

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**KERAS KULLANARAK
TÜRKİYE GÜN ÖNCESİ ELEKTRİK PİYASASI
PİYASA TAKAS FİYATI TAHMİNİ**

YÜKSEK LİSANS TEZİ

Burak KÜÇÜKASLAN

Elektrik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Programı

MAYIS 2019



İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**KERAS KULLANARAK
TÜRKİYE GÜN ÖNCESİ ELEKTRİK PİYASASI
PİYASA TAKAS FİYATI TAHMİNİ**

YÜKSEK LİSANS TEZİ

Burak KÜÇÜKASLAN

(504151057)

Elektrik Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Belgin Emre TÜRKAY

MAYIS 2019



İTÜ, Fen Bilimleri Enstitüsü'nün 504151057 numaralı Yüksek Lisans Öğrencisi Burak KÜÇÜKASLAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “KERAS KULLANARAK TÜRKİYE GÜN ÖNCESİ ELEKTRİK PİYASASI PİYASA TAKAS FİYATI TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Belgin Emre TÜRKAY**

İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Ramazan ÇAĞLAR**

İstanbul Teknik Üniversitesi

Doç. Dr. Ozan ERDİNÇ

Yıldız Teknik Üniversitesi

Teslim Tarihi : **3 Mayıs 2019**

Savunma Tarihi : **14 Haziran 2019**





Anneme,



ÖNSÖZ

Bu çalışmada desteğini benden esirgemediği, paylaştığı birikimi ve yönlendirmeleriyle, bana gösterdiği sabırla, çalışmama olan katkıları için Tez Danışmanım Sayın Prof. Belgin Emre Türkay’a en içten teşekkürlerimi sunarım.

Her zaman yanımda olan çok değerli babama teşekkür ederim.

Mayıs 2019

Burak Küçükaslan
(Elektrik Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xvii
ÇİZELGE LİSTESİ.....	xxi
ŞEKİL LİSTESİ.....	xxiii
ÖZET	xxv
SUMMARY	xxvii
1. GİRİŞ	1
1.1 Tezin Amacı	5
1.2 Literatür Araştırması	5
2. TÜRKİYE ELEKTRİK PİYASASI	21
2.1 Giriş.....	21
2.2 Türkiye Gün Öncesi Elektrik Piyasası (GÖP).....	24
2.2.1 Genel esaslar	26
2.2.2 Süreçler	26
2.2.3 Teklifler.....	26
2.2.3.1 Saatlik teklif	27
2.2.3.2 Blok teklif	27
2.2.3.3 Esnek teklif.....	27
2.2.4 Optimizasyon modeli	27

2.2.4.1 Çözüm yöntemi	29
3. DERİN ÖĞRENME	31
3.1 Giriş	31
3.2 Tanım.....	31
3.3 Derin Öğrenme Mimarileri.....	32
3.3.1 Konvolüsyonel sinir ağları	32
3.3.2 Tekrarlayan sinir ağları	33
3.3.3 Uzun kısa vadeli hafıza ağları	34
3.3.4 Derin inanç ağları	35
3.3.5 Derin oto-kodlayıcılar	35
3.4 Derin Öğrenme Uygulamaları	36
3.4.1 Doğal dil işleme	36
3.5 Derin Öğrenme Kütüphaneleri	37
4. ÖNERİLEN MODEL	39
5. ÖNERİLEN MODELİN EĞİTİMİ VE TESTİ.....	53
6. SONUÇ VE ÖNERİLER.....	67
KAYNAKLAR.....	73
ÖZGEÇMİŞ.....	81

KISALTMALAR

AB	: Avrupa Birliđi
ACF	: Autocorrelation Function
AE	: Autoencoders
ADN	: Active Deep Network
ANN	: Artificial Neural Network
ARIMA	: Autoregressive Integrated Moving Average
ARMA	: Autoregressive Moving Average
ARTMAP	: Adaptive Resonance Theory MAP
ARX	: Autoregressive Exogenous
AUC	: Area Under Curve
AWNN	: Adaptive Wavelet Neural Network
BG	: Bilgisayarlı Görüntüleme
BOTAŞ	: Boru Hatları ile Petrol Taşıma Anonim Şirketi
BP	: Back Propagation
CADx	: Computer-Aided Diagnosis
CCA	: Canonical Correlation Analysis
CILVR	: Computational Intelligence, Learning, Vision, and Robotics
CLSM	: Convolutional Latent Semantic Model
CMARS	: Conic Multivariate Adaptive Regression Splines
CNN	: Convolution Neural Network
COCO	: Common Objects in Context
CRM	: Customer Relationship Management

CUDA	: Compute Unified Device Architecture
DAE	: Deep/Stacked Autoencoder
DARPA	: Defense Advanced Research Projects Agency
DBN	: Deep Belief Network
DDİ	: Doğal Dil İşleme
DEFT	: Deep Exploration and Filtering of Text
DLTC	: Deep Learning Technology Center
DNN	: Deep Neural Network
DSSM	: Derin Bir Anlamsal Benzerlik Modeli
EPDK	: Enerji Piyasası Düzenleme Kurumu
EPIAŞ	: Enerji Piyasaları İşletme A.Ş.
FF	: Firefly
FA	: Fuzzy Adaptive Resonance Theory MAP
FIS	: Fuzzy Inference System
GARCH	: Generalized Autoregressive Conditional Heteroskedasticity
Gİ	: Görüntü İşleme
GÖP	: Gün Öncesi Piyasası
GPU	: Graphics Processing Unit
GRU	: Gate Recurrent Unit
HMM	: Hidden Markov Model
ICPR	: International Conference on Pattern Recognition
IDSIA	: Dalle Molle Institute for Artificial Intelligence Research
ILSVRC	: ImageNet Large Scale Visual Recognition Competition
IOHMM	: Input-Output Hidden Markov Model
ISBI	: International Symposium on Biomedical Imaging

JVM	: Java Virtual Machine
kWh	: Kilowatt-Hour
LNG	: Liquefied Natural Gas
LSE	: Least Squares Estimator
LSTM	: Long- Short Term Memory
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
MICCAI	: International Conference on Medical Image Computing and Computer Assisted Intervention
MLP	: Multilayer Perceptron
MNIST	: Modified National Institute of Standards and Technology Database
MRI	: Magnetic Resonance Imaging
MS COCO	: Microsoft Common Objects in Context
MW	: Megawatt
MWh	: Megawatt - Hour
NLP	: Natural Language Processing
NORB	: NYU Object Recognition Benchmark
NYISO	: New York Independent System Operator
OLS	: Ordinary Least Square
PACF	: Partial Autocorrelation
PGBM	: Point -Wise Gated Boltzmann Machine
PJM	: Interconnection is a Regional Transmission Organization in USA
PTF	: Piyasa Takas Fiyatı
PYS	: Piyasa Yönetim Sistemi
RBF	: Radial Basis Function
RBM	: Restricted Boltzmann Machine

RCMARS	: Robust Conic Multivariate Adaptive Regression Splines
R - CNN	: Region - Convolutional Neural Network
R - DNN	: Recurrent Deep Neural Network
RFM	: Recency, Frequency and Moneatry
RİTM	: Rüzgâr İzleme Test Merkezi
RMSE	: Root Mean Squared Error
RNN	: Recurrent Neural Network
SAIL	: Stanford Artificial Intelligence Laboratory
SARIMA	: Seasonal Autoregressive Integrated Moving Average
SCOP	: Structural Classification of Proteins
SDAE	: Stacked Denoising Autoencoders
SIFT Flow	: Scale - Invariant Feature Transform Flow
Sİ	: Sinyal İşleme
SMF	: Sistem Marjinal Fiyatı
SOM	: Self - Organizing Map
SR	: Sağlık Ve Robotik
SRN	: Simple Recurrent Network
SSI	: Standardized Streamflow Index
SVL	: Stanford Vision and Learning Lab
SVM	: Support Vector Machine
SVR	: Support Vector Regression
SWE	: Share Wave Elastography
TEİAŞ	: Türkiye Elektrik İletim A.Ş
TETAŞ	: Türkiye Elektrik Ticaret Taahhüt A.Ş
TF - IDF	: Term Frequency-Inverse Document Frequency
TWh	: Terawatt - Hour

Uni - ANOVA: Univariate - Analysis of Variance

WT : Wave Transformation

YEKDEM : Yenilenebilir Enerji Kaynakları Destekleme Mekanizması

YSA : Yapay Sinir Ağı





SEMBOLLER

$Arz(P_{max})$	: Maksimum Fiyatta Piyasaya Sunulan Toplam Arz
$Arz(P_{min})$	: Minimum Fiyatta Piyasaya Sunulan Toplam Arz
P_{max}	: Maksimum Fiyat
$Talep(P_{max})$	: Maksimum Fiyatta Piyasaya Sunulan Toplam Talep
$Talep(P_{min})$	: Minimum Fiyatta Piyasaya Sunulan Toplam Talep
m^3	: Metreküp
PTF_s	: s Saati Piyasa Takas Fiyatı
PTF_g	: g Günü Arit. Ort. Piyasa Takas Fiyatı
PTF_a	: a Ayı Arit. Ort. Piyasa Takas Fiyatı
$\left(\frac{F_{iBAlış}}{F_{iBSatış}}\right)_s$	: s Saati Fiyattan Bağımsız Alış-Satış Teklifi Oranı
$\alpha_s^{\frac{F_{iBAlış}}{F_{iBSatış}}}$	: s Saati Fiyattan Bağımsız Alış-Satış Teklifi Oranı Katsayısı
$\Delta_s^{\frac{F_{iBAlış}}{F_{iBSatış}}}$	: s Saati Fiyattan Bağımsız Alış-Satış Teklifi Oranı Hata Payı
$Yük\ Tahmini_g$	: g Günü Yük Tahmini Miktarı
$\alpha_g^{Yük\ Tahmin}$	: g Günü Yük Tahmini Miktarı Katsayısı
$\Delta_s^{Yük\ Tahmini}$	: g Günü Yük Tahmini Miktarı Hata Payı
$Istanbul\ Sıcaklık_g$	: g Günü Arit. Ort. İstanbul Hava Sıcaklığı
$\alpha_g^{Istanbul\ Sıcaklık}$	: g Günü Arit. Ort. İstanbul Hava Sıcaklığı Katsayısı
$\Delta_s^{Istanbul\ Sıcaklık}$	: g Günü Arit. Ort. İstanbul Hava Sıcaklığı Hata Payı
$Istanbul\ Sıcaklık_a$	: a Ayı Arit. Ort. İstanbul Hava Sıcaklığı
$\alpha_a^{Istanbul\ Sıcaklık}$	: a Ayı Arit. Ort. İstanbul Hava Sıcaklığı Katsayısı

$\Delta_{Istanbul\ Sıcaklık}$	: a Ayı Arit. Ort. İstanbul Hava Sıcaklığı Hata Payı
$Rüzgar\ Sant_g$	: g Günü Rüzgar Sant.Tah. Elk. Üretim Mik.
$\propto_g^{Rüzgar\ Sant}$	: g Günü Rüzgar Sant.Tah. Elk. Üretim Mik. Katsayısı
$\Delta_g^{Rüzgar\ Sant}$	: g Günü Rüzgar Sant.Tah. Elk. Üretim Mik. Hata Payı
$Rüzgar\ Sant_a$	: a Ayı Rüzgar Sant.Tah. Elk. Üretim Mik.
$\propto_a^{Rüzgar\ Sant}$	: a Ayı Rüzgar Sant.Tah. Elk. Üretim Mik. Katsayısı
$\Delta_a^{Rüzgar\ Sant}$	: a Ayı Rüzgar Sant.Tah. Elk. Üretim Mik. Hata Payı
$Konya\ Gök\ Endeks_g$	: g Günü Konya Güneş-Gökyüzü Açıklık Endeksi
$\propto_g^{Konya\ Gök\ Endeks}$	: g Günü Konya Güneş-Gökyüzü Açıklık Katsayısı
$\Delta_g^{Konya\ Gök\ Endeks}$	: g Günü Konya Güneş-Gökyüzü Açıklık Hata Payı
$BOTAŞ\ Tarife_a$	: a Ayı BOTAŞ Doğal Gaz Satış Fiyatı
$\propto_a^{BOTAŞ\ Tarife}$	: a Ayı BOTAŞ Doğal Gaz Satış Fiyatı Katsayısı
$\Delta_a^{BOTAŞ\ Tarife}$	: a Ayı BOTAŞ Doğal Gaz Satış Fiyatı Kuru Hata Payı
$\left(\frac{USD\ Dolar}{TL}\right)_g$	: g Günü Merkez Bankası USD Dolar-TL Kuru
$\propto_g^{\frac{USD\ Dolar}{TL}}$	: g Günü Merkez Bankası USD Dolar-TL Kuru Katsayısı
$\Delta_g^{\frac{USD\ Dolar}{TL}}$	: g Günü Merkez Bankası USD Dolar-TL Kuru Hata Payı
$\left(\frac{USD\ Dolar}{TL}\right)_a$	: a Ayı Merkez Bankası USD Dolar-TL Kuru
$\propto_a^{\frac{USD\ Dolar}{TL}}$	: a Ayı Merkez Bankası USD Dolar-TL Kuru Katsayısı
$\Delta_a^{\frac{USD\ Dolar}{TL}}$	: a Ayı Merkez Bankası USD Dolar-TL Kuru Hata Payı
$(TETAŞ-EÜAŞ\ Tarife)_a$	: a Ayı TETAŞ-EÜAŞ Toptan Satış Elektrik Tarifesi
$\propto_a^{TETAŞ-EÜAŞ\ Tarife}$	: a Ayı TETAŞ-EÜAŞ Toptan Satış Elektrik Tarifesi Katsayısı

$\Delta_a^{TETAŞ-EÜAŞ Tarife}$: a Ayı TETAŞ-EÜAŞ Toptan Satış
Elektrik Tarifesi Hata Payı

$Mesken AG Tarife_a$: a Ayı Alçak Gerilim Mesken Elektrik
Tarifesi

$\alpha_a^{Mesken AG Tarife}$: a Ayı Alçak Gerilim Mesken Elektrik
Tarifesi Katsayısı

$\Delta_a^{Mesken AG Tarife}$: a Ayı Alçak Gerilim Mesken Elektrik
Tarifesi Hata Payı

$Doğal Gaz Santrali Yakıt Maliyeti_g$: g Günü Doğal Santrali Yakıt Maliyeti

$\left(\frac{Doğal Gaz Tüketim Miktarı}{Doğal Gaz Elektrik Üretim Miktarı} \right) g$: g Günü Elektrik Üretimi İçin Harcanan
Doğal Gaz Miktarı-Doğal Gaz Santrali Elektrik Üretim Miktarı Oranı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 2018 Santral yakıt tipine göre elektrik üretim miktarı ve payı.....	22
Çizelge 2.2 2018 Santral yakıt tipine göre santral kurulu güç miktarı ve adeti.....	23
Çizelge 3.1 Derin öğrenme kütüphaneleri ve özellikleri.....	37
Çizelge 4.1 Doğal gaz santralleri yakıt maliyeti ve PTF.....	47
Çizelge 4.2 YEKDEM Destekleme Fiyatları I Sayılı Cetvel.....	48
Çizelge 4.3 2018 Günlere göre aylık ortalama PTF.....	51
Çizelge 5.1 Giriş verisi örneği 29.06.2018 06:00.....	54
Çizelge 5.2 n Train(Eğitim) parametresinin belirlenmesi.....	56
Çizelge 5.3 Optimizer parametresinin belirlenmesi.....	57
Çizelge 5.4 Epochs parametresinin belirlenmesi.....	58
Çizelge 5.5 Batch Size parametresinin belirlenmesi.....	59
Çizelge 5.6 Tabakalara ait nöron sayısının belirlenmesi.....	60
Çizelge 5.7 Aktivasyon Fonksiyonu parametresinin belirlenmesi.....	61
Çizelge 5.8 Shuffle parametresinin belirlenmesi.....	63
Çizelge 5.9 2018 Yılı aylık ortalama PTF Tahmin – PTF ve MAPE.....	64



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 2018 Yılı saatlik aritmetik ort. PTF	24
Şekil 2.2 Yıllara göre GÖP eşleşme miktarı	25
Şekil 2.3 2018 Yılı aylık GÖP teklif veren piyasa katılımcısı sayısı	25
Şekil 2.4 Çözüm yönetmi akış şeması	30
Şekil 4.1 29 Haziran 2018 06:00 - 07:00 GÖP arz - talep eğrisi	39
Şekil 4.2 29 Haziran 2018 GÖP fiyattan bağımsız teklifler ve PTF.....	40
Şekil 4.3 29 Haziran 2018 GÖP fiyattan bağımsız teklifler oranı ve PTF	40
Şekil 4.4 2018 Türkiye günlük tahmini elektrik tüketim miktarı ve günlük ort. PTF	41
Şekil 4.5 2018 Yılı İstanbul günlük ortalama sıcaklık ve günlük ort. PTF	42
Şekil 4.6 2018 Yılı İstanbul aylık ortalama sıcaklık ve aylık ort. PTF.....	42
Şekil 4.7 2018 Yılı İstanbul saatlik ortalama sıcaklık ve saatlik PTF dağılımı.....	43
Şekil 4.8 2018 rüzgar santralleri günlük elektrik üretim miktarı ve günlük ort. PTF	44
Şekil 4.9 2018 rüzgar santralleri aylık elektrik üretim miktarı ve aylık ort. PTF.....	44
Şekil 4.10 2018 Konya gökyüzü açıklık ve güneş endeksi ve günlük ort. PTF	45
Şekil 4.11 Doğal gaz santralleri yakıt maliyeti ve PTF	46
Şekil 4.12 2018 BOTAŞ doğal gaz tarifesi ve PTF	47
Şekil 4.13 2018 MB USD Dolar/TL alış kuru ve günlük ort. PTF	48
Şekil 4.14 2018 MB aylık usd dolar/tl alış kuru ve aylık ort. PTF	49
Şekil 4.15 2018 TETAŞ - EÜAŞ toptan satış tarifesi ve aylık ort. PTF.....	50
Şekil 4.16 2018 alçak gerilim tek zamanlı mesken elektrik tarifesi aylık ort. PTF..	50
Şekil 5.1 2018 Yılı 8760 saatlik PTF Tahmin ve PTF.....	65



KERAS KULLANARAK TÜRKİYE GÜN ÖNCESİ ELEKTRİK PİYASASI PİYASA TAKAS FİYATI TAHMİNİ

ÖZET

Gün öncesi elektrik piyasasında (GÖP) oluşan piyasa takas fiyatının (PTF) tahmini, elektrik sektöründe yaşanan yeniden yapılanma ve dikey ayrıştırma süreci ile birlikte önemli hale gelmiştir. Gün öncesi elektrik piyasasında yapılan alış ve satış işlemlerinin çekirdeğini piyasa takas fiyatı oluşturmaktadır. Bu nedenle gün öncesi elektrik piyasasında oluşan piyasa takas fiyatı, elektrik ticareti yapan piyasa oyuncularını için önemlidir. Alış ve/veya satış yapılacak ürün, hizmet veya emtianın fiyatının ne olacağını bilmek; ilgili ticari faaliyeti yürüten kişi veya kuruluşa büyük avantaj sağlayacaktır. Gün öncesi elektrik piyasasında oluşacak olan piyasa takas fiyatının başarılı bir şekilde tahmin edilmesi, piyasa katılımcılarının piyasada izleyecekleri strateji ve oyun planını belirlemeleri için gereklidir. Piyasa oyuncularının karlarını maksimize etmeleri ve ticari faydalarını en üst düzeye çıkarmaları için başarılı piyasa takas fiyatı tahminleri yapmaları gereklidir. Piyasa takas fiyatı tahmin modelleri bu yönüyle piyasa oyuncularını için kilit anahtar role sahiptir. Bu doğrultuda bu çalışmada, EPİAŞ'ın işlettiği Türkiye Gün Öncesi Elektrik Piyasasına ait Saatlik Piyasa Takas Fiyatının tahmin edilebilmesi için bir model geliştirilmiştir. Önerilen model gerçek verileri girdi olarak kullanarak, derin öğrenme kütüphanesi keras ile çalışmaktadır. Derin öğrenme modeline ait optimum mimari belirlenmiştir, derin öğrenme modeline ait parametreler ve modelin tahmin performansı arasındaki ilişki ortaya konulmuştur. Modelde 2018 yılına ait giriş değişkeni verileri ve piyasa takas fiyatı verisi ile derin öğrenme modeli eğitilmiş ve test edilmiştir. 2018 yılına ait 8760 saatin aritmetik ortalama piyasa takas fiyatı % 2.5 MAPE ile tahmin edilmiştir. Önerilen modelin tahmin performansının iyileştirilmesine yönelik yorum ve öneriler yapılmıştır. Modelde kullanılan giriş değişkenlerine ait veri kalitesinin artırılması halinde önerilen modelin tahmin performansının artacağı belirtilmiştir. Güneş ve rüzgar santrallerine ilişkin veriler, ilk kez bu çalışmada Türkiye GÖP Saatlik PTF tahmini için giriş değişkeni olarak kullanılmıştır. Derin öğrenme kütüphanesi keras ilk kez bu çalışmada Türkiye GÖP Saatlik PTF tahmini için kullanılmıştır. Bu çalışmada önerilen modelin uygulanabilirliği ve gerçek piyasa koşullarında kullanılabilir olması, önerilen modelde sadece kamuya açık kaynaklardan temin edilen verilerin kullanılması; modelin, ekonomik ve finansal belirsizlik ile fiyat dalgalanmasının yüksek olduğu 2018 yılında gösterdiği % 2.5 MAPE değerine sahip tahmin performansı bu tezde yapılan çalışmanın başarılı olduğunu göstermektedir.



TURKEY DAY-AHEAD ELECTRICITY MARKET

MARKET - CLEARING PRICE FORECASTING by USING KERAS

SUMMARY

Forecasting the market-clearing price on day-ahead electricity market have become crucial due to reorganization and vertical parsing process within electricity industry / market. Market-clearing price is the core element for buying and selling operations in day-ahead electricity market. Therefore, market-clearing price in day-ahead electricity market is significant to market players who deal with electricity trade. Knowing the price of a product, service or commodity will benefit organizations and market players on their commercial activities. Forecasting the market-clearing price on day-ahead electricity market is vital for market players to establish their market strategy and game plans. Market players are highly dependent on accurate price forecasts to maximize their profits. Thus, market-clearing price forecasting models are the key for market players. In this study, a model is developed to forecast the hourly market-clearing price in day-ahead electricity market in Turkey, which is operated by EPIAŞ.

Fields of Activity of EPIAŞ:

- Day-ahead market transactions
- Intraday market transactions
- Settlement and financial transactions of the day-ahead, intraday and balancing power markets
- Settlement of Ancillary Services Market
- Operation of RERSM
- Invoicing (credit and debt notices for market players)
- Eligible consumer transactions

Liberality process in the electricity market started with the Electricity Market Law No. 4628 with a view to establishment of an electricity market basing on transparency, integrity and competition, allowing integration with the electricity markets of other countries. To this end, a great number of steps were taken in a planned way to build a more dynamic and powerful electricity market and significant advances were made with respect to a market model where the market players assume active roles and monitor the market by means of best methods. The first step of transformation of the electricity market from a single purchaser and a single seller model to a liberal and competitive model was taken on August 1, 2006 by switching to hourly settlement on the consumption part and to monthly settlement system with 3 periods on the production part and the financial settlement system covering 3-months period was launched on July 1, 2006. The next step was start of the operations of the Day-Ahead Planning system on December 1, 2009. These transition periods have great importance

in the transformation of the electricity market to a more powerful and dynamic structure. It has provided valuable experience and insight to the parties which took role in the market transactions and activities previously for new Market operating Licence granted by the market models Turkish organized Wholesale Electricity Market model is a market of bilateral contracts which is balanced by Spot Market Day-Ahead and by Balancing Power Market in real time. Establishment of Spot Market and Balancing Power Market ensures establishment of a competitive electricity market and promotion of the investments. Balancing Mechanism is consisted of Day-Ahead Electricity Market and Intraday Electricity Market operated by EPIAŞ as market operator and the Balancing Power Market operated by TEİAŞ. Day-Ahead Electricity Market started operation on December 1, 2011 and the intraday market on July 1, 2015. Furthermore, settlement of the imbalances is made on hourly basis. EPIAŞ is a private company as per the electricity Market Law No. 6446 enacted by Turkish Grand National Assembly on March 14th, 2013 and published on the Official Journal No. 28603 on March 30, 2013 and it deals with operation of the Day-Ahead Market, Intraday Market as well as settlement of the Balancing Power Market operated by TEİAŞ and the Ancillary Services Markets. Electricity Market Law governs operation of the organized wholesale electricity markets, settlement activities made in such markets and a new activity called “market operator” together with other financial transactions. These activities were previously executed by the Market Financial Settlement Centre (PMUM) in the body of TEİAŞ. EPIAŞ was established under the Energy Turkish Energy Market Regulatory Authority (EMRA) in the scope of the Electricity Market Law. Primary activities of EPIAŞ is planning, formation, development and operation of the energy markets indicated in the market operating licence in an active, transparent and reliable way. EPIAŞ sets reliable reference price without discrimination among the players. And thus it guarantees an increased liquidity by higher number of market players, range of products and trading transactions. The most noticeable indication that EPIAŞ especially focuses on transparency and liberal market is the rate of market players, i.e. 40%, in the total market share among its shareholders. While EPIAŞ operates the electricity markets as approved by the Ministry of Energy and Natural Resources (ETKB) and EMRA, it is also responsible for building new markets such as natural gas, oil, green certificate and carbon. The proposed model, which only uses public data as an input, operates with deep learning library Keras. With this feature, the proposed model in this study can be used by everyone. The success and performance of the proposed model can be tested by everyone. Optimum architecture is defined for the deep learning model. Relationship between the parameters of deep learning model and forecasting performance of the model is exhibited. Input variables used in the model are explained. Deep learning model has been educated and tested by using input variables data and market-clearing price data of 2018. Arithmetic mean of market-clearing price of 8760 hours in 2018, has been forecasted with 2.5% MAPE. The proposed model had the most successful forecasting performance in March with 0.6% MAPE and the lowest forecasting performance in August 8.8% MAPE. The reason for the low performance of forecasting in August is due to the high financial and economic uncertainty and the increase in gas and electricity tariffs. It is exhibited that, hourly market-clearing price of Turkey’s day-ahead market would be successfully forecasted with only using public data via deep learning library Keras. Comments and suggestions presented to improve the forecasting performance of the proposed model. Solar and wind power plant data are used in this study as an input variable for hourly market-clearing price forecasting model, which is the first time in Turkey’s day-ahead electricity market. Thus, the proposed model in this study has contributed to literature

for forecasting Turkey's day-ahead electricity market hourly market-clearing price. Deep learning library Keras has been used first time for the forecasting the hourly market-clearing price of Turkey's day-ahead electricity market. This study shows that deep learning library Keras would successfully be used for forecasting day-ahead electricity market hourly market-clearing price. Price forecasting can be made by creating different scenarios and market conditions with the proposed model. How the possible changes in the variables in the scenario may affect the price can be determined. Weekly, monthly, seasonal and annual price forecasts can be made. The results produced by the proposed model can be used to determine the strategy to be followed in different markets such as bilateral agreement market and futures market. In this respect, the model proposed in this study has a guiding feature for decision makers and market players.





1. GİRİŞ

Gün öncesi elektrik piyasasında oluşan piyasa takas fiyatının (PTF) tahmini, elektrik sektöründe yaşanan yeniden yapılanma ve dikey ayrıştırma süreci ile birlikte önemli hale gelmiştir [1]. Gün öncesi elektrik piyasasında yapılan alış ve satış işlemlerinin esasını piyasa takas fiyatı oluşturmaktadır. Bu nedenle gün öncesi elektrik piyasasında oluşan piyasa takas fiyatı, elektrik ticareti yapan piyasa oyuncuları için büyük öneme sahiptir. Gün öncesi elektrik piyasasında oluşacak olan piyasa takas fiyatının başarılı bir şekilde tahmin edilmesi, piyasa katılımcılarının piyasada izleyecekleri strateji ve oyun planını belirlemeleri için gereklidir. Bu sayede piyasa oyuncularının karlarını maksimize etmeleri ve ticari faydalarını en üst düzeye çıkarmaları mümkündür [1, 2].

Piyasa takas fiyatı çok yüksek belirsizliğe sahip stokastik bir zaman serisine sahip olduğu için, gelecekteki fiyatın ne olacağını kesin bir doğrulukla tahmin etmek çok zordur [1]. Elektrik fiyat zaman serisi, elektrik tüketim zaman serisinden farklı olarak; ortalama ve varyans gibi önemli istatistiki değerleri aykırı özelliklere sahiptir [1]. Benzer günlere ait yük eğrileri arasında yüksek korelasyon ve istatistiki benzerlik bulunurken; bu günlere ait elektrik fiyatları arasında büyük farklar ve oynaklıklar görmek mümkündür; bu durumun nedeni elektriği diğer mal ve emtialardan farklı özelliklere sahip olmasıdır [1].

Elektrik üretiminde kullanılan yakıt fiyatlarındaki fiyat dalgalanması; elektrik şebekesinin iletim kapasitesinin belirsizliği; piyasayı düzenleyen otoritenin piyasa yapısı ve mevzuatlarda yapacağı değişiklikler; hidro, güneş ve rüzgar gibi yenilenebilir enerji kaynaklı elektrik üretimindeki dalgalanmalar; elektrik üretimdeki kesintiler, santral, trafo ve iletim hattı arızaları; kısa ve uzun vadeli dönemde talepte meydana gelecek değişiklikler, hava durumunda oluşabilecek beklenmedik değişiklikler, piyasa oyuncularının davranış ve stratejilerinde yapacağı değişiklikler; elektrik fiyatları üzerinde belirleyici olan önemli belirsizliklerden bazılarıdır [1].

Literatürde yer alan Piyasa Takas Fiyatı Tahmin modellerinde Derin Öğrenme algoritmalarını kullanan çalışmalar mevcuttur. Derin öğrenme algoritmaları kuraklık

tahmini, yüz tanıma, hisse senedi ve Bitcoin fiyatları tahmini, elektrik tüketim miktarı tahmini gibi çeşitli alanlarda kullanılmaktadır.

Agana ve diğ. makalesinde, derin öğrenme algoritmaları kullanarak kuraklık tahmin problemini incelemektedir. Kuraklık, toplum üzerinde tehlikeli etkileri olan doğal bir felakettir. Etkileri çoğunlukla hidrolojik kuraklık olarak kendini gösterir. Geçmişteki kuraklıkları belirlemek ve gelecektekileri tahmin etmek, olası kuraklık etkilerini sınırlamak için çok önemlidir. Kuraklık değişkenlerinin rastgele ve doğrusal olmayan doğası, doğru kuraklık tahminini zorlu bir bilimsel problem haline getirir. Bu çalışmada, Standartlaştırılmış Akış Dizini (SSI) 'nin gecikmeli değerlerini girdi olarak kullanarak uzun vadeli kuraklık tahmini için iki Kısıtlı Boltzmann Makineden oluşan bir model önerilmektedir. Önerilen model, Yukarı Colorado Nehri Havzasında bulunan Gunnison Nehri Havzası boyunca farklı zaman ölçeğine ait kuraklık endekslerini tahmin etmek için kullanılmıştır. Önerilen modelin verimliliği Çok Katmanlı Algılayıcı (MLP) ve Destek Vektörü Regresyonu (SVR) gibi geleneksel yaklaşımlarla karşılaştırılmıştır. Elde edilen sonuçlara göre önerilen model geleneksel yöntemlere göre performans üstünlüğü göstermiştir. 1993 – 2013 yıllarında test edilen önerilen model, MLP ve SVR sırasıyla 0.03, 0.05 ve 0.04 MAE değerlerine sahiptir [4].

Chen ve diğ. makalesinde, derin öğrenmeye kısa genel bir bakış sağlamış; mevcut araştırmalar, büyük verilerle uğraşmanın getirdiği zorlukların yanı sıra, derin öğrenmeyle ilgili geleceğe dönük eğilimlerden bahsetmiştir. Derin öğrenme, şu anda makine öğrenmesi ve görüntü tanıma konularında son derece aktif kullanılan bir araştırma alanıdır. Derin öğrenme; konuşma tanıma, görüntü işleme ve doğal dil işleme gibi geniş bir uygulama alanında büyük başarılar kazanmıştır. Bugün mevcut verilerin büyüklüğü ile büyük veri, çeşitli sektörler için büyük fırsatlar sunmakta; aynı zamanda veri ve var olan bilgileri kullanmak için benzeri görülmemiş zorluklarla karşılaşılmasına neden olmaktadır [5].

Liu ve diğ. makalesinde, vahşi doğadaki yüz özelliklerini tahmin etmek ve modellemek için yeni bir derin öğrenme modeli önermiştir. Yüz özelliklerini tahmin etmek, karmaşık yüz çeşitliliğinden dolayı zordur. Model, özellik etiketleri ile birlikte bir araya getirilmiş, farklı şekilde önceden eğitilmiş iki CNN, LNet ve ANet'i kademelendirir. LNet yüz lokalizasyonu için büyük genel nesne kategorileri tarafından

önceden eğitilirken; ANet nitelik tahmini için büyük yüz kimlikleri tarafından önceden eğitilmiştir. Önerilen model % 83 başarı göstermiştir [6].

Korczak ve diğ. makalesinde, A - Trader isimli hisse senedi alım satım sisteminde derin öğrenmeyi kullanarak, finansal zaman serilerini tahmin etme ve bu yöntemleri geliştirme ile ilgili görüşlerini sunmaktadır. Makalenin ilk bölümünde, FOREX piyasasında finansal zaman serileri tahmini sorunu ele alınmaktadır. Klasik sinir ağları ve derin öğrenme modelleri ana hatlarıyla belirtilmiş, performansları analiz edilmiştir. Son kısımda, H2O kütüphanesinin kullanılarak uygulanan derin öğrenme modelinin uygulanması ve değerlendirilmesini sunulmuştur. Önerilen model 0.83 – 1.64 Sharp Rasyosuna sahiptir [7].

Vargas ve diğ. makalesinde, Standard & Poor 500 endeksinin gün içi hareket yönünü tahmin etmek için finansal haber başlıkları ve bir takım teknik göstergeleri girdi olarak kullanan bir derin öğrenme modeli önermektedir. Derin öğrenme yöntemleri, verideki karmaşık kalıpları ve etkileşimleri, süreci hızlandırarak otomatik olarak algılayabilir ve analiz edebilir. Bu çalışma, geleneksel NLP görevlerinde iyi sonuçlar veren Konvolüsyonel Sinir Ağları (CNN) ve Tekrarlayan Sinir Ağları (RNN) gibi mimarilere odaklanmaktadır. Sonuçlar, CNN'nin metinlerden anlamsallık kazanmada RNN'den daha iyi olabileceğini; RNN'in içerik bilgisini yakalamakta ve borsa tahmini için karmaşık zamansal özellikleri modellemekte daha iyi olduğunu göstermiştir. Önerilen modele ait sonuçlar benzer diğer çalışmalarla karşılaştırıldığında performans bazında daha iyi sonuçlar elde edildiği görülmektedir. EB - CNN modeli eğitim ve test verilerinde sırasıyla % 65.08 ve % 64.2 ile en başarılı model olmuştur [8].

Hossain ve diğ. makalesinde, kuzeybatı Nevada'daki meteorolojik sensörlerden toplanan geçmiş basınç, nem ve sıcaklık verilerini girdi olarak kullanarak; hava sıcaklığı tahmini için önerilen iki farklı yaklaşımı karşılaştırmıştır. Kullanılan veriler açıklanmış; standart sinir ağı ile derin öğrenme ağının kıyası yapılmıştır. Ampirik sonuçlar, Yığın Dengeleyici Otomatik Kodlayıcıları (SDAE) olan derin sinir ağının, bu gürültülü zaman serisini tahmin görevinde standart çok katmanlı ileri beslemeli ağdan daha iyi performans gösterdiğini göstermektedir. Hava sıcaklığının; barometrik basınç, nem ve rüzgâr hızı gibi veriler kullanılarak, yalnızca tarihsel hava sıcaklığı verilerinden hareketle tahmin edilmesinin iyileştirilebileceği gösterilmiştir [9].

McNally ve diğ. makalesinde, Bitcoin fiyatının ABD Doları cinsinden yönünü doğru tahmin edilebilecek bir model önermektedir. Fiyat verileri Bitcoin Fiyat Endeksi'nden alınmıştır. Bayesian optimizasyonlu tekrarlayan sinir ağı (RNN) ve Uzun Kısa Süreli Bellek (LSTM) ağı kullanılarak çeşitli testler yapılmıştır. LSTM modeli ile % 52'lik sınıflandırma doğruluğu, % 8'lik bir RMSE elde edilmiştir. Zaman serisi tahmini için popüler olan ARIMA modeli, derin öğrenme modelleriyle karşılaştırılmıştır. Doğrusal olmayan derin öğrenme modelleri, kötü performans gösteren ARIMA modelinden daha iyi bir tahmin performansı göstermiştir. Son olarak, her iki derin öğrenme modeli de GPU'da ve CPU'da eğitilirken; GPU'daki eğitim süresi, CPU uygulamasına göre % 67.7 oranında daha iyi bir performans göstermiştir [10].

Ghulam ve diğ. makalesinde, ileri beslemeli Derin Sinir Ağı (FF - DNN) ve Tekrarlayan Derin Sinir Ağı (R - DNN) modellerinin kısa dönemli elektrik yükü tahmininde uygulanabilirliğini, doğruluk ve hesaplama performansı açısından karşılaştırmaktadır. Elde edilen sonuçlar, zaman - frekans özellik analizinin derin sinir ağlar ile beraber kullanımının, elektrik tüketimini etkileyen baskın faktörleri yakalayarak daha yüksek yük tahmini doğruluğu elde etmeyi sağladığını; yeni nesil güç sistemlerinde ve SmartGrid'de kesinlikle önemli katkı sağlayabildiğini ortaya koymuştur. 2012 yılı New England iletim sistemi operatörüne ait elektrik tüketim miktarı verisinde test edilen FF – DNN ve R – DNN modelleri ile sırasıyla % 1.42 MAPE ve % 1.3 MAPE elde edilmiştir [11].

Lv ve diğ. makalesinde, mekansal ve zamansal korelasyonları dikkate alan derin öğrenme temelli yeni bir trafik akışı tahmin modeli önermiştir. Trafik akışı tahmini için önerilen yığınlı otomatik kodlayıcı SAE modeli, trafik verilerinin yalnızca sığ yapısını düşünen önceki yöntemlerden farklı olarak, trafik verilerine ait doğrusal olmayan mekansal ve zamansal korelasyonlar gibi gizli özellikleri başarılı bir şekilde göstermektedir. Önerilen modelin PeMS veri setindeki performansı değerlendirilmiş ve önerilen model BP NN, RW, SVM ve RBF NN modelleriyle karşılaştırılmıştır. Elde edilen sonuçlar önerilen modelin diğer modellerden daha üstün olduğunu göstermiştir. SAE Modeli 15 dk ve 60 dk sonrası trafik akışı tahmini için sırasıyla RMSE 50 ve RMSE 183.9 değerlerine sahiptir [12].

1.1 Tezin Amacı

Bu çalışmanın amacı, sadece kamuya açık verileri kullanarak Enerji Piyasaları İşletme A.Ş'nin (EPIAŞ) işlettiği Türkiye Gün Öncesi Elektrik Piyasasına (GÖP) ait bir PTF tahmin modeli geliştirmek; geliştirilecek bu model ile Türkiye Gün Öncesi Elektrik Piyasasına ait Saatlik PTF'nin başarıyla tahmin edilebileceğini göstermektir.

1.2 Literatür Araştırması

Özözen ve diğ. makalesinde, fiyat tahmini için BP öğrenimine sahip SARIMA ve YSA'dan oluşan hibrid bir model kullanmıştır. Model Türkiye Gün Öncesi Elektrik Piyasası için uygulanmıştır, elde edilen sonuçlar ARIMA ve ANN yöntemleri ile yapılan tahmin sonuçları ile karşılaştırılmıştır. Makalede kullanılan modelin tahmin hatalarını yaklaşık % 4 oranında azaltan sonuçlar verdiği görülmüştür [13].

Benli ve diğ. makalesinde, Türkiye'de var olan; tek zamanlı, gündüz, puant ve gece olmak üzere dört farklı zaman dilimine ait elektrik tarifesine ait fiyatları tahmin etmek için çalışma yapmıştır. 4 farklı zaman dilimine ait elektrik tarife fiyatlarının tahmin edilmesi amacıyla 19 farklı tahmin yaklaşımının incelenmesi yapılmıştır. Modellerin doğruluk testi için 2007 - 2014 dönemi seçilmiştir. Elde edilen sonuçlara göre, Holt-Winter'ın yumuşatma, çifte üssel yumuşatma ve ARIMA modeli sırasıyla % 1.54 MAPE, % 1.88 MAPE, % 1.22 MAPE performanslarını göstermiştir. Tek zamanlı tarife tahmininde, 2011 - 2014 dönemi için en iyi tahmin modeli % 1.04 MAPE ile Holt - Winter'ın 12 mevsimsellikte yumuşatma modeli; 2007 - 2014 dönemi için ARIMA (0,1,0) (0,0,1) modeli % 1.22 MAPE ile en iyi tahmin modeli olarak bulunmuştur [2].

Yorulmuş ve diğ. makalesinde, Uzun Kısa Süreli Bellek (LSTM) modelini çok adımlı tahmin yaklaşımı ile kullanarak; Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE) açısından Türkiye Gün İçi Piyasası elektrik fiyatı için en iyi tahminleri yapabilecek bir model kurmayı amaçlamıştır. LSTM modelinin iki tabaka ile kullanılması sonucu 17,2 ₺/MWh MAE değeri elde edilmiştir. 1 Şubat 2017 – 31 Mart 2018 dönemi aritmetik ortalama PTF'nin 164,35 ₺/MWh olduğu göz önüne alındığında makalede kullanılan modelin yaklaşık % 10 MAPE değerine sahip olduğu görülmektedir [14].

Mimović yüksek lisans tezinde, Türkiye elektrik piyasasının analizini sunmaktadır. Türkiye'nin AB mevzuatı ve uygulamalarına uyumu çalışma kapsamında gözden geçirilmiştir. Çalışmada önce çıkan hususlar şunlardır: AB, 1996, 2003 ve 2009 yıllarında kabul edilen üç enerji paketi ile enerji piyasalarını yeniden yapılandırmıştır. Elektrik direktiflerinin temel amacı, piyasaya rekabet getirmeyi sağlamak, piyasaların şeffaflığını, finansal istikrarını ve arz güvenliğini sağlamaktır. Türkiye, AB üyesi olma hedefi ile birlikte; Enerji Topluluğunun sözleşme yapan tarafını olduğundan Enerji Topluluğunda gözlemcisi statüsündedir. Türkiye bu nedenle piyasasındaki rekabeti sağlamak için AB uygulamalarını takip etmektedir. Türkiye elektrik piyasasında ilk büyük değişiklik elektrik piyasası kanunun 2001'de yürürlüğe girmesiyle gerçekleşmiştir. İlgili kanun 2008 yılında değiştirilirken, 2013 yılında yeni bir elektrik piyasası kanunu yürürlüğe girmiştir. Her ikisi de serbestleşme sürecini hızlandırmayı ve AB mevzuatı ve uygulamalarına uygunluğu sağlamayı amaçlamıştır. Piyasa şu anda rekabetçi, finansal olarak istikrarlı ve şeffaf bir toptan satış pazarına dönüştürülmektedir. Mevcut hedefler ve yapılan çalışmalar neticesinde Türkiye Elektrik Piyasasının bölgede lider olması muhtemeldir. Türkiye, dikey olarak entegre olan elektrik piyasasını tamamen rekabetçi ve şeffaf bir elektrik piyasasına dönüştürme sürecinde büyük çaba sarf etmiştir. AB Üye Devletleri örneğini takip edip, piyasa oyuncularına rekabetçi bir piyasa sunmaya çalışmaktadır. Bununla birlikte aşılması gereken birçok zorluk vardır. Bunlardan en önemlisi, bazı dağıtım bölgelerinde % 75'e kadar çıkan, oldukça yüksek olan dağıtım kayıplarının seviyesidir. Bu durum uzun vadede sürdürülebilir değildir çünkü yüksek maliyetli bölgelerin kayıpları düşük maliyetli bölgelerin müşterileri tarafından karşılanmaktadır. Ayrıca ithal doğal gazla olan bağımlılık azaltılmalıdır. Türkiye'deki doğal gaz piyasası serbestleştirilmeli ve daha rekabetçi fiyatlar elde etmek amacıyla daha rekabetçi hale getirilmelidir. Manipülasyon risklerini ortadan kaldırmak ve piyasaya olan güvenini arttırmak için REMIT tipi kurallar uygulamalıdır [15].

Biricik ve diğ. makalesinde, Türkiye elektrik piyasasında kısa dönemli elektrik fiyatı tahmini için, ileri beslemeli YSA kullanılarak elektrik fiyatını etkileyen özellikler(takvim, geçmiş fiyat, yük, hava durumu ve döviz kurları), karakteristiklerine göre kümelenerek tahmin performansına olan etkileri test edilmiş ve değerlendirilmiştir. Takvim bilgisi ve geçmiş fiyat bilgileri tüm testlerde kullanılmış, kalan özellik kümelerinin tüm kombinasyonları oluşturularak fiyat tahmin

performansına olan etkileri gözlenmiştir. Değişik uzunluklarda eğitim kümeleri kullanılarak, değişik eğitim kümelerinin eğitim süresine olan etkisi incelenmiştir. Sonuçta, eğitim süresinden bağımsız olarak, fiyat tahmininde en başarılı özellik kümesinin, takvim ve geçmiş fiyat bilgilerinin yanında yük tahmin planı olduğu görülmüştür. Bu kombinasyona geçmiş yük bilgileri eklendiğinde başarı % 0.21 düşmüştür. Tek basına takvim ve geçmiş fiyat bilgisinin kullanılması ile % 7.76 MAPE sonucu elde edilmiştir [16].

Biricik ve diğ. makalesinde, Mevsimsel Otoresgressif Entegre Hareketli Ortalama (SARIMA) ve Yapay Sinir Ağı (YSA) kullanarak Türkiye Elektrik Piyasasında yük tahmininde kullanmak için iki farklı model önermektedir. Önerilen modellerin her ayın son haftasına ait performansları, karşılaştırmalı olarak sunulmuştur. Mevcut çalışmaların aksine, adil ve tarafsız performans değerlendirmesi için testlere hafta sonları ve özel günleri dahil edilmiştir. Elektrik fiyatı, meteorolojik parametreler ve para birimi gibi faktörlerin tahmin performansına olan etkisi değerlendirilmiştir. 12 haftalık test haftasında model performansları ANN modeli için MAPE % 1.80, SARIMA modeli için MAPE % 2.60 olmuştur. ANN modelinin SARIMA'yla karşılaştırıldığında Türkiye Piyasasına daha uygun olduğunu görülmüştür; bununla birlikte SARIMA bazı durumlarda (özellikle tatil sonrası tahminlerde), YSA'dan daha iyi performans göstermiştir [17].

Uğurlu ve diğ. makalesinde, mevsimsellik, yüksek oynaklık, ani fiyat artışları gibi bazı özelliklere sahip elektrik fiyatının mevsimsellik özelliğini incelemektedir. Elektrik fiyatları saatlere, ayın günlerine, haftanın günlerine, aylara, yıllara ve tatillere göre büyük bir değişiklik göstermektedir. Bu çalışmanın ilk amacı bu gerçeği belirtmek ve elektrik fiyatları hakkında açıklayıcı bilgiler vermektir. İkinci amaç, deterministik mevsimselliği bir Uni - ANOVA işlemini beyazlatma öncesi bir yöntem olarak kullanarak ortadan kaldırmaktır. Elde edilen bulgular, Uni - ANOVA sürecinin 2013 – 2015 dönemi için deterministik mevsimsellik oranını büyük ölçüde ortadan kaldırdığını; PTF standart sapmasını 43.05 ₺/MWh değerinden 22.44 ₺/MWh değerine düşürdüğünü göstermiştir. Ancak stokastik mevsimselliğin hala elektrik fiyat verilerini etkilediğini görülmektedir [18].

Ocakoğlu ve diğ. makalesinde, Türkiye Elektrik Piyasasında finansal araçları kullanarak riskten korunma ve efektif elektrik ticareti için bir model önermektedir. İlk olarak, tedarik yapısı ve Türkiye Elektrik Piyasasının temel bileşenleri incelenmiştir.

Sonra piyasa mekanizması tanıtılmış ve spot piyasa için tahmin modeli önerilmiştir. Önerilen fiyat tahmini modeline ait sonuçlar ve tahmin performansı Black - Scholes metodolojisi tarafından belirlenen opsiyon sözleşmesine ait değerlerle karşılaştırılmıştır. Opsiyon sözleşmesi kullanarak 2017 2. Yarıyıl dönemi için oluşabilecek 5.18 ₺/MWh'lik zararın 0.45 ₺/MWh ile sınırlandırılabilceği gösterilmiştir [19].

Gökgöz ve diğ. makalesinde, Türkiye Elektrik Piyasasında sığ - ANN ve DNN modellerinin elektrik fiyatı tahmin performansını incelemektedir. Modellerin tahmin başarısı, Türkiye elektrik piyasasında kamuya açık, günümüze ait verilerle değerlendirilmiştir. Modellerin girdi değişkenleri olarak tarihsel yük, fiyat ve hava sıcaklığı verileri kullanılmıştır. Veri kümesi Ocak 2016 - Aralık 2017 tarihleri arasında bir saatlik çözünürlükte toplanan ölçüm ve verileri içermektedir. Elden edilen sonuçlara göre DNN modeli 0.346 ₺/MWh MAE değeri ile sığ ANN'ye kıyasla daha iyi tahmin performansı sergilemiştir [20].

Gökgöz ve diğ. makalesinde, Türkiye Elektrik Piyasası elektrik fiyatı tahmini için yapay sinir ağı modellerinin kullanımını tanıtmaktadır. Gradyan iniş, momentumlu gradyan iniş, Broydan, Fletcher, Goldfarb ve Shanno (BFGS) ,farklı nöron ve transfer fonksiyonlarına sahip Levenberg Marquardt algoritmaları; 26.304 saatlik tarihsel veriye sahip 13 faktör ile beraber kullanılarak 400 farklı yapay sinir ağı modeli oluşturulmuştur. Farklı modellerin performanslarına ait MAPE'ler kıyaslanmıştır; en başarılı model % 9.76 MAPE değeri ile Levenberg - Marquardt algoritması olmuştur [21].

Uğurlu ve diğ. makalesinde, Geçitli Tekrarlamalı Üniteleri (GRU), elektrik fiyatı tahmini için yeni bir teknik olarak kullanmayı önermiştir. Uzun Kısa Vadeli Bellek (LSTM) ve Geçitli Tekrarlamalı Üniteleri (GRU) zaman serisi fiyat tahmini için özel olarak hazırlamıştır. 3 katmanlı GRU'lar, elde edilen test sonuçlarında tüm diğer sinir ağı yapılarını ve son teknoloji istatistik tekniklerini tahmin performansında istatistiksel olarak anlamlı bir şekilde geride bırakmıştır [22].

Özmen ve diğ. makalesinde, elektrik fiyatını minimum hata ile tahmin etmek için özelleştirilmiş bir modelleme yaklaşımı önermektedir. Burada önerilen yaklaşım, fiyat tahmininde hatayı minimize etmek için optimum elektrik fiyatının elde edilmesini sağlayan sağlam ve sürekli optimizasyon tekniklerine dayanmaktadır. Elektrik fiyatları

ve zaman serileri genellikle dinamik regresyon modeli kullanılarak tahmin edilmektedir. Bu nedenle, elektrik fiyatı tahmini performansı, dinamik regresyon ile karşılaştırılmıştır. Dinamik regresyon, CMARS ve RCMARS ait MAE değerleri sırasıyla 0.75, 0.53 ve 0.54 olmuştur. Genel sonuçlar, CMARS ve RCMARS'ın dinamik regresyondan daha iyi performans gösterdiğini göstermektedir [23].

Bicil doktora tezinde, tek değişkenli doğrusal zaman serisi tekniği olan Otoregresif Hareketli Ortalama Modeli ile yapay sinir ağı modellerinden Çok Katmanlı Algılayıcının Türkiye Gün Öncesi Piyasası Ocak 2012 - Nisan 2014 dönemi saatlik elektrik fiyatlarını tahmin etme konusundaki performanslarını karşılaştırmıştır. Türkiye Elektrik Piyasası için Piyasa Takas Fiyatı öncelikle bir mevsimsel ARMA süreci olarak tanımlanarak tahmin yapılmıştır. Ardından piyasa takas fiyatı verilerindeki uç değerler kırılarak mevsimsel ARMA süreci yeniden tanımlanmış ve tahmin yapılmıştır. Benzer şekilde çok katmanlı algılayıcı ile piyasa takas fiyatı ve uç değerlerin olmadığı kırılmış piyasa takas fiyatı tahmin gerçekleştirilmiştir. Çok katmanlı algılayıcı ile farklı aktivasyon fonksiyonu ve öğrenme algoritmaları ile beraber değerlendirilerek tahmin performansının değişimi incelenmiştir. Tahmin performansları bakımından kırılmış piyasa takas fiyatı verileri ile tahmin performansının arttığı, tahmin döneminin içine aldığı Kasım 2013 – Nisan 2014 döneminde alt dönemler itibarıyla tahmin performanslarının farklılaştığı; oynaklığın düşük olduğu dönemlerde doğrusal ARMA modellerinin performansının yükseldiği, oynaklığın yüksek olduğu dönemlerde çok katmanlı algılayıcının performansının yükseldiği gözlemlenmiştir. Kasım 2013 – Nisan 2014 dönemi için ARMA modelinin % 19.3 MAPE, çok katmanlı algılayıcının % 8.2 MAPE değerine sahip olduğu görülmüştür [24].

Kölmek ve diğ. makalesinde, yapay sinir ağları ile fiyat tahmininde farklı ağ topolojileri ve parametrelerini seçerek en uygun konfigürasyona sahip ağı belirlemeye çalışmaktadır. Eğitim esnasında farklı ağ yapıları test ederek, farklı sayıda nöron ve katmana sahip ağların tahmin performansları analiz edilmiştir. Eğitim algoritması ve aktivasyon fonksiyonu gibi parametreler değiştirilerek ve bu parametrelerin tahmin hata oranını düşürüp düşürmediği sorgulanmıştır. Aşırı yüksek değerlere sahip girdilere fiyat-kırpma yöntemi uygulayarak, yeni girdilerin tahmin performansına olan etkisi gözlemlenmiştir. Testlerden elde edilen sonuçlara göre; modelin performansına en olumlu katkıyı yapan girdilerin tarihsel fiyat verileri olduğu görülmüştür. En iyi

performansı gösteren ağıta ait özellikler: 1 gizli tabaka, 11 adet nöron, Hyperbolic tanjant, LevenbergMarquardt parametreleridir. ANN ve ARIMA için ortalama MAPE değerleri sırasıyla % 14.15 ve % 15.6 olarak elde edilmiştir [25].

GÖP fiyatlarının stokastik modellenmesi, PTF'deki ani ve ciddi fiyat dalgalanmalarına ve uzun dönemli mevsimselliklere bağlıdır. Bu nedenle ani ve ciddi fiyat dalgalanmalarını tespit edecek modellerin oluşturulması ve uzun dönemli mevsimselliklerin bileşenlerinin analizi büyük önem arz etmektedir. Akyıldırım ve diğ. makalesinde, Janczura ve Weron (2010) ve Janczura ve diğ. (2013) çalışmasındaki yöntemi takip edilerek beş değişik ani artış tespit yönteminin sonuçları değerlendirilmiştir. Ayrıca ani artış gözlemlerin etkileri giderildikten sonra, üç değişik mevsimsellik yöntemine (kukla değişkenler, Fourier serileri, dalgacık tabanlı yöntemler) göre örneklem dışı gözlemlerin tahmin performansına etkisi karşılaştırılmıştır. Modellemek için 2009 - 2013 yıllarında arasında Türkiye GÖP PTF verisi kullanan bu çalışmada; PTF'nin doğru olarak modellenerek ekonomiye katkı sağlanması hedeflenmiştir [26].

Ulussever ve diğ. makalesinde, Türkiye Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatını fiyat dalgalanmasını çeşitli GARCH modelleri kullanarak tahmin için bir model önermiştir. Türkiye Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı ciddi dalgalanmalar göstermektedir. Bu sebeple şartlı fiyat dalgalanmasının tahmin edilmesi, ekonomi için ciddi önem arz eden bu piyasada fiyat dinamiklerini daha iyi anlamaya yardımcı olacaktır. Ocak 2010 - Nisan 2017 dönemi için haftalık piyasa takas fiyatı fiyat dalgalanması tahmin edilmiş ve çeşitli GARCH modelleri ile elde edilen sonuçların performansları karşılaştırılmıştır. Tahmin edilen GARCH modellerinde asimetric etkiler, fiyat dalgalanmasının piyasa takas fiyatı değişimine olası etkileri, kalın kuyruklu dağılımlar ve fiyat dalgalanmasının kararlılığı dikkate alınmıştır. Bulgular zamana göre değişen fiyat dalgalanmasının Türkiye Gün Öncesi Elektrik Piyasasının önemli bir özelliğı olduğunu ortaya çıkarmıştır. Buna ek olarak, bu piyasada fiyat dalgalanmasının modellemesinde kalın kuyruklu dağılımlar kullanılarak ekstrem fiyat değişimlerinin dikkate alınmasının model performansını geliştirdiğı tespit edilmiştir [27].

Yıldız ve diğ. makalesinde, Türkiye Gün Öncesi Elektrik Piyasası için bir tahmin modeli geliştirmiştir. Modelin mimarisi ileri beslemeli geri yayılım sinir ağı yaklaşımına dayanmaktadır. Dört yıllık dönemdeki gerçek piyasa verileri, eğitim ve

test aşamalarında kullanılmıştır. Elde edilen sonuçlar, modelin tahmin performansının güçlü bir şekilde piyasa talebine ve üretim kapasitelerine bağlı olduğunu göstermiştir. 2014 dönemi için % 9.44 MAPE değeri elde edilmiştir [28].

Ulussever ve diğ. makalesinde, fiyat oluşum dinamiklerini tanımlamak ve kısa vadeli fiyat davranışını tahmin etmek için bir stokastik aşırı talep modeli önermiştir. Türkiye Gün Öncesi Elektrik Piyasasında saatlik piyasa takas fiyatı değişiklikleri model parametrelerini belirlemek için kullanılmıştır. Aşırı talep modeli, 2010 - 2016 dönemi Türkiye Gün Öncesi Elektrik Piyasasında Piyasa Takas Fiyatının tahmininde 08:00 ve 11:00 saatleri için sırasıyla 0.1217 ve 0.1032 RMSE değerleri elde edilmiştir [29].

Zakerı yüksek lisans tezinde, Türkiye Elektrik Piyasası saatlik Piyasa Takas Fiyatını sınıflandırmak ve kısa dönemli fiyat tahmini yapmak için bir model önermiştir. Piyasa Takas Fiyatını modellemeye başlamadan önce, olağan dışı fiyatlar belirlenmiştir. Çalışmada, % 99.7 güven aralığı dışındaki tüm değerleri, aralığın sınır değerleriyle değiştirme yaklaşımı sergilenmiştir. Bu amaçla, ortalama fiyatın artı ve eksi üç standart sapma değerlerine karşılık gelen noktalar; üst limit ve alt limit olarak belirlenmiştir. Fiyatı modellemek için ARX tipi bir model kullanılmıştır. Fiyat serilerinde birden fazla mevsimsellik olduğundan, SARIMA modeli yerine regresyon modelinin kullanımı tercih edilmiştir. Modelde fiyatın gecikmeli değerleri, otoregresif parçayı oluşturmak için regresör olarak kullanılmıştır. Gecikmeler ACF ve PACF fiyatlarına göre belirlenmiştir. Talep, hafta sonlarındaki (cumartesi ve pazar) mevsimsellik ile başa çıkmak amacıyla dış değişken olarak kullanılmıştır. Gerçek PTF ve tahmini PTF arasında % 96.5'lik korelasyon değeri elde edilmiştir [30].

Saklıca yüksek lisans tezinde, enerji ticareti ve risk yönetimi için çok önemli olan fiyat dalgalanması ve fiyatı etkileyen temel etmenleri; Türkiye Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatını baz alarak değerlendirilmiştir. Çalışma Ocak 2015 ile Şubat 2016 (dahil) arasını kapsamaktadır. Stokastik fiyat dalgalanması dinamiklerini anlamak için Taylor modeli kullanılmıştır. Ordinary Least Square yöntemi ile saatlik Piyasa Takas Fiyatına etki eden anlamlı, açıklayıcı değişkenler belirlenmiştir. Bu değişkenler, daha kesin tahmin sonuçları üreten Maximum Likelihood modeli ve Efficient Importance Sampling metodunda kullanılarak; saatlik Piyasa Takas Fiyatının fiyat dalgalanması hesaplanmıştır. Piyasa Takas Fiyatı fiyat dalgalanmasına etki eden faktörlerin, stokastik fiyat dalgalanması sürekliliği ve stokastik fiyat dalgalanması standart sapma değerleri üzerinden değerlendirmesi yapılmıştır. Sonuçlar fiyat

dalgalanması büyüklüğünün, her gün türü ve günün her saatinde değişken olduğunu göstermiştir. Ocak 2015 - Şubat 2016 dönemi Pazar günleri için saat 19:00'a ait Nu ve Delta değerleri sırasıyla 0.05 ve 0.99 olarak elde edilmiştir, bu saate ait fiyat dalgalanmasının gözlemlenemeyen faktörlerden kaynaklandığını göstermiştir [31].

Dalgın yüksek lisans tezinde, tek gizli katmanlı, farklı sayıda nöron içeren, Levenberg-Marquardt geriye yayılım algoritmasına sahip yapay sinir ağı modeli kullanarak; Türkiye Gün Öncesi Elektrik Piyasası için Piyasa Takas Fiyatı tahmini çalışması yapmıştır. Çalışmada girdi kümesindeki etkenler detaylı olarak incelenmiştir. İlk olarak zamana bağlı geçmiş fiyatların etkisi 1, 7, 14, 21 ve 28 günlük tekrarlarla denenerek, bir gün ve bir haftalık tarihsel değerlerin birlikte alınması ile daha iyi sonuçlar alındığı görülmüştür. İkinci olarak, toplam talep miktarlarının doğrudan kullanılması yerine rüzgar enerjisi kaynaklı üretim miktarının toplam talep miktarından çıkartılması şeklinde tanımlanan net talebin etkisi ele alınmış; rüzgar değerlerini dikkate alan yapay sinir ağı modelinin daha düşük hatalarla çalıştığı görülmüştür. En düşük hata oranına sahip modelde ağırlık değerleri incelenmiş; gizli katmanda etkisi en fazla olan girdi değişkenlerinden biri olan doğal gaz maliyetinin modelden çıkarılması ile 14 – 28 Kasım 2016 dönemi için MAPE değerinin % 7.9'dan % 10.29'a çıktığı ve tahmin performansının düştüğü gösterilmiştir [32].

Garcia ve diğ. makalesinde, İspanya ve Kaliforniya Gün Öncesi Elektrik Piyasaları Piyasa Takas Fiyatlarını Genelleştirilmiş Otoresgressive Koşullu Heteroskedastik (GARCH) metodolojisi kullanarak tahmin etmek için bir model önermektedir. İspanya ve Kaliforniya Gün Öncesi Elektrik Piyasalarındaki saatlik Piyasa Takas Fiyatlarının ortalama tahmin hataları, çalışılan aya bağlı olarak % 9 civarında gerçekleşmiştir. GARCH modelinin, fiyat dalgalanması ve ani fiyat artışları olduğu zamanlarda, genel bir zaman serisi olan ARIMA modelinden daha iyi performans gösterdiği tespit edilmiştir [33].

Wu ve diğ. makalesinde, Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı Tahmini için karma bir zaman serisi ve uyarlanabilir dalgacık sinir ağı (AWNN) modeli önermektedir. Fiyat serileri yerine, bir dönemlik sürekli bileşik dönüş serisi kullanılmıştır. PJM Gün Öncesi Elektrik Piyasasına ait çeşitli fiyat artışlarına sahip birkaç vaka, önerilen modeli test etmek için kullanılmıştır. Önerilen hibrit model literatürde yer alan çalışmalardan daha iyi performans göstermiştir. Ani fiyat artışlarının aşırı oynaklığı göz önüne alındığında; önerilen modelin ani fiyat artışlarını

tahmin etmede gösterdiği % 5.18 ile % 16.78 MAPE değerleri arasındaki performansın literatürdeki çalışmalara kıyasla yeterince iyi olduğu ortaya konulmuştur [34].

Mandal ve diğ. makalesinde, Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı Tahmini için dalgacık dönüşümüne (WT) dayanan bir veri filtreleme tekniğini, ateş böceği (FF) algoritmasına dayalı bir optimizasyon tekniğini ve bulanık ARTMAP (FA) ağını temel alan; yumuşak bir hesaplama modelini kullanan yeni bir hibrit akıllı algoritma önermektedir. Önerilen modeli test etmek için Ontario ve PJM Gün Öncesi Elektrik Piyasalarına ait Piyasa Takas Fiyatları kullanılmıştır. Önerilen hibrit dalgacık dönüşümü + ateş böceği + bulanık ARTMAP modelini kullanarak yapılan günlük ve haftalık fiyat tahminlere ait sonuçlar, tahmin hatasında % 40'dan daha fazla bir iyileşme olduğunu göstermiştir [35].

Negnevitsky ve diğ. makalesinde, elektrik güç sistemindeki tahmin problemleri ve tekniklerine genel bir bakış sunmaktadır. Mevcut tahmin teknikleri, rüzgar enerjisi tahmini için veri madenciliğine odaklanarak gözden geçirilmiştir. Rüzgar enerjisi, elektrik tüketimi ve fiyat tahmini ile ilgili sorunlara ve tekniklere kısa bir genel bakış sunulmuştur [36].

Zareipour ve diğ. makalesinde, elektrik piyasasına ait gelecekteki fiyatları, bir dizi önceden belirlenmiş fiyat eşiğine göre sınıflandırılmayı ele almıştır. Destek vektör makinelerine dayanan iki alternatif model, çok sınıflı, çok adımlı bir fiyat sınıflandırma yöntemi olarak önerilmiştir. Modellerin her biri fiyat, yük ve öngörülen emre amade kapasite dikkate alınarak değerlendirilmiştir. Modeller, Ontario ve Alberta Gün Öncesi Elektrik Piyasalarına ait Piyasa Takas Fiyatları kullanılarak test edilmiştir; bu piyasaların her ikisi de yüksek fiyat dalgalanmaları sergilemektedir. Elde edilen sonuçlar önerilen fiyat sınıflandırma modellerinin, mevcut olan Piyasa Takas Fiyatı tahmin modellerine kıyasla önemli ölçüde daha doğru sonuçlar verdiğini göstermiştir. Makalede önerilen model 2'nin Alberta Gün Öncesi Elektrik Piyasasında, 2004 yılı ilkbahar, yaz ve kış dönemlerinde 2 – 3 haftalık süreleri kapsayan dönem için % 6.84 MPCE değerine sahip olduğu gösterilmiştir [37].

Anbazhagan ve diğ. makalesinde, Elman ağı kullanarak Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı Tahmini için tekrarlayan bir sinir ağı modeli önermektedir. Önerilen Elman ağına tahmin ait sonuçları; İspanya Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatını tahmin etmek için önerilen otoregressif entegre hareketli

ortalama (ARIMA), dalgacık ARIMA, bulanık sinir ağı, adaptif dalgacık sinir ağı, dalgacık dönüşümlü sinir ağı, dalgacık-ARIMA radyal temelinin melezi, kademeli nöro-evrimsel algoritma ve dalgacık dönüşümü, parçacık sürüsü optimizasyonu ve yöntemleriyle kıyaslanmıştır. Dalgacık dönüşümü, parçacık sürüsü optimizasyonu ve adaptif ağ tabanlı bulanık çıkarım sisteminin kombinasyonu (WPA) % 5.07 ile en iyi tahmin performansını göstermiştir [1].

Amjady ve diğ. makalesinde, özellik seçimi için Rölyef algoritmasının değiştirilmiş versiyonu ve hibrit sinir ağından oluşan yeni bir fiyat tahmin modeli önermiştir. Önerilen model Ontario, New England ve İtalya Gün Öncesi Elektrik Piyasalarında test edilerek, son yayınlanan fiyat tahmin yöntemlerinden bazıları ile karşılaştırılmıştır. Yapılan kıyaslamada önerilen model % 9.23 MAPE ile en iyi tahmin performansını göstermiştir [38].

Li ve diğ. makalesinde, Piyasa Takas Fiyatı tahmin modeli olarak bulanık çıkarım sistemi (FIS), en küçük kareler kestirimi (LSE) ile FIS - LSE kombinasyonu önermiştir. Tahmin sistemi, hem FIS'deki sayısal olmayan sezgiselliği hem de LSE'deki doğrusal olarak ilişkili faktörleri içermektedir. Önerilen model; yapay sinir ağı, ARMA ve GARCH zaman serisi modelleriyle karşılaştırılmış, bu modellerden daha başarılı bir performans sergilemiştir. Çeşitli tekniklerle yapılan kapsamlı testlerin sonuçlarına göre en iyi tahmin performansını % 9.69 MAPE ile LSE göstermiştir [39].

Genel olarak fiyat oynaklığı, yakıt fiyatları (genellikle döviz kurlarıyla ilgili), santrallerin mevcudiyeti, hidro kaynaklı üretim, talep esnekliği ve varyasyonları, şebeke kısıtları ve piyasada yönetim kuralları gibi çok sayıda parametreye bağlıdır. Benini ve diğ. makalesinde, İspanya, Kaliforniya, İngiltere ve PJM Gün Öncesi Elektrik Piyasalarındaki 1999 ve 2000 yıllarına ait Piyasa Takas Fiyatı oynaklığının nicel bir analizini sunmaktadır. Fiyatların artmasıyla birlikte fiyat dalgalanmasının da arttığı ve bu gerçeğin özellikle puant yük dönemlerinde belirgin olduğu görülmüştür [40].

Amjady makalesinde, Gün Öncesi Elektrik Piyasalarında kısa vadeli Piyasa Takas Fiyatı tahmini için bulanık sinir ağına dayanan yeni bir fiyat tahmin modeli önermiştir. Bu bulanık sinir ağı, yeni bir hiperkubik eğitim mekanizması ile katmanlar arası ileri besleyici bir mimariye sahiptir. Önerilen model İspanya Gün Öncesi Elektrik Piyasasında test edilmiştir. Modele ait sonuçlar modelin; ARIMA zaman serileri,

dalgacık - ARIMA, MLP ve RBF sinir ağıları gibi diğer fiyat tahmin yöntemlerinden daha iyi bir tahmin performansına sahip olduğunu göstermiştir. Önerilen modelin haftalık ortalama tahmin hatası % 7.5 olmuştur [41].

Pinto ve diğ. makalesinde, Gün Öncesi Elektrik Piyasalarında Piyasa Takas Fiyatını tahmin etmek için dinamik bir yapay sinir ağı modeli önermiştir. Önerilen yapay bir sinir ağı modeli, en son mevcut verileri göz önünde bulundurmak amacıyla her uygulamada kendisini yeniden eğitmektedir; bu nedenle model tahminlerini zaman içinde meydana gelen gelişmelere göre adapte edebilmektedir. Yapılan ticaret simülasyonunda 400,000 Euro gelir elde edilen, 730 günlük eğitim süresinin en ideal eğitim süresi olduğu gösterilmiştir [42].

Zareipour ve diğ. makalesinde, literatürde Gün Öncesi Elektrik Piyasalarında Piyasa Takas Fiyatının tahmin edilmesi ve tahmin doğruluğunun iyileştirilmesi için çeşitli teknikler önerilmesine karşın Piyasa Takas Fiyatı tahmini hatasının, Piyasa Takas Fiyatı tahmin modeli kullananlar üzerindeki ekonomik etkilerini inceleyen hiçbir çalışma rapor edilmediğini belirtmiştir. Bu çalışmada, Gün Öncesi Elektrik Piyasalarında Piyasa Takas Fiyatının tahmini modellerinin iki farklı endüstriyel yükün kısa vadeli işletme planlarına dahil edilmesi incelenmiş ve hatalı Piyasa Takas Fiyatının tahmini yapılmasının ekonomik etkileri analiz edilmiştir. Tahmin hatasında yapılacak % 1 iyileştirmenin, maliyetlerde % 0.1 - % 0.35 arasında azalma sağlayacağı gösterilmiştir [43].

Lora ve diğ. makalesinde, en yakın komşular metodolojisine dayanan Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatını tahmin etmek için basit bir model önermiştir. Modeli tanımlayan ilgili parametrelerin nasıl elde edildiği açıklanmıştır. Önerilen model 2002 yılı İspanya Gün Öncesi Elektrik Piyasasına ait verilerle test edilmiştir. Önerilen yöntemin performansı yayınlanmış en son çalışmalardan ANN, Neuro-Fuzzy sistemleri, GARCH ve ARIMA (dalgacık dönüşümü olan ve olmayan) ile karşılaştırılmıştır. Literatürde yer alan çalışmalarla kıyaslandığında önerilen modelin tatmin edici bir performans gösterdiği belirtilmiştir. İspanyol Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatının belirsizliği göz önüne alındığında, elde edilen aylık % 8'e yakın ortalama hata modelin başarılı olduğunu göstermiştir [44].

Motamedi ve diğ. makalesinde, tüketicilerin toplu hareketi, Gün Öncesi Elektrik Piyasasında talep eğrisini değiştirme potansiyeline sahiptir; bu nedenle yapılan

tahminlerden daha farklı Piyasa Takas Fiyatları ortaya çıkabilir önermesinden hareketle; Piyasa Takas Fiyatı ve elektrik talebini tahmin ederken farklı dinamikleri dikkate alan karma bir tahmin modeli önermiştir. Önerilen model, tahmini Piyasa Takas Fiyatı ve tahmini elektrik talebinin birbirleri üzerindeki çift yönlü etkilerini dikkate almaktadır. Önerilen model, ortak bir Piyasa Takas Fiyatı tahmini ve elektrik talebi tahmini için veri girişli madencilik (DAM) algoritmalarıyla, çok girişli çoklu üretim (MIMO) tahmin motorunu birleştirmektedir. Tüketicilerin Piyasa Takas Fiyatı tahminlerine verdikleri tepkileri modellemek için veri girişli madencilik (DAM) tabanlı bir kural çıkarma mekanizması kullanılmaktadır. Çıkarılan kurallar daha sonra çok girişli çoklu (MIMO) motorunun başlangıçta yaratılan elektrik talebi ve Piyasa Takas Fiyatı tahminlerini ayarlamak için kullanılmaktadır. Model Avustralya ve New England Gün Öncesi Elektrik Piyasalarında test edilmiştir. Avustralya ve New England Gün Öncesi Elektrik Piyasaları için sırasıyla % 10.01 MAPE ve % 8.38 MAPE değerleri elde edilmiştir [45].

Chen ve diğ. makalesinde, manifold öğrenme metodolojisini (yerel olarak doğrusal gömme (LLE) uygulayarak Piyasa Takas Fiyatı eğrilerinin modellenmesi ve analizi için parametrik olmayan yeni bir model önermektedir. Modelde manif öğrenme ve yeniden yapılanmaya dayalı tahmin, kısa ve orta vadeli Piyasa Takas Fiyatı tahmini yapmak için kullanılmıştır. Model NYISO - Doğu ABD Gün Öncesi Elektrik Piyasasından alınan geçmiş Piyasa Takas Fiyatı verileriyle test edilmiştir. Elde edilen sonuçlar modelin kısa vadeli tahminler için iyi performans gösterdiğini ve diğer yöntemler için bile zor olan orta vadeli tahminleri kolaylaştırdığını göstermiştir. Holt –Winters algoritması ile % 7.2 MAPE elde edilmiştir [46].

Zhou ve diğ. makalesinde, Piyasa Takas Fiyatı tahminini için ARIMA modeli kullanmıştır. Otoregressif entegre hareketli ortalama (ARIMA) yaklaşımı, hata düzeltme ve güven aralığı tahmini özelliklerini içerek şekilde geliştirilmiştir. Kaliforniya Gün Öncesi Elektrik Piyasası saatlik Piyasa Takas Fiyatı modeli test etmek için kullanılmıştır. Test sonuçları, Piyasa Takas Fiyatı tahmini için önerilen genişletilmiş ARIMA yaklaşımının tatmin edici bir doğrulukla etkili olduğunu göstermiştir. 2000 yılı Kaliforniya Gün Öncesi Elektrik Piyasası saatlik Piyasa Takas Fiyatı tahmininde konvansiyonel ARIMA ortalama % 8.3 tahmin hatasına sahipken, geliştirilen ARIMA modelinin aynı dönem için tahmin hatası % 1.55 olmuştur [47].

Szkuta ve diğ. makalesinde, Yapay Sinir Ağları (YSA) algoritmasını kullanarak Sistem Marjinal Fiyatının (SMP) kısa vadeli tahmini için bir model önermektedir. Önerilen model, backpropagation ile üç katmanlı yapay sinir ağı yapısına sahiptir. Victoria elektrik piyasasına ait Sistem Marjinal Fiyatı verisi, yapay sinir ağının eğitimi ve test edilmesi için kullanılmıştır. Elde edilen sonuçlar, yapay sinir ağına dayalı bir yaklaşımın Sistem Marjinal Fiyatını tahmin etmede başarılı olduğunu göstermiştir. 14 – 20 Mayıs 1997 dönemi için elde edilen tahmin sonuçları 0.64 – 1.33 arası RMSE değerlerine sahiptir [48].

Rodriguez ve diğ. makalesinde, yalnızca kamuya açık bilgi ve verileri kullanarak Ontario Gün Öncesi Elektrik Piyasası saatlik Piyasa Takas Fiyatı tahmini için basit ve kullanımı kolay bir teknik geliştirmek amacıyla; sinir ağları ve bulanık mantık yapay zeka algoritmalarının kombinasyonunu içeren bir model önermektedir. Önerilen modelin tahmin performansı bağımsız iletim sistemi operatörünün tahmin sonuçları ile karşılaştırılmıştır. Bağımsız iletim sistemi operatörünün tahmin hatası % 55.21, önerilen modelin tahmin hatası % 1.47 olarak gerçekleşmiştir [49].

Bunn makalesinde, elektrik piyasalarında yük ve fiyat tahmini için yenilikçi olan tekniklerin bir incelemesini sunmaktadır. Toptan elektrik piyasalarında yüklerin ve fiyatların tahmin edilmesi karşılıklı olarak birbirleriyle iç içe geçmiş faaliyetlerdir. Talep tarafını tahmin etmek için değişken bölümlendirme, çoklu modelleme, sinir ağları; arz tarafı için yapay ajanlar kullanarak stratejik simülasyonlar hazırlamaya ağırlık verilmiştir [50].

Ruibal ve diğ. makalesinde, belirli bir dönemdeki saatlik Piyasa Takas Fiyatı ve ilgili dönemin ortalama Piyasa Takas Fiyatını tahmin etmek için teklif bazlı stokastik bir model önermektedir. Model, iki belirsizlik kaynağını göz önüne alarak, fiyatlandırma sürecinin hem ekonomik hem de fiziksel yönlerini ele almaktadır: santrallerin emre amadeliliği ve talep. Üç oligopol model temel alınarak inceleme yapılmıştır: Bertrand, Cournot ile Rudkevich, Duckworth ve Rosen arz fonksiyonu dengesi (SFE). Piyasadaki oyuncu sayısı, beklenen en yüksek talep ve talebin fiyat esnekliği konusunda duyarlılık analizi yapılmıştır. Sonuçlar, piyasadaki oyuncu sayısı azaldıkça, beklenen Piyasa Takas Fiyatı önemli miktarda arttığını göstermiştir. Son olarak doğru bir sıcaklık tahmininin, Piyasa Takas Fiyatı tahmin hatasını önemli ölçüde azaltabileceği gösterilmiştir. Elektrik tüketiminin zirve yaptığı saatlerde,

sıcaklığın saatlik Piyasa Takas Fiyatı varyansının % 75'ini açıklayabildiği gösterilmiştir [51].

Guan ve diğ. makalesinde, üretim ve tüketim birimi olan piyasa oyuncularının Kaliforniya Gün Öncesi Elektrik Piyasasında gerçekte nasıl teklif verdiklerini görmek için, piyasa oyuncularının tarihsel teklif verme davranışını incelemiştir. Mahkûm ikilem matris oyununu formüle ederek ve oyuncuların stratejik davranışlarını açıklamak için “fırsatçı taktik çarpışması” kavramını ortaya konulmuştur [52].

Catalão ve diğ. makalesinde, kısa vadeli Piyasa Takas Fiyatı tahmini için hibrid yeni bir model önermektedir. Önerilen model, dalgalık dönüşümü, parçacık sürüsü optimizasyonu ve adaptif ağ tabanlı bulanık çıkarım sisteminin kombinasyonuna dayanmaktadır. Önerilen model İspanya Gün Öncesi Elektrik Piyasasında Piyasa Takas Fiyatı verisiyle test edilmiştir. Önerilen yaklaşımın, önceki çalışmalara ait sonuçlar dikkate alındığında, kabul edilebilir bir hesaplama süresiyle daha iyi bir tahmin performansı ortaya koyduğu görülmektedir. Test sonuçları MAPE ortalaması % 5.07 değerine sahipken, ortalama hesaplama süresi 1 dakikadan azdır [53].

García - Martos ve diğ. makalesinde, karışık modeller kullanarak Piyasa Takas Fiyatını doğru tahmin etmek için yeni ve çok kolay bir model önermiştir. Daha küçük tahmin hatasına sahip modeli seçmek ve tahmin için kullanılacak uygun süreyi tespit etmek için bir hesaplama deneyi yapılmıştır. Modele İspanya Gün Öncesi Elektrik Piyasasında Piyasa Takas Fiyatı verisinde test edilmiştir. 1998 - 2003 yılları arası her saat için tahmini Piyasa Takas Fiyatı hesaplanmıştır; tüm döneme ilişkin ortalama tahmin hatası % 12.61'dir. Hafta içi için elde edilen ortalama hata % 11.9 ve hafta sonları için elde edilen ortalama hata % 14.4 olmuştur [54].

González ve diğ. makalesinde, Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı analizi ve tahmini için bir Girdi - Çıktı Gizli Markov Modeli (IOHMM) önermiştir. Önerilen IOHMM sadece fiyat tahmini yapmakla kalmıyor, aynı zamanda piyasa hakkında dinamik bilgi sağlamaktadır. Önerilen model ve taksonomi, durağan ve durağan olmayan zaman serisi modelleri arasında ayırım yapmaktadır. Sabit modeller kısa süreli elektrik zaman serilerine uygulanabilse de, büyük serilere uygulandığında ciddi problemler ortaya çıkarmaktadır. Buna karşılık, durağan olmayan modellerin elektrik fiyatlarına daha uygun olduğu görülmektedir. Model, İspanya Gün Öncesi

Elektrik Piyasasında Piyasa Takas Fiyatıyla test edilmiştir. Test sonucunda % 15.83'lük MAPE elde edilmiştir [55].

Fan ve diğ. makalesinde, kısa vadeli Piyasa Takas Fiyatını tahmin etmek için hibrit, iki aşamalı, kendi kendini organize eden harita ağına (SOM) ve destek vektörüne dayalı makineye (SVM) sahip yeni bir model önermektedir. İlk aşamada, giriş verilerini kümelemek için denetimsiz bir şekilde birkaç alt gruba SOM ağı uygulanmaktadır. İkinci aşamada her bir alt kümenin eğitim verilerini, denetlenen şekilde hazırlamak için bir grup SVM kullanılmaktadır. Önerilen modelin performansını test etmek için, New England Gün Öncesi Elektrik Piyasası tarihsel Piyasa Takas Fiyatı verisi kullanılmıştır. Aralık 2002 için % 10.24, Mart 2005 için % 6.35 MAPE değerleri elde edilmiştir [56].

El - Khattam ve diğ. makalesinde, bir dağıtım şirketi açısından dağıtık üretim (DG) kapasite yatırım planlamasının belirlenmesinde kullanmak için yeni bir sezgisel yaklaşım önermektedir. Dağıtık üretim kapasitesi için optimum boyutlandırma ve yer seçimi kararları, yeni bir optimizasyon modeline dayanan bir fayda - maliyet analizi yaklaşımı ile elde edilmektedir. Model, dağıtım şirketi yatırım ve işletme maliyetlerini en aza indirmeyi amaçlamaktadır. Bara bazında fayda - maliyet analizi, öngörülen en yüksek talep ve en yüksek Piyasa Takas Fiyatı senaryoları için saatlik olarak değerlendirmeler yapılmaktadır. Bu yaklaşım en uygun dağıtık üretim kapasite yatırım planını elde etmeyi sağlamaktadır. Önerilen sezgisel yöntem, optimizasyon modelinde ikili değişkenlerin kullanımını hafifletmeye yardımcı olarak hesaplama yükünü büyük ölçüde azaltmaktadır. Bara başına günlük toplam 1205 \$ – 5396 \$ arasında değişen fayda elde edilebileceği gösterilmiştir [57].

Meng ve diğ. makalesinde, gelişmiş, kendinden uyarlamalı radyal temel işlevli (RBF) sinir ağını baz alan güvenilir bir Piyasa Takas Fiyatı tahmin modeli önermektedir. Önerilen radyal temel işlevli sinir ağı modeli, bulanık c - araçları ile eğitilmiştir. Ağların yapısını otomatik olarak yapılandırmak ve model parametrelerini elde etmek için diferansiyel gelişim kullanılmıştır. Bu tekniklerle, nöronların sayısı, küme merkezleri ve gizli katmanın yarıçapları ve çıkış ağırlıkları otomatik olarak verimli bir şekilde hesaplanabilir. Hareketli pencere dalgası gürültüsüzleştirme tekniği, ağ performansını artırmak için tanıtılmıştır. Model, Avustralya Ulusal Elektrik Piyasası'nın Queensland Elektrik Piyasası bölgesel Piyasa Takas Fiyatı verisi kullanılarak test edilmiştir. % 7.8 MAPE değeri elde edilmiştir [58].

Boogert ve diğ. makalesinde, kamuya açık olan bilgileri kullanarak, saatlik Piyasa Takas Fiyatını modellemek için bir arz - talep sistemi kullanmıştır. Arz - talep sistemini oluşturmak için gerekli basit bir modelin nasıl oluşturulduğu gösterilmiştir. Başlıca bulgulardan biri, performansı artırmak için üretim rezervlerinin tahmin modeline dahil edilmesi gerektiğidir. Elde edilen sonuçlar, öngörülen üretim kapasitenin 24 saat sonrasına ait Piyasa Takas Fiyatı hareketlerini öngörmede oldukça başarılı olduğunu göstermektedir. Modelle, belirli bir eşiğin üzerindeki Piyasa Takas Fiyatındaki bir yükselişin seviyesi ve olasılığı tahmin edebilmektedir. Saatlik Piyasa Takas Fiyatının 80 €/MWh'i aşma olasılığı % 14.1, 150 €/MWh'i aşma olasılığı % 2.1 olarak bulunmuştur [59].



2. TÜRKİYE ELEKTRİK PİYASASI

2.1 Giriş

Enerji Piyasaları İşletme A.Ş. (EPİAŞ), 18 Mart 2015 tarihinde kurulmuştur. EPİAŞ'ın kuruluşuna dayanak oluşturan ilgili mevzuatlar: 14.03.2013 tarihli ve 6446 sayılı Elektrik Piyasası Kanunu'nun [60] 11. maddesi Enerji Piyasaları İşletme A.Ş. Teşkilat Yapısı ve Çalışma Esasları Hakkında Yönetmelik, Elektrik Piyasası Lisans Yönetmeliği ve Dengeleme ve Uzlaştırma Yönetmeliğidir [61]. EPİAŞ, 20 Ağustos 2015 tarihli ve 5741-2 sayılı Enerji Piyasası Düzenleme Kurulu (EPDK) Kurul Kararıyla 1 Eylül 2015 tarihi itibarıyla piyasa işletim faaliyetini Türkiye Elektrik İletim A.Ş'den (TEİAŞ) devralmıştır. EPİAŞ, Türk Ticaret Kanunu hükümleri çerçevesinde özel hukuk hükümlerine tâbi bir anonim şirket olarak kurulmuştur. EPİAŞ, faaliyet alanına giren enerji piyasalarını işletmekte, bu piyasalarda yapılan ticaretin mali uzlaştırmasını sağlamakta ve bu kapsamda gerekli faaliyetleri yürütmektedir. EPİAŞ'a Elektrik Piyasası Kanunu'yla tarafından verilen hak ve yükümlülükler; mevcut piyasaları geliştirmek, yeni enerji piyasaları kurulmasına yönelik çalışmalar yapmak ve EPDK'ya sunmaktır. Enerji Bakanlığının uygun görmesi hâlinde; uluslararası enerji borsalarına ortak veya üye olmak, piyasa işletim ücreti tarifesini belirleyerek EPDK'ya sunmaktır. EPİAŞ, gün öncesi piyasası (GÖP) ve gün içi piyasasını (GİP) işletmekle, piyasa işlemlerine ilişkin itirazları değerlendirilip sonuçlandırılmakla, teklifler ile belirlenen PTF'nin duyurulmasıyla sorumludur. İşlettiği piyasalara ilişkin olarak ticaret sonuçlarını, detay ödeme bilgilerini, teminat bilgileri ve ilgili diğer verileri ilgili piyasa katılımcısına bildirmektedir. Piyasa katılımcılarının alacak ve borç tutarları hesaplayıp, piyasa katılımcılarına alacak ve borç bildirimlerini yapmaktır. Kayıt ve serbest tüketici işlemlerini gerçekleştirme ve fiyat oluşumu ve gerçekleşen işlemlere ilişkin istatistikleri taraflar arasında ayırım yayımlanması sağlamaktır [62]. Çizelge 2.1'de ve Çizelge 2.2'de sırasıyla 2018 yılı santral yakıt tipine göre elektrik üretimin dağılımı ve santral kurulu gücüne ait bilgilere yer verilmiştir [63, 64].

Çizelge 2.1 2018 Santral yakıt tipine göre elektrik üretim miktarı ve payı

Santral Yakıt Tipi	Elektrik Üretim Miktarı (MWh)	Pay (%)
Doğal Gaz	90,231,871	% 30.0
İthal Kömür	62,149,300	% 20.7
Hidro	59,754,948	% 19.9
Linyit+Asfaltit+Taş Kömürü	49,670,364	% 16.5
Rüzgâr	19,882,202	% 6.6
Güneş	7,477,291	% 2.5
Jeotermal	6,905,606	% 2.3
Biyokütle	3,215,678	% 1.1
Fuel Oil	1,429,494	% 0.5
Toplam [63]	300,716,754	% 100

Çizelge 2.2 2018 Santral yakıt tipine göre santral kurulu güç miktarı ve adeti


Santral Yakıt Tipi	Kurulu Güç (MW)	Pay (%)	Santral Adeti	Pay (%)
Doğal Gaz	25,673	% 29.001	317	% 4.260
Barajlı	20,536	% 23.198	120	% 1.612
Linyit	9,597	% 10.841	48	% 0.645
İthal kömür	8,939	% 10.098	14	% 0.188
Akarsu	7,755	% 8.760	538	% 7.229
Rüzgar	7,005	% 7.913	250	% 3.359
Güneş	5,068	% 5.725	5,874	% 78.930
Jeotermal	1,260	% 1.423	47	% 0.632
Fuel oil	709	% 0.801	16	% 0.215
Biyokütle	646	% 0.730	143	% 1.922
Taş kömür	616	% 0.696	3	% 0.040
Asfaltit	405	% 0.457	1	% 0.013
Atık ısı	310	% 0.350	68	% 0.914
Nafta	5	% 0.006	1	% 0.013
Lng	2	% 0.002	1	% 0.013
Motorin	1	% 0.001	1	% 0.013
TOPLAM [64]	88,526	% 100	7,442	% 100

2.2 Türkiye Gün Öncesi Elektrik Piyasası (GÖP)


EPIAŞ tarafından işletilen gün öncesi elektrik piyasası (GÖP), fiziki teslimat gününden bir gün öncesinde, elektrik ticaretinin yapıldığı bir piyasadır. GÖP'ün amacı;

- Fiziki ticarete konu olan elektrik enerjisine ait referans fiyatının belirlenmesini sağlamak,
- İkili anlaşma piyasasına alternatif başka bir piyasada ticaret yapma imkanı sağlamak,
- İletim sistemi operatörü TEİAŞ'a bir gün öncesinden üretim ve tüketim açısından dengeli bir sistem sağlamak,
- Enterkonnekte sistemde var olan kısıtların bir gün öncesinden yönetilebilmesi için teklif bölgeleri oluşturularak, TEİAŞ'a kısıt yönetimi yapabilme imkânı sağlamaktır [62].

Şekil 2.1'de 2018 yılındaki her bir saate ait aritmetik ortalama PTF yer almaktadır. Aritmetik ortalama PTF'si en düşük olan saat 187.58 ₺/MWh ile 04:00, aritmetik ortalama PTF'si en yüksek olan saat 253.46 ₺/MWh ile 21:00 olmuştur [53].




Şekil 2.1 2018 Yılı saatlik aritmetik ort. PTF



Şekil 2.2 Yıllara göre GÖP eşleşme miktarı

Şekil 2.2’de 2012 - 2018 dönemi ait GÖP eşleşme miktarı yer almaktadır [63]. Yıllık GÖP eşleşme miktarının artış trendine sahip olduğu görülmektedir. Şekil 2.3’de 2018 yılında her bir aya ait GÖP’e teklif veren piyasa katılımcısı sayısı yer almaktadır. En yüksek ve en düşük piyasa katılımcısı sayısı sırasıyla 768 adetle Mayıs, 728 adetle Eylül ve Ekim ayında gerçekleşmiştir [63].



Şekil 2.3 2018 Yılı aylık GÖP teklif veren piyasa katılımcısı sayısı

2.2.1 Genel esaslar

GÖP’de ticaret yapmak isteyen piyasa katılımcıları Piyasası Katılım Anlaşması’nı imzalamak zorundadır. EPDK’nın vermiş olduğu faaliyet lisansına sahip piyasa katılımcıları katılım anlaşmasını imzalayarak GÖP’de ticaret yapabilir. GÖP’de ticaret günlük olarak yapılır. Uzlaştırma saatlik bazda yapılan işlemlerin alış ve satış tutarları üzerinden toplanarak yapılır. Ticarete konu olan güne 24 saatlik zaman dilimi ilgili güne ait GÖP işlemlerini oluşturur. Herhangi bir piyasa katılımcısı GÖP teklifini bir sonraki günden başlayarak 5 gün sonrası dahil olacak şekildeki süreci kapsayan günlerde verebilir. Piyasa katılımcılarının EPIAŞ’a ödeceği veya EPIAŞ’ın piyasa katılımcılarına ödeyeceği ödemelere ilişkin bildirimlerine ait duyurular EPIAŞ tarafından Takasbank üzerinden yapılır [61, 62].

2.2.2 Süreçler

GÖP’e katılan piyasa katılımcıları bir sonraki güne ait GÖP tekliflerini her gün saat 12:30’a kadar GÖP sistemi aracılığıyla EPIAŞ’a bildirirler. GÖP tekliflerini değerlendirme ve doğrulama işlemi EPIAŞ saat 12:30 - 13:00 arasında yapılır. Teyit edilen teklifler saat 13:00 – 13:30 arasında, optimizasyon aracı ile değerlendirilir ve ilgili günün her bir saatine ilişkin PTF ve eşleşme miktarları belirlenir. Onaylanmış alış - satış miktar bilgisini içeren ticari işlem onayları ilgili piyasa katılımcısına her gün 13:30’da bildirilir [61, 62].

2.2.3 Teklifler

Mevcut piyasada saatlik, blok ve esnek olmak üzere üç farklı teklif tipi mevcuttur. Tüm teklif tiplerine ait fiyatlar yüzde birlik hassasiyete sahiptir. Teklifler sadece Türk Lirası (TL/MWh) para biriminde yapılmaktadır. Teklif miktarları Lot cinsinden tam sayı olarak bildirilir. 1 Lot = 0.1 MWh. Teklifler alış ya da satış yönünde verilir. Hangi yönde teklif verileceği teklife ait miktarın önündeki işaret ile belirlenir (Örn: Alış Teklifi 500 LOT, Satış Teklifi – 600 LOT). EPIAŞ tarafından asgari fiyat teklif sınırı 0 TL/MWh, azami teklif fiyatı sınırı 2,000 TL/MWh olarak belirlenmiştir. Değişen piyasa koşullarına göre EPIAŞ, asgari ve azami fiyat limitlerini güncelleyerek, PYS aracılığıyla piyasa katılımcılarına duyurur. EPIAŞ tarafından asgari miktar teklif sınırı 0 LOT, azami teklif miktar sınırı ise $\pm 130,000$ LOT olarak belirlenmiştir. Esnek ve blok teklif miktarı 600 MWh’i (6,000 Lot) geçemez [61, 62].

2.2.3.1 Saatlik teklif

Saatlik teklifler alış yönünde 32 adet, satış yönünde 32 adet olmak üzere en fazla 64 adet fiyat kırılımına sahip olabilir. Saatlik tekliflerde fiyat kırılımları artan bir biçimde belirlenmelidir. Aynı fiyat kırılımında geçerli hem alış hem satış yönünde saatlik teklif bulunamaz. Arz - Talep eğrisi oluşturulurken ardışık iki fiyat - miktar seviyesi arasındaki boş değerler doğrusal interpolasyon metodu ile belirlenerek doldurulur [61, 62].

2.2.3.2 Blok teklif

Blok teklifler fiyat, miktar ve kapsadığı zaman dilimi bilgisini içerir. Bir blok teklif en az 3 en fazla 24 saati kapsayacak şekilde oluşturulabilir. Blok teklif saatleri ardışık ve tam saat dilimleri olarak belirlenirler. Blok teklif tamamı bölünemez tek bir bütün olarak işlem görür. Her bir blok teklif, kapsadığı saat aralığı için ya kabul edilir ya da tamamen reddedilir. En fazla 50 adet blok teklif verilebilir [61, 62].

2.2.3.3 Esnek teklif

Esnek teklifler; miktar ve fiyat bilgisi ikilisinden oluşur. Esnek teklifler sadece sistem satış yönünde verilirler. Belirli bir saate ilişkin değildir. En fazla 10 adet esnek teklif verilebilir [61, 62].

2.2.4 Optimizasyon modeli

Gün Öncesi Piyasası Optimizasyon Yazılımı, GÖP piyasa katılımcıları teklifleri ile her saate ait için piyasa takas fiyatını (PTF) ve tekliflere ait eşleşme miktar ve eşleşme fiyatını belirler. Bu süreçte, birden çok algoritma ve matematiksel modeli eniyi (optimal) çözüm elde etme amacıyla kullanır. Problem çözümü için kısıtlı bir zaman olduğundan, yazılım önce sezgisel algoritmalar kullanarak kısıtlara uyan kaliteli bir çözüm bulmayı hedefler. Ardından bir matematiksel program çözücüsü kullanarak optimal çözümü bulmaya çalışır. Tekliflerin kabul edilme şartları bazı kısıtlara bağlanmıştır. Saatlik alış ya da satış teklifleri için bu kural, ilgili saatin hesaplanan PTF değerine denk gelen parçalı doğrusal fonksiyonundaki miktardır. Blok teklifler birden fazla saati kapsadığından, bazı saatler için blok teklif fiyatı PTF değerine göre uygun iken bazı saatlerde uygun olmayabilir. Bu yüzden, satış yönündeki bir blok teklif, teklif fiyatı kapsadığı saatlerin ortalama PTF'sinden düşük ya da eşit olduğu durumda kabul edilirken, benzer şekilde, alış yönündeki bir blok teklif, teklif fiyatı

kapsadığı periyotların ortalama PTF'sinden yüksek ya da eşit olduğu durumda kabul edilir. Esnek satış tekliflerinde ise, teklifin fiyatı açıklanan en yüksek PTF'den düşük ya da eşitse bu teklif kabul edilir. Ancak, problemin doğasından ötürü bazı durumlarda blok ve esnek tekliflerde ilgili teklif fiyatı ve PTF ilişkisi yukarıda anlatılardan farklı olsa da bu teklifler kabul edilebilirler. Bu tür tekliflere paradoks dolayısı ile kabul edilen teklifler de denir. Bu tür tekliflerin kabulü fark tutarı oluşumuna neden olur. Problemin amaç fonksiyonu günlük piyasa fazlasını en çoklamaktır. Günlük piyasa fazlası, günlük üretici ve tüketici fazlalarının toplamına eşittir. Bir katılımcının üretici fazlası, eşleştirme sonucu oluşan satış miktarı karşılığı alacağı tutar ile bu miktarı satmak için piyasaya teklif ettiği tutar arasındaki farktır. Bir katılımcının tüketici fazlası ise, eşleştirme sonucu oluşan alış miktarı için piyasaya teklif ettiği tutar ile bu miktarı almak için ödeyeceği tutar arasındaki farktır. Piyasa fazlası saatlik, blok ve esnek teklifler kullanılarak hesaplanır. Piyasaya açıklanan sonuçlar aşağıdaki özellikleri sağlamalıdır:

- Her saatte arz – talep dengesi sağlanmalıdır.
- Bir saatlik teklifin eşleşme miktarı, o teklifte belirtilen saatteki PTF'ye karşılık gelen miktardır. Bir saatlik teklifte o saatin PTF'sine karşılık gelen bir fiyat kısıtlımı yoksa, lineer interpolasyon uygulanarak eşleşme miktarı bulunur.
- Blok teklifler ya tamamen kabul edilir, ya da tamamen reddedilir. Blok tekliflerde kısmi kabul uygulanmaz.
- Esnek teklifler ya tamamen kabul edilir ya da tamamen reddedilir.
- Satış blok teklifin fiyatı, geçerli olduğu saatlerin ortalama PTF' sinden düşük ya da eşit fiyatta ise satış blok teklifi, kabul edilir. Alış blok teklifin fiyatı, geçerli olduğu saatlerin ortalama PTF' sinden yüksek ya da eşit fiyatta ise alış blok teklifi kabul edilir.
- Esnek teklif fiyatı en yüksek PTF'ye eşit veya en yüksek PTF'den daha düşük kabul edilmelidir.

Bu kısıtların hepsi açıklanan sonuçlarda sağlanması gerekirken, bazı durumlarda bu kısıtları sağlayan herhangi bir sonuç bulunamayabilir. Talep ya da arz fazlalığında, açıklanan sonuçlar b, e, g kısıtlarını karşılamak zorunda değildir. Yukarıda kısıtları verilen problem karma tam sayılı ikinci dereceden program olarak modellenmiştir. Bu model, yüksek hassasiyete sahip eşleşme miktarı ve eşleşme fiyatını bulur. Yönetmeliğin ilgili maddesi uyarınca, fiyatlarda kuruş miktarda ise lot hassasiyetli

yuvarlama yapılır. Talep fazlası (enerji eksikliği) veya arz fazlası (enerji fazlası) durumlarında, sistemdeki arz ve talep piyasada mevcutta geçerli olan fiyat limitleri içerisinde ve bir önceki bölümde belirtilen kısıtların hepsini sağlayacak şekilde eşitlenemez. Arz talep dengesini sağlayabilmek için, saatlik teklifler kesintiye uğrar ve blok ve esnek tekliflerdeki kabul koşulu sağlanmayabilir. Enerji fazlası durumunda, o saatin PTF'si minimum fiyatta çıkar. Bu durumda minimum fiyatta piyasaya sunulan toplam talep, $Talep(P_{min})$, bu fiyattaki toplam arzdan, $Arz(P_{min})$, azdır. Enerji eksikliği durumunda, o saatin PTF'si maksimum fiyatta P_{max} çıkar. Bu durumda maksimum fiyatta piyasaya sunulan toplam arz, $Arz(P_{max})$, bu fiyattaki toplam talepten, $Talep(P_{max})$, azdır [65].

2.2.4.1 Çözüm yöntemi

Çözüm yöntemi, ön - işlem, sezgisel, optimizasyon ve son-işlem algoritmaları olarak dört ana modülden oluşmaktadır. İlk üç modül ardışık çalışırken, raporlama harici son - işlem modülüne ait algoritmalar programın herhangi bir noktasında çalışabilir. Raporlama, çözücüdeki son adımdır. Bu adımda, bulunan çözüm piyasaya açıklanacak formata dönüştürülür.


Ön - işlem: Toplaştırma işlemi, her saatteki tüm saatlik tekliflerin birleştirilip tek bir saatlik teklifin oluşturulmasıdır. Değişken elemeye amaçlanan optimal değeri göz önünde bulundurarak problem boyutunu düşürmekyi sağlamaktır.

Sezgisel algoritmalar: Optimizasyon modülüne yüksek toplam fazlaya sahip olan bir başlangıç çözümü verebilmek için iki adet sezgisel algoritma paralel olarak çalıştırılır. Sezgisel algoritmalar, hangi blok teklifin kabul edilip hangi blok teklifin reddedilerek en iyi toplam fazlanın elde edileceğini bulmaya çalışır. Bunu yaparken esnek teklifler yokmuş (ya da reddedilmiş) gibi davranır. En uygun blok kombinasyonu bulunduktan sonra, bu çözüme esnek teklifler eklenir. Esnek tekliflerin kabul/ret kararlarını da içeren çözümlerin arasından en yüksek toplam fazlayı veren çözüm seçilir ve optimizasyon aracına başlangıç çözümü olarak verilir. Eğer optimizasyon modülü verilen sürede bu çözümünden daha iyi bir çözüm bulamazsa, sezgisel yöntemler tarafından bulunan en iyi çözüm nihai çözüm olarak seçilir.

Optimizasyon: Sezgisel algoritmaların ürettiği çözüm, matematiksel program çözücüsüne verilerek belirlenen sürede en iyi çözüme ulaşılması hedeflenir. Kısıtlı ve kısıtsız (modelin e ve g kısıtlarının olmadığı durum) modelin ikisi de matematiksel

program çözücüsü tarafından çözülür. Eğer kısıtsız model e ve g kısıtlarındaki şartlara sahipse, bu çözüm nihai çözüm olarak açıklanır. Aksi takdirde, kısıtlı model çözülür, kısıtsız modelin çözümü e ve g kısıtlarını sağlayacak şekilde değiştirilir ve bu iki çözüm birbirleri ile karşılaştırılarak en yüksek toplam fazlayı veren çözüm, nihai çözüm olarak açıklanır.

Son - işlem: Bu modül, arz veya talep fazlası olduğu durumlarda uygulanan kesinti prosedürünü, çözüm doğrulama ve onarma algoritmalarını ve raporlamayı içerir. Doğrulama algoritmaları, sezgisel ve optimizasyon modüllerinin ürettiği çözümlerin Optimizasyon Modeli başlığı altında belirtilen kısıtlara uygunluk şartlarını kontrol eder. Eğer üretilen bir çözüm, bu kısıtları sağlamıyorsa onarma algoritması kullanılarak çözüm olurlu hale getirilir. Arz veya talep fazlası olduğu durumlarda, üçüncü bölümde belirtilen bazı kısıtlar (e ve g kısıtları) esnetilerek arz ve talep eşitliği sağlanmaya çalışılır [65].



Şekil 2.4 Çözüm yönetmi akış şeması

3. DERİN ÖĞRENME

3.1 Giriş

Doğal dil işleme, makine öğrenmesi alanlarında derin öğrenme yaklaşımları sayesinde 2000’li yıllarda büyük sekteye uğrayan yapay zekaya dayalı yöntemleri tekrar ön plana çıkarmıştır. Yapay sinir ağlarındaki (YSA) gizli katman ve düğüm sayılarının artırılmasına karşın donanımsal gelişmelerin yetersiz kalması sebebiyle yapay zeka yöntemleri 2000’li yılların başında artık kullanılmamaktaydı. Ancak GPU ve diğer donanımsal gelişmeler sayesinde çok sayıda gizli katmandan oluşan yapay sinir ağları hesaplama maliyetleri düştüğünden, tekrar kullanılmaya başlanmıştır. Derin öğrenme yaklaşımı çoklu soyutlama yapısı ile verinin temsillerini öğrenmek için bir araya getirilmiş çoklu işleme katmanlarında oluşur. Makine öğrenmesi yaklaşımlarının performansı özelliklerin doğru seçimine bağlıdır. Seçimi yapılacak özellikleri ortaya çıkarmak için çeşitli ön işlemler, boyut indirgeme, özellik seçme vb. işlemler yapılmaktadır. Bu işlemin maliyetini azaltmak amacıyla özelliklere olan bağımlılığı azaltmak gereklidir [66].

3.2 Tanım

Denetimli derin beslemeli çok katmanlı perceptronlar için ilk genel, öğrenme algoritması Ivakhnenko ve Lapa tarafından 1965 yılında yayınlanmıştır. Bu çalışmada, her katmanda, en iyi özellikler istatistiksel yöntemlerle seçilip bir sonraki katmana iletilmektedir. Ivakhnenko ve Lapa ağıın uçtan uca eğitimi amacıyla geri yayılım (backpropagation) kullanmak yerine önceki katmanlardan sonraki katmanlara en küçük kareler yöntemini kullanmayı tercih etmiştir. Ivakhnenko’dan sonra ilk derin öğrenme mimarisini “Neokognitron” isimli yapıyla 1979 yılında Fukushima geliştirmiştir. Fukushima omurgalı canlıların görsel sinir sistemlerinden ilham aldığı çalışmada, "denetimsiz öğrenme" ile kendi kendini organize eden bir ağ geliştirmiştir. Fukushima'nın ağı modern ağlara benzerlik taşıyan katmanlara sahiptir. Derin mimarilerde öğrenmenin yeterli seviyede olmaması çoklu katmanlarında hatanın geri yayılmasından kaynaklanmaktadır. Geri yayılım algoritmasına ait ilk başarılı derin sinir ağı çalışmasını Yann LeCun ve arkadaşları posta kutusu yazıları üzerinde geliştirmiştir. Ağ başarılı çalışmasına karşın , ağıın eğitim süresinin 3 günden fazla olması nedeniyle geliştirilen ağıın pratikte uygulanabilir olmadığı görülmüştür.

Yann LeCunn başka bir çalışmada el yazısı rakamlarını (MNIST) sınıflandırmak amacıyla “LeNet” ağını ile kıvrımlı ağların geri yayılımını birlikte kullanmıştır. 1995 yılında Brendan Frey, Peter Dayan ve Geoffrey Hinton geliştirdikleri uyanık - uyku (wake-sleep) algoritması ile 6’sı tamamen bağlı (fully connected), yüzlerce gizli katman içeren bir ağı, ağı eğitimi süresinin iki gün olmasına rağmen böyle bir yapıya sahip ağı eğitiminin mümkün olduğunu göstermiştir. 1997 yılında Hochreiter ve Schmidhuber’in geliştirdiği tekrarlayan sinir ağları (recurrent neural networks) için Uzun Kısa Vadeli Bellek (long short - term memory) gibi bazı önemli gelişmeler kaydedilmiştir. YSA algoritmaları Bu dönemlerde sahip olduğu avantajlara rağmen hesaplama maliyetinin fazla olması nedeniyle kullanılmamış, destek vektör makineleri (support vector machine) gibi probleme özgü çalışan daha basit modeller, 2000’li yıllara kadar daha çok kullanılmıştır. Bilgisayarların çalışma hızlarının artması, grafik işlemcilerin (GPU) hesaplamalarda kullanılması ile hesaplama hızı, 10 yıllık bir sürede yaklaşık 1000 kat artmıştır. Bu gelişmelerin sonucu olarak bu dönemde YSA yeniden destek vektör makinelerine rakip olmaya başlamıştır. 2000 yılında Igor Aizenberg ve arkadaşları ilk kez "Derin Öğrenme" (deep learning) ifadesini ortaya atmıştır. 2006’da Geoffrey Hinton yayınladığı bir çalışmada, çok katmanlı ileri beslemeli bir sinir ağının her iterasyonda bir katmanı nasıl etkili şekilde eğitebildiğini ardından denetimli bir geri yayılım yöntemini kullanarak ince ayar yapılabileceğini göstermiştir. GPU hızlarının artmasına paralel olarak derin ağlara ön - eğitim (pre - training) işlemi uygulamadan, eğitim işleminin yapılabilmesi mümkün hale gelmiştir. Cireşan ve arkadaşları trafik işaretleri, medikal görüntüleme ve karakter tanıma yarışmalarını kazandıkları derin ağ çalışmalarında bu yaklaşımı kullanmıştır. Krizhevsky, Sutskever ve Hinton 2012’de benzer bir mimariye sahip, GPU kullanan çalışmalarında, ezberlemeyi (overfitting) azaltmak amacıyla “dropout” adı verilen normalleştirme yöntemini kullanmıştır. ILSVRC - 2012 ImageNet yarışmasında elde edilen sonuçlar Dropout yönteminin başarısını kanıtlamıştır [66].

3.3 Derin Öğrenme Mimarileri

3.3.1 Konvolüsyonel sinir ağları

Konvolüsyonel Sinir Ağları (Convolution Neural Network-CNN) çok katmanlı algılayıcıların (Multi Layer Perceptron - MLP) bir türüdür. İleri yönlü bir sinir ağı olan CNN algoritması, hayvanların görme sisteminden ilham alarak geliştirilmiştir. CNN,

bir veya daha fazla konvolüsyonel katman, alt örnekleme (subsampling) katmanı ve bunun ardından standart çok katmanlı bir sinir ağı gibi bir veya daha fazla tamamen bağlı katmandan oluşur. 1988 yılında Yann LeCun tarafından geliştirilen LeNet isimli mimari ilk CNN ağıdır. LeNet ağı, alt katmanların art arda yerleştirilmiş konvolüsyon ve maksimum havuzlama katmanlarından oluşmaktadır. Sonraki üst katmanlar ise tamamen bağlı geleneksel MLP'ye karşılık gelmektedir. CNN algoritmalarının görüntü, ses işleme, doğal dil işleme (NLP), biyomedikal gibi birçok farklı alanda kullanımı mevcuttur. Cireşan yaptığı çalışma ile MNIST veri kümesi üzerinde CNN kullanarak hata oranını % 2'lere düşürmüştür. Cireşan ve arkadaşları tarafından, MNIST ve NORB veri kümeleri üzerinde yapılan başka bir çalışmada CNN'nin en başarılı ve öğrenme sürecinin en hızlı ağ olduğunu belirtmiştir. 2014 yılı ImageNet Yarışması'nda nesne sınıflandırması ve algılaması dallarında en başarılı dereceleri alan ekipleri hepsi CNN algoritmasının türevlerini kullanmıştır. 2015'te yapılan bir çalışmada CNN, ters yüzler de dahil olmak üzere geniş açı aralıklarındaki yüzleri yakalayabilme başarısını göstermiştir. Bu ağ, çeşitli açılar ve yönlerde yüzleri içeren 200,000 görüntü ve yüzleri olmayan 20 milyon görüntü daha içeren bir veri tabanı üzerinde eğitilmiştir. CNN algoritmaları ilaç keşfinde de kullanılmıştır. İlaç tasarımı için geliştirilen ilk derin sinir ağı 2015 yılında Atomwise şirketinin geliştirdiği AtomNet olmuştur. Ebola ve skleroz gibi hastalıklarda yeni biyomolekülleri keşfedebilmek için kullanılan sistem, kimyasal tepkimeleri 3 boyutlu temsilleriyle eğitilmiştir. İlk kez profesyonel bir oyuncuyu (insanı) yenebilen program Google DeepMind tarafından geliştirilen CNN tabanlı AlphaGo olmuştur [66].

3.3.2 Tekrarlayan sinir ağları

Basit Tekrarlayan Ağ (Simple Recurrent Network - SRN), ilk defa Jeff Elman tarafından tasarlanmıştır. Elman'ın cümle yapısı çalışmasında kullanılan her bir kelime için gizli kalıpların üzerinde ortalama örüntü kümeleme sonucunda isim ve fiil kategorileri temiz şekilde ayrılmıştır. Bunun yanında isimler arasında canlı - cansız ayrımları, hatta insan - hayvan, hayvanlar arasında avcı - yırtıcı gibi kümeler de ayrılmıştır. Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN), birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağı sınıfıdır. Bu döngü ile dinamik zamansal davranış sergilemesine olanak tanıyan bir ağ iç durumu oluşturulmuştur. İleri beslemeli sinir ağların aksine, RNN'ler kendi giriş belleğini girdilerin rastgele dizilerini işlemek için kullanabilmektedir. Tekrarlayan

sinir ağındaki (RNN) temel düşünce sıralı bilgileri kullanmaktır. Görüntü tabanlı verilerde tüm girdilerin (veya çıktıların) birbirinden bağımsız olduğunun varsayılmasına rağmen NLP gibi zaman değişkeni olan alanlarda bu durum mümkün değildir. Örneğin, bir cümle içinde bir sonraki kelimeyi tahmin etmek için, o anki kelimeden önce hangi sözcüklerin geldiğini bilmek gerekmektedir. RNN mimarisinin yinelenen (recurrent) olarak adlandırılmasının sebebi, bir dizinin her ögesi için (cümledeki kelimeler gibi) aynı görevi önceki çıktılara bağlı olarak yerine getirmesidir. Alex Graves, ses verilerinin fonetik sunumuna gerek duymadan ses verilerini doğrudan metine çeviren bir RNN tabanlı konuşma tanıma sistemi geliştirmiştir [66].

3.3.3 Uzun kısa vadeli hafıza ağıları

RNN mimarilerinde önceki bilginin kullanımını temel alan bir yaklaşım söz konusudur. Örneğin “Gökyüzü mavidir” ifadesinde “Mavi” kelimesini tahmin etmek kolaydır. Fakat ifadede yer alan kelimelerin sayısı artması ile kelimeler arası boşluk arttığında RNN modelin geçmişten gelen bir bilgiyi kullanması oldukça zorlaşmaktadır. Örneğin, “Ankara’da yaşadım Eymir gölü kıyısında koşmayı çok severim.” gibi bir metinde “Eymir” kelimesini tahmin ederken, içinde bulunduğu cümleden yola çıkarak “Ankara” ile ilgili olacağı tahmin edilebilir, ancak doğru kelimenin “Eymir” olduğunu tahmin etmek için, metnin başındaki cümledeki yer bilgisini hafızada tutmak gerekmektedir. Teoride mümkün olan uzun - vadeli bağımlılıkların, pratikte probleme yol açtığı görülmüştür. Bu problemi çözmek amacıyla uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türü olan Uzun Kısa Vadeli Bellek (Long Short Term Memory - LSTM) ağıları Hochreiter ve Schmidhuber tarafından 1997 yılında geliştirilmiştir. LSTM mimarisi giriş, unutma ve çıkış olmak üzere 3 kapı, blok girişi, Sabit Hata Döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme (peephole) bağlantılarına sahiptir. Bloğun çıkışı tekrar tekrar bloğun girişine ve tüm kapılarına bağlanır. Gözetleme bağlantıları ve unutma kapısı ilk geliştirilen mimaride bulunmamaktadır. LSTM’in kendi durumunu sıfırlamak için unutma kapısı, kesin zamanlamaları öğrenmeyi kolaylaştırmak için ise gözetleme bağlantıları eklenmiştir. LSTM mimarisi konuşma/metin işleme alanlarında başarılı sonuçlar vermektedir. Farklı lehçelerdeki zengin içerikleri barındıran TIMIT veri kümesi, çerçeve tabanlı ses sınıflandırma çalışmasında kullanılmış, % 70 başarı oranı elde edilmiştir. Uygun ayarlamalar ile uçtan uca eğitimden geçen başka bir LSTM yaklaşımı ile aynı veri

kümesi üzerinde % 83 başarı oranına ulaşılmıştır. Fernández ve arkadaşları, anahtar kelime tespitinde geniş kapsamlı konuşma verileri barındıran Verbmobil veri kümesi üzerinde % 84.5'lik bir doğruluk oranını LSTM ile elde etmişlerdir. Baccouche'nin insan aktivitelerini ön bilgi kullanmadan sınıflandırmayı öğrenen tamamen otomatikleştirilmiş CNN ve LSTM tabanlı derin öğrenme modeli başarılı sonuçlar vermiştir. Müzik bestesi üretimi denenmesi, protein homolojisinin algılanması, robotik kalp cerrahisinde düğümleri bağlamayı öğrenen bir sistemin tasarlanması, düzensiz dillerde öğrenme, çevrimdışı elyazı tanıma konuları LSTM'in kullanıldığı alanlar arasında yer almaktadır [66].

3.3.4 Derin inanç ağları

Geoffrey Geoffrey Hinton tarafından tanıtılan, Derin inanç ağları (DBN), önceki bölümde verilen RBM'lerin yığını olarak tanımlanmaktadır. Her RBM katmanı hem önceki hem de sonraki katmanlarla bağlıdır. Ancak herhangi bir katmanın düğümleri birbirleriyle yatayda iletişimi bulunmamaktadır. En son katman olarak bir softmax katmanı ile sınıflandırma veya denetimsiz bir öğrenme için kümeleme yeteneğine sahiptir. DBN mimarileri görüntü tanıma ve üretme konularında uygulanmıştır. Salakhutdinov ve Hinton, bütün dokümana TF - IDF uygulamak yerine DBN kullanan bir sistem ile büyük bir belge veri kümesinde kelime - sayısı vektörleri elde etmiştir [66].

3.3.5 Derin oto-kodlayıcılar

Diabolo ağı olarak adlandırılan Oto - kodlayıcılar (Autoencoders - AE) denetimsiz öğrenme için kullanılan bir özel yapay sinir ağıdır. AE, bir veri kümesi için boyut indirgemeyi sağlamak amacıyla bir temsil (kodlama) öğrenmeyi hedeflemektedir. AE, temel olarak girdi verisinin sıkıştırılmış gösteriminden en iyi özelliklerin öğrenilmesini hedefleyen bir ileri beslemeli sinir ağıdır. AE mantığında, girdi verisi şifreleme - şifre çözme işleminden sonra çıktı olarak yine aynı girdiyi görene kadar ağırlıklar değiştirilir. Hedefe ulaşıldığında gizli katmandaki düğüm sayısı ile girdi verisi temsil edilmiş olmaktadır. Derin veya yığınlı oto - kodlayıcılar ise (Deep/Stacked Autoencoder - DAE), her bir katmandaki çıktıların ardışık katmanın girişlerine bağlandığı AE'lerin çok katmanlarından oluşan sinir ağıdır. Yapılan bir çalışmada, DAE mimarisi kumaş hatası tespiti için uygulanmış, 2 ardışık AE ile oluşturulan derin ağ ile oldukça ayırt edici özellikler elde edilmiştir. Mail spam

yakalama için kullanılan bir başka çalışmada ise sonuçlar Naive Bayes, Destek Vektör Makineleri, Karar Ağaçları gibi diğer yöntemler ile kıyaslanmış hem doğruluk hem de fl ölçümlerinde daha iyi performans gösterdiği görülmüştür [66].

3.4 Derin Öğrenme Uygulamaları

3.4.1 Doğal dil işleme

DAE, LSTM, CNN mimarileri ile doğal dil işleme alanında başarılı etkileyici sonuçlar elde edilmiştir. Az sayıda etiketli veri ile duygu analizi yapmak bilinen bir problemdir. Shusen Zhou, Aktif derin ağ (ADN) olarak isimlendirdikleri bir yarı - eğitici öğrenme algoritması ile bu problem üzerinde çalışmıştır. RBM tabanlı kurulan bu derin ağ, 5 duygu analizi veri kümesi üzerinde uygulanmıştır. Zhou ve arkadaşları başka bir çalışmada, bulanık DBN adı verilen iki aşamalı bir yarı - eğitici öğrenme metodu geliştirmiştir. İlk olarak DBN ile yarı - eğitici öğrenme tarafından oluşturulan veri seti ile eğitilmiştir. Ardından, derin mimari tarafından öğrenilmiş görüşleri baz alan bir bulanık üyelik fonksiyonu devreye girmiş, kıyaslanan önceki çalışmalara göre etkili sonuçlar alınmıştır. Duygu analizinden ilham alan You ve arkadaşları, hapishanelerdeki kısa mesajların otomatik denetiminin yapılması için kısa mesajları (güvenli ve güvensiz) sınıflandıran RNN modeli kullanmıştır. Çalışmada, kısa mesajlardan word2vec vasıtasıyla tipik özellikler çıkarılmış ve RNN ile sınıflandırılmıştır. Deneysel sonuçlar, RNN modelinin SVM'ye göre daha yüksek olan ortalama %92.7 başarı elde ettiğini göstermiştir. Cümle sınıflandırma doğal dil işlemede başka önemli bir problemdir. CNN tabanlı bir yaklaşım ile önceden eğitilmiş kelime vektörleri cümle sınıflandırma probleminde kullanılmış ve 4'ü çok değerli 7 konu üzerinde (duygu analizi ve soru sınıflandırma dahil) önemli başarılar elde edilmiştir. Çoklu konu (multi - tasking) öğrenme alanı için de CNN yöntemi kullanılmıştır. Ses tanıma üzerine yapılan çalışmalarda da RNN ağları kullanılmaktadır. Yousefi - Azar metin özetleme için, DAE ile, Terim Frekans (tf) girdisinden bir özellik alanı hesaplamak için tek belge özetleme yöntemini geliştirmiştir. ENAE adını verdiği, tf değerlerine rastgele gürültüler eklenmiş topluluk (ensemble) tabanlı öğrenme yöntemini denemiştir. İki farklı konudaki e - mail veri kümesi üzerinde çalışmış ortalama % 11.2 hatırlama (recall) değerlerine ulaşmıştır. Metinlerdeki anahtar kelimelerin tespiti için LSTM tabanlı bir yaklaşım, bu konuda başarılı olan HMM ile karşılaştırılmıştır; LSTM'in daha başarılı olduğu görülmüştür.

Yazar cinsiyet tespiti amacıyla yapılan bir çalışmada CNN ve LSTM birlikte kullanılmıştır. Rusça metinler üzerinde yapılan çalışma, geleneksel yöntemlerle karşılaştırılmış % 86 doğruluk ile state - of - art çalışmalara yakın başarı göstermiştir [66].

3.5 Derin Öğrenme Kütüphaneleri

Farklı çalışma grupları ve insanlar tarafından, farklı dillerde yazılmış, farklı özelliklere sahip birçok derin öğrenme kütüphanesi mevcuttur. Çizgelge 3.2’de bu kütüphanelerin bazıları hakkında kısa bilgiler verilmiştir [66].


Çizelge 3.1 Derin öğrenme kütüphaneleri ve özellikleri

Kütüphane	Yazıldığı Dil	Geliştiren	Öne Çıkan Özellikler
Theano	Python	MILA Lab	Eğitim dökümanları iyi.Keras, Blocks gibi API’ler ile matematiksel hesaplamalar kolay.GPU desteği var.
Caffe	Python	Berkeley Vision and Learning Center	Caffe Model Zoo’da indirmesi kolay, kullanıma hazır önceden eğitilmiş ağların mevcut.GPU desteği var.
Torch	Lua	Ronan Collobert Clement Farabet	Algoritmaları oluşturma konusunda maksimum esnekliğe ve hıza sahip olması.GPU desteği var. (CUDA).Kullanıcı dostu arayüz
Digits	C++	NVIDIA	Çoklu GPU sistemleri ile çalışabilme imkanı mevcut. Performansı takip etmek amacıyla gelişmiş görsel araçlar mevcut
TensorFlow	Python	Google	Tek bir API ile bir masaüstü, sunucu veya mobil cihazdaki bir veya daha fazla CPU’ya veya GPU’ya dağıtma olanağı.
DeepLearning	Java	Adam Gibson	JVM tabanlı
KNET	Julia	Deniz Yuret	Kolay anlaşılır, kısa kodlama özelliği mevcut.GPU Desteği var.




4. ÖNERİLEN MODEL

Önerilen model kamuya açık kaynakları kullanarak PTF tahminini yapacağı için modelde piyasa katılımcılarının tekliflerine ilişkin bilgilerin kullanılması söz konusu değildir. Her bir saate ait PTF GÖP piyasa katılımcılarının alış ve satış tekliflerinin meydana getirdiği arz ve talep eğrisi oluşturularak, optimizasyon sistemi aracılığıyla belirlenir [63]. Şekil 4.1’de 29 Haziran 2018 06:00 – 07:00 saat dilimine ait Gün Öncesi Elektrik Piyasasına ait Arz ve Talep eğrisi yer almaktadır [63].




Şekil 4.1 29 Haziran 2018 06:00 - 07:00 GÖP arz - talep eğrisi

Piyasa takas fiyatının tahminin yüksek doğrulukla yapılabilmesi için piyasa katılımcılarının tekliflerinde yapacağı değişiklikler, teklifler üzerinde belirleyici olan faktörlerin modellenmesi gerekmektedir. Bu faktörlerin başında, arz ve talep tarafını belirleyen temel 2 etken olan, fiyattan bağımsız alış ve satış teklifleridir. Fiyattan bağımsız tekliflere ilişkin ampirik genel önerme, fiyattan bağımsız alış tekliflerinin piyasa takas fiyatı üzerinde artırıcı etkisinin olması; fiyattan bağımsız satış tekliflerinin piyasa takas fiyatı üzerinde azaltıcı etkisinin olmasıdır. Şekil 4.2’de 29 Haziran 2018 tarihine ait GÖP saatlik PTF ve Fiyattan Bağımsız Alış – Satış Tekliflerine ait veri yer almaktadır. Saat 12:00 ve 13:00’da Fiyattan Bağımsız Alış Tekliflerin azalması ve Fiyattan Bağımsız Satış Tekliflerinin artması ile PTF’nin azaldığı şekil 4.2’de görülmektedir [63].



Şekil 4.2 29 Haziran 2018 GÖP fiyatından bağımsız teklifler ve PTF


Şekil 4.2’de gösterilen Fiyattan Bağımsız Alış ve Satış Tekliflerinin PTF’ye olan etkisinin daha iyi gözlemlenebilmesi amacıyla şekil 4.3’de yer alan grafik ve 4.1’de yer alan denklem oluşturulmuştur. Fiyattan Bağımsız Alış Tekliflerinin, Fiyattan Bağımsız Satış Tekliflerine oranının artması/azalması ile PTF’nin arttığı/azaldığı görülmektedir [63].



Şekil 4.3 29 Haziran 2018 GÖP fiyatından bağımsız teklifler oranı ve PTF

$$PTF_s = \left(\frac{FİB Alış}{FİB Satış} \right)_s \times \alpha_s \frac{FİB Alış}{FİB Satış} \pm \Delta_s \frac{FİB Alış}{FİB Satış} \quad (4.1)$$

Fiyattan bağımsız alış tekliflerinin temel kaynağı piyasa takas fiyatı ne olursa olsun elektrik satın alıp, elektrik tedariği hizmeti sunduğu tüketicilere elektrik hizmetini ulaştırmakla sorumlu olan piyasa katılımcılarıdır. Fiyattan bağımsız alış miktarının modelde temsil edilmesi için Türkiye saatlik tahmini elektrik tüketim miktarı verisi kullanılmıştır [63]. Şekil 4.4’de 2018 yılı Türkiye günlük tahmini elektrik tüketim miktarı ve günlük aritmetik ortalama PTF verisi yer almaktadır [63].




Şekil 4.4 2018 Türkiye günlük tahmini elektrik tüketim miktarı ve günlük ort. PTF

$$PTF_g = \text{Yük Tahmini}_g \times \alpha_g^{\text{Yük Tahmin}} \pm \Delta_s^{\text{Yük Tahmini}} \quad (4.2)$$


TEİAŞ’a ait bu veri, EPIAŞ Şeffaflık Platformunda her gün, bir sonraki günün her bir saatine ait Türkiye tahmini elektrik tüketim miktarını içerek şekilde yayınlanmaktadır. Bu veri sayesinde gün öncesi piyasasında oluşacak talep ve bu talebin içerisinde yer alan fiyattan bağımsız teklifler 4.2’de yer alan denklem ile modelde giriş değişkeni olarak temsil edilebilecektir. Talep üzerinde etkisi olan, modelde kullanılan diğer bir giriş değişkeni ise saatlik ortalama hava sıcaklık verisidir. Hava sıcaklığının belirli değerlerin üzerinde ve altında olması elektrik talebini artırmaktadır. Modelde hava sıcaklığını temsil etmesi için giriş değişkeni olarak İstanbul iline ait saatlik aritmetik ortalama sıcaklık verisi kullanılmıştır. Türkiye’de yer alan 81 ile ait sıcaklık verisinin temin edilip, modelde giriş değişkeni olarak kullanılması pratik ve uygulanabilir olmadığı için bu yaklaşım sergilenmiştir. 2017 İstanbul elektrik tüketim miktarı, 2017

Türkiye elektrik tüketim miktarının % 17'si olarak gerçekleşmiştir [66]; bu nedenle İstanbul iline ait sıcaklık verisinin modelde giriş değişkeni olarak kullanımı temsiliyeti açısından uygunluk taşımaktadır [68]. Şekil 4.5'de 2018 yılı İstanbul günlük aritmetik ortalama hava sıcaklığı ve günlük ortalama PTF verisi yer almaktadır [63, 68]. Şekil 4.6'da 2018 yılı İstanbul aylık aritmetik ortalama hava sıcaklığı ve aylık ortalama PTF verisi yer almaktadır [63, 68]. 4.3 ve 4.4'de yer alan denklemler ile İstanbul iline ait sıcaklık verisinin modelde giriş değişkeni olarak kullanımı sağlanmıştır.




Şekil 4.5 2018 Yılı İstanbul günlük ortalama sıcaklık ve günlük ort. PTF

$$PTF_g = \text{İstanbul Sıcaklık}_g \times \alpha_g^{\text{İstanbul Sıcaklık}} \pm \Delta_s^{\text{İstanbul Sıcaklık}} \quad (4.3)$$



Şekil 4.6 2018 Yılı İstanbul aylık ortalama sıcaklık ve aylık ort. PTF


$$PTF_a = \text{İstanbul Sıcaklık}_a \times \alpha_a^{\text{İstanbul Sıcaklık}} \pm \Delta_a^{\text{İstanbul Sıcaklık}} \quad (4.4)$$



Şekil 4.7 2018 Yılı İstanbul saatlik ortalama sıcaklık ve saatlik PTF dağılımı

Şekil 4.5, Şekil 4.6, Şekil 4.7’de görüldüğü gibi sıcaklık değerinin artışı ile PTF arttığı görülmektedir. Yaz aylarında artan hava sıcaklığının artışı ile soğutma amaçlı elektrik kullanımının artması, buna bağlı olarak elektrik tüketim miktarının ve GÖP talep miktarının artması PTF’nin artışına neden olmaktadır.


Fiyattan bağımsız satış tekliflerin temel kaynağı piyasada yer alan YEKDEM teşviklerinden yararlanan santral sahibi piyasa katılımcılarıdır. Güneş ve rüzgar santralleri yararılandıkları teşvik mekanizması sayesinde fiyattan duyarsız olarak, fiyat ne olursa olsun elektrik üretilip, satma refleksine sahiptir. Fiyattan bağımsız satış tekliflerinin modelde giriş değişkeni olarak kullanılması amacıyla rüzgar santrallerinin ve güneş santrallerinin bir sonraki günün her bir saatine ait tahmini elektrik üretim miktarının temin edilip, modelde kullanılması gerekmektedir. Rüzgar santrallerinin ertesi güne ait tahmini elektrik üretim miktarı, Rüzgar İzleme Test Merkezinin (RİTM) yayınladığı tahmini elektrik üretim miktarı verisinden temin edilmiştir; 4.5 ve 4.6’da yer alan denklemler ile modelde giriş değişkeni olarak kullanılmıştır. Rüzgar İzleme Test Merkezi (RİTM), Türkiye’de yer alan rüzgar santrallerinin tamamına yakınına ait anlık elektrik üretimi miktarı ve tahmini elektrik üretim miktarı verisini kamuya paylaşmaktadır [69].



Şekil 4.8 2018 rüzgar santralleri günlük elektrik üretim miktarı ve günlük ort. PTF

$$PTF_g = Rüzgar\ Sant_g \times \alpha_g^{Rüzgar\ Sant} \pm \Delta_g^{Rüzgar\ Sant} \quad (4.5)$$


Şekil 4.8 ve Şekil 4.9’da 2018 yılı rüzgar santrallerine ait günlük ve aylık elektrik üretim miktarı ile günlük ve aylık aritmetik ortalama PTF verisi yer almaktadır [63, 69].



Şekil 4.9 2018 rüzgar santralleri aylık elektrik üretim miktarı ve aylık ort. PTF

$$PTF_a = Rüzgar\ Sant_a \times \alpha_a^{Rüzgar\ Sant} \pm \Delta_a^{Rüzgar\ Sant} \quad (4.6)$$


Güneş santrallerine ilişkin elektrik üretim miktarını belirleyen temel 2 unsur vardır, bunlar: güneşin doğup - batma saatleri ve havadaki bulutluluk oranıdır. Türkiye’de yer alan güneş santrallerinin sayıca tamamına yakına lisanssız, görece çok küçük kurulu güce (1 MW) sahip santrallerden oluşmaktadır [64]. Her bir güneş santraline ait gün doğumu ve batışına ilişkin veriye ek olarak havadaki bulutluluk verisinin derlenerek modelde giriş değişkeni olarak kullanılması pratiklik ve uygulanabilirlik açısından mümkün değildir. Bu sorunun üstesinden gelmek amacıyla modelde sadece Konya iline ait gün doğumu ve batımı saatleri ile havadaki bulutluluk oranı giriş değişkeni olarak kullanılmıştır. Bu yaklaşımın altında yatan gerekçe güneş santrallerin 2018 Aralık ayı sonu itibariyle Türkiye’de il bazında dağılımında Konya ilinin önemli bir % 9.58’lik paya sahip olması yatmaktadır [67]. Bu sayede tüm Türkiye’de yer alan güneş santrallerinin yapacağı elektrik üretim miktarı, Konya ilinde yer alan güneş santralleri aracılığıyla 4.7’de yer alan denklem ile temsil edilmiştir. Şekil 4.10’da 2018 yılı Konya iline ait günlük gökyüzü açıklık ve güneşlilik endeksi ile günlük aritmetik ortalama PTF verisi yer almaktadır [63, 68].



Şekil 4.10 2018 Konya gökyüzü açıklık ve güneş endeksi ve günlük ort. PTF

$$PTF_g = Konya\ Gök\ Endeks_g \times \alpha_g^{Konya\ Gök\ Endeks} \pm \Delta_g^{Konya\ Gök\ Endeks} \quad (4.7)$$

Doğal gaz santralleri için doğal gazın maliyeti, doğal gaz santrallerinin elektrik üretim maliyetleri içinde önemli bir paya sahiptir [70]. Doğal gaz fiyatlarının artış ve azalışı, doğal gaz santrallerinin yakıt maliyetlerinde yukarı veya aşağı yönlü harekete neden olmaktadır. Doğal gaz maliyetlerinde meydana gelen değişiklikler doğal gaz santrali sahibi piyasa katılımcılarının gün öncesi piyasasına sunmuş oldukları teklifleri, elektrik üretim maliyetleri doğrultusunda değiştirmelerine neden olmakta; doğal gaz santrali sahibi piyasa katılımcılarının tekliflerinde yaptıkları bu değişiklikler de piyasa takas fiyatı üzerinde belirleyici olmaktadır. Bu çalışmada önerilen modelde doğal gaz fiyatlarının giriş değişkeni olarak temsil edilmesi amacıyla 4.8 ve 4.9’da yer alan denklemler ile BOTAŞ’ın doğal gaz santrallerine uyguladığı doğal gaz toptan satış tarifesinde yer alan fiyatlar kullanılmıştır [71]. Şekil 4.11 ve Çizelge 4.1’de 2 - 8 Temmuz 2018 doğal gaz santralleri yakıt maliyeti ve günlük ortalama PTF verisi yer almaktadır [63,70].




Şekil 4.11 Doğal gaz santralleri yakıt maliyeti ve PTF

Şekil 4.12’de 2018 BOTAŞ aylık toptan doğal gaz satış tarife fiyatı ve aylık ortalama PTF verisi yer almaktadır [63, 71].

$$\text{Doğal Gaz Santrali Yakıt Maliyeti}_g = \left(\frac{\text{Doğal Gaz Tüketim Miktarı}}{\text{Doğal Gaz Elektrik Üretim Miktarı}} \right)_g \quad (4.8)$$

Çizelge 4.1 Doğal gaz santralleri yakıt maliyeti ve PTF

Tarih	PTF (₺/MWh)	Doğal Gaz Elektrik Üretim Miktarı (MWh)	Doğal Gaz Tüketim Miktarı (m ³)	1 MWh Elektrik Üretmek İçin Harcanan Doğal Gaz Miktarı (m ³)
2 Temmuz 2018	278	308,079	50,283,182	163
3 Temmuz 2018	276	337,206	56,295,898	167
4 Temmuz 2018	266	344,883	57,023,566	165
5 Temmuz 2018	264	347,207	57,477,806	166
6 Temmuz 2018	281	353,042	57,530,920	163
7 Temmuz 2018	284	335,008	51,644,294	154
8 Temmuz 2018	278	253,647	44,786,945	177



Şekil 4.12 2018 BOTAŞ doğal gaz tarifi ve PTF


$$PTF_a = BOTAŞ\ Tarife_a \times \alpha_a^{BOTAŞ\ Tarife} \pm \Delta_a^{BOTAŞ\ Tarife} \quad (4.9)$$

YEKDEM destekleme fiyatlarının dolar kuru üzerinden belirlenmiş olması [72], sektörde yer alan şirketlerin yabancı para birimi kaynaklı kredileri ve kredilerin geri ödeme maliyetleri, ithal edilerek elektrik üretiminde kullanılan doğal gaz ve kömür gibi yakıtların fiyatlarının dolar cinsinden olması gibi nedenlerden dolayı; dolar kurunun piyasa takas fiyatı üzerinde doğrudan ve/veya dolaylı olarak belirleyici bir

etkisi bulunmaktadır. Çizelge 4.2’de YEKDEM Destekleme Fiyatları yer almaktadır [72]. YEKDEM teşvikleri, YEKDEM’den yararlanan santrallerin yakıt tipine göre cetvelde yer alan fiyatlar baz alınarak yapılmaktadır. Destekleme fiyatlarının Dolar kuru üzerinden belirlenmesi nedeniyle, Dolar kurunun dolaylı olarak PTF üzerinde etkisi vardır. Dolar kurunda meydana gelen değişimlerin piyasa takas fiyatı üzerindeki etkisinin göz ardı edilmemesi amacıyla modelde Merkez Bankası Dolar Alış Kuru 4.10 ve 4.11’de yer alan denklemler ile giriş değişkeni olarak kullanılmıştır. Şekil 4.13’de ve Şekil 4.14’de günlük/aylık Merkez Bankası Dolar Alış Kuru ve günlük/aylık aritmetik ortalama PTF verisi yer almaktadır [73].


Çizelge 4.2 YEKDEM Destekleme Fiyatları I Sayılı Cetvel

Santral Yakıt Tipi	Destekleme Fiyatı (ABD Doları cent/kWh)
Hidro	7.3
Rüzgar	7.3
Jeotermal	10.5
Biyokütle (çöp gazı dahil)	13.3
Güneş	13.3



Şekil 4.13 2018 MB USD Dolar/TL alış kuru ve günlük ort. PTF


$$PTF_g = \left(\frac{USD \text{ Dolar}}{TL} \right)_g \times \alpha_g \frac{USD \text{ Dolar}}{TL} \pm \Delta_g \frac{USD \text{ Dolar}}{TL} \quad (4.10)$$



Şekil 4.14 2018 MB aylık usd dolar/tl alış kuru ve aylık ort. PTF


$$PTF_a = \left(\frac{USD \text{ Dolar}}{TL} \right)_a \times \propto_a \frac{USD \text{ Dolar}}{TL} \pm \Delta_a \frac{USD \text{ Dolar}}{TL} \quad (4.11)$$

Enerji Piyasası Düzenleme Kurulu (EPDK) tarafından belirlenen, serbest tüketici hakkını kullanmayan veya serbest tüketici olma niteliklerini taşımayan tüketicilere uygulanan elektrik satış tarife fiyatları ile Enerji Piyasası Düzenleme Kurulu (EPDK) tarafından belirlenen Türkiye Elektrik Ticaret Taahhüt A.Ş. (TETAŞ) ile Elektrik Üretim A.Ş. (EÜAŞ)’nin toptan satış elektrik satış tarife fiyatları modelde giriş değişkeni olarak kullanılmıştır. İlgili tarifelere ait fiyatlar gösterge niteliği taşımakta, bu tarifelere ait fiyatlarda meydana gelen değişimler dolaylı olarak piyasa takas fiyatı üzerinde belirleyici olmaktadır. İlgili tarifelere ait fiyatlar ile piyasa takas fiyatı arasındaki ilişkinin modellenmesi ve ilgili tarife fiyatlarının piyasa takas fiyatının tahmini modelinde kullanılabilmesi amacıyla, tek zamanlı alçak gerilim mesken elektrik tarife fiyatı ve elektrik toptan satış tarife fiyatı modelde 4.12 ve 4.13’de yer alan denklemler ile giriş değişkeni olarak kullanılmıştır [74]. Şekil 4.15’de aylık TETAŞ – EÜAŞ Toptan Satış Tarifesi ve aylık aritmetik ortalama PTF verisi yer almaktadır [63, 74]. Şekil 4.16’da aylık Alçak Gerilim Tek Zamanlı Mesken Elektrik Tarifesi ve aylık aritmetik ortalama PTF verisi yer almaktadır [63, 74].



Şekil 4.15 2018 TETAŞ - EÜAŞ toptan satış tarifesi ve aylık ort. PTF

$$PTF_a = (TETAŞEÜAŞ \text{ Tarife})_a \times \alpha_a^{TETAŞEÜAŞ \text{ Tarife}} \pm \Delta_a^{TETAŞEÜAŞ \text{ Tarife}} \quad (4.12)$$



Şekil 4.16 2018 alçak gerilim tek zamanlı mesken elektrik tarifesi aylık ort. PTF

$$PTF_a = \text{Mesken AG Tarife}_a \times \alpha_a^{\text{Mesken AG Tarife}} \pm \Delta_a^{\text{Mesken AG Tarife}} \quad (4.13)$$

Her günün kendi piyasa dinamiğinden kaynaklı paradigmanın modelde temsil edilmesi amacıyla haftanın günlerinin sayısallaştırılmış değerleri modelde giriş değişkeni olarak kullanılmıştır. Pazartesi'den pazara, günlere sırasıyla 1, 2, 3, 4, 5, 6, 7 sayısal değerleri atanmıştır. Piyasa takas fiyatında meydana gelen değişimler, günlerin kendi fiyat dinamiklerinin modelde yer alması, güncel fiyat dinamiklerinin modelde temsil edilebilmesi için piyasa takas fiyatının 1 gün, 1 hafta ve 2 hafta öncesi günleri aynı saat dilimlerine ait piyasa takas fiyatı verileri modelde giriş değişkeni olarak kullanılmıştır [63]. Çizelge 4.3'de 2018 yılına ait günlere ve aylara ait aritmetik ortalama PTF (₺/MWh) yer almaktadır [63].

Çizelge 4.3 2018 Günlere göre aylık ortalama PTF

Ay	1	2	3	4	5	6	7
Oca	184.63	187.10	183.04	181.68	186.47	180.72	174.81
Şub	179.50	190.20	176.45	175.37	174.79	178.41	155.63
Mar	164.24	155.04	163.25	169.88	165.03	158.74	129.25
Nis	197.31	206.78	204.65	197.54	199.70	188.17	166.58
May	182.18	180.15	185.50	185.29	185.87	178.82	155.05
Haz	184.81	188.10	192.36	190.52	181.84	184.71	178.13
Tem	211.34	213.77	209.63	211.54	210.82	202.67	197.55
Ağu	307.36	306.09	296.79	297.97	299.99	294.87	289.75
Eyl	331.24	330.79	325.68	328.22	337.92	332.74	307.79
Eki	315.33	323.45	329.04	322.44	322.20	308.51	295.95
Kas	287.91	294.51	293.38	298.77	290.64	290.93	280.65
Ara	254.21	257.08	263.99	261.71	259.02	268.97	242.26



5. ÖNERİLEN MODELİN EĞİTİMİ VE TESTİ

Modelde amaçlanan, EPIAŞ'ın işlettiği Gün Öncesi Piyasasında oluşan piyasa takas fiyatının bir sonraki günün 24 saatine ait değerini tahmin etmektir. EPIAŞ şeffaflık platformunda bir sonraki güne ait gün öncesi piyasası kesinleşmemiş piyasa takas fiyatı her gün saat 13:00'da, kesinleşmiş piyasa takas fiyatı her gün saat 14:00'da açıklanmaktadır.

Modelde yer alan derin öğrenme algoritması 2018 yılına ait 8760 saatin piyasa takas verisi ve giriş değişkeni verileri ile eğitilmiştir. Çizelge 5.1'de 29.06.2018 tarihi saat 06:00'a ait giriş değişkeni veri seti örnek olarak verilmiştir. Piyasa takas fiyatının 1 gün önceki, 7 gün önceki ve 14 gün önceki aynı saatlerdeki değeri giriş değişkeni olarak kullanılmıştır. Tek zamanlı alçak gerilim mesken elektrik tarifi kullanılan diğer giriş değişkeni verileridir. Konya iline ait bulutluk oranı ve güneşin havada olup olmadığı verisi, EÜAŞ ve TETAŞ'ın toptan satış tarifi, BOTAŞ'ın doğal gaz santralleri için uyguladığı doğal gaz toptan satış tarifi, Merkez Bankası dolar tl alış kuru, haftanın günlerinin sayısallaştırılmış değerleri, bir sonraki güne ait tahmini elektrik tüketim miktarı ve bir sonraki güne ait rüzgar santralleri elektrik tahmini elektrik üretim miktarı modelde kullanılan diğer giriş değişkenleridir. Tüm giriş değişkenleri saatlik formatta hazırlanıp, derlenmiştir. 2018 yılında yer alan özel ve resmi tatil günlerine ait giriş değişkeni ve PTF veri seti bu çalışmada önerilen tahmin modelinin eğitim ve test sürecine dahil edilmiştir. Literatürde yer alan diğer bazı çalışmalarda özel ve resmi tatil günlerinde önerilen modellerde eğitim ve test sürecine dahil edilmemiştir; bu sayede modellerin tahmin performansının daha yüksek gözükmesi sağlanmıştır. Özel ve resmi tatil günlerinde elektrik tüketiminin normal hafta içi ve haftasonu günlerine göre düşük olduğundan ve PTF üzerinde belirleyici etkisi olan etkenlerin özel ve resmi günlerde etkisinin az olması nedeniyle fiyat tahmin modelleri özel ve resmi günlerde düşük performans göstermektedir. Modelin tahmin performansını olduğundan daha yüksek göstermek amacıyla bu çalışmada özel ve resmi tatil günlerinin eğitim ve test süreçlerine dahil edilmemesi yaklaşımı ortaya konulmamıştır. Modelde kullanılacak mimarinin belirlenmesi amacıyla, kurgulanan derin öğrenme modeline ait parametreler optimize edilmiştir. Çizelge 5.2'de modelde kullanılan derin öğrenme modeline ait parametreler yer almaktadır. Modele ait derin öğrenme parametreleri değiştirilerek modelin eğitim, test ve toplam veri setine ait

öğrenme performansı ölçülmüştür. Kurgulanan farklı derin öğrenme mimarilerinin tahmin performansını ölçmek için RMSE ve R^2 kriterleri kullanılmıştır.

Çizelge 5.1 Giriş verisi örneği 29.06.2018 06:00

Numara	Veri	Değer	Birim
1	PTF D-1	150	₺/MWh
2	PTF D-7	164.54	₺/MWh
3	PTF D-14	147.86	₺/MWh
4	Gün	5	-
5	Tahmini Elektrik Tüketim Miktarı	28,600	MWh
6	Tahmini Rüzgar Elektrik Üretim Miktarı	1606	MWh
7	BOTAŞ Doğal Gaz Tarifesi	0.8776	₺/m ³
8	TETAŞ - EÜAŞ Toptan Satış Tarifesi	141	₺/MWh
9	Alçak Gerilim Tek Zamanlı Mesken Elektrik Tarifesi	246.66	₺/MWh
10	Merkez Bankası Dolar/TL Alış Kuru	4.6349	₺
11	İstanbul Aritmetik Ortalama Hava Sıcaklığı	20.5	°C
12	Konya Gökyüzü Açıklık ve Güneşlilik Endeksi	100	%

Önerilen modelin eğitim ve test işlemlerinin yapıldığı bilgisayar Intel Core i7 – 5700 HQ CPU 2.70 GHz işlemciye ve 8 GB paylaşımsız RAM’e sahiptir. Önerilen modeli kurgulamak için gerekli çalışmalar, Python 3.6 programlama dilinde yazılmış derin öğrenme kütüphanesi Keras ile Pycharm programı kullanılarak yapılmıştır [75, 76, 77]. Modeli kurgulamak ve derin öğrenme mimarisini inşaa etmek için ihtiyaç duyulan kütüphaneler Anaconda yazılımı aracılığıyla yüklenmiştir [78]. Keras, Python ile yazılmış ve TensorFlow, CNTK, Theano'nun üzerinde çalışabilen üst düzey bir sinir ağları uygulama derin öğrenme kütüphanesidir. Keras, Python için 250.000'den fazla kullanıcısı ve 700'den fazla açık kaynaklı katılımcısı ile (2018'in ortalarından itibaren) önde gelen bir derin öğrenme kütüphanesidir. Çabuk sonuç sağlamaya odaklanarak geliştirilmiştir. Kullanıcı dostu, modülerlik ve genişletilebilir olması özellikleriyle kolay ve hızlı prototipleme sağlar. Konvolüsyon ağları, yinelenen

ağları ve her ikisinin kombinasyonlarını destekler. CPU ve GPU'da sorunsuz çalışır. Keras, önemli sayıda girişimde, araştırma laboratuvarlarında (CERN, Microsoft Research ve NASA dahil) ve Netflix, Yelp, Square, Uber, Google gibi büyük şirketlerde kullanılmaktadır. Keras Python 2.7 - 3.6 versiyonları ile uyumlu olarak çalışabilir. Keras varsayılan olarak, TensorFlow'u tensör manipülasyon kütüphanesi olarak kullanır [75, 79].

Keras, Google mühendisi François Chollet tarafından, dört temel ilkeyi dikkate alınarak geliştirilmiştir [80]:

- Modülerlik: Bir model sadece bir sekans veya grafik olarak okunup, anlaşılabilir. Derin bir öğrenme modelinin tüm özellikler, keyfi bir şekilde birleştirilip ayrılabilir.
- Minimalizm: Kütüphane, bir sonuç elde etmek için yeterli seviyedir, gereksiz süsten uzak ve okunabilirliği en üst seviyeye çıkaracak biçimde tasarlanmıştır.
- Genişletilebilirlik: Araştırmacıların yeni fikirleri denemelerini ve keşfetmelerini sağlamaya yönelik olarak, kütüphane içine yeni bileşenler kolaylıkla eklenebilir, eklenen yeni bileşenler kolaylıkla kullanılabilir.
- Python: Özel dosya formatlarına sahip ayrı bir model dosyası yoktur. Her şey doğal Python'dır.

Modelde kullanılacak mimarini belirlenmesi amacıyla; n Train, 1.Tabaka Nöron Sayısı, 1.Tabaka Drop Out, 1.Tabaka Aktivasyon Fonksiyonu, 2.Tabaka Nöron Sayısı, 2.Tabaka Drop Out, 2.Tabaka Aktivasyon Fonksiyonu, Loss, Optimizer, Metrics, Epochs, Batch Size, Shuffle parametreleri kullanılmıştır. Modele ait derin öğrenme parametreleri değiştirilerek modelin eğitim, test ve toplam veri setine ait öğrenme performansı ölçülmüştür. İdeal mimarinin belirlenmesinde RMSE Test ve R^2 Test parametreleri dikkate alınmıştır. Çizelge 5.2 'de en uygun n Train parametresinin belirlenmesi amacıyla modelde var olan diğer tüm parametreler sabit tutularak, modelin eğitimi için kullanılacak veri kümesi adeti belirlenmiştir. n Train = 6000 değeri modelin eğitimi için kullanılacak veri kümesi en uygun adeti olarak belirlenmiştir. Mimari 3'e ait n Train = 6000 değeri için RMSE Test ve R^2 Test değerleri sırasıyla 34.35 ve 0.629 olarak elde edilmiştir. Çizelge 5.2'de yer alan mimarilerin R^2 Eğitim değerinin yüksek olmasına rağmen R^2 Test değerinin düşük olmasının nedeni Shuffle = False olarak belirlenmiş olmasından kaynaklanmaktadır. Shuffle = False belirlenmesi halinde eğitim için kullanılacak veri seti rastgele seçilmemektedir. Bu

durum derin öğrenme modelinin ezberleme yapmasına ve test verilerinde tahmin performansının düşük olmasına neden olmaktadır.

Çizelge 5.2 n Train(Eğitim) parametresinin belirlenmesi

Parametre	Mimari 1	Mimari 2	Mimari 3	Mimari 4
n Train	4800	5400	6000	7200
1.Tab. Nöron Say.	100	100	100	100
1.Tab. Drop Out	0.05	0.05	0.05	0.05
1.Tab. Akt. Fonk.	relu	relu	relu	relu
2.Tab. Nöron Say.	50	50	50	50
2.Tab. Drop Out	0.05	0.05	0.05	0.05
2.Tab. Akt. Fonk.	relu	relu	relu	relu
Loss	mae	mae	mae	mae
Optimizer	adagrad	adagrad	adagrad	adagrad
Metrics	mae	mae	mae	mae
Epochs	2000	2000	2000	2000
Batch Size	12	12	12	12
Shuffle	False	False	False	False
RMSE Toplam	72.42	33.46	30.89	30.69
RMSE Eğitim	25.53	27.28	29.17	29.77
RMSE Test	103.97	41.52	34.35	36.64
R ² Toplam	-0.008	0.784	0.816	0.818
R ² Eğitim	0.441	0.566	0.747	0.827
R ² Test	-2.157	0.462	0.629	0.608

Modelin eğitimi için kullanılacak veri kümesi adeti n Train parametresi ile belirlendikten sonra modelde kullanılacak en uygun Optimizer parametresi belirlenmiştir.

Çizelge 5.3 Optimizer parametresinin belirlenmesi

Parametre	Mimari 3	Mimari 5	Mimari 6	Mimari 7	Mimari 8	Mimari 9
n Train	6000	6000	6000	6000	6000	6000
1.Tab. Nöron Say.	100	100	100	100	100	100
Drop Out	0.05	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu	relu	relu
2.Tab. Nöron Say.	50	50	50	50	50	50
Drop Out	0.05	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu	relu	relu
Loss	mae	mae	mae	mae	mae	mae
Optimizer	adagrad	adam	rmsprop	sgd	adadelata	adamax
Metrics	mae	mae	mae	mae	mae	mae
Epochs	2000	2000	2000	2000	2000	2000
Batch Size	12	12	12	12	12	12
Shuffle	False	False	False	False	False	False
RMSE Toplam	30.89	55.36	43.95	80.39	46.27	63.88
RMSE Eğitim	29.17	62.17	46.62	58.4	46.84	71.95
RMSE Test	34.35	36.41	37.49	114.43	45	41.2
R ² Toplam	0.816	0.41	0.62	-0.24	0.58	0.215
R ² Eğitim	0.747	-0.145	0.355	-0.01	0.349	-0.534
R ² Test	0.629	0.584	0.558	-3.1	0.364	0.467

Çizelge 5.3’de en uygun Optimizer parametresinin belirlenmesi amacıyla modelde var olan diğer tüm parametreler sabit tutularak, modelin eğitimi için kullanacak veri kümesi adeti belirlenmiştir. Optimizer = adagrad değeri modelin eğitimi için kullanacak en uygun parametre olarak belirlenmiştir. Mimari 3’e ait Optimizer = adagrad değeri için RMSE Test ve R² Test değerleri sırasıyla 34.35 ve 0.629 olarak elde edilmiştir.

Çizelge 5.4 Epochs parametresinin belirlenmesi

Parametre	Mimari 3	Mimari 10	Mimari 11	Mimari 12
n Train	6000	6000	6000	6000
1.Tab. Nöron Say.	100	100	100	100
Drop Out	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu
2.Tab. Nöron Say.	50	50	50	50
Drop Out	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu
Loss	mae	mae	mae	mae
Optimizer	adagrad	adagrad	adagrad	adagrad
Metrics	mae	mae	mae	mae
Epochs	2000	3000	5000	10000
Batch Size	12	12	12	12
Shuffle	False	False	False	False
RMSE Toplam	30.89	30.433	30.59	31.55
RMSE Eğitim	29.17	27.645	27.38	27.05
RMSE Test	34.35	35.752	36.6	39.62
R ² Toplam	0.816	0.821	0.82	0.808
R ² Eğitim	0.747	0.773	0.77	0.78
R ² Test	0.629	0.598	0.579	0.507

Modelin eğitimi için kullanılacak Optimizer parametresi belirlendikten sonra modelde kullanılacak en uygun Epochs parametresi belirlenmiştir. Çizelge 5.4 ‘de en uygun Epochs parametresinin belirlenmesi amacıyla modelde var olan diğer tüm parametreler sabit tutularak, modelin eğitimi için kullanıcak iterasyon adeti belirlenmiştir. Epochs = 2000 değeri modelin eğitimi için kullanıcak en uygun iterasyon adeti olarak belirlenmiştir. Mimari 3’e ait Epochs = 2000 değeri için RMSE Test ve R² Test değerleri sırasıyla 34.35 ve 0.629 olarak elde edilmiştir.

Çizelge 5.5 Batch Size parametresinin belirlenmesi

Parametre	Mimari 3	Mimari 13	Mimari 14	Mimari 15	Mimari 16
n Train	6000	6000	6000	6000	6000
1.Tab. Nöron Say.	100	100	100	100	100
Drop Out	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu	relu
2.Tab. Nöron Say.	50	50	50	50	50
Drop Out	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu	relu
Loss	mae	mae	mae	mae	mae
Optimizer	adagrad	adagrad	adagrad	adagrad	adagrad
Metrics	mae	mae	mae	mae	mae
Epochs	2000	2000	2000	2000	2000
Batch Size	12	24	36	48	72
Shuffle	False	False	False	False	False
RMSE Toplam	30.89	30.22	30.01	30.1	30.4
RMSE Eğitim	29.17	28.194	27.57	27.86	27.75
RMSE Test	34.35	34.23	34.73	34.47	35.49
R ² Toplam	0.816	0.824	0.826	0.825	0.822
R ² Eğitim	0.747	0.764	0.774	0.769	0.771
R ² Test	0.629	0.632	0.621	0.627	0.604

Modelin eğitimi için kullanılacak Epochs parametresi belirlendikten sonra modelde kullanılacak en uygun Batch Size parametresi belirlenmiştir. Çizelge 5.5 ‘de en uygun Batch Size parametresinin belirlenmesi amacıyla var olan diğer tüm parametreler sabit tutularak, modelin eğitiminde her bir iterasyonda kaç adetlik veri kümesinin eğitileceği belirlenmiştir. Batch Size = 12 değeri modelin eğitimi için kullanıcak en uygun veri kümesi adeti olarak belirlenmiştir. Mimari 3’e ait Batch Size = 12 değeri için RMSE Test ve R² Test değerleri sırasıyla 34.35 ve 0.629 olarak elde edilmiştir.

Çizelge 5.6 Tabakalara ait nöron sayısının belirlenmesi

Parametre	Mimari 3	Mimari 17	Mimari 18	Mimari 19	Mimari 20
n Train	6000	6000	6000	6000	6000
1.Tab. Nöron Say.	100	50	100	200	400
Drop Out	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu	relu
2.Tab. Nöron Say.	50	50	100	200	400
Drop Out	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	relu	relu	relu	relu
Loss	mae	mae	mae	mae	mae
Optimizer	adagrad	adagrad	adagrad	adagrad	adagrad
Metrics	mae	mae	mae	mae	mae
Epochs	2000	2000	2000	2000	2000
Batch Size	12	12	12	12	12
Shuffle	False	False	False	False	False
RMSE Toplam	30.89	30.692	32.305	33.66	35.46
RMSE Eğitim	29.17	27.915	30.901	32.54	35.85
RMSE Test	34.35	35.998	35.165	35.98	34.61
R ² Toplam	0.816	0.818	0.799	0.782	0.758
R ² Eğitim	0.747	0.769	0.717	0.686	0.619
R ² Test	0.629	0.593	0.611	0.593	0.624

Modelin eğitimi için kullanılacak Batch Size parametresi belirlendikten sonra modelde kullanılacak tabakalarda yer alacak nöron adetleri belirlenmiştir. Çizelge 5.6 ‘da en uygun 1.Tabaka Nöron Sayısı ve 2.Tabaka Nöron Sayısı parametresinin belirlenmesi amacıyla var olan diğer tüm parametreler sabit tutularak, modelin eğitiminde her bir tabakalarda yer alacak en uygun nöron adeti belirlenmiştir. 1.Tabaka Nöron Sayısı = 100 ve 2.Tabaka Nöron Sayısı = 50 değeri modelin eğitimi için kullanıcak, tabakalarda yer alacak en uygun nöron adeti olarak belirlenmiştir. Mimari 3’e ait

1.Tabaka Nöron Sayısı = 100 ve 2.Tabaka Nöron Sayısı = 50 değeri için RMSE Test ve R^2 Test değerleri sırasıyla 34.35 ve 0.629 olarak elde edilmiştir.

Çizelge 5.7 Aktivasyon Fonksiyonu parametresinin belirlenmesi

Parametre	Mimari 3	Mimari 21	Mimari 22	Mimari 23	Mimari 24
n Train	6000	6000	6000	6000	6000
1.Tab. Nöron Say.	100	100	100	100	100
Drop Out	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	softmax	elu	selu	softmax
2.Tab. Nöron Say.	50	50	50	50	50
Drop Out	0.05	0.05	0.05	0.05	0.05
Aktivasyon Fonk.	relu	softmax	elu	selu	softmax
Loss	mae	mae	mae	mae	mae
Optimizer	adagrad	adagrad	adagrad	adagrad	adagrad
Metrics	mae	mae	mae	mae	mae
Epochs	2000	2000	2000	2000	2000
Batch Size	12	12	12	12	12
Shuffle	False	False	False	False	False
RMSE Toplam	30.89	202.53	30.45	31.26	30.747
RMSE Eğitim	29.17	170.05	28.4	29.33	28.75
RMSE Test	34.35	259.48	34.5	35.1	34.63
R^2 Toplam	0.816	-6.88	0.821	0.811	0.818
R^2 Eğitim	0.747	-7.57	0.76	0.745	0.754
R^2 Test	0.629	-20.12	0.626	0.613	623

Modelin eğitimi için kullanılacak tabakalarda yer alacak nöron adetleri belirlendikten sonra modelde kullanılacak tabakalarda yer alacak aktivasyon fonksiyonları belirlenmiştir. Çizelge 5.7 ‘de en uygun 1.Tabaka Aktivasyon Fonksiyonu ve 2.Tabaka Aktivasyon Fonksiyonu parametresinin belirlenmesi amacıyla var olan diğer tüm parametreler sabit tutularak, modelin eğitiminde her bir tabakalarda yer alacak en

uygun aktivasyon fonksiyonları belirlenmiştir. 1.Tabaka Aktivasyon Fonksiyonu = relu ve 2.Tabaka Aktivasyon Fonksiyonu = relu değeri modelin eğitimi için kullanıcak, tabakalarda yer alacak en uygun aktivasyon fonksiyonları olarak belirlenmiştir. Mimari 3'e ait 1.Tabaka Aktivasyon Fonksiyonu = relu ve 2.Tabaka Aktivasyon Fonksiyonu = relu değeri için RMSE Test ve R^2 Test değerleri sırasıyla 34.35 ve 0.629 olarak elde edilmiştir.

Modelin eğitimi esnasında ezberlemenin önüne geçmek, modelin eğitim ve test veri kümelerindeki öğrenme performansını artırmak amacıyla var olan veri kümesinin karıştırılarak modelde kullanılması amaçlanmıştır. Çizelge 5.8 'de shuffle parametresinin en uygun değerinin belirlenmesi amacıyla var olan diğer tüm parametreler sabit tutularak, modelin eğitimi ve testi yapılmıştır. Shuffle =True parametresi ile modelin eğitim ve test performansında artış sağlanmıştır. Mimari 25'e ait Shuffle =True değeri için RMSE Test ve R^2 Test değerleri sırasıyla 30.05 ve 0.824 olarak elde edilmiştir.Shuffle parametresinin tahmin performansı üzerinde önemli bir etkisi olduğu Çizelge 5.8'de yer alan Mimari 3 ve Mimari 25'e ait eğitim ve test sonuçlarında görülmektedir.

25 farklı derin öğrenme mimarisi eğitim ve test için kullanıldıktan sonra elde edilen RMSE Test ve R^2 Test verileri doğrultusunda PTF tahmini için en uygun model olarak Çizelge 5.8'de yer alan Mimari 25 belirlenmiştir. Mimari 25'e ait parametreler önerilen modelde eğitim ve test işlemleri için kullanılmıştır. Mimari 25'e ait parametreler ile yapılan eğitim ve test işlemleri sonucu Çizelge 5.9'da yer alan PTF Tahmin Sonuçları elde edilmiştir.


Çizelge 5.8 Shuffle parametresinin belirlenmesi

Parametre	Mimari 3	Mimari 25
n Train	6000	6000
1.Tab. Nöron Say.	100	100
Drop Out	0.05	0.05
Aktivasyon Fonk.	relu	relu
2.Tab. Nöron Say.	50	50
Drop Out	0.05	0.05
Aktivasyon Fonk.	relu	relu
Loss	mae	mae
Optimizer	adagrad	adagrad
Metrics	mae	mae
Epochs	2000	2000
Batch Size	12	12
Shuffle	False	True
RMSE Toplam	30.89	30.618
RMSE Eğitim	29.17	30.875
RMSE Test	34.35	30.052
R ² Toplam	0.816	0.819
R ² Eğitim	0.747	0.817
R ² Test	0.629	0.824

Çizelge 5.9 2018 Yılı aylık ortalama PTF Tahmin – PTF ve MAPE

Ay	Art.Ort. PTF (₺/MWh)	Art.Ort. PTF Tahmin (₺/MWh)	MAPE
Ocak	182.86	174.10	% 5.0
Şubat	175.77	173.42	% 1.4
Mart	158.56	159.53	% 0.6
Nisan	193.57	185.12	% 4.6
Mayıs	179.44	183.49	% 2.2
Haziran	185.62	188.92	% 1.7
Temmuz	208.13	203.01	% 2.5
Ağustos	298.91	274.84	% 8.8
Eylül	327.27	317.04	% 3.2
Ekim	317.28	306.65	% 3.5
Kasım	291.22	284.83	% 2.2
Aralık	257.89	256.81	% 0.4
Art.Ort.	231.64	225.88	% 2.5

Minumum MAPE % 0.4 değeri ile Aralık 2018’de, Maksimum MAPE % 8.8 değeri ile Ağustos 2018’de elde edilmiştir. Ağustos 2018’de tahmin hatasının yüksek çıkması nedenleri arasında finans piyasalarında oluşan yüksek fiyat dalgalanması ve belirsizlik, tarifelere yapılan zamlar olarak belirtilebilir. 2018 yılına ait 8760 saatin aritmetik ortalama piyasa takas fiyatı 231.64 ₺/MWh iken önerilen model ile yapılan tahmini piyasa takas fiyatı 225.88 ₺/MWh olarak elde edilmiştir.



Şekil 5.1 2018 Yılı 8760 saatlik PTF Tahmin ve PTF

Şekil 5.1’de yer alan grafik ve Çizelge 5.9’da yer alan sonuçlar modelin tahmin başarısı ve performansını ortaya koymaktadır. Literatürde yer alan mevcut çalışmalar ile kıyaslandığında önerilen modelin tahmin performansının, literatürde yer alan mevcut çalışmalardaki modellerin ürettiği tahmin başarısını geride bıraktığı görülmektedir.



6. SONUÇ VE ÖNERİLER

Modelde kullanılan giriş değişkeni verilerinin veri kalitesi, tahmin modelinin performansını belirleyen en önemli unsurdur. Veri kalitesi ifadesi ile temsili yapılan veriye ait doğruluk derecesi ifade edilmiştir. Veri kalitesinin düşük olması, piyasa takas fiyatı tahmin modeline ait tahmin performansına olumsuz etki edecektir. Sahip olduğu veri kalitesinin düşük olması, model performansına büyük etki yapacak olan giriş değişkeni verilerinin başında yük tahmini verisi gelmektedir. Yük tahmin verisi, veri kalitesinde oluşacak olumsuzluğun piyasa takas fiyatı tahmin modeli performansına Gün Öncesi Piyasasında oluşacak talebi dolaylı olarak temsil etmesi için kullanılan tahmini elektrik tüketimi verisi % 100 doğruluğa sahip değildir. Yük tahmini verisinde meydana gelen tahmin hataları modele ait eğitim sürecinde modelin yanlış ve eksik eğitimine neden olmaktadır. Piyasa takas fiyatı tahmin edilecek güne ait tahmini elektrik tüketim verisi de % 100 doğruluğa sahip olmadığı için tahmin sonucunun hatalı çıkması beklenen bir durumdur. Piyasa takas fiyatının tahmini için gerekli süreç ve emeği en düşük seviyede tutabilmek adına TEİAŞ'a ait yük tahmin verisi, modelde giriş değişkeni olarak kullanılmıştır. Yük tahmin verisi kaynaklı tahmin hatasını azaltmak için oluşturulacak bir elektrik tüketim tahmini modelinin üreteceği yük tahmin verisi, fiyat tahmini modelinde giriş değişkeni olarak kullanılabilir. Yapılacak olan yük tahminin performansı, TEİAŞ'a ait yük tahmin performansından iyi olması durumunda; piyasa takas fiyatı tahmin modeli performansında iyileşme sağlanacaktır.

Veri kalitesinin düşük olması, piyasa takas fiyatı tahmin modeline ait tahmin performansına olumsuz etki edecektir. Sahip olduğu veri kalitesinin düşük olması, model performansına büyük etki yapacak olan giriş değişkeni verilerinin başında yük tahmini verisi gelmektedir. Yük tahmin verisi, veri kalitesinde oluşacak olumsuzluğun piyasa takas fiyatı tahmin modeli performansına Gün Öncesi Piyasasında oluşacak talebi dolaylı olarak temsil etmesi için kullanılan tahmini elektrik tüketimi verisi % 100 doğruluğa sahip değildir. Yük tahmini verisinde meydana gelen tahmin hataları modele ait eğitim sürecinde modelin yanlış ve eksik eğitimine neden olmaktadır. Piyasa takas fiyatı tahmin edilecek güne ait tahmini elektrik tüketim verisi de % 100 doğruluğa sahip olmadığı için tahmin sonucunun hatalı çıkması beklenen bir durumdur. Piyasa takas fiyatının tahmini için gerekli süreç ve emeği en düşük seviyede

tutabilmek adına TEİAŞ'a ait yük tahmin verisi, modelde giriş değişkeni olarak kullanılmıştır. Yük tahmin verisi kaynaklı tahmin hatasını azaltmak için oluşturulacak bir elektrik tüketim tahmini modelinin üreteceği yük tahmin verisi, fiyat tahmini modelinde giriş değişkeni olarak kullanılabilir. Yapılacak olan yük tahminin performansı, TEİAŞ'a ait yük tahmin performansından iyi olması durumunda; piyasa takas fiyatı tahmin modeli performansında iyileşme sağlanacaktır.

Model performansına önemli etkisi olan ve göz ardı edilmesi halinde fiyat tahmini modelinin hatalı sonuçlar üretme ihtimalini artıran; hidro kaynaklara ilişkin bir veri modelde giriş değişkeni olarak kullanılmalıdır. Hidro elektrik santrallerin baraj ve havzalarına gelen su miktarı verisi ve bir sonraki gün hidro elektrik santrallerin baraj ve havzalarına gelmesi muhtemel su miktarının modelde kullanılması halinde, modelin eğitim başarısı ve tahmin performansı olumlu yönde artacaktır. 2018 yılında Türkiye'de yer alan 11,894 MW kurulu güce sahip hidro elektrik santral YEKDEM'den yararlanmaktadır [81]. YEKDEM Destekleme fiyatları, hidro elektrik santral sahibi piyasa katılımcılarının gün öncesi piyasası piyasa takas fiyatı ne olursa olsun elektrik üretip satma refleksine sahip olmalarına neden olmaktadır. Hidroelektrik santrallerin elektrik üretimi yapabilmelerinde belirleyici faktör santral baraj ve havzasında var olan su miktarıdır. Baraj ve havzasına gelen su miktarı arttıkça, hidro elektrik santral daha yüksek kapasite faktörüyle çalışıp, elektrik üretimi yapma fırsatına sahip olacaktır. Hidro kaynaklı olası elektrik üretimi artışı, dolaylı olarak gün öncesi piyasasında arz miktarında artışa neden olacaktır. Hidro kaynaklı elektrik üretiminin artması, fiyattan bağımsız teklif miktarını artıracığı için piyasa takas fiyatının düşmesini durumuyla karşılarız. Kamuya açık kaynakları kullanarak bir sonraki gün Türkiye'de yer alan tüm hidroelektrik santrallerin baraj ve havzalarına ne kadar miktarda su geleceği verisine ulaşmak mümkün değildir. Bu çalışma kamuya açık kaynakları kullanarak piyasa takas fiyatı tahmini yapma amacıyla yola çıktığı için önerilen fiyat tahmini modelinde hidro kaynaklara ilişkin bu tür bir veri giriş değişkeni olarak kullanılmamıştır.

2018 Türkiye elektrik üretim miktarının % 30'u doğal gaz santralleri tarafından yapılmıştır. Doğal gaz santrallerinin elektrik üretim maliyetini oluşturan temel unsur, elektrik üretimi yapmak için kullanacakları doğal gaz maliyetidir. BOTAŞ'ın doğal gaz santrallerine doğal gaz satışı için uyguladığı gaz tarifelerinde yapacağı değişiklik doğal gaz santrali sahibi piyasa katılımcılarının elektrik üretimi maliyetlerini

değiştirmekte; bu zincirleme reaksiyon doğal gaz santrali piyasa katılımcılarının gün öncesi piyasasına sundukları teklifleri, değişen elektrik üretim maliyetleri doğrultusunda değiştirmeleriyle sonuçlanmaktadır. Önerilen modelde bu durumun giriş değişkeni olarak temsil edilmesi amacıyla BOTAŞ'ın doğal gaz santrallerine uyguladığı gaz tarife fiyatları kullanılmıştır. Bu durum fiyat tahmin performansında olumsuz etkiye sahip olmaktadır. Her bir doğal gaz santralinin verimlilik, santral yaşı, iklim ve hava koşulları gibi faktörler göz önünde bulundurularak yapılacak elektrik üretim maliyetinin hesaplanması; hesaplanan her bir doğal gaz santraline ait elektrik üretim maliyetinin modelde giriş değişkeni olarak kullanılması tahmin performansını olumlu yönde etkileyecektir. Bahse konu olan verilere kamuya açık kaynaklar kullanarak temin etmek mümkün olmadığı için önerilen modelde bu veriler giriş değişkeni olarak kullanılmamıştır.

Dolar kurunun dolaylı olarak piyasa takas fiyatı üzerinde belirleyici bir rolü vardır. YEKDEM destekleme fiyatları dolar kuru üzerinden hesaplanmaktadır. Elektrik sektöründe yapılan özelleştirme ihaleleri dolar üzerinden yapılmıştır. Gerek özelleştirmelerin geri ödemeleri gerekse yapılan diğer yatırımlarda sermaye olarak kullanmak üzere kullanılan döviz kredilerinin maliyeti dolara endekslidir. Santral yatırımında kullanılan parça ve ekipmanın ithal olması, bu yatırıma ilişkin maliyetin dolara endeksli olmasına neden olmaktadır. Türkiye'de 2018 yılında üretilen elektriğin % 50.7'si ithal kaynaklar ile yapılmıştır. İthal kaynaklı elektrik üretim maliyetini belirleyen unsurlar yakıt fiyatları ve dolar kurudur. Dolar kurunun ne olduğu yukarıda ifade edilen birçok durum nedeniyle önem arz etmektedir. Dolar kurunun ne olduğu ve olacağı, doğrudan ve dolaylı yollarla piyasa takas fiyatı üzerinde belirleyici olmaktadır. Önerilen modelde bu durum ampirik bir yaklaşımla çözülmeye çalışılmış; dolar kurunun kendisi bir giriş değişkeni olarak modelde kullanılmıştır. Daha detaylı ve kapsamlı bir çalışma ile dolar kurunun piyasa takas fiyatı üzerindeki doğrudan ve dolaylı etkisi ortaya konulup, bu durum modelde giriş değişkeni olarak kullanılırsa modelin tahmin performansı artacaktır.

Piyasa takas fiyatı üzerinde belirleyici olan en önemli faktörlerden biri elektrik tüketim miktarı verisidir. Elektrik tüketim miktarı üzerinde belirleyici olan faktörlerin başında ise hava sıcaklığı gelmektedir. Hava sıcaklığının yüksek ve düşük olması soğutma ve ısınma amaçlı elektrik tüketimini tetiklemekte, bu durum elektrik tüketiminin artışına neden olmaktadır. Önerilen modelde sadece İstanbul iline ait hava sıcaklığı verisi giriş

değişkeni olarak kullanılmıştır. Önerilen modelde bu yaklaşımın ortaya konulma gerekçesi, modelin uygulanabilirliğini artırmak; modeli çalıştırmak için gerekli süreçleri kısaltmayı sağlamaktır. Bu durum modelin hatalı tahminler yapmasına neden olmaktadır. İdeal durum Türkiye’de yer alan 81 ile ait sıcaklık verisinin giriş değişkeni olarak kullanılmasıdır. Sıcaklık verisi ile birlikte nem verisinin giriş değişkeni olarak modele dahil edilmesi hissedilen sıcaklık ve dolayısıyla elektrik tüketimi arasında daha lineer bir ilişki ortaya koymayı sağlayacaktır.

Derin öğrenme modellerinin tahmin performansı, modelin eğitimi için kullanılan veri kümesinin büyüklüğüyle doğrudan ilişkilidir. Derin öğrenme uygulamalarında modelin eğitiminde kullanılan veri kümesi büyükçe, model giriş değişkenleri ile bağımlı değişken arasındaki lineer ve lineer olmayan ilişkiyi daha iyi anlamakta; bu durum modelin tahmin performansına olumlu etki etmektedir. Modelde kullanılacak veri setinin büyümesiyle birlikte modele ait tahmin performansının artması beklenmektedir.

Bu çalışmada önerilen modeli diğer modellerden farklı kılan özelliklerden ilki modelde kullanılan giriş değişkeni verilerinin tamamının kamuya açık kaynaklardan temin edilmiş olmasıdır. Bu özelliği, modelin başkaları tarafından kullanılabilmesini sağlamaktadır. Bu sayede modelin piyasa takas fiyatı tahmin performansı herkes tarafından test edilip, modelin piyasa takas fiyatı tahmin başarısı herkes tarafından görülebilecektir. Giriş değişkeni verilerinde herhangi bir temizleme işlemi uygulanmamış; özel ve resmi günler modelin eğitim ve test sürecine dahil edilmiştir. Literatürdeki çalışmalarda, özel ve resmi günlerin modelin eğitim ve test sürecinden çıkarılması işlemi ile modelin başarısının olduğundan daha yüksek gözükmesinin sağlanması, bu çalışmada yapılmamıştır.

Bu çalışmada önerilen modeli diğer modellerden farklı kılan özelliklerden ikincisi; modelin havadaki bulutluluk oranı ve güneşin havada olup olmaması bilgisi ile rüzgar santrallerine ait tahmini elektrik üretim verisini giriş değişkeni olarak kullanmasıdır. Bu veriler ilk kez bu çalışmada, Türkiye Elektrik Piyasası Gün Öncesi Elektrik Piyasası Piyasa Takası Fiyatı tahmini modelinde giriş değişkeni olarak kullanılması kullanılmıştır. Bu özelliği ile önerilen model, piyasa takas fiyatı tahmini için literatüre katkıda bulunmuş; piyasa takas fiyatının tahmini için farklı bir bakış açısı ortaya koymuştur.

Bu çalışmada önerilen modeli, diğer modellerden farklı kılan özelliklerden üçüncüsü; modelin gerçek piyasa koşulları içinde gayet basit ve az operasyonel işlem gerektirerek kullanılabilir olmasıdır. Kullanılan giriş değişkeni verilerinin temin edilmesi, giriş değişkeni veri dosyasının oluşturulması ve tahmin modelinin çalıştırılması işlemleri saat 11:30'da tamamlanabilmektedir. Türkiye Gün Öncesi Elektrik Piyasası Teklif bildirim kapı kapanma saati 12:30'dan 1 saat önce fiyat tahmini işlemi sonuçlandırılarak; piyasaya dönük strateji ve teklif yaklaşımının belirlenmesinde kullanılabilecek, tahmini piyasa takas fiyatı verisi elde edilebilmektedir.

Bu çalışmada önerilen modeli, diğer modellerden farklı kılan özelliklerden dördüncüsü; derin öğrenme kütüphanesi keras'ın ilk kez bu çalışmada Türkiye Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı Tahmini için kullanılmış olmasıdır.

Modelin uygulanabilirliği; modelin, ekonomik ve finansal belirsizlik ile fiyat dalgalanmasının yüksek olduğu 2018 yılında gösterdiği tahmin performansı; modele ait diğer özellikler; bu çalışmada önerilen tahmin modelini, literatürde yer alan Türkiye Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı Tahmini için yapılan mevcut çalışmalardan ayırıp, bu çalışmada önerilen tahmin modelini öne çıkarmaktadır.



KAYNAKLAR

- [1] **S. Anbazhagan, N. Kumarappan** (2013). Day-Ahead Deregulated Electricity Market Price Forecasting Using Recurrent Neural Network
- [2] **Benli T.O., Şengül H** (2016). A Comparison of Various Electricity Tariff Price Forecasting Techniques in Turkey and Identifying the Impact of Time Series Periods
- [3] **Javier Contreras** (2017). Forecasting Models of Electricity Prices
- [4] **Norbert A Agana, Abdollah Homaifar**. A Deep Learning Based Approach for Long-Term Drought Prediction
- [5] **Xue-Wen Chen, Xiaotong Lin** (2014). Big Data Deep Learning: Challenges and Perspectives
- [6] **Ziwei Liu, Ping Luo, Xiaogang Wang, Xiaoou Tang** (2015). Deep Learning Face Attributes in the Wild
- [7] **Jerzy Korczak, Marcin Hernes** (2017). Deep Learning for Financial Time Series Forecasting in A-Trader System
- [8] **Manuel R. Vargas, Beatriz S. L. P. de Lima, Alexander G. Evsukoff** (2017). Deep Learning for Stock Market Prediction from Financial News Articles
- [9] **Moinul Hossain, Banafsheh Rekabdar, Banafsheh Rekabdar, Sergiu Dascalu** (2015). Forecasting the Weather of Nevada: A Deep Learning Approach
- [10] **Sean McNally, Jason Roche, Simon Caton** (2018). Predicting the Price of Bitcoin Using Machine Learning

- [11] **Ghulam Mohi Ud Din, Angelos K. Marnerides** (2017). Short Term Power Load Forecasting Using Deep Neural Networks
- [12] **Yisheng Lv, Yanjie Duan, Wenwen Kang, Zhengxi Li, Fei-Yue Wang** (2015). Traffic Flow Prediction With Big Data:A Deep Learning Approach
- [13] **Avni Özözen, Gülgün Kayakutlu, Marcel Ketterer, Özgür Kayalıca** (2016). A Combined Seasonal ARIMA and ANN Model for Improved Results in Electricity Spot Price Forecasting Case Study in Turkey
- [14] **Özgür Kayalıca Hakan Yorulmuş, Umut Uğurlu, Oktay Taş** (2018). A Long Short Term Memory Application on the Turkish Intraday Electricity Price Forecasting
- [15] **Tanja Mimić** (2015). An Analysis of the Turkish Electricity Market
- [16] **Göksel Biricik, Ö. Özgür Bozkurt, Z. Cihan Tayşi** (2015). Analysis of Features Used in Short-Term Electricity Price Forecasting for Deregulated Markets
- [17] **Göksel Biricik, Ö. Özgür Bozkurt, Z. Cihan Tayşi** (2017). Artificial Neural Network and SARIMA Based Models for Power Load Forecasting in Turkish Electricity Market
- [18] **Umut Uğurlu, Burç Ulengin, Oktay Taş** (2016). Basic Time Series Patterns of Turkish Electricity Prices
- [19] **K.O. Ocakoğlu, A.C. Tolga** (2018). Effective Trading in Turkish Electricity Market: Hedging with Options
- [20] **Fazıl Gökgöz, Fahrettin Filiz** (2018). Electricity Price Forecasting: A Comparative Analysis with Shallow-ANN and DNN

- [21] **Fazıl Gökğöz, Fahrettin Filiz** (2016). Effective Trading in Turkish Electricity Market: Hedging with Options
- [22] **Umut Uğurlu, İlkay Öksüz, Oktay Taş** (2018). Electricity Price Forecasting Using Recurrent Neural Networks
- [23] **Ayşe Özmen, Miray Hanım Yıldırım, Özlem Türker Bayrak, Gerhard Wilhelm Weber**. Electricity Price Modelling for Turkey
- [24] **İbrahim Murat Bicil** (2015). Elektrik Piyasasında Fiyatlandırma Ve Türkiye Elektrik Piyasasında Fiyat Tahmini
- [25] **Mehmet Ali Kölmek, İsa Navruz** (2015). Forecasting the Day-Ahead Price in Electricity Balancing and Settlement Market of Turkey by Using Artificial Neural Networks
- [26] **Erdinç Akyıldırım, Ahmet Göncü, Albert Altarovici** (2014). Modeling Long-term Seasonality and Spikes of the Spot Electricity Prices in Turkey
- [27] **Talat Ulussever, Mehmet Ali Soytas, Hasan Murat Ertuğrul** (2017). Modelling Price Dynamics in Turkish Electricity Market: Lessons from GARCH Estimates
- [28] **Ceyhun Yıldız, Ahmet Gani, Mustafa Tekin, Ö. Fatih Keçecioglu, Hakan Açıkgöz, Mustafa Şekkeli** (2016). Price Forecasting Model for Turkish Day-Ahead Electricity Market Using Neural Network
- [29] **Talat Ulussever, Mehmet Ali Soytas, Hasan Murat Ertuğrul** (2017). Short term Price Prediction in Electricity Market Using Nonlinear Excess Demand Specification
- [30] **Seyd Amır Hamed Zakeri** (2015). Time Series Analysis and Forecasting Electricity Prices in Turkey

- [31] **Ahmet Saklıca** (2016). Turkish Electricity Spot Prices Volatility Modelling
- [32] **Aslıhan Dalgın** (2017). Yapay Sinir Ağları Kullanılarak Türkiye Gün Öncesi Piyasası Elektrik Fiyat Tahmini
- [33] **Reinaldo C. Garcia, Javier Contreras, Marco van Akkeren, João Batista C. Garcia** (2005). A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices
- [34] **Lei Wu, Mohammad Shahidehpour** (2010). A Hybrid Model for Day-Ahead Price Forecasting
- [35] **Paras Mandal, Ashraf Ul Haque, Julian Meng, Anurag K. Srivastava, Ralph Martinez** (2013). A Novel Hybrid Approach Using Wavelet, Firefly Algorithm, and Fuzzy ARTMAP for Day-Ahead Electricity Price Forecasting
- [36] **Michael Negnevitsky, Paras Mandal, Anurag K. Srivastava** (2009). An Overview of Forecasting Problems and Techniques in Power Systems
- [37] **Hamidreza Zareipour, Arya Janjani, Henry Leung, Member, Amir Motamedi, Antony Schellenberg** (2011). Classification of Future Electricity Market Prices
- [38] **N. Amjady, A. Daraeepour, F. Keynia** (2009). Day-Ahead Electricity Price Forecasting by Modified Relief Algorithm and Hybrid Neural Network
- [39] **Guang Li, Chen-Ching Liu, Chris Mattson, Jacques Lawarrée** (2007). Day-Ahead Electricity Price Forecasting in a Grid Environment
- [40] **Michele Benini, Mirko Marracci, Paolo Pelacchi, Member, Andrea Venturini**. Day-Ahead Market Price Volatility Analysis in Deregulated Electricity Markets


- [41] **Nima Amjady** (2006). Day-Ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network
- [42] **T. Pinto, T. M. Sousa, Z. Vale** (2012). Dynamic Artificial Neural Network for Electricity Market Prices Forecast
- [43] **Vale Hamidreza Zareipour, Claudio A. Cañizares, Kankar Bhattacharya** (2010). Economic Impact of Electricity Market Price Forecasting Errors: A Demand-Side Analysis
- [44] **Alicia Troncoso Lora, Jesús M. Riquelme Santos, Antonio Gómez Expósito, José Luis Martínez Ramos, José C. Riquelme Santos** (2007). Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques
- [45] **Amir Motamedi, Hamidreza Zareipour, William D. Rosehart** (2012). Electricity Price and Demand Forecasting in Smart Grids
- [46] **Jie Chen, Shi-Jie Deng, Xiaoming Huo** (2008). Electricity Price Curve Modeling and Forecasting by Manifold Learning
- [47] **M. Zhou, Z. Yan, Y.X. Ni, G. Li, Y. Nie**. Electricity Price Forecasting With Confidence-Interval Estimation through an Extended ARIMA Approach
- [48] **B.R. Szkuta, L.A. Sanabria, T.S. Dillon** (1999). Electricity Price Short-Term Forecasting Using Artificial Neural Networks
- [49] **Claudia P. Rodriguez, George J. Anders** (2004). Energy Price Forecasting in the Ontario Competitive Power System Market
- [50] **Derek W. Bunn** (2000). Forecasting Loads and Prices in Competitive Power Markets

- [51] **Claudio M. Ruibal, Mainak Mazumdar** (2008). Forecasting the Mean and the Variance of Electricity Prices in Deregulated Markets
- [52] **Xiaohong Guan, Yu-Chi Ho David L. Pepyne** (2001). Gaming and Price Spikes in Electric Power Markets
- [53] **J. P. S. Catalão, H. M. I. Pousinho, V. M. F. Mendes** (2011). Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Electricity Prices Forecasting
- [54] **Carolina García-Martos, Julio Rodríguez, María Jesús Sánchez** (2007). Mixed Models for Short-Run Forecasting of Electricity Prices: Application for the Spanish Market
- [55] **Alicia Mateo González, Antonio Muñoz San Roque, Javier García-González** (2005). Modeling and Forecasting Electricity Prices with Input/Output Hidden Markov Models
- [56] **S. Fan, C. Mao, L. Chen** (2007). Next-Day Electricity-Price Forecasting using a Hybrid Network
- [57] **Walid El-Khattam, Kankar Bhattacharya, Yasser Hegazy, Member M. M. A. Salama** (2004). Optimal Investment Planning for Distributed Generation in a Competitive Electricity Market
- [58] **K. Meng, Z.Y. Dong, K.P. Wong** (2008). Self-Adaptive Radial Basis Function Neural Network for Short-Term Electricity Price Forecasting
- [59] **Alexander Boogert, Dominique Dupont** (2008). When Supply Meets Demand: The Case of Hourly Spot Electricity Prices
- [60] **Elektrik Piyasasi Kanunu. (2001). T. C. Resmi Gazete, 24335, 3 Mart 2001**

- [61] **Elektrik Piyasası Dengeleme Ve Uzlaştırma Yönetmeliği.(2009)**
T. C. Resmi Gazete, 27200, 14 Nisan 2009.
- [62] **EPIAŞ, Enerji Piyasaları İşletme A.Ş., 2018 Yılı Faaliyet Raporu,**
1 Ocak – 31 Aralık 2018 <[http:// epias.com.tr/wp-content/uploads/2019/03/2018-Yılı-Yönetim-Kurulu-Faaliyet Raporu.pdf](http://epias.com.tr/wp-content/uploads/2019/03/2018-Yılı-Yönetim-Kurulu-Faaliyet-Raporu.pdf)>, erişim tarihi sürekli.
- [63] **EPIAŞ Şeffaflık Platformu** <[http:// seffaflik.epias.com.tr/transparency](http://seffaflik.epias.com.tr/transparency)> ,
- [64] **YTBS - Yüktevzi Bilgi Sistemi** <[http:// ytbsbilgi.teias.gov.tr/](http://ytbsbilgi.teias.gov.tr/)> ,
erişim tarihi sürekli.
- [65] **EPIAŞ, Gün Öncesi Elektrik Piyasası Fiyat Belirleme Yöntemi (2016)**
- [66] **Abdulkadir ŞEKER, Banu DİRİ, Hasan Hüseyin BALIK (2017). Derin**
Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme
- [67] **EPDK - Enerji Piyasası Düzenleme Kurumu, Elektrik Piyasası Aylık**
Sektör Raporları 2017
- [68] **RP5 - Rasat Portalı** <[http:// rp5.ru](http://rp5.ru)> , erişim tarihi sürekli.
- [69] **RİTM - Rüzgar İzleme ve Test Merkezi** <[http:// ritm.gov.tr/guc/ritm_tr.html](http://ritm.gov.tr/guc/ritm_tr.html)> , erişim tarihi sürekli.
- [70] **T.C. Enerji Ve Tabii Kaynaklar Bakanlığı, Enerji İşleri Genel**
Müdürlüğü, Enerji İstatistikleri Dairesi Başkanlığı, Enerji
İstatistik Bülteni, Sayı: 293 / 2018 - 27.Hafta
- [71] **BOTAŞ - Boru Hatları ile Petrol Taşıma A.Ş, BOTAŞ Doğal Gaz Toptan**
Satış Tarifeleri Ve Satış Fiyatları <[http:// botas.gov.tr](http://botas.gov.tr)> , erişim tarihi sürekli.

- [72] **Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun. (2005). T. C. Resmi Gazete, 25819, 18 Mayıs 2005.**
- [73] **TCMB - Türkiye Cumhuriyet Merkez Bankası** <<http://evds2.tcmb.gov.tr/index.php?>>, erişim tarihi sürekli.
- [74] **EPDK - Enerji Piyasası Düzenleme Kurumu, Elektrik Piyasası Tarifeler Listesi** <<http://epdk.org.tr>>, erişim tarihi sürekli.
- [75] **Keras** <<http://keras.io>>, erişim tarihi sürekli.
- [76] **Python (3.6)** [Computer software]
- [77] **JetBrains PyCharm (2018.3.2)** [Computer software]
- [78] **Anaconda3 (1.9.6)** [Computer software].
- [79] **Keras** <<http://machinelearningmastery.com/introduction-python-deep-learning-library-keras/>>, erişim tarihi sürekli.
- [80] **Keras** <<http://linkedin.com/in/fchollet>>, erişim tarihi sürekli.
- [81] **EPIAŞ Şeffaflık Platformu** <<http://seffaflik.epias.com.tr/transparency/uretim/yekdem/kurulu-guc.xhtml>>, erişim tarihi sürekli.

ÖZGEÇMİŞ



Ad-Soyad : Burak KÜÇÜKASLAN :

Doğum Tarihi ve Yeri

E-posta

ÖĞRENİM DURUMU:

- **Lisans :**

MESLEKİ DENEYİM VE ÖDÜLLER:

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER: