indian electricity market. **Renewable Energy**, **194**, 538-551. <https://doi.org/https://doi.org/10.1016/j.renene.2022.05.116>
17. Csereklyei, Z., Qu, S., Ancev, T. 2019. The effect of wind and solar power generation on wholesale electricity prices in Australia. **Energy Policy**, **131**, 358-369. <https://doi.org/https://doi.org/10.1016/j.enpol.2019.04.007>
18. Cieplinski, A., D'Alessandro, S., Marghella, F. 2021. Assessing the renewable energy policy paradox: A scenario analysis for the Italian electricity market. **Renewable and Sustainable Energy Reviews**, **142**, 110838. <https://doi.org/https://doi.org/10.1016/j.rser.2021.110838>

19. Concettini, S., Creti, A., Gualdi, S. 2022. Assessing the regional redistributive effect of renewable power production through a spot market algorithm simulator: The case of Italy. **Energy Economics**, **114**, 106225. <https://doi.org/https://doi.org/10.1016/j.eneco.2022.106225>
20. Coester, A., Hofkes, M. W., Papyrakis, E. 2018. Economics of renewable energy expansion and security of supply: A dynamic simulation of the German electricity market. **Applied Energy**, **231**, 1268-1284. <https://doi.org/https://doi.org/10.1016/j.apenergy.2018.09.143>
21. Sánchez de la Nieta, A. A., Contreras, J. 2020. Quantifying the effect of renewable generation on day-ahead electricity market prices: The Spanish case. **Energy Economics**, **90**, 104841. <https://doi.org/https://doi.org/10.1016/j.eneco.2020.104841>
22. Aggarwal, S. K., Saini, L. M., Kumar, A. 2009. Day-ahead Price Forecasting in Ontario Electricity Market Using Variable-segmented Support Vector Machine-based Model. **Electric Power Components and Systems**, **37**(5), 495-516. <https://doi.org/https://doi.org/10.1080/15325000802599353>
23. Şenocak, F. 2018. *Elektrik piyasa takas fiyatı ağırlıklı ortalamasının anfis ve yapay sinir ağları ile tahmini* Karadeniz Teknik Üniversitesi]. Karadeniz Teknik Üniversitesi.
24. Demirezen, S., Çetin, M. 2021. Rassal Orman Regresyonu ve Destek Vektör Regresyonu ile Piyasa Takas Fiyatının Tahmini. **Nicel Bilimler Dergisi**, **3**(1), 1-15. <https://doi.org/https://doi.org/10.51541/nicel.832164>
25. Ertaylan, A., Aktaş, Ö., Doğan, Y. 2021. Yapay Sinir Ağları ile Piyasa Takas Fiyatı Tahminlemesi. **Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi**, **23**(67), 93-105. <https://doi.org/https://doi.org/10.21205/deufmd.2021236708>
26. Akay, M. F., Abut, F., Bedir, B., Erdoğan, M., Kanar, E. 2021. Forecastng the System Margnal Prce Usng Long Short-Term Memory and Support Vector

Machne. **International Mediterranean Science and Engineering Congress**, 628-633.

27. Arslan, B., Ertuğrul, İ. 2022. ÇOKLU REGRESYON, ARIMA VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE TÜRKİYE ELEKTRİK PİYASASINDA FİYAT TAHMİN VE ANALİZİ. **Journal of Management Economics Research**, **20**(1), 331-353. <https://doi.org/https://doi.org/10.11611/yead.988146>
28. Karatekin, C., Başaran, T. 2022. Gün Öncesi Piyasasında Elektrik Enerjisi Fiyatının Veri Analizi İle Tahmin Edilmesi [Forecasting the Day Ahead Electricity Energy Price By Using Data Analysis Methods]. **Journal of the Institute of Science and Technology**, **12**(4), 2075-2084. <https://doi.org/https://doi.org/10.21597/jist.1082880>
29. Sirin, S. M., Yilmaz, B. N. 2020. Variable renewable energy technologies in the Turkish electricity market: Quantile regression analysis of the merit-order effect. **Energy Policy**, **144**, 111660. <https://doi.org/https://doi.org/10.1016/j.enpol.2020.111660>
30. Avci, E., Ketter, W., van Heck, E. 2018. Managing electricity price modeling risk via ensemble forecasting: The case of Turkey. **Energy Policy**, **123**, 390-403. <https://doi.org/https://doi.org/10.1016/j.enpol.2018.08.053>
31. Z. C. , T., G. , B., Ö. Ö, B. (2015, 16-19 May 2015). Evaluation of price forecast systems for Turkish Electric Market. Signal Processing and Communications Applications Conference (SIU),
32. Ugurlu, U., Oksuz, I., Tas, O. 2018. Electricity Price Forecasting Using Recurrent Neural Networks. *Energies*, **11**(5).
33. Ozyildirim, C., Beyazıt, M. 2014. Forecasting and Modelling of Electricity Prices by Radial Basis Functions: Turkish Electricity Market Experiment. **İktisat İşletme ve Finans**, **29**. <https://doi.org/https://doi.org/10.3848/iif.2014.344.4256>
34. KÖLMEK, M. A., Navruz, İ. 2015. Forecasting the day-ahead price in electricity balancing and settlement market of Turkey by using artificial neural networks.

Turkish Journal of Electrical Engineering Computer Sciences, 23(3), 841-852. <https://doi.org/https://doi.org/10.3906/elk-1212-136>

35. Ozozen, A., Kayakutlu, G., Ketterer, M., Kayalica, O. (2016, 4-8 Sept. 2016). A combined seasonal ARIMA and ANN model for improved results in electricity spot price forecasting: Case study in Turkey. Portland International Conference on Management of Engineering and Technology (PICMET),
36. ARİFOĞLU, A., KANDEMİR, T. 2022. ELECTRICITY PRICE FORECASTING IN TURKISH DAY-AHEAD MARKET VIA DEEP LEARNING TECHNIQUES. **Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 9(2), 1433-1458. <https://doi.org/https://doi.org/10.30798/makuiibf.1097686>
37. Yıldırım, M. H., Özmen, A., Bayrak, Ö. T., Weber, G. W. (2012, 2012//). Electricity Price Modelling for Turkey. Operations Research Proceedings 2011, Berlin, Heidelberg.
38. Hayfavi, A., Talasli, I. 2014. Stochastic multifactor modeling of spot electricity prices. **Journal of Computational and Applied Mathematics**, 259, 434-442. <https://doi.org/https://doi.org/10.1016/j.cam.2013.10.008>
39. Abdurrohman, M., Putrada, A. G., Deris, M. M. 2022. A Robust Internet of Things-Based Aquarium Control System Using Decision Tree Regression Algorithm. **IEEE Access**, 10, 56937-56951. <https://doi.org/https://doi.org/10.1109/ACCESS.2022.3177225>
40. Matignon, R. 2007. Data mining using SAS enterprise miner John Wiley & Sons ve pp.
41. Dorogush, A. V., Ershov, V., Gulin, A. 2018. CatBoost: gradient boosting with categorical features support. **arXiv preprint arXiv:1802.03464**.
42. Diao, L., Niu, D., Zang, Z., Chen, C. (2019). Short-term weather forecast based on wavelet denoising and catboost. 2019 Chinese control conference (CCC),

43. Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., Gulin, A. 2018. CatBoost: unbiased boosting with categorical features. **Advances in neural information processing systems**, 31.
44. Jolliffe, I. T. 2002. Principal component analysis for special types of data Springer ve New York, pp.
45. Jackson, J. E. 2005. A user's guide to principal components John Wiley & Sons ve pp.
46. Lundberg, S. 2017. A unified approach to interpreting model predictions. **arXiv preprint arXiv:.07874**.
47. James, G., Witten, D., Hastie, T., Tibshirani, R. 2013. An introduction to statistical learning Springer ve New York, 18 pp.
48. Shapley, L. S. 1953. A value for n-person games.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Ömer POLAT

Uyruğu: Türkiye (T.C)

Doğum Tarihi ve Yeri:

Medeni Durum:

e-mail:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü Enerji Sistemleri Mühendisliği Anabilimi	2024
Lisans	Erciyes Üniversitesi, Enerji Sistemleri Müh..	2021
Lise	Mustafa Kemal Anadolu Lisesi, İzmir	2013

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2024/8-Halen	INNOVATECH LTD. KORE CUMHURİYETİ İZMİR MERKEZ ŞUBESİ	Yapay zekâ geliştirici ve Veri bilimcisi
2024/1-2024/8	Brands-A Gıda ve Tüketim Mal. İthalat İhracat San. Ve Tic. Ltd. Şti.	Yapay zekâ geliştirici ve Veri bilimcisi
2021-2022	Emon Enerji Üretim A.Ş	Enerji Mühendisi

YABANCI DİL

İngilizce

YAYINLAR

1. Polat, Ö. ve Selçuklu, S. B. (2024). IMPACT OF RENEWABLE CAPACITY INCREASE ON ELECTRICITY MARKETS. *HODJA AKHMET YASSAWI 8th International Congress On Scientific Research*, ISBN: 978-625-367-744-2, page 2274.

