

**T.C.  
İSTANBUL OKAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**DOKTORA TEZİ  
İŞLETME ANABİLİM DALI  
İŞLETME PROGRAMI**

**Mustafa KAYA**

**DERİN ÖĞRENME YÖNTEMLERİ İLE ELEKTRİK  
FİYAT TAHMİNİ: TÜRKİYE GÜN ÖNCESİ ELEKTRİK  
PİYASASI UYGULAMASI**

**DANIŞMAN**  
Prof. Dr. M. Erdinç TELATAR

**İSTANBUL, Haziran 2022**

**T.C.  
İSTANBUL OKAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**DOKTORA TEZİ  
İŞLETME ANABİLİM DALI  
İŞLETME PROGRAMI**

**Mustafa KAYA  
(182502013)**

**DERİN ÖĞRENME YÖNTEMLERİ İLE ELEKTRİK  
FİYAT TAHMİNİ: TÜRKİYE GÜN ÖNCESİ ELEKTRİK  
PİYASASI UYGULAMASI**

**DANIŞMAN  
Prof. Dr. M. Erdinç TELATAR**

**İSTANBUL, Haziran 2022**

T.C.  
İSTANBUL OKAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ  
İŞLETME ANABİLİM DALI  
İŞLETME PROGRAMI

Mustafa KAYA  
(182502013)

DERİN ÖĞRENME YÖNTEMLERİ İLE ELEKTRİK  
FİYAT TAHMİNİ: TÜRKİYE GÜN ÖNCESİ ELEKTRİK  
PİYASASI UYGULAMASI

Tezin Enstitüye Teslim Edildiği Tarihi : 24.06.2022  
Tezin Savunulduğu Tarih : 22.06.2022

|                    |                                                                |       |
|--------------------|----------------------------------------------------------------|-------|
| Tez Danışmanı      | : Prof. Dr. M. Erdoğru TELATAR<br>(İstanbul Okan Üniversitesi) | _____ |
| Diğer Jüri Üyeleri | : Prof. Dr. Özgür ÇENGEL<br>(Galata Üniversitesi)              | _____ |
|                    | Prof. Dr. Mehmet Baha KARAN<br>(Hacettepe Üniversitesi)        | _____ |
|                    | Prof. Dr. Uğur YOZGAT<br>(Nişantaşı Üniversitesi)              | _____ |
|                    | Doç. Dr. Murat BOLELLİ<br>(Altınbaş Üniversitesi)              | _____ |

İSTANBUL, Haziran 2022

# İÇİNDEKİLER

|                                                                            |      |
|----------------------------------------------------------------------------|------|
| <b>ÖZET</b>                                                                | iv   |
| <b>ABSTRACT</b>                                                            | v    |
| <b>TEŞEKKÜR</b>                                                            | vi   |
| <b>KISALTMALAR</b>                                                         | vii  |
| <b>ŞEKİL LİSTESİ</b>                                                       | viii |
| <b>BÖLÜM 1. GİRİŞ VE AMAÇ</b>                                              | 1    |
| <b>BÖLÜM 2. GENEL BİLGİLER</b>                                             | 5    |
| 2.1. TÜRKİYE ELEKTRİK PİYASASININ KISA TARİHÇESİ.....                      | 5    |
| 2.2. ELEKTRİK PİYASASI YAPISI .....                                        | 6    |
| 2.2.1. Gün Öncesi Piyasası (GÖP)                                           | 8    |
| 2.2.2. Gün İçi Piyasası (GİP)                                              | 10   |
| 2.2.3. Dengeleme Güç Piyasası (DGP)                                        | 11   |
| 2.2.4. İkili Anlaşmalar                                                    | 13   |
| 2.3. YAPAY ZEKÂ İLE İLGİLİ GENEL BİLGİLER.....                             | 13   |
| 2.3.1. Kısa Tarihçe                                                        | 13   |
| 2.3.2. Yapay Zekâ                                                          | 16   |
| 2.3.3. Makine Öğrenmesi Nedir?                                             | 18   |
| 2.3.4. Makine Öğrenmesi, Yapay Sinir Ağları ve Derin Öğrenme               | 20   |
| 2.4. ELEKTRİK PİYASALARINDA TAHMİNLEME LİTERATÜRÜ .....                    | 22   |
| <b>BÖLÜM 3. YÖNTEM</b>                                                     | 39   |
| 3.1. ÖZ-DİKKAT KATMANLI KODLAYICI-KOD ÇÖZÜCÜ DÖNÜŞTÜRÜCÜ AĞ MODELİ .....   | 39   |
| 3.1. DÖNÜŞTÜRÜCÜ (TRANSFORMER).....                                        | 40   |
| 3.2. ÖZ-DİKKAT MEKANİZMASI.....                                            | 40   |
| 3.3. KODLAYICI-KOD ÇÖZÜCÜ MİMARİSİ .....                                   | 41   |
| 3.4. KAPILI TEKRARLAYAN ÜNİTE (GATED RECURRENT UNIT - GRU) .....           | 41   |
| 3.5. YIĞILMIŞ SİNİR AĞLARI .....                                           | 43   |
| 3.6. EVRİŞİMLİ SİNİR AĞLARI (CNN).....                                     | 43   |
| 3.7. TEKRARLAYAN SİNİR AĞLARI (RNN: <i>Recurrent Neural Network</i> )..... | 44   |
| 3.8. UZUN KISA SÜRELİ HAFIZA (LSTM) .....                                  | 45   |
| 3.1. YOĞUN SİNİR AĞLARI (DENSE-DNN).....                                   | 46   |

|                 |                                                                                                                    |           |
|-----------------|--------------------------------------------------------------------------------------------------------------------|-----------|
| 3.2.            | ÇİFT YÖNLÜ TEKRARLAYAN SİNİR AĞLARI.....                                                                           | 47        |
| 3.3.            | CNN-LSTM .....                                                                                                     | 48        |
| 3.4.            | CNN-GRU.....                                                                                                       | 48        |
| <b>BÖLÜM 4.</b> | <b>ARAŞTIRMA METODOLOJİSİ</b>                                                                                      | <b>50</b> |
| 4.1.            | KULLANILAN VERİ.....                                                                                               | 50        |
| 4.1.1.          | Veri Erişim Linkleri:                                                                                              | 50        |
| 4.1.2.          | Türetilmiş Özellikler:                                                                                             | 52        |
| 4.1.3.          | Fast Fourier Dönüşümü                                                                                              | 53        |
| 4.1.4.          | Özellik Mühendisliği:                                                                                              | 54        |
| 4.1.5.          | Veri Normalleştirme                                                                                                | 55        |
| 4.1.6.          | Veri Pencereleme:                                                                                                  | 55        |
| 4.2.            | DEĞERLENDİRMEDE KULLANILAN METRİKLER .....                                                                         | 56        |
| 4.2.1.          | Ortalama Mutlak Hata (MAE):                                                                                        | 57        |
| 4.2.2.          | Ortalama Kare Hata (MSE):                                                                                          | 57        |
| 4.2.3.          | Kök Ortalama Kare Hata (RMSE):                                                                                     | 57        |
| 4.2.4.          | Determinasyon katsayısı ( $R^2$ )                                                                                  | 57        |
| 4.3.            | MODELLER .....                                                                                                     | 58        |
| 4.3.1.          | Öz-Dikkat Katmanlı Kodlayıcı-Çözücü Dönüştürücü:                                                                   | 59        |
| 4.3.2.          | Simple RNN:                                                                                                        | 59        |
| 4.3.3.          | LSTM:                                                                                                              | 59        |
| 4.3.4.          | GRU:                                                                                                               | 60        |
| 4.3.5.          | Yığın Basit RNN:                                                                                                   | 60        |
| 4.3.6.          | Yığın LSTM:                                                                                                        | 61        |
| 4.3.7.          | Yığın GRU:                                                                                                         | 61        |
| 4.3.8.          | Çift Yönlü LSTM:                                                                                                   | 62        |
| 4.3.9.          | Çift Yönlü GRU:                                                                                                    | 63        |
| 4.3.10.         | Çift Yönlü Yığın LSTM:                                                                                             | 63        |
| 4.3.11.         | Çift Yönlü Yığın GRU:                                                                                              | 64        |
| 4.3.12.         | CNN – LSTM:                                                                                                        | 64        |
| 4.3.13.         | CNN – GRU:                                                                                                         | 65        |
| <b>BÖLÜM 5.</b> | <b>BULGULAR</b>                                                                                                    | <b>67</b> |
| 5.1.            | ÖZ-DİKKAT TABANLI DÖNÜŞTÜRÜCÜ KODLAYICI-ÇÖZÜCÜ MODELİ<br>İÇİN ÖĞRENME ADIMLARINA GÖRE SONUÇLARIN DEĞERLENDİRİLMESİ | 68        |
| 5.2.            | RNN TABANLI MODELLER İÇİN ÖĞRENME ADIMLARINA GÖRE<br>SONUÇLARIN DEĞERLENDİRİLMESİ.....                             | 80        |
| 5.3.            | RNN TABANLI MODELLERİN KENDİ EN İYİ SKORLARI .....                                                                 | 91        |

|                                                                                                                  |     |
|------------------------------------------------------------------------------------------------------------------|-----|
| 5.4. EN İYİ BAŞARIYI ELDE EDEN 4 FARKLI MODELİN EN İYİ SKORLU<br>ÖĞRENME EĞRİLERİNE GÖRE DEĞERLENDİRİLMESİ ..... | 93  |
| 5.5. TÜM MODELLERİN ÖĞRENME ADIMLARINA GÖRE GENEL<br>DEĞERLENDİRMESİ.....                                        | 94  |
| BÖLÜM 6. SONUÇ VE ÖNERİLER                                                                                       | 96  |
| KAYNAKÇA                                                                                                         | 99  |
| EKLER                                                                                                            | 103 |



## ÖZET

### DERİN ÖĞRENME YÖNTEMLERİ İLE ELEKTRİK FİYAT TAHMİNİ: TÜRKİYE GÜN ÖNCESİ ELEKTRİK PİYASASI UYGULAMASI

Bu çalışma, Türkiye gün öncesi elektrik piyasasında, sonraki 24 saatlik piyasa takas fiyatlarını (PTF) tutarlı bir şekilde tahmin etmek için, çeşitli derin öğrenme yöntemlerini analiz etmeyi amaçlamaktadır. Bu amaçla, “öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü model” ve ayrıca on iki tane de “RNN tabanlı model” oluşturulmuştur. Çalışmada, 2017-2021 dönemi için EPİAŞ Şeffaflık Platformu’ndan sağlanan saatlik üretim, tüketim ve piyasa takas fiyatı verileri kullanılmıştır. Bahsi geçen dönem ve veri için öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü ağ modeli elektrik fiyatlarını yüksek tutarlılıkla tahmin etmiştir. Bu model veride kullanılan COVID-19 kukla özelliği sayesinde, veride gruplama yaparak, normal dönem ve COVID-19 dönemini ayrı ayrı öğrenerek, dönemsel tahminlerde de yüksek tutarlılık elde etmiştir. Oluşturulan öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelin ne kadar başarılı olduğunu test etmek için, on iki tane RNN (Tekrarlayan Sinir Ağı) tabanlı model, aynı veri seti ile ayrıca test edilmiştir. Çalışmada oluşturulmuş RNN tabanlı modeller fiyatları başarılı bir şekilde tahmin etse de bu modellerden hiçbiri öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelin tahmin gücüne ulaşamamıştır. Diğer yandan, öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelin, elektrik fiyatlarının tahmininde ilk kez kullanılması ise bu çalışmanın alana en önemli katkısı olmuştur.

**Anahtar Kelimeler:** Elektrik Fiyat Tahmini, Derin Öğrenme, Öz-Dikkat Katmanlı Dönüştürücü Kodlayıcı-Çözücü Ağ, Tekrarlayan Sinir Ağı

**Tarih:** 22.06.2022

# **ABSTRACT**

## **ELECTRICITY PRICE FORECAST BY DEEP LEARNING METHODS: AN APPLICATION IN THE DAY-AHEAD ELECTRICITY MARKET OF TURKEY**

This study aims to analyze various deep learning methods to accurately predict the next 24-hour market clearing prices in the Turkish day-ahead electricity market with deep learning methods. For this purpose, a transformer encoder-decoder with self-attention model and twelve RNN-based models are designed to predict electricity price. In the study, hourly production, consumption, and market clearing price data provided by EPIAŞ Transparency Platform for the period 2017-2021 are used. For the given period and data, the transformer encoder-decoder with self-attention model predicted electricity prices with high accuracy. Through the COVID-19 dummy feature used in the analysis, the model has achieved high accuracy in periodic prediction by grouping the data, learning the normal period and the COVID-19 period separately. To test the success of transformer encoder-decoder with self-attention model, twelve RNN (Recurrent Neural Network) based models were also tested with the same dataset. Although the RNN-based models created in the study successfully predicted prices, none of these models could reach the predictive power of the transformer encoder-decoder with self-attention model. The use of the transformer encoder-decoder with self-attention model for the first time in the prediction of electricity prices is the main contribution of this study to the field.

**Key Words:** Electricity Price Prediction, Deep Learning, Transformer Encoder-Decoder with Self-Attention, Recurrent Neural Network

**Date:** 22.06.2022

## TEŞEKKÜR



## KISALTMALAR

**DNN:** Derin Sinir Ağı

**SimpleRNN:** Basit Tekrarlayan Sinir Ağı

**LSTM:** Uzun-Kısa Süreli Bellek Sinir Ağı

**GRU:** Kapılı Tekrarlayan Birim

**Stacked\_SimpleRNN:** Yığılmış Basit Tekrarlayan Sinir Ağı

**Stacked\_LSTM:** Yığılmış Uzun-Kısa Süreli Bellek Sinir Ağı

**Stacked\_GRU:** Yığılmış Kapılı Tekrarlayan Birim

**Bi\_LSTM:** Çift Yönlü Uzun-Kısa Süreli Bellek Sinir Ağı

**Bi\_GRU:** Çift Yönlü Kapılı Tekrarlayan Birim

**Stacked\_Bi\_LSTM:** Yığılmış Çift Yönlü Uzun-Kısa Süreli Bellek Sinir Ağı

**Stacked\_Bi\_GRU:** Yığılmış Çift Yönlü Kapılı Tekrarlayan Birim

**CNN\_LSTM:** Evrişimli Sinir Ağı\_Uzun-Kısa Süreli Bellek Sinir Ağı

**CNN\_GRU:** Evrişimli Sinir Ağı\_Kapılı Tekrarlayan Birim

**TEDSA:** Öz-Dikat Tabanlı Dönüştürücü Kodlayıcı-Çözücü

**YSA:** Yapay Sinir Ağı

**BSA:** Biyolojik Sinir Ağları

**DVM:** Destek Vektör Makinesi

**DVR:** Destek Vektör Regresyonu

**DVS:** Destek Vektör Sınıflandırması

**EPIAŞ:** Enerji Piyasaları İşletme Anonim Şirketi

**EM:** Eşleşme Miktarı

**GZU:** Lisanssız üretim dahil gerçek zamanlı üretim miktarı

**GÖP:** Gün Öncesi Piyasası

**GİP:** Gün İçi Piyasası

**DGP:** Dengeleme Güç Piyasası

**PTF:** Piyasa Takas Fiyatı

**TEİAŞ:** Türkiye Elektrik İletim Anonim Şirketi

## ŞEKİL LİSTESİ

|                                                                                                                  |    |
|------------------------------------------------------------------------------------------------------------------|----|
| Şekil 2.1. Elektrik Piyasasının Tarihsel Gelişimi (Kaynak: Epias).....                                           | 5  |
| Şekil 2.2. Türkiye Elektrik Piyasa İşleyiş Yapısı.....                                                           | 7  |
| Şekil 2.3. Türkiye Elektrik Piyasası Yetki Dağılımı.....                                                         | 7  |
| Şekil 2.4. McCulloch ve Pitts Nöron Modeli (McCulloch ve Pitts 1943).....                                        | 14 |
| Şekil 2.5. Biyolojik Sinir Hücresi Şematik Gösterimi .....                                                       | 14 |
| Şekil 2.6. Konferans Katılımcıları (Dartmouth Koleji, 1956).....                                                 | 15 |
| Şekil 2.7. Yapay Zekanın Katmanları .....                                                                        | 20 |
| Şekil 2.8. Yapay Sinir Ağı ile Derin Sinir Ağlarının Yapısal Farkları .....                                      | 21 |
| Şekil 2.9 Elektrik Fiyat Tahmini ve Modelleme Yaklaşımları (Rafał Weron, 2014) .....                             | 26 |
| Şekil 3.1. Öz-Dikkat Katmanlı Dönüştürücü Kodlayıcı-Kod Çözücü Ağ Modeli (Wu, Green, Ben, & O'Banion, 2020)..... | 39 |
| Şekil 3.2. GRU Hücresi Şematik Gösterimi.....                                                                    | 42 |
| Şekil 3.3. RNN Hücresi Şematik Gösterimi.....                                                                    | 45 |
| Şekil 3.4. LSTM Hücre Yapısı Şematik Gösterimi.....                                                              | 46 |
| Şekil 3.5. Tek ve Çift Yönlü Tekrarlayan Sinir Ağları .....                                                      | 48 |
| Şekil 4.1 Veriye Genel Bakış .....                                                                               | 51 |
| Şekil 4.2. Verilere Yakın Bakış (17 Ocak 2021'den İtibaren).....                                                 | 51 |
| Şekil 4.3. Gün için Cosinüs Sinus Eğrisi .....                                                                   | 52 |
| Şekil 4.4 Saat özelliği için Sin/Cos Dönüşümü .....                                                              | 53 |
| Şekil 4.5. Verideki Tepe Noktaları Yıllık ve Günlük .....                                                        | 54 |
| Şekil 4.6. Veri Pencereleme .....                                                                                | 56 |
| Şekil 4.7 Modelleme Aşamaları.....                                                                               | 58 |
| Şekil 4.8. SimpleRNN Modelinin Yapısı.....                                                                       | 59 |
| Şekil 4.9. LSTM Modelinin Yapısı.....                                                                            | 60 |
| Şekil 4.10. GRU Modelinin Yapısı.....                                                                            | 60 |
| Şekil 4.11. Yığın Basit RNN Modelinin Yapısı.....                                                                | 61 |
| Şekil 4.12. Yığın LSTM Modelinin Yapısı.....                                                                     | 61 |
| Şekil 4.13. Yığın GRU Modeli Yapısı.....                                                                         | 62 |
| Şekil 4.14. Çift Yönlü LSTM modeli.....                                                                          | 62 |
| Şekil 4.15. Çift Yönlü GRU modeli.....                                                                           | 63 |

|                                                                                 |    |
|---------------------------------------------------------------------------------|----|
| Şekil 4.16. Çift Yönlü Yığın LSTM: Modelinin Yapısı .....                       | 63 |
| Şekil 4.17. Çift Yönlü Yığın GRU Modelinin Yapısı.....                          | 64 |
| Şekil 4.18. CNN – LSTM Modelinin Yapısı .....                                   | 65 |
| Şekil 4.19. CNN – GRU Modelinin Yapısı.....                                     | 66 |
| Şekil 5.1 Pandemi Dönemi İçin Alınan Örnek Ara Tahmin .....                     | 69 |
| Şekil 5.2 Normal Dönem İçin Alınan Örnek Ara Tahmin .....                       | 69 |
| Şekil 5.3. 100 Öğrenme Adımı Kayıp Grafiği .....                                | 70 |
| Şekil 5.4. 200 Öğrenme Adımı İçin Kayıp Grafiği .....                           | 71 |
| Şekil 5.5. 300 Öğrenme Adımı İçin Kayıp Grafiği .....                           | 72 |
| Şekil 5.6. 400 Öğrenme Adımı İçin Kayıp Grafiği .....                           | 73 |
| Şekil 5.7. 500 Öğrenme Adımı İçin Kayıp Grafiği .....                           | 74 |
| Şekil 5.8. 600 Öğrenme Adımı İçin Kayıp Grafiği .....                           | 75 |
| Şekil 5.9. 700 Öğrenme Adımı İçin Kayıp Grafiği .....                           | 76 |
| Şekil 5.10. 800 Öğrenme Adımı İçin Kayıp Grafiği .....                          | 77 |
| Şekil 5.11. 900 Öğrenme Adımı İçin Kayıp Grafiği .....                          | 78 |
| Şekil 5.12. 1000 Öğrenme Adımı İçin Kayıp Grafiği .....                         | 79 |
| Şekil 5.13. RNN Temelli Modeller: 100 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 81 |
| Şekil 5.14. RNN Temelli Modeller: 200 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 82 |
| Şekil 5.15. RNN Temelli Modeller: 300 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 83 |
| Şekil 5.16. RNN Temelli Modeller: 400 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 84 |
| Şekil 5.17. RNN Temelli Modeller: 500 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 85 |
| Şekil 5.18. RNN Temelli Modeller: 600 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 86 |
| Şekil 5.19. RNN Temelli Modeller: 700 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 87 |
| Şekil 5.20. RNN Temelli Modeller: 800 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 88 |
| Şekil 5.21. RNN Temelli Modeller: 900 Öğrenme Adımı İçin Öğrenme Eğrileri.....  | 89 |
| Şekil 5.22. RNN Temelli Modeller: 1000 Öğrenme Adımı İçin Öğrenme Eğrileri..... | 90 |
| Şekil 5.23. Modellere Göre En İyi İlk Dört Sonucu Veren Modeller .....          | 93 |

## TABLO LİSTESİ

|                                                                                     |    |
|-------------------------------------------------------------------------------------|----|
| Tablo 2.1. Çalışmada Kullanılan Makalelerdeki Yöntem ve Metrikler Tablosu .....     | 37 |
| Tablo 4.1. Modellerde Kullanılan Özellikler Hakkında Genel Bilgi .....              | 55 |
| Tablo 4.2. Veri İçerisindeki Önemli Dönemler.....                                   | 55 |
| Tablo 5.1. Öz-Dikkat Tabanlı Dönüştürücü Kodlayıcı-Çözücü Modeli Sonuçları.....     | 69 |
| Tablo 5.2. RMSE Skoruna Göre İlk 10 RNN Tabanlı Modelin Sıralaması .....            | 80 |
| Tablo 5.3. RNN Tabanlı Modelin RMSE Metriğine Kendi En İyi Skorları. ....           | 91 |
| Tablo 5.4. On Üç Modelin Kendi En iyi RMSE Skoruna Göre Genel Sırlamadaki Yeri..... | 95 |

## BÖLÜM 1. GİRİŞ ve AMAÇ

90'lı yılların başından itibaren, birçok ülkede elektrik piyasaları, üretim ve tedarik faaliyetlerinde rekabeti başlatmak amacıyla (doğal tekel olarak görüldükleri için) liberalleşme (deregülasyon) süreci başlamıştır (Escribano, Ignacio Peña, & Villaplana, 2011). Ülkemizde de “2001 yılında yürürlüğe giren 4628 sayılı elektrik piyasası kanunuyla” elektrik piyasası için deregülasyon süreci başlamıştır. Escribano vd.'ne göre (2011) *bu reformun temel sonuçlarından biri, fiyatların, genellikle havuz denilen yerde arz (üreticiler) ile talep (enerji satın alan ve tüketicilere satan araçlar olan tedarikçiler) arasındaki etkileşim tarafından belirlenmesidir. Bu kapsamda üreticiler piyasa havuzunda elektrik satmak için rekabet ederken, tüketicilere tedarikçiler havuzdan belirlenen denge fiyatlarından elektrik satın alırlar. Elektrik fiyatları, elektrik piyasalarının kendine has özellikleri nedeniyle, ayrıca elektrik üretiminin doğası gereği (depolanamazlık vb.) son derece yüksek oynaklık sergileyen bir karaktere sahip olmuştur. Elektrik fiyatlarının temel özelliklerinden biri ise, ani veya kısmen ani (gün öncesi) fiyatlarda artışlar veya sıçramalar olarak bilinen aşırı değişikliklerdir. Bu değişkenlikler nedeniyle gün öncesi fiyatlarının tahminlenmesi, deregülasyonun başladığı günden günümüze önemli bir konu olmaya devam etmiştir (Karakatsani & Bunn, 2008) (Rafal Weron, 2006).*

Elektrik üretimin talepten az ya da fazla üretilmesi durumunda fiyatı direkt etkilemektedir. Elektrik piyasasındaki üreticilerin ve tüketicilerin zarar etmemek için elektrik fiyatını doğru tahmin etmesi gerekmektedir. Yorulmuş vd. (2018) gün öncesi piyasası ile gün içi piyasası bazı benzerliklere sahip olsa da tahmin bağlamında zorlukların büyük etkisi olduğunu ortaya koymuştur. Öncelikle gün öncesi piyasasında tahminler genel olarak 12h-36h arasındadır. Gün içi piyasasında genellikle 1 saat ilerisi için tahminler yapılmaktadır. Türkiye piyasasında olduğu gibi (bir buçuk saat) müzayede kapanış saati ile teslimat arasında bir saatten fazla bir süre varsa iki saat ileri için tahminlerin yapılması gerektiğini vurgulamışlardır.

Gün öncesi ve gün içi olmak üzere iki tipte fiyat belirlenen bu spot elektrik piyasalarında fiyatlar içinde bulunan günün saati, haftanın günü ve mevsime göre tüketime bağlı olarak değişken bir yapı izlemektedir. Dolayısıyla yüksek derecede değişkenlik gösteren bu piyasalarda, fiyatların belirlenmesi piyasanın temel taşlarından birini oluşturmaktadır. “Elektrik piyasasının durağan olmayan yapısına ilişkin olarak piyasa katılımcısı olan tedarik şirketleri kısa, orta ve uzun vadeli kontratlarında müşterilerine takdim edecekleri fiyat opsiyonları için gerçeğe yakın bir yaklaşıma sahip olabilmeyi hedeflemektedir. Bu nedenle, PTF’nin (Piyasa Takas Fiyatı) mümkün olduğunca gerçek değerine yakın bir şekilde tahmin edilmesi önem taşımaktadır” (Dikbaş, 2019). Bu noktada, geçmiş fiyat verilerinden hareketle gün öncesi veya gün içi fiyatlarının tahmin edilmesi piyasa aktörlerinin bu belirsizlikte pozisyon belirlemede her geçen gün daha fazla önem kazanmaktadır. Bundan dolayıdır ki hem elektrik sektöründe hem de akademide elektrik fiyat tahmini araştırmaları çok çeşitli metotlar kullanılarak her geçen gün yaygınlaşmaktadır.

Son yıllarda Türkiye’de özellikle yenilenebilir enerji üretimine verilen destekler dolayısıyla piyasa aktörleri çeşitlenmiş ve spot piyasada rekabet artmıştır. Bu durum artan rekabet fiyatlandırma stratejilerine de direkt etki etmektedir. Bu rekabetin özellikle Yenilenebilir Enerji Kaynakları Destekleme Mekanizması (YEKDEM) gibi desteklerin sağladığı fiyat ve satın alma garantisi gibi sübvansiyonların, eskiye göre daha temkinli bir seyir izleyecek olması nedeniyle, daha da sertleşeceği öngörülebilir. Piyasada işlem yapan firmalarının yatırımlarını risklerden koruyarak bu piyasada bir aktör olarak kalabilmeleri ve üretim yapabilmeleri için haftalık, aylık, günlük ve saatlik fiyatları doğru ve tutarlı bir biçimde tahmin etmeleri çok daha önemli bir hale gelecektir. Bu, yalnızca piyasada elektrik alıp satan firmalar için değil, piyasayı yöneten “Enerji Piyasaları İşletme A.Ş.” (EPIAŞ) ve piyasadaki tüm aktörler açısından da önem arz etmektedir.

Dünya tahmin literatürü de elektrik piyasalarındaki bu hareketlilikten hareketle her geçen gün elektrik fiyat tahmin edilmesine yönelik araştırmalar üretmektedir. Genel olarak, güncel araştırma yönelimine bakıldığında elektrik fiyatının doğru ve tutarlı tahmininin önemine vurgu yapıldığı ve tahmin yönteminin klasik ekonometrik modellerin yerine, makine öğrenmesi ve bunların melez yöntemlere doğru evrildiği gözlenmektedir. Burada bahsedilen melez yöntemler, çeşitli makine öğrenmesi metotlarının birlikte kullanıldığı modellerin yanı sıra ekonometrik modeller ile makine

öğrenmesi metotlarının birlikte kullanıldığı modelleri içermektedir. Çalışmalardan vurgulanan önemli bir nokta da veri üzerine oldukça az ön varsayım gerektiren öğrenme algoritmalarının, elektrik fiyatlarının tahmin edilmesi açısından, verinin belirsiz ve değişken doğasına oldukça uygun olduğudur.

Çalışmada kullanılan veri 2017-2021 yılları arasında COVID-19 pandemisi öncesi, COVID-19 pandemi dönemi, kapanmalar ve kontrollü normalleşme dönemini kapsayacak şekilde seçilmiştir. EPIAŞ şeffaflık platformu üzerinden verilere erişim sağlanmıştır. Veriler, PTF (Piyasa Takas Fiyatı), Üretim ve Tüketim verileridir. Bu veri seti içerisinde 23 farklı özellik yer almaktadır.

Bu çalışmanın temel amacı, Türkiye gün öncesi elektrik piyasasında saatlik fiyat tahmin edilmesi için derin öğrenme yöntemleri kullanarak tutarlığı yüksek bir modeli ortaya koymaktır. Oluşturulacak bu model ile varılmak istenen hedef ise Türkiye elektrik gün öncesi piyasasında, sonraki gün için 24 saatlik elektrik fiyatını, güvenilirliği yüksek bir şekilde tahmin etmektir.

Araştırmanın özgün değeri öncelikle literatürde daha önce işlenmemiş olan öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelinin elektrik fiyat tahmini için kullanılması olacaktır. Bu çalışmanın literatüre bir diğer katkısı ise, basit tekrarlayan ağ (*SimpleRNN*), uzun kısa süreli bellek (*LSTM*), kapılı tekrarlayan birim (*GRU*), yığın basit tekrarlayan ağ (*Stacked\_SimpleRNN*), yığın uzun kısa süreli bellek (*Stacked\_LSTM*), yığın kapılı tekrarlayan birim (*Stacked\_GRU*), iki yönlü uzun kısa süreli bellek modeli (*Bi\_LSTM*), iki yönlü kapılı tekrarlayan birim modeli (*Bi\_GRU*), yığın iki yönlü uzun kısa süreli bellek modeli (*Stacked\_Bi\_LSTM*), iki yönlü kapılı tekrarlayan birim (*Stacked\_Bi\_GRU*), evrişimli - uzun kısa süreli bellek modeli (*CNN\_LSTM*), evrişimli kapılı tekrarlayan birim (*CNN\_GRU*) olarak isimlendirilen 13 farklı modelin farklı öğrenme adım sayılarında sonraki gün yirmi dört saatlik piyasa takas fiyatlarını tahmin performanslarının test edilmesidir. Ayrıca COVID-19 döneminin kukla değişken olarak tüm modellerde kullanılması elektrik fiyatı tahmin etme literatürde bir ilk olmuştur.

PwC Türkiye ve T.C. Cumhurbaşkanlığı Yatırım Ofisi “Türkiye Elektrik Piyasasına Genel Bakış-2021” raporunda, Türkiye elektrik piyasasında 2018’in sonuna kadar elektrik tüketim hızla arttığı, ancak 2019 ve 2020’de elektrik tüketiminin, COVID-19 pandemisinin etkisiyle bu yıllarda artmadan sabit kalmış olduğu belirtilmektedir (Türkiye Elektrik Piyasasına Genel Bakış, 2021, sf. 14). Bu bilgiden yola çıkarak COVID-19

pandemisi gibi küresel ve yerel etkisi yüksek olayların ve krizlerin de oluşturulacak modellere dahil edilmesi çalışmanın literatüre bir diğer katkısı olacaktır. Çalışma kapsamında, modellerin tahmin gücünün iyileştirilmesi amacı ile literatürde var olan çeşitli melez modelleme yöntemlerinin incelenmesi, birden fazla yöntem kullanılarak sonuçlarının karşılaştırılması ve en uygun modellemenin seçilerek hata oranı en düşük bir şekilde tahmin yapabilen bir model ortaya konulması planlanmaktadır.

Bulgular hem Türkiye hem de uluslararası literatürdeki bulgular ile çeşitli metrikler açısından kıyaslanacak şekilde detaylı bir biçimde tartışılmıştır. Bu sayede hem elektrik fiyatı tahmin etme literatüründe model seçimine yönelik gelecek çalışmalara hem de Türkiye elektrik piyasası için yapılan tahmin etme çalışmalarına yol gösterici olması beklenmektedir.


Elektrik piyasalarındaki güncel belirsizlikler ele alındığında çalışmanın bulguları hem sektör hem de akademik paydaşlar açısından katkı sağlar niteliktedir.

Çalışma ilk olarak veri analizi, özellik mühendisliği ve özellik seçimi çalışmaları aşaması ile başlamıştır. İkinci aşamada literatürden yola çıkılarak kullanılacak metrikler ve modeller seçilmiştir. Üçüncü aşamada modeller, Tensorflow, Keras ve PyTorch kütüphaneleri kullanılarak Python v3.7 dili ile kodlanmış ve testleri yapılmıştır. Dördüncü aşamada tüm modeller farklı adım sayılarında test edilmiş sonuçları kayıt altına alınmıştır. Beşinci aşamada çalışmanın bulguları analiz edilmiş ve sonuçlar yorumlanmıştır.

## BÖLÜM 2. GENEL BİLGİLER

### 2.1. TÜRKİYE ELEKTRİK PİYASASININ KISA TARİHÇESİ

Türk elektrik piyasası reformu, rekabeti getirmeyi ve piyasada sürdürülebilir büyümeyi amaçlayan “4628 sayılı Elektrik Piyasası Kanunu'nun (EPK)” yürürlüğe girmesiyle Mart 2001'de başlamıştır. Aşağıdaki şekilde (Şekil 2.1) kısa tarihçe genel olarak verilmiştir.



Şekil 2.1. Elektrik Piyasasının Tarihsel Gelişimi (Kaynak: Epiaş)

Piyasa kanununun amacı, elektriği tüketicilere kesintisiz ve uygun fiyatlı olarak sağlamaktır. Kanun, elektrik piyasasının düzenlenmesinden sorumlu özerk bir organ olarak işlev gören EPDK'yı kurdu. Daha sonra EPDK'nın işlevleri doğal gaz, sıvılaştırılmış petrol gazı ve petrol piyasalarını da kapsayacak şekilde genişletilmiştir. EPDK, görevlerini ana karar organı olan Enerji Piyasası Düzenleme Kurulu aracılığıyla yürütmektedir. 2001 yılında “Türkiye Elektrik Üretim ve İletim A.Ş. (TEAŞ)” üç bölüme ayrılmıştır:

“Elektrik İletim A.Ş. (TEİAŞ)”

- İletim sisteminin geliştirilmesi, bakımı ve işletilmesi

“Elektrik Üretim Şirketi (EÜAŞ)”

- Devlete ait elektrik üretim kapasitesini işletmek

“Elektrik Ticaret ve Taahhüt Şirketi (TETAŞ)”

- YİD ve TOR şirketleri ile uzun vadeli PPA'lar dahil toptan elektrik ticareti

2006 yılı sonuna kadar elektrik dağıtım sektörünün özelleştirilmesi amacıyla Mart 2004'te yeni bir elektrik stratejisi kabul edilmiştir. Yenilenebilir enerji ve enerji verimliliği için ülkenin stratejisine çerçeve belirleyen, sırasıyla 2005 ve 2007'de ayrı yenilenebilir enerji ve enerji verimliliği yasaları kabul edildi. TEDAŞ, 2004 yılında ana hatlarıyla belirlenen strateji doğrultusunda dağıtım sektörünü özelleştirmek için bir holding şirketi ve 21 bölgesel yan kuruluş (önceden merkezi bir yönetimden) olarak yeniden yapılandırılmıştır. Dağıtım bölümleri 2004 ve 2006 yılları arasında özelleştirilerek tamamlanmıştır.


2004 stratejisi aynı zamanda Türkiye Pazarında bir elektrik borsası geliştirmeyi de öngörmüştür. Ocak 2005'e kadar geçici bir dengeleme ve uzlaştırma mekanizmasının kurulması hedeflenmiştir ve Temmuz 2006'ya kadar gün öncesi piyasasının kurulması planlanmıştır. Hazırlık döneminin ardından, 2009 yılında gün öncesi planlama mekanizması kurulmuş ve 2011 yılında Gün Öncesi Piyasasının açılmasına kadar işlemeye devam etmiştir. Dengeleme ve uzlaştırma mekanizması ise 2006 yılında kurulmuş ve TEİAŞ devreye alınmıştır. Elektrik Piyasası Mali Uzlaştırma Merkezi (PMUM) olarak da adlandırılan Türkiye'de dengeleme ve uzlaştırma mekanizmasının işletilmesi, 2015 yılında PMUM, TEİAŞ'tan ayrılarak bağımsız bir kuruluş olan İstanbul Enerji Borsası (EİB) olmuştur. TETAŞ ve EÜAŞ, 9 Temmuz 2018 tarihinde EÜAŞ altında birleştirilmiştir.

2021 yılında YEKDEM için 10 yıldır yürürlükte olan geçmiş tarifenin yerini alacak yeni FIT'nin getirilmesi, yenilenebilir enerji alanında sektörde önemli gelişmelere sahne olmuştur. YEK-G sisteminin kurulması, elektrik tüketicilerine satın aldıkları enerjinin yenilenebilir kaynağını doğrulama fırsatı vermesi açısından da çok önemli gelişme olmuştur.

## **2.2. ELEKTRİK PİYASASI YAPISI**

Dünyada kurulu elektrik piyasalarının önde gelen amacı, elektrik enerjisinin depolanamaması nedeniyle mümkün olabilecek en az kayıp ve maliyet ile talep kadar üretilmesini sağlamaktır. Türkiye’de bu amaca ulaşmak için üretim ile talep dengesi sağlamak ve gereken teknolojik, idari ve mali altyapıyı sağlama sorumluluğu çeşitli kamu


kurumlarına verilmiştir. Türkiye’de kurulu olan elektrik piyasası altyapısı da dünya örneklerine benzer şekildedir (Şekil 2.2). Piyasa; gün öncesi, gün içi ve dengeleme güç piyasası olarak faaliyetler gerçekleştirmektedir.



Şekil 2.2. Türkiye Elektrik Piyasa İşleyiş Yapısı

Türkiye Elektrik Piyasası’nda GÖP 2011 yılında devreye girmiştir. Sonrasında “avans ve teminat ödeme mekanizması” ile “Yenilenebilir Enerjisi Destekleme Mekanizması” YEKDEM piyasaya dahil edilmiştir, “6446 sayılı Elektrik Piyasası Kanunu” 2013’te yayımlanmış ve bundan sonra Gün İçi Piyasası 1 Temmuz 2015 tarihinde devreye sokulmuştur.

EPİAŞ kurulana kadar piyasa faaliyetleri “Piyasa Mali Uzlaştırma Dairesi Başkanlığı” tarafından TEİAŞ’ta yürütülmüştür. TEİAŞ tarafından yürütülen “Gün Öncesi” ve “Gün İçi” piyasaları ve “Uzlaştırma” faaliyetleri 01.09.2015 günü EPİAŞ tarafından yürütülmeye başlamıştır. “Dengeleme Güç Piyasası”, TEİAŞ sorumluluğunda yürütülmeye devam etmektedir (Şekil 2.3).



Şekil 2.3. Türkiye Elektrik Piyasası Yetki Dağılımı

### 2.2.1. Gün Öncesi Piyasası (GÖP)

Türkiye Enerji Piyasası piyasa işletmecisi (EPIAŞ) tarafından yönetilen ve yürütülen bir piyasadır. Genelde elektrik spot piyasası olarak da adlandırılır. Elektrik ticaretini ve dengeleme faaliyetlerini sürdürmek için kullanılan önemli bir mekanizmadır.

#### 2.2.1.1. GÖP Genel Esasları

- *Gün Öncesi Piyasasına ilişkin piyasa katılımcılarının yükümlülüklerini içeren Gün Öncesi Piyasası Katılım Anlaşması' nı imzalayarak piyasa katılımcısı olan tüm lisans sahibi tüzel kişiler Gün Öncesi Piyasasına katılabilirler.*
- *Gün Öncesi Piyasası işlemleri günlük olarak, saatlik bazda gerçekleştirilir. Her bir gün, 00:00'dan başlayıp, ertesi gün 00:00'da sona eren saatlik zaman dilimlerinden oluşur.*
- *Gün öncesi piyasası teklifleri bir sonraki günden başlanarak 5 gün sonraya kadar verilebilir.*
- *Gün Öncesi Piyasasının uzlaştırmasında uygulanan fiyat ve miktarlar günlük bazda ve her bir saat için belirlenir.*
- *Uzlaştırma hesaplamaları sonucunda piyasa katılımcılarının gün öncesi dengeleme faaliyetlerine ilişkin olarak, bir fatura döneminin her günü için Piyasa İşletmecisine ödeyeceği ya da Piyasa İşletmecisi tarafından piyasa katılımcılarına ödenecek tutarları içeren günlük avans ödeme bildirimi, günlük bazda ertesi gün Piyasa İşletmecisi tarafından merkezi uzlaştırma bankası aracılığı ile ilgili piyasa katılımcılarına duyurulur.*
- *Teminat mektupları her gün saat 10:30' a kadar Piyasa İşletmecisine, teminat mektubu dışındaki diğer teminatlar ise saat 11:00'a kadar merkezi uzlaştırma bankasına, piyasa katılımcısı tarafından sunulur.*

(“<https://www.epias.com.tr/gun-oncesi-piyasasi/genel-esaslar/>, Erişim tarihi: 15/11/2021”)

#### 2.2.1.2. GÖP Süreci

- Her gün saat 12:30' a kadar, gün öncesi piyasasına katılan piyasa katılımcıları bir sonraki güne ait gün öncesi piyasası tekliflerini Yeni GÖP sistemi aracılığıyla Piyasa İşletmecisine bildirirler.
- Gün Öncesi Piyasasına teklif verilip verilemeyeceğinin belirlenmesi için gün öncesi piyasası açılış zamanından önce saat 12:30-13:00 arasında teminat kontrolü yapılır.
- Bildirilen her bir gün öncesi piyasası teklifi Piyasa İşletmecisi tarafından saat 12:30-13:00 arasında değerlendirilerek doğrulanır.
- Teyit edilen teklifler saat 13:00 – 13:30 arasında, optimizasyon aracı ile değerlendirilir ve ilgili günün her bir saatine ilişkin piyasa takas fiyatları ve piyasa takas miktarları belirlenir.
- Her gün 13:30' da onaylanmış alış-satış miktarlarını içeren ticari işlem onayları ilgili piyasa katılımcısına bildirilir. Bu bildirimlerin içeriğinde hata bulunması durumunda piyasa katılımcısı saat 13:30-13:50 arasında itiraz edebilir.
- İtirazlar saat 13:50 – 14:00 arasında değerlendirilir ve sonucu katılımcıya bildirilir. Saat 14:00'da ertesi günün 24 saatine ilişkin fiyat ve eşleşmeler nihai olarak duyurulur.
- Her gün saat 00:00 – 17:00 arasında piyasa katılımcıları tarafından ikili anlaşma bildirimleri Yeni GÖP sistemine girilir.
- Her gün saat 17:00 – 17:05 arasında ikili anlaşmalar KOPİ yöntemi uyarınca kontrol edilir.
- Her gün saat 17:05 – 17:15 arasında KOPİ uyarınca iptal edilen ikili anlaşmalar için itiraz süreci işletilir.

("https://www.epias.com.tr/gun-oncesi-piyasasi/surecler/, Erişim tarihi: 15/11/2021")

### 2.2.2. Gün İçi Piyasası (GİP)

Türkiye Enerji Piyasası, piyasa işletmecisi olan EPIAŞ tarafından yönetilen ve organize edilen bir piyasadır. Bu piyasa gün içinde yapılan elektrik ticaretini ve dengeleme faaliyetlerini sürdürmek için kullanılan önemli bir mekanizmadır.

#### 2.2.2.1. GİP Genel Esaslar

- *Gün Öncesi Piyasasına ilişkin piyasa katılımcılarının yükümlülüklerini içeren Gün Öncesi Piyasası Katılım Anlaşması' nı imzalayarak piyasa katılımcısı olan tüm lisans sahibi tüzel kişiler Gün Öncesi Piyasasına katılabilirler.*
- *Gün Öncesi Piyasası işlemleri günlük olarak, saatlik bazda gerçekleştirilir. Her bir gün, 00:00'dan başlayıp, ertesi gün 00:00'da sona eren saatlik zaman dilimlerinden oluşur.*
- *Gün öncesi piyasası teklifleri bir sonraki günden başlanarak 5 gün sonraya kadar verilebilir.*
- *Gün Öncesi Piyasasının uzlaştırmasında uygulanan fiyat ve miktarlar günlük bazda ve her bir saat için belirlenir.*
- *Uzlaştırma hesaplamaları sonucunda piyasa katılımcılarının gün öncesi dengeleme faaliyetlerine ilişkin olarak, bir fatura döneminin her günü için Piyasa İşletmecisine ödeyeceği ya da Piyasa İşletmecisi tarafından piyasa katılımcılarına ödenecek tutarları içeren günlük avans ödeme bildirimi, günlük bazda ertesi gün Piyasa İşletmecisi tarafından merkezi uzlaştırma bankası aracılığı ile ilgili piyasa katılımcılarına duyurulur.*
- *Teminat mektupları her gün saat 10:30' a kadar Piyasa İşletmecisine, teminat mektubu dışındaki diğer teminatlar ise saat 11:00'a kadar merkezi uzlaştırma bankasına, piyasa katılımcısı tarafından sunulur.*

("https://www.epias.com.tr/qun-ici-piyasasi/genel-esaslar/ , Erişim tarihi: 15/11/2021")

#### 2.2.2.2. GİP Süreci

- *Her gün saat 12:30' a kadar, gün öncesi piyasasına katılan piyasa katılımcıları bir sonraki güne ait gün öncesi piyasası tekliflerini Yeni GÖP sistemi aracılığıyla Piyasa İşletmecisine bildirirler.*

- *Gün Öncesi Piyasasına teklif verilip verilemeyeceğinin belirlenmesi için gün öncesi piyasası açılış zamanından önce saat 12:30-13:00 arasında teminat kontrolü yapılır.*
- *Bildirilen her bir gün öncesi piyasası teklifi Piyasa İşletmecisi tarafından saat 12:30-13:00 arasında değerlendirilerek doğrulanır.*
- *Teyit edilen teklifler saat 13:00 – 13:30 arasında, optimizasyon aracı ile değerlendirilir ve ilgili günün her bir saatine ilişkin piyasa takas fiyatları ve piyasa takas miktarları belirlenir.*
- *Her gün 13:30’ da onaylanmış alış-satış miktarlarını içeren ticari işlem onayları ilgili piyasa katılımcısına bildirilir. Bu bildirimlerin içeriğinde hata bulunması durumunda piyasa katılımcısı saat 13:30-13:50 arasında itiraz edebilir.*
- *İtirazlar saat 13:50 – 14:00 arasında değerlendirilir ve sonucu katılımcıya bildirilir. Saat 14:00’da ertesi günün 24 saatine ilişkin fiyat ve eşleşmeler nihai olarak duyurulur.*
- *Her gün saat 00:00 – 17:00 arasında piyasa katılımcıları tarafından ikili anlaşma bildirimleri Yeni GÖP sistemine girilir.*
- *Her gün saat 17:00 – 17:05 arasında ikili anlaşmalar KOPİ yöntemi uyarınca kontrol edilir.*
- *“Her gün saat 17:05 – 17:15 arasında KOPİ uyarınca iptal edilen ikili anlaşmalar için itiraz süreci işletilir.”*

(“<https://www.epias.com.tr/gun-ici-piyasasi/surecler/> , Erişim tarihi: 15/11/2021”)

### **2.2.3. Dengeleme Güç Piyasası (DGP)**

Dengeleme güç piyasası Türkiye Enerji Piyasası Sistem İşletmecisi (TEİAŞ) tarafından organize edilmektedir. Piyasaya “Gerçek Zamanlı Piyasa” da denilmektedir. Üretilen elektriğin teslimatında ortaya çıkan arızalar, üretim tahminindeki sapmalar sonucu arz ve talep dengeleme problemi gibi durumlarda dengeleme faaliyetlerinin gerçekleştirildiği mekanizmadır.

#### 2.2.3.1. DGP Genel Esaslar

- Gerçek zamanlı dengeleme; yan hizmetler ve dengeleme güç piyasasından oluşur. Dengeleme güç piyasası, Sistem İşletmecisine (MYTM) gerçek zamanlı dengeleme için en fazla 15 dakika içinde devreye girebilecek yedek kapasiteyi sağlar. Frekans kontrolü ve talep kontrolü hizmetleri, yan hizmetler aracılığıyla sağlanır.
- Gün Öncesi Piyasası ve Gün İçi Piyasası ile Sistem İşletmecisi 'ne (MYTM) her ne kadar üretim ve tüketim miktarları dengelenmiş bir piyasa sunulmuş olsa da gerçek zamanda sapmalar olmaktadır. Örneğin, bir santralin arızadan dolayı devre harici olması veya büyük bir tüketim tesisinin bir anda çalışmaya başlaması/çalışmayı durdurması dengeyi bozmaktadır, bu durumda MYTM dengeyi sağlamak için Dengeleme Güç Piyasası'na sunulmuş teklifleri kullanarak, sistem dengesini sağlamaya çalışmaktadır.
- DGP'ye katılan tüm piyasa katılımcıları emre amade kapasitelerini sunmak zorundadır.
- Bağımsız olarak 15 dakika içerisinde asgari 10 MW yük alabilen veya yük atabilen dengeleme birimleri DGP'ye katılmakla yükümlüdür.

("https://www.epias.com.tr/genel-esaslar/ , Erişim tarihi: 15/11/2021")

#### 2.2.3.2. DGP Süreci

Her gün saat 14:00 itibariyle Gün Öncesi Piyasasının tamamlanması ile başlar.

Piyasa katılımcısı her gün saat 16:00'a kadar:

- Kendi adına kayıtlı üretim tesisleri için emre amade kapasitelerini (EAK) ve saatlik üretim değerlerini içeren kesinleşmiş günlük üretim programlarını (KGÜP)
- Dengeleme Güç Piyasasına ilişkin yük alma, yük atma tekliflerini

TPYS aracılığıyla Sistem İşletmecisine bildirir.

Yük alma, yük atma teklifleri Sistem İşletmecisi tarafından her bir saat için fiyat sırasına dizilir.

Sistem İşletmecisi,

- Sistemde meydana gelen / geleceği öngörülebilir enerji açığı ya da fazlasının giderilmesi,

- *Sistem kısıtlarının giderilmesi*

*amaçlarıyla uygun bulunan tekliflere ilişkin talimatları ilgili piyasa katılımcılarına bildirilir.*

*(“<https://www.epias.com.tr/dgp-sureci/> , Erişim tarihi: 15/11/2021”)*

#### **2.2.4. İkili Anlaşmalar**

Piyasada, enerjinin alınıp satılmasına dair üretici ve tedarikçi arasında yapılan ticari sözleşmelere ikili anlaşmalar denilmektedir. Taraflar arası anlaşmazlıklar özel hukuk hükümlerine tabidir.

Şekil 2.2’den de anlaşılacağı üzere Elektrik Piyasası, Fiziksel ve Fiziksel Olmayan Elektrik Ticareti faaliyetleri ile işletilmektedir. Fiziksel Elektrik Ticareti faaliyetlerinden Piyasa İşletmecisi EPİAŞ ve Sistem İşletmecisi TEİAŞ sorumludur. Fiziksel Olmayan Elektrik Ticareti alanında ise türev piyasalar aracılığı ile alım-satım yapılmaktadır.


*(“<https://www.epias.com.tr/dgp-sureci/> , Erişim tarihi: 15/11/2021”)*

### **2.3. YAPAY ZEKÂ İLE İLGİLİ GENEL BİLGİLER**

#### **2.3.1. Kısa Tarihçe**


Düşünebilen sistemler yaratma çabası modern bilgisayarların kullanılmaya başlamasında çok öncelere dayanmaktadır. Aristo ve Euclid bu alandaki ilk çalışmaları yapan bilim insanlarıdır. Ayrıca 17. yüzyılda yaşamış bilim insanlarından Leibniz, Hobbes ve Descartes, cebir veya geometri gösterimi gibi, tüm rasyonel düşüncelerin de sistematik olarak açıkça tanımlanabilmesi konusunda araştırmalar yapmışlardır.

Sinir bilimi araştırmacısı Warren S. McCulloch ve mantık konusunda çalışmalar yürüten Walter Pitts, 1943 yılında beynin nöronları kullanarak oldukça karmaşık kalıplar üretebilmesini anlamak için bir çalışma yapmışlardır. Bu çalışma sonucunda aşağıdaki şekilde (Şekil 2.4) gösterimi olan tek bir nöron için oldukça basitleştirilmiş bir hesaplama modelini geliştirmişlerdir. Bu çalışma sayesinde, günümüzdeki birçok yapay sinir ağı geliştirilmiştir.



Şekil 2.4. McCulloch ve Pitts Nöron Modeli (McCulloch ve Pitts 1943)

Donald Hebb de öğrenme alanına önemli katkılarda bulunmuştur. Hebb, biyolojik temelden yola çıkarak sinir hücrelerinin aralarındaki ilişkilerinin ağırlıklarını ortaya koyan bir öğrenme kuralını geliştirmiştir. Bu kurala alanda “Hebb kuralı” ismi verilmiştir. Bu kurala göre “birlikte ateşlenen nöronlar birbirine bağlanır” (“neurons that fire together wire together”) (Hebb, 1949). “Hebb kuralı” gereğince, iki sinir hücresi birbiri ile ateşlenecek kadar yakın ise ve aynı anda aktive oluyorsa, sinir hücreleri arasında bir bağ gelişmeye başlar ve güçlenir; beraber uyarılmazlarsa var olan bu bağ gelişmeyecek veya aralarındaki bağ kopacaktır.



Şekil 2.5. Biyolojik Sinir Hücresi Şematik Gösterimi

“Hebb kuralı” gereğince, A sinir hücresi B sinir hücresinden girdi alıyorsa ve her iki sinir hücresi de aktif durumdaysa, A nöronu ile B nöronu arasındaki bağlantının gücü artar (Şekil 2.5). Hebb’in çalışmasından yola çıkıldığında yapay sinir hücrelerinin birbirleri arasındaki ağırlıkları belirlemek yapay sinir ağlarının öğrenmesi açısından önemli bir konu olarak ortaya çıkmaktadır.

1950 yılına gelindiğinde Alan Turing, “Computing Machinery and Intelligence” adlı çalışmasını yayınlamıştır. Turing bu çalışmasında herhangi bir makinenin zeki olup olmayacağını ele almış ve bu konuyu değerlendirebilmek bir dizi ölçüt geliştirmiştir.

“Yapay zekâ” terimini ortaya atan McCarthy 1955 yılında düşünen makineler hakkındaki çalışmalarını geliştirebilmek için bir çalışma grubu oluşturmaya karar vermiştir. 1956 yılında Dartmouth Koleji’nde bu fikrini hayata geçirmek için bir konferans düzenler (Şekil 2.6). Bu konferanstan sonra “Yapay Zekâ” akademik bir disipline dönüşmüştür.



Şekil 2.6. Konferans Katılımcıları (Dartmouth Koleji, 1956)

Dartmouth konferansından itibaren, 1970’li yılların ilk birkaç yılını kapsayan döneme “Yapay zekânın altın yılı” denilmektedir. Bu dönemde araştırmalar açısından finansal bir sorun yaşanmazken, çalışma alanı yüklü hibeler ile desteklenmiştir. Ancak tüm bu olumlu havaya rağmen, ilerleyen zamanlarda sonuca ulaşmayan çalışmalar sebebiyle alana ilgi zayıflamış ve fonlar kesilmiştir. Fonların kesildiği bu yıllara “Yapay zekâ kışı” denilmektedir. “Yapay zekâ kışı”, bu alandaki uzmanların, uğraştıkları problemlerin zorluk derecesini dikkate almadan çalışmalarını yürütmeleri nedeniyle ortaya çıkmıştır. Bunun sonucu olarak çalışmaların yavaşlaması hatta durması ile gelen sponsorluk ve fonlar da azalmış veya hiç kalmamıştır. “Yapay zekâ kışı” boyunca, araştırmacılar ihtiyaç duydukları fonu sağlayabilmek için yaptıkları çalışmalarının içeriğini değil ancak isimlerini farklılaştırarak (Örneğin: “örüntü tanıma”, “bilişim”, “bilgi tabanlı sistem”) bu sorunun üstesinden gelmeye çalışmışlardır.

1980’lerin başında “Yapay zekâ”, dar bir alanda, uzmanların bilgilerine dayanan ve buradan elde edilmiş mantıksal kuralları yerine getiren, belirli dar alandaki soruları

cevaplayan veya bu alandaki sorunları çözen uzman sistemler olarak tekrar ortaya çıkmıştır. Örneğin 1980 yılında “Digital Equipment Corporation (DEC), müşterinin gereksinimlerine göre bilgisayar bileşenleri otomatik olarak seçerek, DEC’in VAX bilgisayar sistemlerinin oluşturulmasına yardımcı olmak için R1’i kullanmıştır” (McDermott, 1981). Bu sistem 1986 yılına kadar kendisine verilen 2500 kural ile verilen 80.000’den fazla siparişi, %95-98 doğrulukla almıştır. “R1 montajlarda teknisyenlerin yanlış bileşen kullanmasından kaynaklanan hatalar nedeniyle müşterilere ücretsiz parça veya bilgisayar verme problemini azaltmış, montaj sürecini hızlandırmış ve müşteri memnuniyetini artırmıştır. Bu sayede DEC şirketin yılda ortalama 40 milyon dolar tasarruf etmesini sağlamıştır” (Crevier, 1993).

### 2.3.2. Yapay Zekâ

“Yapay Zekâ” terimi ilk defa Dartmouth Kolejinde 1956 yılında gerçekleştirilen bir konferansta açıkça kullanılmıştır. AI Magazines (1955), dergisi McCarthy vd.’nin 31 Ağustos 1955 yapay zekâyı tarif ettikleri orijinal belgelerin görsellerini yayınlamıştır. Bu belgelerde McCarthy vd. yapay zekâyı “Öğrenme ve zekânın tüm özellikleri en ince detaylar ile tanımlanırsa, bilgisayarlar da bunları kullanıp insan gibi düşünebilir” olarak tanımladılar. Günümüzde yapay zekâ, insanın bilişsel yeteneklerini bir dizi bilim, teori ve teknik uygulayarak taklit etmeyi amaçlayan bir disiplin olarak tanımlanmaktadır. Nabiyev’in tanımına göre “Yapay zekâ, bir bilgisayarın ya da bilgisayar destekli bir makinenin, genellikle insana özgü nitelikler olan çözüm yolu bulma, anlama, bir mana çıkartma, genelleme ve geçmişteki deneyimlerinden öğrenme gibi yüksek mantıksal süreçlere ilişkin görevleri yerine getirme yeteneğidir” Nabiyev (2012). Yapay zekâ tanımlarında kullanılan ortak ifade “insan zekâ ve davranışlarının, bilgisayarlar tarafından taklit edilmesidir”. Ancak bu tanımlarda bir nokta eksik bırakılmış, en önemli konulardan biri olan öğrenme tanımda yer almamıştır.

Yapay zekânın tanımlar sonucu sadece “insan zekâsının ve davranışlarının bilgisayarlar tarafından taklit edilmesi” şeklinde kabul edilmesi yanlıştır. Yapay zekâ aslında matematiksel mantık, istatistik, olasılıklar, hesaplamalı nöro-biyoloji, bilgisayar bilimi gibi alanlardan elde edilen yöntem ve işlemlerin bütünüdür. Yapay zekâ tanımından yola çıkarak varılan yapay zekânın “insanların tamamen yerini alacağı” yargısı ise bu alandaki en büyük yanılgıdır. Bu sistemler insanların yerini almak için değil, kazanılan insani yeteneklerin, yine insanların yararına kullanılması amacıyla

tasarlanmışlardır. Bu olumsuz yargı yerine, gelişen bu alan sonuçları ile birçok yeni uzmanlık alanın oluşacağı ve insanın istihdam edilebileceği daha çok alan olacağı öngörülmektedir.

### **2.3.2.1. Yapay Zekâ Türleri**

Yapay zekâ iki ana tür olarak ele alınmaktadır. Birinci tür, uygulamalı yapay zekâ olarak tanımlanır ve yaygın olarak çalışılan bu yapay zekâ türüdür. Uygulamalı yapay zekâ alanındaki sistemler, tek bir görevi başarmak için tasarlanmış sistemlerdir. Bu türün uygulama alanlarına örnek verecek olursak otonom araçlar, hisse senedi fiyat tahmini, görüntülemenin hastalık tespiti gibi alanlardır. Genelleştirilmiş yapay zekâ ise bu alandaki ikinci türdür. Birinci türe göre daha az kullanılmaktadır. Bu tür daha çok, bilinmeyen veya daha önce karşılaşılmamış sorunlara çözüm bulmak için geliştirilmektedir. Genelleştirilmiş yapay zekâ, uğraşılan problem ile ilgili yeterli büyüklükte veriyi girdi alıp, verilen herhangi bir görevi teoride başarabilecek sistemler veya cihazlar olarak da tanımlanabilir.

Bu alanda “dar” veya “zayıf” olarak tanımlanan bir tür daha bulunmaktadır. Bu tür, tek bir konuda uzmanlaşmış olan sistemler olarak ifade edilebilir. Örnek verecek olursak Google Asistan, tanıdığı bir dilde sözlü olarak verilen komutları yorumlayarak verilen komutu yerine getirir. Google Asistan’dan otonom şekilde araba kullanması, hava durumu tahmini yapması veya tıbbi görüntüleri analiz etmesi beklenemez. Google Asistan gibi belirli bir konu için özellikle geliştirilmiş sistemler; montaj robotları endüstriyel montaj için, kişisel dijital asistanlar ajanda yönetimi için, finansal öngörü sistemleri hisse senedi fiyatı tahmininde ve tıbbi görüntüleme destek sistemi de hastadan alınan görüntüyü yorumlamak için radyoloji doktoruna yardımcı olmak amacı ile oluşturulmuşlardır. Dar yapay zekâ alandaki sistemler, başka bir problem karşısında kendi başına bu problemin üstesinden gelmeye veya yeteneklerini farklı alanlara uygulama becerisine sahip değildirler. Ancak teorik olarak bunu başarabileceği düşünülen “güçlü” zekâ türü, yapay genel zekâ olarak adlandırılmıştır (YGZ). İnsan zekâsı ve problem çözme kabiliyetine karşılık gelen hipotetik bir yapay zekâ türüdür. Beynimiz bir konuda yazı yazmayı, nota okumayı veya kod yazmayı kolayca öğrenebilir. Güçlü yapay zekânın da bir konuda yazı yazmayı, nota okumayı veya kod yazmayı öğrenebileceği öngörülmektedir. Bu alanda bir sistemin parçası olabilecek alt sistemler geliştirilmiş olsa da (örneğin: beste yapan sistemler) henüz bütün bir sistem

geliştirilmemiştir. Güçlü ve dar olarak isimlendirilen iki yapay zekâ türü, yapay zekâ alandaki evrimin iki ucu olarak kabul edilebilir.

### 2.3.3. Makine Öğrenmesi Nedir?

Makine öğrenmesinde, insanların öğrenme yöntemlerini taklit etmeyi sağlayabilmek için algoritmaların kullanımına odaklanılır. Son yıllarda Yapay Zekâ alanında öğrenme ve uygulama doğruluğunu artıran önemli bir dalıdır.

“Makine öğrenmesi” terimini ilk kez 1959 yılında Arthur Samuel tarafından kaleme alınan “Some studies in machine learning using the game of checkers” isimli araştırma makalesinde kullanılmıştır. Dama Oyunu ustalarından olan Robert Nealey, geliştirilen oyunu 1962 yılında bir bilgisayara karşı oynamış, ancak oyunu kaybetmiştir. Günümüz şartlarında yapılabilenler ele alındığında bu durum gayet önemsiz gözükse de yapay zekâ alanında çok önemli bir dönüm noktası olmuştur.

Günümüzde makine öğrenmesi, gelişmekte olan veri bilimi alanında çok önemli bir bileşen durumundadır. Büyük verinin anlaşılır ve kullanılabilir hale gelmesi için çeşitli istatistiksel yöntemler ile algoritmalar kullanılarak sınıflamalar yapmak veya öngörülerde bulunmak üzere makineler eğitilmektedir. Veri madenciliği çalışmalarında temel bağlantıları ortaya çıkarmak için makine öğrenmesi yöntemleri kullanılmaktadır.

#### 2.3.3.1. Makine öğrenmesi nasıl çalışır?

Makine öğrenmesi çalışmasındaki aşamalar üç ana başlıkta toplanır.

**Karar Süreci:** Tahmin ya da sınıflandırma yapmak ihtiyacı için kullanılır. Etiketlenmiş veya etiketlenmemiş girdi verileri ile model beslenerek veride var olabilecek herhangi bir kalıpla ilgili olarak tahmin üretilecektir.

**Hata:** Modelden elde edilen tahmini değerlendirebilmek için kullanılır. Var olan örnekler arasında, hata işlevi, modelin verdiği sonucun doğruluğunu kıyaslamak için de kullanılabilir.

**Model Optimizasyonu Süreci:** Modelin verdiği sonuç, eğitim verisinde yer alan veri noktaları ile daha uyumluysa, ağırlıklar düzenlenerek çelişki azaltılabilir. Bu işlemleri tekrarlayarak sürecin en iyileştirilmesi için bir doğruluk eşiğine ulaşana kadar eşit ağırlıklar model içerisinde özerk olarak güncellenir.

### **2.3.3.2. Makine Öğrenmesinde Uygulanan Yöntemler**

#### **2.3.3.2.1. Gözetimli öğrenme**

Etiketli veriler kullanarak eğitilen sınıflama ve tahmin görevlerinde kullanılan yönteme verilen isimdir. Veriler ile model beslendikçe, ağırlıklar uygun hale gelene dek model tarafından düzenlenir. Bu sayede aşırı uyum ya da yetersiz uyumdan kaçınılması sağlanabilir. Lojistik Regresyon, Destek Vektörü Makinesi (SVM: Destek Vektör Makinesi), Rastgele Orman (RF: Random Forest), Yapay Sinir Ağları gibi yöntemler gözetimle öğrenmede sıkça kullanılan yöntemlere örnek olarak verilebilir.

#### **2.3.3.2.2. Gözetimsiz Öğrenme**

Etiketsiz verileri kümelemek için kullanır. Bu yöntem “denetimsiz makine öğrenmesi” olarak da bilinir. Yöntemin barındırdığı algoritmalar sayesinde, insanın müdahale etmesine gerek kalmadan verideki saklı kalıpları bulabilir veya gurupları keşfedebilirler. Yöntem kabiliyetleri sayesinde keşif amaçlı veri analizi, müşteri gruplama ve görüntü tanıma konularında ideal bir araç olarak kullanılmaktadır. Yöntem bir modeldeki özellik sayısını azaltmak için bu alandaki çalışmalarda kullanılmaktadır. Özellik sayısını azaltmak için kullanılan yöntemlerden biri olarak “Birincil Bileşen Analizi (PCA)” verilebilir. Gözetimsiz öğrenme alanında yapılan çalışmalarda kullanılan yöntemler K-Ortalamalar Kümesi, Olasılıklı Kümeleme ve Yapay Sinir Ağı yöntemleri olarak sıralanabilir.

#### **2.3.3.2.3. Yarı Gözetimli Öğrenme**

“Gözetimli öğrenme” ile “gözetimsiz öğrenme” türlerinin özelliklerini barındıran bir yöntem olarak tanımlanabilir. Yöntem eğitim aşamasında, büyük ölçekteki etiketsiz veri kümesinden sınıflandırma yaparken, küçük ölçekteki etiketli veri kümesini kullanarak ayırıştırma yapar. Yarı gözetimli öğrenme, gözetimli öğrenme yönteminde kullanılabilecek büyüklükte etiketli veriye sahip olamama durumunda önemli bir çözüm aracı olarak ortaya çıkmaktadır.


#### **2.3.3.2.4. Pekiştirmeli makine öğrenmesi**

Pekiştirmeli makine öğrenmesi, “davranışsal makine öğrenmesi” modeli olarak kullanılır. Bu yöntem “gözetimli öğrenme” ile benzerlikler gösterir. Ancak bu model basit

veriler kullanılarak eğitilemez. Model, deneme yoluyla elde edilen olumlu veya olumsuz sonuçlardan öğrenir. Belirli bir sorun için en iyi yöntemi geliştirmek istediğimizde, model elde edilen başarılı sonuçlar dizisi kullanılarak eğitilir.

#### 2.3.4. Makine Öğrenmesi, Yapay Sinir Ağları ve Derin Öğrenme

“Derin öğrenme” terimi ile “makine öğrenmesi” terimi yanlış bir şekilde birbirlerinin yerine kullanılmaktadır. Bu nedenle bu iki terimin arasındaki farklılıkları açıkça belirtmek önemli bir konu haline gelmiştir. Yapay sinir ağları ile derin öğrenme gibi makine öğrenmesi de yapay zekânın alt alanlarından bir tanesidir. Ancak bu terimler aşağıdaki şekilde (Şekil 2.7) gösterildiği gibi birbirlerini kapsamaktadır. *Yapay sinir ağları*, *makine öğrenmesinin* bir alt alanı olduğu gibi, *derin öğrenme* de *yapay sinir ağlarının* alt alanıdır. (<https://www.ibm.com/tr-tr/cloud/learn/machine-learning> Erişim Tarihi: 05/02/2022”)



Şekil 2.7. Yapay Zekanın Katmanları

Derin öğrenme alanı ile makine öğrenmesi alanının farklılaştığı durum, yöntemlerde kullanılan algoritmaların öğrenme yöntemleridir. Derin öğrenme, öğrenirken özellik ayıklama kısmını önemli ölçüde otomatik olarak gerçekleştirir ve bu konudaki insan müdahalesini ortadan kaldırır. Bu sayede çok kısa sürede büyük ölçekteki veri kümelerinin kullanılmasına imkân verirler. Lex Fridman, 2019 yılında Massachusetts Teknoloji Enstitüsü'nde verdiği bir derste *derin öğrenme* kavramını açıklarken “ölçeklenebilir makine öğrenmesi” olarak ifade etmiştir (<https://www.ibm.com/cloud/learn/machine-learning>, Erişim tarihi: 24/08/2021”). Klasik makine öğrenmesi alanında, modelin öğrenebilmesi için insan müdahalesine çok gereklidir. Bu nedenle,

genellikle öğrenmenin iyileştirilmesi amacı ile uzmanlar veriyi daha fazla yapılandırarak girdi olarak kullanılmasını sağlamaktadırlar.

Derin öğrenme algoritmaları etiketli veri kümelerinden faydalanabilir; ancak derin öğrenme algoritmaları etiketli veri kümelerine mutlak ihtiyaç duymazlar. Derin öğrenme, yapılandırılmamış verilerin ham halini de (görseller veya metin ifadeler) işleyebilir ve kategorize edebilir. Aynı zamanda bu kategorileri birbirinden ayıran özellik kümelerini de otomatik olarak belirleyebilir. Son yıllarda derin öğrenme ve yapay sinir ağları; zaman serisi, tahmin yapma, bilgisayar görüşü, konuşma tanıma ve özellikle doğal dil işleme gibi alanlarda kaydedilen ilerlemenin hızlanmasının sebebi olarak görülmektedir.

*Yapay sinir ağları* (YSA), bir dizi algoritma kullanarak insanın bilişini taklit etmeye çalışan yapılardır.

Temel düzeyde, bir sinir ağı dört ana bileşenden oluşur:


- Girdiler,
- Ağırlıklar,
- Önyargı veya eşik,
- Çıktı.

Aşağıdaki gibi formüle edilebilir:

$$\sum_{i=1}^m w_i x_i + bias = w_1 x_1 + w_2 x_2 + w_3 x_3 + bias \quad (3.4.1)$$

(“<https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>, Erişim tarihi: 24/08/2021”)

IBM’in tanımına göre: “Üçten fazla gizli katmandan oluşan girişleri ve çıkışı bünyesinde barındıran yapay sinir ağı, derin öğrenme algoritması veya derin yapay sinir ağı olarak tanımlanabilir. Sadece iki veya üç katmana sahip olan yapay sinir ağı, temel bir yapay sinir ağıdır.” (“<https://www.ibm.com/cloud/learn/machine-learning>, Erişim tarihi: 24/08/2021”).



Şekil 2.8. Yapay Sinir Ağı ile Derin Sinir Ağlarının Yapısal Farkları

## 2.4. ELEKTRİK PİYASALARINDA TAHMİNLEME LİTERATÜRÜ

Bu bölümde özetlenen makaleler 2006 ve 2020 yılları arasında elektrik fiyat tahmini alanında makine öğrenmesi ve yapay zekâ konularında yayınlanmış ve online olarak erişilen akademik makalelerden seçilmiştir. İncelenen makalelerin konusu ve bulguları kısaca özetlenmiştir.

Amjady (2006), makalesinde, elektrik piyasaları için yeni bir bulanık sinir ağına dayalı verimli bir fiyat tahmini yöntemi önermiştir. Önerdiği sinir ağı, yeni bir hiper-kübik eğitim mekanizması ile katmanlar arası ve ileri beslemeli mimariye sahiptir. Bu yöntemle gün öncesi elektrik piyasaları için saatlik piyasa takas fiyatlarını tahmin etmeye çalışmıştır. Yazar, bulanık mantık ve etkili bir öğrenme algoritmasının birleşimi ile fiyat serilerinin durağan olmayan davranışları ve aykırı değerleri için uygun bir model sunduğunu iddia etmiştir. Çalışmada İspanya elektrik piyasası verileri kullanılmıştır. Önerdiği yöntem ile varılan sonuç ise “ARIMA zaman serileri, dalgacık-ARIMA, MLP ve RBF sinir ağları gibi diğer fiyat tahmin tekniklerine göre daha doğru sonuçlar sağlayabileceği” sonucuna varmıştır.

Azevedo ve Vale (2006) çalışmada, sinir ağları ve kümeleme tekniklerine dayanan yeni bir fiyat tahmini yöntemi sunmaktadır. Yazarlar sunulan yöntemin avantajını “Tarihsel verilerin olasılık dağılımı hakkında herhangi bir istatistiksel varsayımda bulunmaması” olarak belirtmişlerdir. Bu yöntemin özünü ise istatistiksel bilgilerin geçmiş verilerden elde etmesi olarak sunmuşlardır. Yazarlar elektrik fiyatlarının ortaya koyduğu örüntülerin ve istatistiksel bilgilerin yapay sinir ağları tarafından özümzenmesini zorlaştırdığını ifade etmişlerdir. K-Means yöntemini kullanarak bu sorunu çözmeye çalışmışlardır. Kümeleme teknikleri ile bir grup yapısının var olup olmadığını araştırmışlar ve her var olan grubu belirli bir sinir ağını eğitmek için kullanmışlardır. Bu yöntemle, her bir sinir ağının geçmiş veriler tarafından taşınan bilgileri daha verimli bir şekilde öğrendiğini iddia etmişlerdir. Sundukları yöntemle, “ileriye doğru birkaç programlama dönemi için elektrik piyasası fiyat aralığını tahmin etmek için kullanılabileceği” konusunu vurgulamışlardır. Yaptıkları testlerin sonuçları, önümüzdeki birkaç dönem için piyasa fiyat aralığını tahmin ettiklerinde bir miktar tahmin gücünün bir miktar azaldığını, ancak yine de iyi sonuçlar aldıklarını ileri sürmüşlerdir.

“Tahmindeki doğruluğun zaman ufku ile azaldığını,  $t$  döneminin önceki fiyatı,  $t-1$  dönemi için fiyat aralığı tahmininin bir fonksiyonu olması” ile açıklamışlardır. Bu yöntemle iyi sonuçlar elde edebilmek için geçmiş verilerin sürekli ve dinamik olarak güncellenmesinin önemini vurgulamışlardır. Makalede önerdikleri yöntemin, aynı zamanda piyasa fiyat aralığını, seçilen bir güven seviyesi ile, tahmin etme avantajına da sahip olduğunu belirtmişlerdir. Bu yöntemin, risk yönetimi için de çok yararlı olduğu görüşünü belirtmişlerdir. Çalışmada yazarlar, İspanya pazarı için istenen tarihteki fiyat tahmininde iyi sonuçlar elde edildiği sonucuna varmışlardır.

Georgilakis (2006) çalışmasında, deregüle edilmiş elektrik piyasalarında piyasa takas fiyatlarının oynak olduğunu ifade etmiştir. Georgilakis, piyasa katılımcıları tarafından kullanılan teklif verme stratejilerinin karmaşık olmasına bağlı olarak çeşitli belirsizliklerin karmaşık bir şekilde etkileşime girdiğini ve bu nedenle piyasa takas fiyat tahminin zor bir konu olduğuna dikkat çekmiştir. Ayrıca araştırmacı, makalesinde 24 gün öncesi piyasa takas fiyatlarını tahmin etmek için uyarlamalı olarak eğitilmiş bir sinir ağı önermiştir. Yazar modeli açıklarken “Uyarlanabilir eğitim mekanizması, yapay sinir ağının hatalarından ders almasına ve yeni veriler elde edildikçe mimarisini ayarlayarak çıktısını düzeltmesine olanak tanıyan bir geri bildirim süreci içermektedir” şeklinde tanımlamışlardır.

Huisman vd. (2007), gün öncesi piyasalarda saatlik elektrik fiyatlarının özelliklerine odaklanmışlardır. Çalışmada verilen gün öncesi elektrik dağıtım teklifleri ertesi gün tüm saatler için eş zamanlı olarak sunulmaktadır. Yazarlar saatlik elektrik fiyat dinamiklerinin bir zaman serisi gibi davranmadığını belirtmişlerdir. Verinin zaman serisi yerine, 24 saatlik kesitler halinde fiyatların günden güne değişen bir panel olarak ele alınması gerektiğini söylemişlerdir. Makale ile gün öncesi piyasalarda saatlik elektrik fiyatları için bir panel modeli tanımlayarak, bu panelin özelliklerini incelemişlerdir. Çalışmada saatlik elektrik fiyatlarının, saatlik özgül ortalama-dönüş sergilediğini ve saatlik belirli bir ortalama fiyat seviyesi civarında dalgalandığını tespit etmişlerdir. Daha önemli bir sonuç olarak, saatler arasında blok yapılı kesitsel bir korelasyonun varlığını tespit etmişlerdir.

Mandal vd. (2007), PJM piyasasında gün öncesi elektrik fiyatını tahmin etmek için benzer günler (SD) yöntemine dayalı bir yapay sinir ağı (YSA) modeli tekniğini önermişlerdir. Önerilen modelin üstünlüğünü göstermek ve YSA'nın eğitimi ve test edilmesi için PJM'den elde edilen halka açık veriler kullanılmıştır. Araştırmada zaman,

yük ve geçmiş fiyat verileri kullanılmıştır. Çalışmada elektrik fiyat tahminini etkileyen faktörler tartışılmıştır. Yazarlar makalede önerdikleri YSA modeli ile tahmin performansının benzer günler yönteminden elde ettikleri tahminlerle karşılaştırma sunmuşlardır. Yük ve elektrik fiyatı arasında 0.6744 korelasyon katsayısı ve PJM verileri için, yeteri derecede düşük değere sahip günlük ve haftalık ortalama mutlak yüzde hatası (MAPE) ve 7 \$ / MWh'den düşük tahmini ortalama kare hatası (FMSE) elde etmişlerdir. Makaledeki bulgular benzer günler yöntemine dayanarak önerilen YSA modelinin, Pennsylvania-New Jersey-Maryland (PJM) piyasasının yerel marjinal fiyatını (LMP) verimli ve doğru bir şekilde tahmin edebildiğini göstermiştir.

Catalão vd. (2007), kısa vadeli elektrik fiyatlarını tahmin etmek için bir sinir ağı yaklaşımını önermişlerdir. Makalede Levenberg-Marquardt algoritması ile eğitilen, üç katmanlı ileri beslemeli bir sinir ağını, sonraki hafta elektrik fiyatlarını tahmin etmek için kullanmışlardır. Yazarlar, önerilen sinir ağı yaklaşımı ile ulaşılan fiyat tahminlerinin doğruluğunu değerlendirmiş ve sonuçları, İspanya ve Kaliforniya elektrik piyasaları verilerine göre yorumlamışlardır.

Pino vd. (2008), sonraki gün saatlik tahminlerini İspanya elektrik üretim piyasası için hesaplamışlardır. Bu tahminleri yapabilmek için kullandıkları metodolojiyi, birçok tahmin uygulamasında başarıyla kullanılan yapay sinir ağlarına dayandırmışlardır. Çalışmada, elektrik fiyatının, tahmin edilecek olan günün, türüne göre farklı davranışlar göstermesi nedeniyle hafta sonları, tatiller ve iş günleri göz önüne alınarak tahminlerini yapmışlardır. Yazarlar enerji fiyatı zaman serilerinin genellikle çok fazla veriden oluştuğunu ve yeterli düzeyde bir tahmine ulaşmak için az sayıda veri varsa sorun olabileceğini dile getirmişlerdir. Yazarlar, yapay sinir ağları için ART tipi sinir ağı kullanarak çok katmanlı algılayıcı (MLP) eğitim örnekleri için seçim yapmaya dayanan bir eğitim yöntemi önermektedirler; MLP eğitildikten sonra, nihai tahminleri hesaplamak için kullanılmıştır. Makalede elde edilen tahminler, Box-Jenkins ARIMA tahmin yönteminden elde edilenlerle karşılaştırılmıştır. Çalışmada, “Sinir ağlarının özellikle hafta sonları ve tatillerde ARIMA modellerinden daha iyi performans gösterdiği” sonucuna varmışlardır. Yazarlar ayrıca her iki yöntemde de hafta sonları, tatil ve iş günleri için ortalama mutlak hata yüzdesi açısından iyi tahminler elde edildiğini belirtmişlerdir. Hızlı ve tutarlı tahminlere ihtiyaç duyan elektrik üretim piyasasında yer alan firmaların bu çalışmanın sonuçlarından faydalanabilecekleri vurgulamıştır.

Weron ve Misiorek (2008), makalelerinde, açık artırma tipi elektrik piyasalarında kısa vadeli (gün öncesi) spot fiyat tahmini için 12 farklı zaman serisi yönteminin doğruluğunu karşılaştırmışlardır. Ele aldıkları yöntemleri, standart otoregresyon (AR) modelleri ve bunların uzantıları olan spike önceden işlenmiş, eşik ve yarı parametrik otoregresyonlar; parametrik olmayan yeniliklere sahip AR modelleri, ortalama geri dönen atlama geçişleri olarak sıralamışlardır. Kullanılan 12 yöntem için Kaliforniya piyasası saatlik spot fiyatlarını içeren bir zaman serisi ile İskandinav pazarı saatlik spot fiyatlarını ve hava sıcaklık verilerini kullanmışlar ve sonuçları bu verilere göre karşılaştırmışlardır. Sistem yüküne sahip modellerin eksojen değişken olarak genelde sadece fiyat modellerinden daha iyi performans gösterdiğine, ancak hava sıcaklığının eksojen değişken olarak kullanıldığı durumlarda her zaman geçerli olmadığı sonucuna varmışlardır. Ayrıca yazarlar, çalışmalarının bir diğer önemli sonucu olarak, yarı parametrik modellerin genellikle diğer modellere göre daha iyi nokta ve aralık tahmini verdiğini belirtmişlerdir. Daha da önemlisi kullandıkları yöntemlerin çeşitli piyasa koşullarında iyi bir performans gösterme potansiyeline sahip olduğunu vurgulamışlardır.


Härdle ve Trück (2010) çalışmalarında, saatlik elektrik fiyatlarının davranışı için dinamik yarı parametrik faktör modellerinin (DSFM) kullanılmasını önermişlerdir. Önerdikleri üç faktörlü modelin, saatlik elektrik fiyatlarındaki değişimi yüksek bir oranda açıklayabildiğini belirtmişlerdir. Yazarlar, bu makale ile kullandıkları analizlerin piyasanın özelliklerine ilişkin iç görüler sağladığını da iddia etmişlerdir.

Neupane vd. (2012), sonraki 24 saatlik elektrik fiyatlarını tahmin etmek için Yapay Sinir Ağı (YSA) modeli kullanmışlardır. Girdileri, geçmiş elektrik fiyatı verileri, hava durumu verileri ve takvim verileri gibi bilgilerden türetilen bir özellik havuzundan seçmişlerdir. Bu çalışmalarında, geçmiş fiyat verilerinden elde edilen özellikleri kullanan bir YSA modeli önermişlerdir. Yaptıkları testlerde, PSF (*Pattern Sequence-Based Forecasting: Kalıp Sırasına Dayalı Tahmin*) adı verilen bir yöntemle karşılaştırmalı analizler gerçekleştirmişlerdir. Yöntem sayesinde modelin daha iyi tahmin doğruluğu sunduğunu gözlemlemişlerdir. Yazarlar makalelerinde hem 2006 hem de 2011–2012 verileri üzerinde analizler yapmışlardır. Bu analizler sonucunda modelin gürültü varlığında doğru ve sağlam tahmin yapabildiğini sonucuna da ulaşmışlardır.

Fanone vd. (2013), 2009'da Almanya'da yürürlüğe giren Yenilenebilir Enerji Yasası (EEG) sonucunda, yenilenebilir kaynaklardan üretilen elektrik payının, elektrik

piyasasında önemli ölçüde arttığını vurgulamışlardır. Bu durumu, “EEG, negatif fiyat olasılığını artırarak gün içi elektrik fiyatlarının dinamiklerini önemli ölçüde etkilemektedir” şeklinde yorumlamışlardır. Bu araştırmada, Almanya piyasasındaki gün içi elektrik fiyatlarını modellemek için Gauss dışı bir süreci önermişler ve model için bir tahmin prosedürü sunmuşlardır. Yazarlar, kullandıkları modelin aşırı pozitif ve negatif artışlar oluşturabileceğini vurgulamışlardır. Yapılan simülasyon ile modelin, verilerdeki özellikleri yakalama yeteneğini göstermeye çalışmışlardır.

Weron (2014) çalışmasında, 2014 yılına gelene kadar olan son 15 yılda elektrik fiyat tahmini (EPF: Energy Price Forecasting) için değişen derecelerde başarıyla çeşitli yöntemler ve fikirlerin denendiğini vurgulamıştır. Weron bu inceleme makalesinde, “mevcut çözümlerin karmaşıklığını, güçlü ve zayıf yönlerini ve tahmin araçlarının sunduğu veya karşılaşılabilecek fırsatları ve tehditleri açıklamayı” amaçladığını belirtmiştir. Ayrıca EPF'nin önümüzdeki on yıl içinde gideceği veya gidebileceği yönler hakkında değerlendirmeler yapmıştır. Weron, bu çalışmasında, özellikle aynı veri setlerini, aynı sağlam hata değerlendirme prosedürlerini ve bir modelin diğerine göre daha iyi performans göstermesinin önemini vurgulayan ve istatistiksel testini de içeren objektif karşılaştırmalı EPF çalışmalarına duyulan ihtiyacı da dile getirmiştir. Weron'un bu çalışmasının aldığı atıf sayısı 15.05.2021 tarihi itibarı ile 1076'dır ve alan yazınında alınan en yüksek atıf sayısıdır.



Şekil 2.9 Elektrik Fiyat Tahmini ve Modelleme Yaklaşımları (Rafał Weron, 2014)

Kölmek ve Navruz (2015), Türkiye elektrik piyasası için yaptıkları bu çalışmada yapay sinir ağları üzerinden fiyat modellemesi ve uygun yapay sinir ağı konfigürasyonlarının

tespiti konusunu ele almışlardır. Yazarlar bu çalışmalarının, Türkiye spot piyasasında fiyat tahmin etmek için uygulanan ilk sinir ağı yaklaşımı olduğunu vurgulamışlardır. Araştırmacılar, farklı ağ topolojileri ve parametreleri seçtikten sonra, modele en uygun konfigürasyonu bulmak için ağ performansını hata oranlarına göre gözlemlemişlerdir. Ayrıca çalışmada, ele alınan ARIMA ve YSA modellerinin sonuçları da karşılaştırılmıştır. Doğrusal olmayan bir tahmin yöntemi ve ideal olarak oluşturulmuş bir sinir ağını öneren çalışma ile oluşturulan sinir ağı modelinin zaman serisi modeline göre daha iyi sonuçlar verdiğini gösterilmişlerdir. Çalışmada sunulan YSA modelinin, fiyat sınıflandırması ve ani artışların da kullanılmasıyla daha da geliştirilebilir olduğunu ve SDAP tahminine de uygulanabileceğini dile getirmişlerdir.

(Abedinia, Amjady, Shafie-Khah, & Catalão, 2015) Abedinia vd. bu çalışmalarında, fiyat verilerinin gelecekteki değerlerini tahmin etmek için CNN (Evrişimli Sinir Ağı) tabanlı bir tahmin motoru önermişlerdir. Araştırmacılara göre “CNN tabanlı tahmin motoru, CNN'nin ağırlıklarını optimize etmek için yeni bir eğitim mekanizması kullanılmıştır”. Sözü edilen mekanizma, kimyasal reaksiyon optimizasyon algoritmasının değiştirilmiş bir versiyonudur ve CNN'e yüksek öğrenme yeteneği veren verimli bir stokastik arama yöntemine dayanmaktadır. Çalışmada önerilen fiyat tahmini stratejisi, PJM ve İspanya piyasa verileri ile test edilmiş ve elde edilen sonuçlar, diğer birkaç tahmin yönteminden elde edilen sonuçlarla kapsamlı bir şekilde karşılaştırılmıştır. Bu karşılaştırmalardan elde edilen sonuca göre, önerilen stratejinin etkinliğinin yüksek olduğu iddia edilmiştir.

Raviv vd. (2015), ayrıştırılmış saatlik fiyatların, North Pool piyasasındaki günlük ortalama fiyat için yararlı tahmin bilgileri içerdiğini göstermişlerdir. Araştırmacılar, günlük ortalama elektrik fiyatının bir sonraki gün için elektrik fiyatını temsil eden önemli bir referans olduğunu belirtmişlerdir. Saatlik fiyatların tam paneli için kullanılacak çok değişkenli modellerin, günlük ortalama fiyatın tek değişkenli modellerine göre önemli ölçüde daha iyi performans gösterdiğini vurgulamışlardır. RMSE'de (Kök Ortalama Kare Hata) %16'ya varan iyileştirmeler elde edildiğini kaydetmişlerdir. Çalışmadaki bu başarıya erişebilmek için büyük özen gösterilmesi gerektiğinin altını da ayrıca çizmişlerdir. Yazarlar, farklı saatlik fiyatlar arasındaki ilişkilerden yararlanmak için zengin ve çok değişkenli modellere ihtiyaç duyulduğunu ve boyut küçültme teknikleri,

daralma ve tahmin kombinasyonları kullanılarak aşırı uyum riskinin azaltılması gerektiğini de vurgulamışlardır.

Feijoo vd. (2016) yaptıkları bu çalışma ile değişen talep karşısında hızlı ve güvenilir tahminler üreten bir modeli (K-SVR) sunduklarını belirtmişlerdir. Önerdikleri bu model ile literatürdeki en iyi bilinen modeller kullanarak karşılaştırılabilir tahmin doğruluğu sağlayabileceklerini vurgulamışlardır. “K-SVR önemli ölçüde azaltılmış hesaplama süresi ihtiyaç duymaktadır” bilgisini de özellikle vurgulamışlardır. Yazarlar bu çalışmada hesaplama süresini kısaltmak için, literatürdeki modeller tarafından yaygın olarak kullanılan özellik seçme işlemini kullanmamışlardır. Çalışmada K-SVR modelini, 2005–2006, 2011–2012 ve 2014–2015 dönemlere ait PJM piyasa verileri kullanarak test edilmiştir. 2006 yılına ait veriler, mevcut modellerin performansını ölçmek ve karşılaştırma yapmak için kullanılmıştır. Araştırmacılar, 2012 ve 2015 verileri ise gelecekteki çalışmalarda kıyaslama yapılabilme amacı ile kullandıklarını belirtmişlerdir.

Wang vd. (2016), yaptıkları çalışmada DCANN ve Güncellenmiş DCANN’ü gün öncesi piyasasında elektrik fiyatını tahmin etmek için önermişlerdir. Bu model, denetimli ve denetimsiz öğrenmenin karma bir sistemidir. Araştırmacılar, çalışmalarında BPANN, RBFN, SVM ve LSSVM'den farklı olarak, kötü örnekleri silme, geliştirme ve öğrenme için kaliteli girdileri arama fikrini yaratıcı bir şekilde uygulamışlardır. Sayısal sonuçlar ile, önerilen modelin sadece gerçek elektrik fiyatına (normal veya yüksek volatilité) çok yakın sonuçlar vermediğini aynı zamanda kıyas ölçütlerine göre (h-step-forecast için, 10 saatten az olmak kaydıyla) etkili bir araç olduğunu da belirtmişlerdir.

Gökgöz ve Filiz (2016) tarafından sunulan makalede, Türkiye'deki gün öncesi elektrik piyasası için yapay sinir ağı modelleri çalışılmıştır. Yazarlar bu çalışmada “Gradyan inişi, momentumlu gradyan inişi, Broydan, Fletcher, Goldfarb ve Shanno (BFGS) ve Levenberg-Marquardt algoritmasının farklı sayıda nöron ve transfer fonksiyonların kullanılmasıyla, 400 farklı model” oluşturduklarını belirtmişlerdir. Farklı modellerin performansları Ortalama Mutlak Yüzde (MAPE) değerlerine göre karşılaştırmışlardır ve en başarılı modelin MAPE değerini %9.76 olarak vermişlerdir.

Keles vd. (2016), elektrik fiyat tahmininde, yapay sinir ağlarına (YSA) dayalı bir metodolojiyi elektrik fiyatını tahmin için eserlerinde ele almışlardır. Yazarlar çalışmada yapay sinir ağı tahmin modellerinin performansının uygun girdi parametre setlerine bağlı

olduğunu belirtmişler ve elektrik fiyatları üzerinde fark edilebilir bir etkisi olduğunu belirttikleri temel verilerin seçimi ve hazırlanmasına odaklanmışlardır. Bu çalışmada farklı küme algoritmalarını kullanarak ve aynı zamanda önceden seçilmiş modellerin sonuçlarının farklı parametre ayarlarıyla elde edilen sonuçlarını karşılaştırmışlardır. Gün öncesi elektrik fiyatlarını etkileyen ve iyi performans gösteren YSA konfigürasyonu için optimal girdi parametrelerinin belirledikten sonra geliştirdikleri YSA modelini uygulamışlardır. Araştırmacılar, elde ettikleri sonuçlara göre, uyguladıkları bu model ile elektrik fiyatını ideal şekilde tahmin ettiklerini ifade etmişlerdir.

Manner vd. (2016), Avustralya elektrik piyasasında yüksek frekanslı spot fiyatları kullanarak aşırı fiyatların oluşumunu tahmin etme problemini ele almışlar. Özellikle bu tür sözde artışların farklı piyasalarda meydana gelmesini de değerlendirmişlerdir. Yazarların yaklaşımına göre çok değişkenli ve ikili sonuçlar için yeni bir dinamik modele ihtiyaç duyulmaktadır. Ayrıca modeli, ortaya çıkan yeniliklerin ortak biçimde dağıtımı için, bir kopula gösterimi kullanarak oluşturmuşlardır. Sundukları modelin standart çok değişkenli probit modeline göre avantajını da dile getirmişlerdir. Bu avantajlardan ilk olarak modelin hata terimleri arasında doğrusal olmayan bağımlılığa izin verdiğini, ikinci olarak, “gizli hataların dağılımının serbestçe seçilebildiğini”, üçüncü olarak, oluşturdukları modelin hesaplama yükünün büyük ölçüde azaltılabildiğini, bunun sonucunda da daha yüksek boyutlarda örnekler için tahmin yapılmasının mümkün olduğunu belirtmişlerdir. Modellerini, birbirine bağlı faaliyet gösteren dört farklı piyasada meydana gelen yarım saatlik elektrik fiyatlarındaki ani artışlara uygulamışlardır. Uyguladıkları çok değişkenli modelin, tek değişkenli modellere göre üstün bir uyum sağladığını ve ani artış olasılıkları için daha iyi tahminler ürettiğini göstermişlerdir. Ayrıca, çalışma ile piyasalar arasındaki yayılma dinamiklerinin kanıtını ortaya koymuşlardır.

Uğurlu vd. (2016), katıldıkları konferansta esas olarak mevsimsel etkiye odaklanmışlar ve elektrik fiyat tahmini ile ilgili bu tebliği sunmuşlardır. Çalışmalarında, elektrik fiyatlarının ayın günleri, hafta içi ve sonu, aylar, yıllar, tatiller ve saatlere göre büyük değişiklik gösterdiğini belirtmişlerdir. Yazarlar tebliğin ana amaçlarından bir tanesinin elektrik fiyatları hakkında bazı tanımlayıcı bilgiler vermek olduğu, diğerinin ise pre-whitening yöntemi olarak Uni-ANOVA sürecini kullanarak deterministik mevsimselliği ortadan kaldırılması olduğunu vurgulamışlardır. Elde ettikleri bulgulara

göre, Uni-ANOVA sürecinin deterministik mevsimselliği önemli ölçüde ortadan kaldırdığını, ancak stokastik mevsimselliğin hala elektrik fiyatı verilerini etkilediğini ifade etmişlerdir.

Rafiei vd. (2016), saatlik elektrik fiyatı tahmini için olasılıklı bir yaklaşım sunmuşlardır. Bu çalışmada yöntem olarak, yordayıcı modelin belirsizliğini, belirsizlik faktörü olarak ele almışlardır. Önyüklem tekniğinin belirsizliğini modelde bu amaçla kullanılmışlardır. Günlük tahminlerde hızlı ve hesaplama maliyetinin düşük olması için yüksek doğruluk ve hıza sahip geliştirilmiş bir öğrenme yöntemi uygulamışlardır. Sunulan bu yeni öğrenme yöntemi, gelişmiş dalgacık sinir ağları için kullanılan geliştirilmiş aşırı öğrenme yaklaşımına dayanmaktadır. Çalışmada yazarlar önerilen modelin performans etkinliğini, Ontario ve Avustralya elektrik piyasalarının verileri üzerinde test ederek doğrulamışlardır.

Gollou ve Ghadimi (2017), yayınladıkları bu makale ile elektrik fiyatlarının gün öncesi tahmini için yeni bir özellik seçme ve tahmin motoru sunduklarını ifade etmişlerdir. Çalışmada yazarlar önerilen yöntemin veri özelliklerine dayalı olarak bir dizi aday özelliği seçmişler ve daha sonra sistematik bir şekilde uygulanan korelasyon ve örnek tabanlı özellik seçim yöntemleri ile bu aday özelliklerin bir alt kümesini seçen iki aşamalı bir yaklaşım kullanmışlardır. Çalışmada uyguladıkları tahmin yöntemini ise dalgacık dönüşümü ile hibrit tahmin yönteminin bir kombinasyonu olan yapay sinir ağı ve bir optimizasyon algoritması olarak tanımlamışlardır. Önerdikleri yöntemi PJM elektrik piyasası verileri kullanılarak incelenmişler ve makalenin yazıldığı tarihteki en son fiyat tahmin yöntemlerinden bazıları ile karşılaştırmışlardır. Bu karşılaştırmalar sonucunda, önerdikleri stratejinin etkin olduğu sonucuna varmışlardır.

Gao vd. (2017), yaptıkları bu çalışmada Birleşik Krallık elektrik piyasasında sekiz hafta ilerideki üç adıma kadar fiyat tahminlerine uygulanan otoregresif entegre hareketli ortalama (ARIMA) ve yapay sinir ağı (YSA) modellerini kullanmışlardır. Araştırmacılar, 22 Mart - 14 Temmuz 2010 tarihleri arasındaki yarım saatlik İngiltere referans fiyat verisini kullanmışlardır. Tahminlerini de sekiz haftalık kayan eğitim penceresinden (sliding training window) elde etmişlerdir. Farklı MA ve AR gecikme seviyelerine sahip ARIMA modeli ile değişik gecikme ve nöron yapısına sahip ANN modeli oluşturmuşlar ve fiyat tahminlerinin RMSE değerleri üzerinden karşılaştırmışlardır. Elde edilen

sonuçlara göre ARIMA (4.1.2) modelinin ANN (20 nöron, 4 gecikme) modeline göre kalıcılık üzerinde daha büyük bir gelişme sağladığını belirtmişlerdir.

Neupane vd. (2017), bu çalışma ile “toplam talep yanıt etkisine karşı esneklik gösteren ve dinamik bir ortamda paydaşlara oldukça doğru tahmin edilen elektrik fiyatları sağlayan, sağlam bir fiyat tahmin mekanizması” sunduklarını iddia etmişlerdir. Bu çalışmada, bir grup farklı algoritmanın günün her saati için fiyat oluşmadan bir saat önceden tahmin etmek için kullanılan topluluk tahmin modelini önermişlerdir. Her saat için uygun algoritmayı seçmek amacı ile Sabit Ağırlık Yöntemi (FWM) ve Değişken Ağırlık Yöntemini (VWM) farklı stratejiler olarak kullanmışlardır. Çalışmada buna ek olarak, geçmiş elektrik fiyatı, hava durumu ve takvim verilerinden elde edilen bir özellik havuzu oluşturmuşlar ve bu havuzdan bir dizi özelliği seçerek kullanmışlardır. Yazarlar önerdikleri topluluk modelinin, ARIMA (Autoregressive Integrated Moving Average), PSF (*Pattern Sequence-Based Forecasting: Kalıp Sırasına Dayalı Tahmin*) yöntemlerine göre New York, Avustralya, İspanya elektrik piyasaları verileri ile sadece Yapay Sinir Ağları (YSA) kullanarak yaptıkları çalışmadan daha iyi tahminler verdiği sonucuna varmışlardır.

Singh vd. (2017), çalışmalarında önerdikleri klasik yapay sinir ağı modelinin sınırlamalarının üstesinden gelmek için, Avustralya elektrik piyasasının kısa vadeli elektrik fiyatının tahmininde genelleştirilmiş nöron modeli kullanılmıştır. Çalışmada, özelliklerin ön işlemesi, düşük ve yüksek frekans bileşenlerinin daha iyi gösterimi için dalgacık dönüşümü yöntemi kullanılarak gerçekleştirilmiştir. Genelleştirilmiş nöron modelinin serbest parametreleri, modelin genelleme yeteneğini ve etkinliğini artırmak için ortam adaptasyon yöntemi algoritmasını kullanarak ayarlanmışlardır. Simülasyon sonuçlarına göre, araştırmacılar, IEAM optimize edilmiş genelleştirilmiş nöron modelinin izleme performansının, parametreleri optimize etmeden genelleştirilmiş nöron modelinden daha iyi performans sergilediğini tespit etmişlerdir.

Gholipour Khajeh vd. (2018), doğrusal olmayan, zamana bağlı olarak değişen ve son derece karmaşık bir yapısı olan elektrik fiyatının kısa vadeli tahmini için yeni bir tahmin stratejisi önermişlerdir. Yazarlar önerdikleri yöntemi, iki aşamalı özellik seçme algoritması ve yinelemeli eğitim algoritması olarak sunmuşlardır. Özellik seçme algoritmasında alakasız ve gereksiz olan özellikleri elemek için iki aşamalı filtre yöntemi kullanmışlardır. Yazarlar yöntemi, “Bu filtreleme algoritması karşılıklı bilgi ve

korelasyon analizine dayanmaktadır. İyileştirilmiş yinelemeli eğitim algoritmasında, birinci sinir ağının çıktısının, ikinci sinir ağının girdilerinden biri olduğu iki sinir ağıdır” olarak tanımlamışlardır. Bu çalışmada önerilen genel strateji PJM elektrik piyasalarına uygulanmış ve eserin yazıldığı dönemde popülerlik kazanan fiyat tahmin yöntemlerinden bazıları ile karşılaştırılmıştır.

Bento vd. (2018) yazdıkları makalede, benzer ve son gün temelli seçim, korelasyon ve dalgacık analizini bir ön işleme aşamasında birleştiren hibrit bir yöntem sunmuşlardır. Yazarlar çalışmalarında geleneksel sinir ağı öğrenme yeteneğini geliştirmek için Bat ve Ölçekli Eşlenik Gradyan Algoritmalarının yanında ileri beslemeli bir sinir ağı kullanmışlardır. Çalışmada vurguladıkları diğer bir özellik ise, yöntemin, optimal bir paradigmanın olmadığı sinir ağı mimarisi ve dalgacık ayrıştırmasına ince ayar yapma kapasitesidir. Eserde İspanya ve PJM elektrik piyasalarına ilişkin tarihsel verilere gün öncesi çerçevesinde sayısal test uygulamışlar ve makalenin yayınlandığı dönemdeki en iyi yöntemlerle karşılaştırmışlardır. Karşılaştırma sonucunda olumlu tahmin sonuçları elde ettiklerini belirtmişlerdir.

Yorulmuş vd. (2018), Türkiye gün içi piyasası için elektrik fiyatlarını doğru tahmin etmeyi amaçlamayan tebliğlerini 4. Global İşletme Araştırmaları Kongresinde sunmuşlardır. Tebliğde Uzun-Kısa Süreli Hafıza (LSTM) ağını kullanan ilk gün içi elektrik fiyatı tahmin çalışması olduğunu belirtmişlerdir. Çalışmada uygulanan LSTM yöntemi, yazarlar tarafından uzun vadeli bağımlılıkları öğrenebilen özel bir sinir ağına dayandırılmıştır. Yazarlar, “LSTM modelini çok adımlı öngörü yaklaşımıyla uygulayarak Ortalama Mutlak Hata (MAE) ve Ortalama Karekök Hata (RMSE) açısından en iyi tahminleri elde etmeyi amaçlanmıştır. Bulgulara göre çalışmada oluşturulan LSTM modeli gecikmeli değerler, elektrik tüketimi ve elektrik üretim değerleri ile daha iyi performans göstermiştir” bilgilerini vermişlerdir. Çalışmada, özellikle fiyatların gecikmeli değerlerinin ve rezerv marjının kullanılması sayesinde başarılı sonuçlar elde edildiği vurgulanmıştır. Yazarlar önerilen yöntemin, sonuç olarak tahminin doğruluğunda iyileştirdiği göstermişlerdir. Ayrıca yazarlar Türkiye Gün İçi Elektrik Piyasası için, zaman serisi yöntemlerinin yanı sıra diğer sinir ağı modelleri kullanan daha fazla araştırmaya ihtiyaç duyulduğunu özellikle vurgulamışlardır.

Chinnathambi vd. (2018), saatlik spot fiyatları tahmin etmede kalan hataları iyileştirmek için Otomatik Gerilimli Entegre Hareketli Ortalama (ARIMA) ile diğer

tahmin modellerinin bir kombinasyonunu kullanan yeni iki aşamalı bir yaklaşım önermişlerdir. Aşama-1'de, gün öncesi fiyat ARIMA kullanılarak tahmin edilmiş ve ardından ortaya çıkan kalıntılar Aşama-2'de başka bir tahmin yöntemini beslenmiştir. Yazarlar önerdikleri yaklaşımı, İber elektrik piyasası veri kümelerini kullanarak uygulanmışlardır. Fiyat, yük ve sıcaklık gibi özellikler için bir haftadan doksan güne kadar değişen süreler için başarılı sonuçlar elde ettiklerini belirtmişlerdir.

Kuo ve Huang çalışmalarında (2018), elektrik fiyatını etkili bir şekilde tahmin etmek için iki Derin Sinir Ağı, bir Evrişimli Sinir Ağı (CNN) ve Uzun Kısa Süreli Bellek (LSTM) kombinasyonuna dayanan bir elektrik fiyatı tahmin sistemi önermişlerdir. Her bir algoritmanın genel performansını karşılaştırmak için Kök Ortalama Kare hatası (RMSE) ve Ortalama Mutlak Hata (MAE) değerlendirme ölçümlerini kullanmışlardır. Yazarlar çalışmanın sonuçları ile ilgili olarak diğer geleneksel makine öğrenimi yöntemleriyle karşılaştırıldığında, önerilen modelin tahmin performansının en iyisi olduğunu söylemişlerdir. Diğer yandan, CNN ve LSTM modellerini birleştirerek, bu hibrit yöntemin pratik bir şekilde elektrik fiyatı tahminine uygulanabileceğini de göstermişlerdir.

Ziel ve Weron (2018), kısa vadeli elektrik fiyatı tahmini (EPF) konusunda uzun süredir devam eden bir soru olan elektrik fiyatı tahmini için optimal model yapısının tek değişkenli mi yoksa çok değişkenli mi olduğunu ele almak için kapsamlı bu çalışmayı yapmışlardır. Çalışmalarında genel olarak tahmine dayalı performansta küçük bir üstünlük olmasına rağmen, çok değişkenli modelleme çerçevesi için kullanılan 12 veri kümesinin tamamında, yılın mevsimleri veya günün saatleri için tek değişkenli yapıdan daha iyi bir sonuç vermediğini göstermişlerdir. Makalede kullanılan her iki modelleme yaklaşımından gelen gelişmiş yapıları veya tahminleri birleştirmenin, tahmin doğruluğunda daha fazla gelişme sağlayabileceğinin altını çizmişlerdir. Ayrıca yazarlar en iyi performansı gösteren yüksek boyutlu modeller için değişken seçimini de analiz etmişler ve böylece daha iyi performans gösteren tahmin modeli tasarımlarını yapılandırmak için yönergeler oluşturmuşlardır.

Jiang ve Hu (2018), bu çalışmalarında, Uzun Kısa Süreli Bellek (LSTM) ağı modelini gün öncesi elektrik fiyatı tahmini (EPF) için, verimli bir yöntem olarak önermişlerdir. Avustralya pazarı Victoria (VIC) bölgesi ve Singapur pazarında, gün öncesi elektrik fiyatını tahmin etmek için LSTM modelini kullanmışlardır. Yazarlar kullandıkları modele

girdi olarak yalnızca geçmiş fiyat verilerini kullanmak yerine tatiller, haftanın günü, günün saati, hava koşulları, petrol fiyatları ve tarihsel fiyat/talep gibi dışsal değişkenleri de dikkate almışlardır. Önerilen model gelecekteki 24 saatlik fiyatları yinelemeli bir şekilde tahmin etmiştir. Makalede yazarlar, VIC ve Singapur pazarları için her sezonun dört haftalık ortalama mutlak yüzde hatasını (MAPE) incelemişlerdir. Önerilen yöntemin etkinliğini, her iki pazardan gerçek piyasa verileri kullanılarak doğrulamışlardır. Yazarlar, sonuç olarak, LSTM ağının makalede sözü geçen dört popüler tahmin yönteminden daha iyi performans gösterdiğini ve VIC pazarı için ortalama günlük MAPE'de %47.3 iyileşme sağladığını bildirilmişlerdir.

Uğurlu vd. (2018), makalelerinde yeni bir teknik olarak, Uzun Kısa Süreli Bellek (LSTM) ile Kapılı Tekrarlayan Birim (GRU) ağlarını elektrik fiyatı tahmini için önermişlerdir. Üç yıllık kayan zaman aralığı ile çeşitli algoritmalar eğitmişlerdir. Elde ettikleri sonuçları Tekrarlayan Sinir Ağı (RNN) ile karşılaştırmışlardır. Sonuç olarak üç katmanlı GRU'ların Türkiye gün öncesi elektrik piyasasında istatistiksel olarak anlamlı bir şekilde diğer tüm sinir ağı yapıları ve en yeni istatistiksel tekniklerden daha iyi performans gösterdiği sonucuna varmışlardır

Kristiansen (2018), Python programlama dili ile geliştirdiği modeli kullanılarak, Nord Pool piyasası için saatlik gün öncesi fiyatlarını birden çok tahmin modelinin performansını tartışmıştır. Yazar makalede Otoregresif modelleri kullanmıştır. Çalışmada kullanılan veri seti Ocak 2004 ile Mayıs 2011 arasında değişmektedir. Modelleri test etmek için çapraz doğrulamalı sıradan en küçük kareler (OLS) regresyon çerçevesi kullanılmıştır. Modelde ayrıca Ridge ve Lasso dahil olmak üzere regresyonlar ve bir Keras sinir ağı modeli de kullanılmıştır. Araştırmacı modelin ortaya koyduğu sonuçları değerlendirdiğinde otoregresif dışsal modellerin iyi performans gösterdiğini ve piyasa oyuncularını için değer katabileceğini ifade etmiştir.

Lago vd. (2018) bu çalışma ile, elektrik fiyatlarını tahmin etmek için yeni bir modelleme çerçevesi önermişlerdir. Yazarlar, bu işlem için birçok öngörücü modelin daha önce önerilmiş olduğunu, ancak derin öğrenme algoritmalarının alanın henüz tam olarak keşfedilmediğini belirtmişlerdir. Çalışmada bu boşluğu doldurmak, elektrik fiyatlarını tahmin etmek için dört farklı derin öğrenme modeli önermişler ve modellerin tahmine dayalı doğrulukta nasıl iyileştirmeler sağladığını göstermişlerdir. Çalışmada elektrik fiyatlarını tahmin etmek için önerilen çok sayıda yöntemin varlığına rağmen,

kapsamlı bir ölçütün hala eksik olduğu belirtilmiştir. Bu durumun üstesinden gelmek için, elektrik fiyatı tahmini için 27 ortak yaklaşımın doğruluğunu karşılaştırıp analiz etmişlerdir. Eserde elde ettikleri karşılaştırma sonuçlarına dayanarak, önerilen derin öğrenme modellerinin diğer yeni yöntemlere göre nasıl daha iyi performans gösterdiğini ve istatistiksel olarak anlamlı sonuçlar elde ettiğini sunmuşlardır. Ulaştıkları sonuçları kullanarak şunları da vurgulamışlardır: (i) makine öğrenimi yöntemleri, genel olarak, istatistiksel modellerden daha iyi bir doğruluk sağlar; (ii) hareketli ortalama terimleri tahmin doğruluğunu geliştirmez; (iii) hibrit modeller, daha basit emsallerinden daha iyi performans göstermez.

Yılmaz (2018), bu çalışmada, Türkiye spot ve vadeli elektirik piyasasındaki fiyatlar ile hacim arasındaki ilişkiyi incelemiş ve Aralık 2011 - Mayıs 2016 ve Haziran 2016 - Aralık 2017 dönemleri için saatlik elektrik fiyatlarının analizini yapmıştır. Çalışmada elde ettiği sonuçlar ile ileriye dönük fiyatların çoğu zaman spot fiyatların belirleyicileri olarak davrandığını ortaya koymuştur. Araştırma sonuçları dikkat çekici bir şekilde, spot ve vadeli fiyatlar arasındaki farkın, yani risk priminin gelişiminin, spot fiyatın elektrik piyasasındaki arbitraj fırsatlarını desteklediğini göstermiştir. Yazar getirilen yeni ticaret algoritmasının risk primi üzerindeki etkisinin önemli olmadığını da elde edilen sonuçlar arasında vurgulamıştır.

Zahid vd. (2019), bu çalışmalarında elektrik yükü ve fiyat tahmini için Derin Öğrenme (DL) ve veri madenciliği tekniklerini ele almışlardır. Çalışmada özellik seçimi ve çıkarımı için XG-Boost (XGB), Karar Ağacı (DT), Yinelemeli Özellik Kaldırma (RFE) ve Rastgele Orman (RF) yöntemlerini kullanılmışlardır. Sınıflandırıcılar olarak Gelişmiş Evrişimli Sinir Ağı (ECNN) ve Gelişmiş Destek Vektörü Regresyonu (ESVR) yöntemlerini uygulamışlardır. Grid Search algoritmasını ise, sınıflandırıcıların performanslarını artırmak için parametrelerinin ayarlanması için kullanmışlardır. Yazarlar ECNN'ye birden fazla katman ekleyerek fazla öğrenme riski azaltılmışlardır. Çalışmada yapılan karşılaştırmalara göre ECNN modelinin CNN'den neredeyse %2 daha iyi doğruluk derecesi elde ettiği ayrıca ESVR modelinin ise SVR'ye göre neredeyse %1 daha iyi doğruluk derecesi elde ettiği sonucuna varmışlardır.

Cerjan vd. (2019) çalışmalarında, fiyat oynaklığı, değişen sayıda girdi parametresi, değişken veri kullanılabilirliği ve çok sayıda parametre ve girdi verisi gibi sorunları ele alan kısa vadeli bir elektrik fiyatı tahmin yöntemi sunmak için bu makaleyi kaleme

almışlardır. Yazarlar, bu eserde önerdikleri modelin herhangi bir pazara uygulanabileceğini belirtmişlerdir; önerilen hibrit iteratif reaktif uyarlamalı (HIRA) yöntem iki aşamadan oluşmaktadır. Analiz aşamasında elektrik fiyatını etkileyen temel parametreler, piyasa gelişimine bağlı olarak belirlenmiştir. Elde edilen parametreler, hibrit bir yöntem kullanılarak fiyat tahmini için veri girdisi olarak kullanılmıştır. Yazarlar önerdikleri modelde HIRA modeli ile büyük veri seti analizi için istatistiksel bir yaklaşım ile sinir ağı araçlarını birleştirmişler ve benzer günleri, geçmiş verilerin korelasyonunu ve fiyat oynaklığını da kullanarak bu parametrelerin tahminin doğruluğu üzerindeki etkilerini incelemişlerdir.

Öksüz ve Uğurlu (2019) yaptıkları çalışmada, Türkiye gün içi piyasasında, gün içi elektrik piyasası fiyatlarını tahmin etmek amacıyla sinir ağları da dahil olmak üzere çeşitli yöntemleri karşılaştırılmıştır. Yazarlar fiyat tahmininde tekrarlayan sinir ağı yönteminin klasik yöntemlere göre daha iyi performans gösterdiğini vurgulamışlardır. Kurguladıkları model ile kapılı tekrarlayan birim ağı mimarisinin (GRNN), 0.978 ortalama mutlak hata, 1.302 kök ortalama kare hata ile en iyi sonuçları elde ettiği sonucuna varmışlardır. Çalışmada ortaya çıkan bir başka sonuç ise, ilgili saatin gün öncesi piyasa fiyatının, gün içi fiyat tahmini için önemli bir özellik olduğu ve gün öncesi fiyatları ile spread değerlerini tahmin etmenin daha verimli bir tahmin yöntemi olduğudur.

Polson ve Sokolov (2020), derin öğrenme (DL) ile aşırı değer teorisini (EVT) birleştirmişlerdir. Bu hibrit yöntemi, çalışmada enerji şebekelerinde gözlemlenen tepe yüklerini tahmin etmek için kullanmışlardır. Yazarlar, gün içi sistem kısıtlamalarından kaynaklanan arz ve talep dalgalanmalar nedeniyle ortaya çıkan ani iniş çıkışlar nedeniyle enerji yüklerini ve fiyatlarını tahmin etmenin zorlayıcı olduğunu belirtmişlerdir. Çalışma ile yük artışlarının davranışını tahmin etmek ve bu etkileri etkin bir şekilde yakalamak için derin bir zamansal aşırı değer modeli önermişlerdir. Düzeltilmiş doğrusal birim aktivasyon işlevlerine sahip Uzun Kısa Süreli Bellek ağının, eğilimleri ve geçici bağımlılıkları yakaladığını belirtmişlerdir. Modele EVT'yi de ekleyerek önceden belirlenmiş bir eşik üzerindeki yüksek düzeyde değişken yük artışlarını yakalamayı hedeflemişlerdir. Yazarlar, çalışmadan elde edilen sonuçlara göre, DL-EVT'nin, fiyatlar ve talep artışlarında gözlemlenen doğrusal olmayan artış ve azalışları yakalamada hem örnek içi hem de örneklem dışı geleneksel yöntemlerden daha iyi performans gösterdiğini belirtmişlerdir.

Tablo 2.1. Çalışmada Kullanılan Makalelerdeki Yöntem ve Metrikler Tablosu

| Yıl  | Yazar/lar                                                                                   | Adı                                                                                                           | Temel Yöntem            | Uygulanan Teknikler                                                                                               | Metrik                          |
|------|---------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------|-------------------------|-------------------------------------------------------------------------------------------------------------------|---------------------------------|
| 2007 | Paras Mandal, Tomonobu Senjyu, Naomitsu Urasakil, Toshihisa Funabashi, Anurag K. Srivastava | “A Novel Approach to Forecast Electricity Price for PJM Using Neural Network and Similar Days Method”         | ANN, RNN                | ANN, SD (Similar Day), RNN                                                                                        | MAPE, MAE, FMSE                 |
| 2018 | Gholipour Khajeh, Akbar Maleki, Marc A. Rosen & Mohammad H. Ahmadi                          | “Electricity price forecasting using neural networks with an improved iterative training algorithm”           | ANN, RNN                | MLP, CNN                                                                                                          | MAPE                            |
| 2016 | Jianzhou Wang, Feng Liu, Yiliao Song, Jing Zhao                                             | “A novel model: Dynamic choice artificial neural network (DCANN) for an electricity price forecasting system” | ANN, RNN                | BPANN, LSSVM, DCANN, Updated DCANN                                                                                | MAPE, AE                        |
| 2018 | Umut Ugurlu, İlkay Oksuz and Oktay Tas                                                      | “Electricity Price Forecasting Using Recurrent Neural Networks”                                               | RNN                     | Markov, Naive, SETAR, SARIMA, CNN, ANN, LSTM, GRU                                                                 | MAE                             |
| 2018 | Hakan Yorulmus, Umut Ugurlu, Oktay Tas                                                      | “A Long Short Term Memory Application On The Turkish Intraday Electricity Price Forecasting”                  | RNN                     | LSTM                                                                                                              | MAE, MAPE, RMSE, R <sup>2</sup> |
| 2018 | Ping-Huan Kuo and Chiou-Jye Huang                                                           | “An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks”                            | ANN, RNN                | SVM (Support Vector Machine), DT (Decision), RF (Random Forest), MLP, CNN, LSTM, EPNet                            | MAE, RMSE                       |
| 2018 | LianLian Jiang and Guoqiang Hu                                                              | “Day-Ahead Price Forecasting for Electricity Market using Long-Short Term Memory Recurrent Neural Network”    | ANN, RNN                | BP-ANN, WT-ANN, PSO-ANFIS, SARIMA, LSTM                                                                           | MAPE                            |
| 2018 | Rita Beigaite, Tomas Krilavicius                                                            | “Electricity Price Forecasting for Nord Pool Data Using Recurrent Neural Networks”                            | RNN, FNN (Feed-Forward) | FFNN (Feed-Forward Neural Network), ERNN (Elman Recurrent Neural Network), JRNN (Jordan Recurrent Neural Network) | MAPE, MAE, RMSE                 |
| 2018 | Jesus Lago, Fjo De Ridder, Bart De Schutter                                                 | “Forecasting spot electricity prices: Deep learning approaches and                                            | DL, DNN, RNN            | AR, DSARIMA, WARIMA, WARIMA-RBF, ARIMA-                                                                           | MAPE, sMAPE                     |

| Yıl  | Yazar/lar                                                                                                                                           | Adı                                                                                                                                        | Temel Yöntem      | Uygulanan Teknikler                                                                                                                      | Metrik                   |
|------|-----------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------|-------------------|------------------------------------------------------------------------------------------------------------------------------------------|--------------------------|
|      |                                                                                                                                                     | empirical comparison of traditional algorithms”                                                                                            |                   | GARCH, DSHW, TBATS, DR, TF, ARX TARX, IHMARX, SNARX, fARX fARX-Lasso, fARX-EN, MLP, RBF, SVR, SOM-SVR, SVR-ARIMA, RF, XGB, LSTM, GRU CNN |                          |
| 2019 | Michael Polson, I Vadim Sokolov                                                                                                                     | “Deep learning for energy markets”                                                                                                         | DNN, RNN, DL, EVT | Fourier + ARIMA, LSTM                                                                                                                    | MSE, RMSE, MAE, MAPE     |
| 2019 | Maheen Zahid, Fahad Ahmed, Nadeem Javaid, Raza Abid Abbasi1, Hafiza Syeda Zainab Kazmi, Atia Javaid, Muhammad Bilal, Mariam Akbar and Manzoor Ilahi | “Electricity Price and Load Forecasting using Enhanced Convolutional Neural Network and Enhanced Support Vector Regression in Smart Grids” | DNN, CNN          | SVR, ESVR, CNN, ECNN                                                                                                                     | MAE, MAPE, MSE, RMSE     |
| 2019 | İlkay Oksuz and Umut Ugurlu                                                                                                                         | “Neural Network Based Model Comparison for Intraday Electricity Price Forecasting”                                                         | DNN, RNN          | Naive, Regression, Lasso, ANN, LSTM, GRU                                                                                                 | MAE and RMSE             |
| 2019 | Yongli Zhu, Renchang Dai, Guangyi Liu, Zhiwei Wang, Songtao Lu                                                                                      | “Power Market Price Forecasting via Deep Learning”                                                                                         | DL, DNN, RNN      | DT, SVM, LSTM                                                                                                                            | RMSE                     |
| 2020 |                                                                                                                                                     | “A Python Application for Hourly Electricity Prices Forecasting Using Neural Networks”                                                     | ANN, DNN          | ANN                                                                                                                                      | MAPE (NeuroLab vs Keras) |


Yukarıda sunulan elektrik fiyat tahmini literatüründe çok sayıda araştırma olsa da Rafał Weron (2014) çalışmasında özel olarak vurguladığı gibi, bu araştırmalar gerek kullanılan veri ve dönem gerek model gerekse pazarın yapısı gibi farklılıklardan dolayı tam olarak birbirleriyle karşılaştırılabilecek yapıda değildir. Sonraki çalışmalarda araştırmacıların bu hususu dikkate alması literatürün gelişimi açısından oldukça önemlidir.

## BÖLÜM 3. YÖNTEM

### 3.1.ÖZ-DİKKAT KATMANLI KODLAYICI-KOD ÇÖZÜCÜ DÖNÜŞTÜRÜCÜ AĞ MODELİ

Bu çalışmadaki modelde, dönüştürücü, kodlayıcı-kod çözücü ve öz-dikkat mekanizmalarının aşağıdaki başlıklarda sayılan tüm özellikleri kullanılmıştır. Çeviri için kullanılan ağların ardışık veri ve zaman serisi alanında gösterdikleri başarı literatürde çokça tartışılmaktadır. Vaswani vd. (2017), dönüştürücü ağ için, yalnızca dikkat mekanizmalarına dayanan bir modeli çeviri görevi için önermişlerdir. Yazarlar yaptıkları çalışma ile, İngilizceden-Fransızcaya çeviri görevinde literatürdeki en iyi sonuçtan 10 kat daha iyi bir sonuca en kısa sürede ulaşmışlardır.

Bu çalışma, Vaswani vd.'nin literatürde oldukça ses getiren söz konusu modellerinin, elektrik fiyat tahmini alanında da benzer başarıya ulaşip ulaşmayacağını araştırmayı amaçlamaktadır. Bu amaç için çalışmada, öz-dikkat katmanlı kodlayıcı-kod çözücü dönüştürücü ağ modeli kullanılmıştır.



Şekil 3.1. Öz-Dikkat Katmanlı Dönüştürücü Kodlayıcı-Kod Çözücü Ağ Modeli (Wu, Green, Ben, & O'Banion, 2020)

### 3.1.DÖNÜŞTÜRÜCÜ (TRANSFORMER)

Dönüştürücü ağlar, tekrarlayan sinir ağlarında (*RNN*) olduğu gibi, çeviri veya metin özetleme görevlerinde ardışık verileri işlemek için tasarlanmıştır. Tekrarlayan sinir ağlarından farklı olarak dönüştürücü ağlar verileri sırasıyla işlemeyebilirler. Dönüştürücü ağlar bunu yapabilmek için çeşitli dikkat mekanizmalarını kullanırlar. Örnek verecek olursak; giriş verisi cümle ise, ağın cümlelerin başlangıcını cümle bitmeden işlemesine gerek yoktur. Ağ bunu yapmak yerine, cümledeki her bir kelimeye göre cümleye anlam veren bir bağlamı tanımlar. Bunun sonucu olarak dönüştürücü ağlar, tekrarlayan sinir ağlarına göre daha fazla paralelleşebilirler. Parallelleşmenin sonucu olarak dönüştürücü modelinin eğitim sürelerini diğer ağlara göre çok kısadır.

Dönüştürücü ağ, 2017'de Google Brain'deki bir ekip tarafından geliştirilmiş ve kullanıma sunulmuştur. Kullanıma sunulduğu tarihten bu yana doğal dil işleme alanında daha fazla tercih edilen bir ağ modeli haline geldi. Günümüze geldiğimizde bu ağlar doğal dil işleme alanında *RNN* ile *LSTM* ağlarının hızla yerini almaya başlamıştır.

Dönüştürücü ağında işlemlerin daha fazla paralelleştirilebilmesinin sonucu olarak, mevcut teknolojiler ile mümkün olandan daha büyük veri kümeleri üzerinde eğitime olanak sağlayabilmektedir. Son birkaç yılda bu özelliği nedeni ile zaman serisi problemleri üzerine uygulama için deneysel çalışmalar yapılmaya başlanmıştır. Ancak elektrik fiyatı tahmini literatüründe bu açılmanın yapıldığı süre içerisinde herhangi bir çalışma yapılmamıştır. Bu çalışmada 2017-2021 yılları arasındaki veri setimizle yaptığımız denemelerde eğitime süresi 4-5 dakika arasında olmuştur. Bu süre çalışmada kullandığımız diğer modellere göre dramatik derecede bir farktır.

### 3.2. ÖZ-DİKKAT MEKANİZMASI

Dikkat mekanizmaları, girdi dizisi boyunca herhangi bir geçmiş noktada işlemden çekilmesine imkân tanır. Dikkat katmanının, modelde önceden gerçekleşen tüm durumlara erişme yeteneği vardır. Katman bunları öğrenilmiş bir alaka düzeyine göre tartar ve uzaktaki işaretçiler hakkında bilgiler sağlar.

Çok uzun dizileri içeren görevler için hesaplama performansını iyileştirmek için, öz-dikkat katmanı, ilgili çıktı konumu etrafında ortalananmış girdi dizisinde yalnızca sabit boyutundaki bir veriyi dikkate alarak sınırlandırılabilir.

Dikkat mekanizmaları, RNN'lere eklendiğinde, ağıın performansı artırmaktadır. Dönüştürücü mimarisinin gelişimi sayesinde, RNN de elde edilen performans artışının sıralı tekrarlayan veri işlemenin sonucu olmadığı, dikkat mekanizmalarının kendi içinde güçlü bir mekanizma olduğu ortaya koymuştur. Dönüştürücü ağlar, genelde yalın dikkat mekanizmaları kullanırlar. Mekanizma tüm işaretçileri (tokens) aynı anda işleyebilir, bunu ardışık katmanlar arasındaki dikkat ağırlıklarını hesaplayarak yapar. Bu hesaplama mekanizmanın yapısı gereği tüm işaretçiler (tokens) için paralel olarak hesaplanabilir, bunun sonucu olarak da eğitim hızı artar.

### **3.3.KODLAYICI-KOD ÇÖZÜCÜ MİMARİSİ**

Orijinal dönüştürücü modelin de kodlayıcı-kod çözücü mimarisi kullanılmıştır. Kodlayıcı, girdiden birbiri ardına yinelenen kodlama katmanları oluşturur. Kod çözücü, kodlayıcının çıktısı üzerinde birbiri ardına kod çözme katmanları oluşturur.

Kodlayıcı katmanlarının genel işlevi, girdilerdeki bölümlerin birbiriyle olan ilişkilerine ait bilgiler içeren kodlamalar oluşturmaktır. Kod çözücü katmanların işlevi ise, kodlayıcıdan aldıkları kodlamaları tam tersine çevirip bir çıktı dizisi oluşturmaktır. Her kodlayıcı ve kod çözücü katman bu karmaşık işlemi başarabilmek için bir dikkat mekanizmasından faydalanır.

Dikkat mekanizması her bir girdi için, diğer girdiler ile olan alaka düzeyini tartar ve çıktıyı üretmek için bunlardan yararlanır. Her kod çözücü katmanı, önceki kod çözücülerin çıktılarını veri olarak kullanan, ayrı bir dikkat mekanizmasına daha sahiptir.


### **3.4.KAPILI TEKRARLAYAN ÜNİTE (GATED RECURRENT UNIT - GRU)**

GRU ağları hücre durumunu kullanmaz, bilgiyi aktarmak için gizli durum dan faydalanır. GRU ağlarının LSTM den farkı yalnızca üç kapı içermesidir. GRU ağlarında hücre durumu korumamaktadır. LSTM’de dahili hücre durumunda tutulan bilgi, GRU’nun gizli durumunda tutulur. Geçmişten taşınan birleştirilmiş bilgiler gizli durum aracılığı ile bir sonraki katmana gönderilir. (Cho ve diğerleri 2014).

GRU hücresindeki ilk iki kapı, sıfırlama kapısı ve güncelleme kapısıdır. Kapılar RNN ağlarında genellikle yaşanan kaybolan gradyan probleminin önlenmesine de yardımcı

**Güncelleme Kapısı:** Modelin geçmiş zaman adımlarından taşınan bilgilerin ne kadarının sonraki hücreye aktarılacağına karar vermede yardımcı olur. Bu model açısından büyük bir güçtür, çünkü model geçmişten gelen tüm bilgileri kopyalamaya ve kaybolan gradyan sorunu riskini ortadan kaldırmaya da karar verebilir.

**Geçerli Bellek Kapısı:** Bu kapı, doğrusallığı bir miktar bozmak için sıfırlama kapısına dahil edilmiştir. Geçerli bellek kapısını sıfırlama kapısına dahil etmenin bir başka nedeni ise geçmiş zaman adımlarından taşınan bilgilerin, ileriye aktarılan mevcut bilgiler üzerindeki etkisini azaltmak içindir (Cho vd. 2014).



Şekil 3.2. GRU Hücresi Şematik Gösterimi

GRU ağlarının müzik modelleme, konuşma tanıma ve doğal dil işleme gibi belirli görevlerdeki performansının, LSTM ağlarının performansına benzer sonuçlar verdiği

yapılan çalışmalarda tespit edilmiştir (Su ve Kuo, 2019). Ayrıca GRU ağları ile bir diğer tespit ise küçük veri kümelerinde daha iyi performans sergiledikleri olmuştur (Gruber ve Jockisch 2020).

### **3.5. YIĞILMIŞ SİNİR AĞLARI**

Yığılmış ağ mekanizmasının çalışma mantığı, ağdaki bir gizli katmanının çıktısının sonra gelen gizli katmanın girdisi olarak beslenmesidir. Bu sayede derin ağlarda yığılmış (stacked) katmanlar elde edilir (Graves vd., 2013). Uygulamada yığılmış katmanların kullanılmasını asıl nedeni bir dizideki verilerin temsilinin normal ağlara göre çok daha iyi oluşturulması ve daha tutarlı tahminlerin yapılabilmesidir (LeCun vd., 2015).

### **3.6. EVRİŞİMLİ SİNİR AĞLARI (CNN)**

Evrışimli sinir ağları bilginin, giriş düğümünden başlayarak gizli düğümler aracılığı ile çıkış düğümlerine doğru döngü veya döngü olmadan sadece ileri yönde hareket ettiği ileri beslemeli özel bir sinir ağı türüdür. Bu tür ileri beslemeli ağlar genelde örüntü tanıma için kullanılır. İleri beslemeli bir ağ olarak CNN, derin katmanlar ile daha karmaşık modeller oluşturarak verilerdeki kalıpları anlamada çok iyi sonuç verir. Evrışimli sinir ağları tipik olarak evrışimsel ve havuzlama katmanlarından oluşur. Evrışim katmanının rolü, önceki katmandaki özelliklerin yerel bağlantılarını tespit etmek iken, havuz katmanının rolü, anlamsal olarak benzer özellikleri bir araya getirmektir. Evrışimli sinir ağları, zaman serisi problemleri, regresyon, görüntü sınıflandırma, bölümleme, nesne algılama vb. gibi yüksek boyutlu dışbükey olmayan (non-convex) sorunları çözmek için birçok paralel ve kademeli evrışimli filtreden yararlanır. Her katmandaki ağırlıkların paylaşımı ve boyutlardaki sınır nedeni ile geleneksel ağlara göre daha az parametre ve özellik ile daha kısa sürede daha iyi öğrenme performansı sağlar.

Tek boyutlu bir yapıya sahip olan veri kümeleri, tek boyutlu bir evrışimsel sinir ağı (1D CNN) kullanılarak işlenebilir. 1D CNN, genel özellik setinin daha kısa (sabit uzunluklu) bölümlerinden özellikler türetmek beklendiğinde ve özelliğin parça içindeki konumunun önemli olmadığı durumlarda oldukça etkilidir. 1D CNN, Doğal Dil İşleme (NLP) veya zaman serisi problemi gibi vektörleştirilmiş verilerin yer aldığı problemlere kolaylıkla uygulanabilir. 1D CNN, veri setindeki her bir özelliği karakterize eden

vektörlerin bölümlerinde var olan kalıpları veya ilişkileri tanımlayarak sonraki katmanlara aktarmak için kullanılmaktadır. Tanımlanan türetilmiş özellikler, kalıplar ve ilişkiler sonrasında LSTM gibi yeni bir sınıflandırıcıya tam bağlantılı bir katman ile gönderilir. CNN'ler genelde belirli bir sınıflandırıcı için özellik çıkarma katmanları olarak kullanılmaktadırlar. Bunun sonucu olarakta modellerde özellik sıralaması ve seçimi için ekstra bir çalışma ihtiyacını ortadan kaldırır. Yoğun katmanlar tahmin görevini yerine getirirken ReLU, modelde yaşanabilecek kaybolan ve patlayan gradyan sorunlarını azaltmaya yardımcı olmaktadır.

### 3.7. TEKRARLAYAN SİNİR AĞLARI (RNN: *RECURRENT NEURAL NETWORK*)

Sıradan bir sinir ağı ile tekrarlayan sinir ağı arasındaki temel fark gizli katman birimleri arasındaki yatay bağlantı eklemesidir. Bir ağırlık matrisi aracılığıyla, elde edilen değerler, sonraki birimlere aktarılır. Bu sayede sinir ağı, zaman serisi ile ilgili verilerin işlenmesi için gerekli olan hafıza fonksiyonuna sahip olmuş olur. Tekrarlayan sinir ağının denklemi aşağıda verilmiştir.


$$a^{(t)} = b + Wh^{(t-1)} + Ux^{(t)} \quad (3.7.1)$$

$$h^{(t)} = \tanh(a^{(t)}) \quad (3.7.2)$$

$$o^{(t)} = c + Vh^{(t)} \quad (3.7.3)$$

$$y^{(t)} = \text{softmax}(o^{(t)}) \quad (3.7.4)$$

Ancak, tekrarlayan sinir ağlarında, bilgi depolamak ve çıktı vermek için uzun süreli bir bellek birimi olmadığından “gradyan kaybolması” sorunu ile başa çıkamamaktadır. RNN mimarisinin yapısından dolayı uzun bir zaman aralığındaki bir dizi bilgisi ile uğraşırken girdinin çıktı üzerindeki etkisi ya azalır ya da üstel olarak artar. Bunun sonucu olarak ağ katmanı parametrelerinin güncellenemez hale gelebilir. Bu nedenle RNN (*Recurrent Neural Network*) zaman serisi problemlerinde genel olarak daha kısa bir zamanda dizisi için kullanılmaktadır. Aşağıdaki şekilde RNN hücre yapısı için bir gösterim verilmiştir (Şekil 3.3).



Şekil 3.3. RNN Hücresi Şematik Gösterimi


(<https://colah.github.io/posts/2015-08-Understanding-LSTMs/> Erişim Tarihi: 01/05/2022 )

### 3.8. UZUN KISA SÜRELİ HAFIZA (LSTM)

Uzun kısa süreli hafıza ağı, ileri beslemeli ağlardan farklı olarak geri bildirimi de kullanan ve girdinin bölümlerini “öğrenebilen” ve öğrendiği bölümleri tahmin yapmak için kullanabilen özel bir tekrarlayan sinir ağı türüdür (RNN). LSTM ağları özellikle sıralı verileri işlemek için tasarlanmıştır. Bu sayede konuşma tanıma ve makine çevirisi gibi çeşitli alanlarda popüler olmuştur. Aynı zamanda zaman serisi problemlerinde sıklıkla kullanılan ve başarılı sonuçlar veren bir ağ yapısıdır. Tüm düğümleri tamamen birbirine bağlayan geleneksel yapay sinir ağlarından veya düğümleri en küçük birimden tamamına kadar katman katman keşfeden CNN ağlarından farklı olarak, LSTM ağları ilişkiyi bağlam içinde keşfetmek için durum nöronlarını kullanır. Geleneksel RNN ağlarının kaybolan gradyanlarla ilgili önemli bir sorunu vardır. Bu nedenle geleneksel RNN'ler, uzun süreli belleğe de sahip olmadıkları için yalnızca dizideki en son bilgilere dayanarak tahminlerde bulunabilirler. LSTM, kaybolan gradyan problemini çözer ve bu nedenle daha uzun dizileri (uzun süreli bellek) işleyebilir. LSTM, bir dizi özellikten bağlamsal bilgiyi anlayabilen tekrarlayan bir sinir ağıdır. Bir geçit işlevi yardımıyla gizli durum vektörüne bilgi ekleme veya çıkarma yeteneğine sahiptir, böylece önemli bilgileri gizli katman vektörlerinde tutabilmektedir.

LSTM üç kapı işlevinden oluşur. Bu kapılar: unutma kapısı, giriş kapısı ve çıkış kapısıdır. Unutma kapısı,  $C_t$  hesaplama sürecinde  $C_{t-1}$ 'de tutulan bilgi miktarını kontrol

etmek için kullanılır. LSTM grafiksel olarak aşağıdaki şekildeki gibi gösterilebilir (Şekil 3.4):



Şekil 3.4. LSTM Hücre Yapısı Şematik Gösterimi

(<https://colah.github.io/posts/2015-08-Understanding-LSTMs/> Erişim Tarihi: 01/05/2022 )

LSTM Formülasyonu:

$$f_t = \sigma_g(W_f x x_t + U_f x h_{t-1} + b_f) \quad (3.8.1)$$

$$i_t = \sigma_g(W_i x x_t + U_i x h_{t-1} + b_i) \quad (3.8.2)$$

$$o_t = \sigma_g(W_o x x_t + U_o x h_{t-1} + b_o) \quad (3.8.3)$$

$$c_t^l = \sigma_c(W_c x x_t + U_c x h_{t-1} + b_c) \quad (3.8.4)$$

$$c_t = f_t \cdot c_{t-1} + x_t \cdot c_t^l \quad (3.8.5)$$

$$h_t = o_t \cdot \sigma_c(c_t) \quad (3.8.6)$$

### 3.1.YOĞUN SİNİR AĞLARI (DENSE-DNN)

DNN, birden fazla katmana sahip olan bir sinir ağıdır. DNN ağında, bir katmandaki nöronların her biri, önceki katmanda bulunan tüm nöronlardan bir girdi alır diğer bir söyleyişle tüm nöronlar arasında bağlar vardır. Bu katmanlar yoğun katmanlar olarak adlandırılır ve ağdaki gizli katmanları oluşturur. Bu tür sinir ağları, aynı zamanda Çok Katmanlı Algılayıcı (MLP: Multi Layer Perceptron) olarak da bilinirler. Bu ağlar girdi katmanı, girdi hakkında karar veya tahminde bulunan çıktı katmanı ve aradaki herhangi bir sayıda gizli katmandan oluşur. Model genellikle bir dizi girdi-çıkı çifti üzerinde eğitilir. Sonuçta girdiler ve çıktılar arasındaki korelasyonu (veya bağımlılıkları)

öğrenirler. Modelin temel birimi olan algılayıcı, girdi ağırlıklarını kullanarak doğrusal bir kombinasyon oluşturur ve girdiye dayalı olarak bir çıktı üretir. Çıktı doğrusal olmayan bir etkinleştirme işlevinden geçirilir:

$$y = \vartheta(\sum_1^n (w_i x_i + b)) = \vartheta(W^T X + b) \quad (3.5.1)$$


Yukarıdaki gösterimde  $W$  ağırlık vektörünü,  $X$  girdi vektörünü,  $b$  önyargıyı ve  $\vartheta$  ise doğrusal olmayan aktivasyon fonksiyonunu temsil eder.

Sigmoid veya hiperbolik tanjant işlevleri, veriler içindeki karmaşık ilişkileri haritalama yetenekleri nedeniyle geçmişte tipik olarak kullanılan doğrusal olmayan etkinleştirme işlevleridir. Ancak, bu iki doğrusal olmayan etkinleştirme işlevi, kaybolan gradyan sorunu nedeniyle çok katmanlı ağlarda iyi performans vermemektedir.

Doğrultulmuş lineer aktivasyon fonksiyonu ReL ve ReL varyantları, günümüzde yoğun sinir ağlarının eğitiminde en çok tercih edilen fonksiyon olarak karşımıza çıkmaktadır. ReL aktivasyonunu kullanan bir ağdaki nöronlara ReLU (Rectified Linear Active Units) adı verilmiştir. ReL,  $f(x) = \max(0, x)$  parçalı doğrusal bir fonksiyondur. Eğer giriş değeri pozitif ise doğrudan çıktıyı, negatif ise sıfır değerini döndürür. ReLU, kaybolan gradyan sorununun üstesinden gelir ve modellerin daha hızlı öğrenmesini ve daha iyi performans göstermesini sağlar. Bu nedenle, DNN ve CNN ağlarını geliştirirken varsayılan etkinleştirme işlevi olarak kullanılır.

### 3.2. ÇİFT YÖNLÜ TEKRARLAYAN SINİR AĞLARI

Çift yönlü tekrarlayan sinir ağlarının temel işlevi, normal bir tekrarlayan sinir ağının nöronlarını, ileri ve geriye doğru iki yöne bölmesidir. Bu iki durumun çıkışları, zıt yön durumlarının girişlerine bağlı değildir. Tekrarlayan sinir ağları ve çift yönlü tekrarlayan sinir ağlarının genel yapısı aşağıdaki şekilde verilmiştir (Şekil 3.5). Zaman boyutunda ilerideki bilgilerin dahil edilmesi için gecikmeler kullanan standart tekrarlayan sinir ağlarının aksine çift yönlü tekrarlayan sinir ağları zaman boyutunda iki yöndeki bilgileri de kullanırlar. Başka bir söyleyişle iki yönlü tekrarlayan sinir ağları mevcut zamana göre geçmiş ve gelecek bilgilerini girdi olarak kullanılabilir. (Schuster vd., 1997)



(a) Tek Yönlü

(b) Çift Yönlü

Şekil 3.5. Tek ve Çift Yönlü Tekrarlayan Sinir Ağları

Çift yönlü tekrarlayan sinir ağları, dizinin her bir ögesini, ögenin geçmiş ve gelecekteki bağlamlarına dayalı olarak tahmin etmek veya etiketlemek için sonlu bir dizi kullanır. Bu mekanizmada iki ayrı tekrarlayan sinir ağı diziyi soldan sağa, sağdan sola doğru işleyerek çıktıları birleştirir ve tahmin için kullanılacak sinyallere dönüştürülür. Bu teknik özellikle LSTM RNN'ler ile birleştirildiğinde tahminlerde gelişme sağladığı kanıtlanmıştır (Graves ve Schmidhuber, 2005) (Thireou ve Reczko, 2007).

### 3.3. CNN-LSTM

Bu çalışmada tekniklerin her birinin benzersiz özelliklerinden yararlanmak için farklı derin öğrenme teknikleri olan CNN ve LSTM hibrit olarak kullanılmıştır. CNN'nin maksimum havuzlama katmanı sayesinde veri boyutu azaltarak çıktıyı alt örnekler ayırıp aşırı uyum problemi önlenmiştir. LSTM katmanını ise CNN katmanları tarafından kodlanan özellikler içinde mevcut olabilecek uzun menzilli bağımlılıkları yakalamak için kullandık. Bağlam ve bağımlılık bilgileriyle birlikte LSTM katmanı tarafından çıkarılan vektörleri sonraki adımda tek bir birimden oluşan sigmoid aktifleştirilmiş çıktı katmanına ve tahminden önce daha fazla işleme tabi tutulması için yoğun katmanlar eklenmiştir.

### 3.4. CNN-GRU

Bu çalışmada tekniklerin her birinin benzersiz özelliklerinden yararlanmak için farklı derin öğrenme teknikleri olan CNN ve LSTM hibrit olarak kullanılmıştır. CNN'nin maksimum havuzlama katmanı sayesinde veri boyutu azaltarak çıktıyı alt örnekler ayırıp aşırı uyum problemi önlenmiştir. LSTM katmanını ise CNN katmanları tarafından kodlanan özellikler içinde mevcut olabilecek uzun menzilli bağımlılıkları yakalamak için

kullandık. Baęlam ve baęımlılık bilgileriyle birlikte LSTM katmanı tarafından ıkarılan vektörleri sonraki adımda tek bir birimden oluşan sigmoid aktifleřtirilmiř ıktı katmanına ve tahminden önce daha fazla iřleme tabi tutulması için yoęun katmanlar eklenmiřtir.



## BÖLÜM 4. ARAŞTIRMA METODOLOJİSİ

### 4.1. KULLANILAN VERİ

Bu çalışmada, Türkiye EPIAŞ Şeffaflık Platformunda yer alan GÖP (Gün Öncesi Piyasası) PTF, Üretim ve Tüketim verileri kullanılmıştır. Kullandığımız veriler “27/01/2017 00:00” ile “31/12/2021 23:00” tarihleri için saatlik verileri kapsamaktadır. Bu aralığın seçilmesinin sebebi; ilk defa 2016 yılında faaliyete geçen Şeffaflık platformundaki geçmiş verilerdeki veri kirliliğinden kurtulmaktır. Platformdan belirtilen tarih-zaman aralığı için indirilen veride 43824 satır ve 23 özellik (feature) bulunmaktadır.

#### 4.1.1. Veri Erişim Linkleri:

- Gün Öncesi Piyasası:  
<https://seffaflik.epias.com.tr/transparency/piyasalar/gop/ptf.xhtml>
- Üretim:  
<https://seffaflik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml>
- Tüketim:  
<https://seffaflik.epias.com.tr/transparency/tuketim/gerceklesen-tuketim/gercek-zamanli-tuketim.xhtml>

Elde edilen ham veri setinde aşağıda verilen 23 adet özellik bulunmaktadır.

#### a) Fiyat verisi:


Tarih\_Saat, PTF\_(TL/MWh), PTF\_(USD/MWh), PTF\_(EUR/MWh)

#### b) Üretim verisi:

Tarih\_Saat, Toplam\_(MWh), Doğal\_Gaz, Barajlı, Linyit, Akarsu, İthal\_Kömür, Rüzgâr, Güneş, Fuel\_Oil, Jeotermal, Asfaltit\_Kömür, Taş\_Kömür, Biyokütle, Nafta, LNG, Uluslararası


#### c) Tüketim verisi:

Tarih\_Saat, Tüketim\_Miktarı\_(MWh)



Şekil 4.1 Veriye Genel Bakış


Yıllara göre USD bazında fiyat, Toplam Üretim ve Tüketim miktarları yukarıdaki şekilde görselleştirilmiştir (Şekil 4.1). USD bazında fiyat grafiği incelendiğinde 2020 yılının ikinci yarısına kadar genelde fiyat verisinin maksimum ve minimum sınırlarının genelde sabit olarak oynak olduğu gözlenmiştir. Ancak 2020 yılının ikinci yarısından itibaren fiyatın artmaya başladığı ve zaman zaman ani yüksek oynaklıkların var olduğu gözlemlenmektedir. Üretim ve Tüketim verilerinin benzer bir yapı gösterdiği söylenebilir. Pandemi döneminin başında birkaç ay boyunca üretim ve tüketim miktarlarının görece olarak düşük olduğu gözlenmektedir. Açılma ve kapanma dönemlerinde farklı oranda artış ve azalışlar olduğu da grafikten anlaşılmaktadır. Aşağıdaki şekil incelendiğinde 14 günlük Fiyat verisinin saat bazında oynak olduğu anlaşılmaktadır (Şekil 4.2). Bunun yanında üretim ve tüketim verilerinin benzer bir kalıp izlediği söylenebilir.



Şekil 4.2. Verilere Yakın Bakış (17 Ocak 2021'den İtibaren)

#### 4.1.2. Türetilmiş Özellikler:

Korpihalkola'ya, (2019) göre dalgalı spot elektrik fiyatı döngüsel yapıdadır. 24 saatlik dönemde fiyat için net bir döngü, hafta sonlarında fiyatın daha düşük olduğu haftalık bir döngü ve kış zamanlarında fiyatın daha yüksek olduğu yıllık bir döngü vardır. Zamanı tanımlamak için sadece bir sayı kullanmak, zamanın döngüsel yapısını makine öğrenimi modeline aktaramaz (Korpihalkola, 2019). Makine öğrenimi modelimiz 23:55 ve 00:05 arasındaki farkın 10 dakika olduğunu görmez, 23 saat 50 dakika olduğunu düşünecektir (London, 2016). Örneğin, 23:00 ve 00:00 saatleri 00:00 ve 12:00 saatlerine göre zaman olarak daha yakındır, ancak makine öğrenimi modeli öyle olmadığını düşünecektir, çünkü sayısal olarak 0 ile 23 arasındaki mesafe 0 ile 12 arasındaki mesafeden daha büyüktür. Bu sorunu aşabilmenin bir yolu zaman verilerine sinüs ve kosinüs dönüşümleri uygulanmasıdır (London, 2016). Bu bilgilerden yola çıkarak çalışmada Tarih\_Saat özelliğinden 5 adet yeni özellik oluşturulmuştur (hours, days, day\_of\_week, month, year). Oluşturulan bu yeni zaman özelliklerine sinüs ve kosinüs dönüşümleri uygulanmıştır (cos\_hour, sin\_hour, cos\_day, sin\_day, cos\_day\_of\_week, sin\_day\_of\_week, cos\_month, sin\_month, cos\_year, sin\_year). Bu dönüşüm sayesinde modelin tahmin gücünü artıracak şekilde sinyaller elde edilmiştir (Şekil 4.3, Şekil 4.4). Bu bilgi, çalışmada oluşturulan tüm modeller için önemli bir ilişki göstergesi olarak kullanılmıştır. Zaman bilgisi için konumsal kodlamayı sağlamak için: Tarih\_Saat özelliği dört öge olarak temsil edildi saat, gün ve hafta ve ay.




Şekil 4.3. Gün için Cosinüs Sinus Eğrisi

$$t_{sin} = \sin\left(\frac{2\pi x}{y}\right) \quad (4.1.2.1)$$

$$t_{cos} = \cos\left(\frac{2\pi x}{y}\right) \quad (4.1.2.2)$$

$x$  = zaman ,  $y$  = dönem uzunluğu




Şekil 4.4 Saat özelliği için Sin/Cos Dönüşümü

Bunun dışında Üretim ve Tüketim gerçekleşmelerindeki farkı alarak Üretim\_Tüketim\_Farkı olarak isimlendirilmiş yeni bir özellik daha oluşturulmuştur. Üretim tüketim arasındaki farkın etkisini gösteren bu değişken sayesinde üretim ve tüketim verileri arasında güçlü bir ilişki sağlamak hedeflenmiştir.

#### 4.1.3. Fast Fourier Dönüşümü

Piyasa takas fiyatındaki önemli frekansları anlamak için bu özelliğe Fast Fourier Dönüşümü uygulanmıştır. Bu işlem sonucunda Piyasa Takas Fiyatının "1/yıl" ve "1/gün"e yakın frekanslardaki bariz tepe noktaları görselleştirilmiştir.



Şekil 4.5. Verideki Tepe Noktaları Yıllık ve Günlük

#### 4.1.4. Özellik Mühendisliği:

Özellik mühendisliği (Feature Engineering) uygulamasından sonra aşağıdaki 13 özellik modeller kullanılmak üzere seçilmiştir.

a) **Seçilen Fiyat Özellikleri:**

Tarih\_Saat, PTF\_(USD/MWh)

b) **Seçilen Üretim Özelliği:**

Toplam\_(MWh)

c) **Seçilen Tüketim Özelliği:**

Tüketim\_Miktarı\_(MWh)

d) **Seçilen Türetilmiş Özellikler (9 adet):**

Üretim\_Tüketim\_Farkı, cos\_hour, sin\_hour, cos\_day, sin\_day, cos\_day\_of\_week, sin\_day\_of\_week, cos\_month, sin\_month.

Tablo 4.1. Modellerde Kullanılan Özellikler Hakkında Genel Bilgi

| #  | Özellik              | Satır Sayısı | Veri Tipi      |
|----|----------------------|--------------|----------------|
| 1  | Zaman                | 43824        | datetime64[ns] |
| 2  | PTF_(USD/MWh)        | 43824        | float64        |
| 3  | Toplam_(MWh)         | 43824        | float64        |
| 4  | Uretim_Tüketim_Farki | 43824        | float64        |
| 5  | COVID-19             | 43824        | int64          |
| 6  | sin_Hours            | 43824        | float64        |
| 7  | cos_Hours            | 43824        | float64        |
| 8  | sin_Days             | 43824        | float64        |
| 9  | cos_Days             | 43824        | float64        |
| 10 | sin_Days_of_Week     | 43824        | float64        |
| 11 | cos_Days_of_Week     | 43824        | float64        |
| 12 | sin_Months           | 43824        | float64        |
| 13 | cos_Months           | 43824        | float64        |

Tablo 4.2. Veri İçerisindeki Önemli Dönemler


| Dönem                 | Kukla İndeks | Verideki Satır Sayısı<br>Gün<br>(Her gün 24 saatlik veri) | Dönemler İçin Tarih Aralığı |
|-----------------------|--------------|-----------------------------------------------------------|-----------------------------|
| Normal Dönem          | 1            | 28008 satır<br>1167 gün                                   | 01.01.2017 – 12.03.2020     |
| Pandemi ve Kapanmalar | 2            | 11400 satır<br>475 gün                                    | 13.03.2020 – 30.06.2021     |
| Kontrollü Normalleşme | 1            | 4415 satır<br>184 gün                                     | 01.07.2021 – 31.12.2021     |

#### 4.1.5. Veri Normalleştirme

Sinir ağını eğitmeye başlamadan önce, özellikleri ölçeklendirmek modelin tahmin gücü açısından önemlidir. Bu nedenle çalışmada fiyat, üretim, tüketim ve fark verilerine normalleştirme uygulanmıştır. Çalışmada normalleştirme uygulaması için Python Sklearn kütüphanesinde yer alan MinMaxScaler() fonksiyonunu kullanılmıştır.

#### 4.1.6. Veri Pencereleme:

Ölçeklendirilmiş veriden sabit uzunlukta kayan zaman penceresi yaklaşımını kullanarak modellerde kullanacak nihai veri oluşturulmuştur (Şekil 4.6).



Şekil 4.6. Veri Pencereleme

Verinin %70'ni Eğitim, %20'sini doğrulama ve %10'nunu test setleri için ayrılmıştır. Çalışmada veri bölümlemenin gerekçeleri;

- Örnekleri pencerelere bölmeyi mümkün kılması,
- Model eğitildikten sonra, toplanan veriler üzerinden değerlendirilerek doğrulama ve test sonuçlarının daha gerçekçi olmasının sağlanması

olarak açıklanabilir.

Modellerin doğrulama ve test veri setlerindeki değerlere erişimi olmaması için ortalama ve standart sapma yalnızca eğitim verisi kullanılarak hesaplanmıştır. Ayrıca veri içinde uç değerlerin kalıp kalmadığını anlamak için tüm özelliklerin dağılımına bakarak gerekli düzenlemeleri yapılmıştır.

## 4.2. DEĞERLENDİRMEDE KULLANILAN METRİKLER

Modelin performansı ve tahmin gücünün ölçülebilmesi için, öngörü doğruluğunun elde edilmesi oldukça önemli bir konudur. Literatürde modelin tahmin performansını ölçmek için çok çeşitli hata fonksiyonları kullanılmaktadır. Bu çalışmada aşağıdaki performans metriklerini modelin performansını değerlendirmek için Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE) ve determinasyon katsayısıdır ( $R^2$ ) metrikleri kullanılmıştır.

#### 4.2.1. Ortalama Mutlak Hata (MAE):

Ortalama mutlak hata iki sürekli değişken arasındaki farkın ölçüsüdür. MAE, her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. MAE aynı zamanda her veri noktası ile en iyi uyan çizgi arasındaki ortalama yatay mesafedir. MAE değeri kolay yorumlanabilir olduğu için regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır.

$$MAE = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (4.2.1)$$

#### 4.2.2. Ortalama Kare Hata (MSE):

Ortalama kare hata bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu gösteren bir ölçüttür. MSE, makine öğrenmesi modelindeki, tahminleyicinin performansını ölçer, her zaman pozitif değerlidir ve MSE değeri sıfıra yakın olan tahminleyicilerin daha iyi bir performans gösterdiği kabul edilebilir.

$$MSE = \frac{1}{n} \sum_{i=1}^n \left( \frac{d_i - f_i}{\sigma_i} \right)^2 \quad (4.2.2)$$

#### 4.2.3. Kök Ortalama Kare Hata (RMSE):

Çoklu regresyon mantığıyla çalışan makine öğrenmesi modellerinde, tahminleyicinin (*predictor*) tahmin ettiği değerler ile gerçek değerler (*öğrenme verisi*) arasındaki uzaklığın bulunmasında kullandığımız, modelin hata payının büyüklüğünü temsil eden ölçüttür.


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{d_i - f_i}{\sigma_i} \right)^2} \quad (4.2.3)$$

#### 4.2.4. Determinasyon katsayısı ( $R^2$ )

Deneyisel verilerin doğrusal bir eğriye ne kadar iyi uyduğunun en iyi ölçütü, regresyon analiz işleminde hesaplanmış “determinasyon katsayısıdır ( $R^2$ ).”  $R^2 = 1$  olması, deneyisel verilerin kusursuz bir doğrusal eğri sağlandığının kanıtıdır. Ne kadar çok veri noktası varsa,  $R^2$ ’nin güvenilirliği o kadar yüksektir.

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y})^2}{\sum (Y_i - \bar{Y})^2} \quad (4.2.4)$$

### 4.3.MODELLER



Şekil 4.7 Modelleme Aşamaları

Çalışmada kullanılan modeller ve modellerde kullanılan katman ve parametrelerin detayları aşağıdaki açıklamalarda yer almaktadır.

- Öz-Dikkat Katmanlı Kodlayıcı-Çözücü Dönüştürücü Model
- RNN Temelli Modeller:
  - a) SimpleRNN: Basit Tekrarlayan Ağ Modeli
  - b) LSTM: Uzun Kısa Süreli Bellek Modeli
  - c) GRU: Kapılı Tekrarlayan Birim


- d) Stacked\_SimpleRNN: Yığın Basit Tekralayan Ağ Modeli
- e) Stacked\_LSTM: Yığın Uzun Kısa Süreli Bellek Modeli
- f) Stacked\_GRU: Yığın Kapılı Tekrarlayan Birim
- g) Bi\_LSTM: İki Yönlü Uzun Kısa Süreli Bellek Modeli
- h) Bi\_GRU: İki Yönlü Kapılı Tekrarlayan Birim Modeli
- i) Stacked\_Bi\_LSTM: Yığın İki Yönlü Uzun Kısa Süreli Bellek Modeli
- j) Stacked\_Bi\_GRU: İki Yönlü Kapılı Tekrarlayan Birim
- k) CNN\_LSTM: Evrişimli - Uzun Kısa Süreli Bellek Modeli
- l) CNN\_GRU: Evrişimli Kapılı Tekrarlayan Birim Modeli

#### 4.3.1. Öz-Dikkat Katmanlı Kodlayıcı-Çözücü Dönüştürücü:

Pytorch Paketi Model özetini Keras Paketinde olduğu gibi resim olarak vermemektedir bu nedenle Öz-Dikkat Katmanlı Kodlayıcı-Çözücü Dönüştürücü modeli görsel olarak verilememektedir.

#### 4.3.2. Simple RNN:


Model 12 girdi katmanı time özelliği dışında kalan 12 özellik ile beslenen 12 katman, 12 katman için 0.5 dropout katmanı ve 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.8).



Şekil 4.8. SimpleRNN Modelinin Yapısı

#### 4.3.3. LSTM:


Model 12 girdi katmanı time özelliği dışında kalan 12 özellik ile beslenen 12 katman, 12 katman için 0.5 dropout katmanı ve 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.9).



Şekil 4.9. LSTM Modelinin Yapısı

#### 4.3.4. GRU:


Model 12 girdi katmanı time özelliği dışında kalan 12 özellik ile beslenen 12 katman, 12 katman için 0.5 dropout katmanı ve 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.10).



Şekil 4.10. GRU Modelinin Yapısı

#### 4.3.5. Yığın Basit RNN:


Model 12 girdi katmanı time özelliği dışında kalan 12 özellik ile beslenen 12 katman, diğer katmanın çıktısını girdi olarak alan aynı boyutta yığın katmanı, 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.11).



Şekil 4.11. Yığın Basit RNN Modelinin Yapısı

#### 4.3.6. Yığın LSTM:

Model 12 girdi katmanı time özelliği dışında kalan 12 özellik ile beslenen 12 katman, diğer katmanın çıktısını girdi olarak alan aynı boyutta yığın katmanı, 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.12).




Şekil 4.12. Yığın LSTM Modelinin Yapısı

#### 4.3.7. Yığın GRU:

Model 12 girdi katmanı time özelliği dışında kalan 12 özellik ile beslenen 12 katman, diğer katmanın çıktısını girdi olarak alan aynı boyutta yığın katmanı, 12 özellik için


çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.13).



Şekil 4.13. Yığın GRU Modeli Yapısı

#### 4.3.8. Çift Yönlü LSTM:


Model 12 girdi katmanı, time özelliği dışında kalan 12 özellik ile beslenen çift yönlü 12 katman, 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.14).



Şekil 4.14. Çift Yönlü LSTM modeli

#### 4.3.9. Çift Yönlü GRU:


Model 12 girdi katmanı, time özelliği dışında kalan 12 özellik ile beslenen çift yönlü 12 katman, 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.15).



Şekil 4.15. Çift Yönlü GRU modeli

#### 4.3.10. Çift Yönlü Yığın LSTM:


Model 12 girdi katmanı, time özelliği dışında kalan 12 özellik ile beslenen çift yönlü 12 katman, diğer katmanın çıktısını girdi olarak alan aynı boyutta yığın katmanı, 0.5 dropout özelliğine sahip 12 dropout katman ve 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.16).



Şekil 4.16. Çift Yönlü Yığın LSTM: Modelinin Yapısı

#### 4.3.11. Çift Yönlü Yığın GRU:


Model 12 girdi katmanı, time özelliği dışında kalan 12 özellik ile beslenen çift yönlü 12 katman, diğer katmanın çıktısını girdi olarak alan aynı boyutta yığın katmanı, 0.5 dropout özelliğine sahip 12 dropout katman ve 12 özellik için çıktıları veren yoğun katmanından oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.17).



Şekil 4.17. Çift Yönlü Yığın GRU Modelinin Yapısı

#### 4.3.12. CNN – LSTM:


Model CNN ve LSTM networklerinden oluşan hibrit bir yapıda oluşturulmuştur. CNN ve LSTM katmanları (her katmandan sonra 0.5 dropout uygulanmıştır) ile 12 özellik için çıktıları veren yoğun katmandan oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.18).



Şekil 4.18. CNN – LSTM Modelinin Yapısı

#### 4.3.13. CNN – GRU:

Model CNN ve GRU networklerinden oluşan hibrit bir yapıda oluşturulmuştur. CNN ve GRU katmanları (her katmandan sonra 0.5 dropout uygulanmıştır) ile 12 özellik için çıktıları veren yoğun katmandan oluşmaktadır. Model için şema aşağıda verilmiştir (Şekil 4.19).



Şekil 4.19. CNN – GRU Modelinin Yapısı

## BÖLÜM 5. BULGULAR

Çalışmada zaman serisi ve elektrik fiyatı tahmini için literatürde sıkça ele alınan derin ağlar seçilmiştir. Seçilen ağlardan on ikisi RNN tabanlı modellerdir, on üçüncü model ise öz-dikkat katmanlı dönüştürücü çözücü-kodlayıcı (Transformer Encoder-Decoder with Self-Attention) modelidir. Çalışmada modellere eklenen özelliklerden (features) biri olan COVID-19 özelliği (feature) sayesinde tüm modeller küresel durgunluklarını da tahmin edecek şekilde tasarlanmıştır. COVID-19 öncesi dönem (1), COVID-19 tam kapanma dönemi (2) ve Kontrollü açılma ve sonrası dönem (3) olarak işaretlenmiştir. Modellerdeki diğer özellikler ham veriden elde edilmiştir.

Çalışmada daha önce adı geçen tüm RNN modelleri Tensorflow ve Keras kütüphanesi kullanılarak çözümlenmiştir. Öz-dikkat katmanlı dönüştürücü çözücü-kodlayıcı model ise Pytorch kütüphanesi kullanılarak kodlanmış ve çözümlenmiştir. Tüm modeller 100 öğrenme adımından başlanarak 1000 öğrenme adımına kadar yüz adım artırılarak ayrı ayrı çalıştırılmıştır. Elde edilen metrikler her bir öğrenme adımı grubu için ayrı ayrı, kayıplar ise her bir model için tek bir grafik olarak kaydedilmiştir. Ayrıca RNN modellerin karşılaştırılabilmesi için on iki model her öğrenme adımı grubu için on iki grafik beraber olacak şekilde ayrıca kaydedilmiştir.


Öz-dikkat katmanlı dönüştürücü çözücü-kodlayıcı modeli Pytorch kütüphanesi ile kodlandığı için RNN modellerinden ayrı olarak çalıştırılmıştır. Modelin paralelleştirme özelliği sayesinde 1000 öğrenme adımın bir çalışma 10 dakika sürerken diğer 12 modelin her biri için bu süre yaklaşık 30 dakika kadar sürmektedir. Bu da toplamda 360 dakikalık bir süreye, bir başka deyişle yaklaşık 6 saate denk gelmiştir.

Çalışmada RNN modellerinde on iki katman kullanılmıştır. Ayrıca iki yönlü (bi-directional) modeller için geriye-bakma ayarı yirmi dört olarak modellere girilmiştir. CNN modeller için filtre ayarı 128 olarak alınmıştır. Kernel büyüklüğü ise 5 olarak ayarlanmıştır. Tüm modellere 0.5 bırakma (dropout) eklenmiştir. Sürekli (continuous) değerleri tahmin etmek son olarak yoğun (dense) bir katman eklenmiştir. Modellerde 24 saatlik ileriye doğru tahmin yapılmıştır.


Çalışmada temel metrik olarak RMSE metriği tercih edilmiştir. RMSE formülünün doğası gereği büyük hatalara nispeten yüksek bir ağırlık vermektedir. Bu çalışma açısından en düşük hata oranı uygundur. Düşük RMSE değerleri tahmin gücünü artıracığı için, RMSE metriğinin seçilmesinde etkili olmuştur. RMSE dışında MAE, MSE ve  $R^2$  metrikleri de modelde kullanılmıştır. Tüm metriklerin sonuçları her bir öğrenme adımı grubu için eğitim (train) ve doğrulama aşamalarında ayrı ayrı kaydedilmiştir (bknz. Ek-Tablo 1).

### **5.1.ÖZ-DİKKAT TABANLI DÖNÜŞTÜRÜCÜ KODLAYICI-ÇÖZÜCÜ MODELİ İÇİN ÖĞRENME ADIMLARINA GÖRE SONUÇLARIN DEĞERLENDİRİLMESİ**

Öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modeli öğrenme adım sayısı ve RMSE skoruna göre yapılan genel sıralamada (overall rank) ilk 9 da yer almıştır. Sadece 100 öğrenme adımı (epoch) için elde edilen skorlara göre tüm modeller arasında 109. sırada yer almıştır. Dikkat katmanı sahip bu dönüştürücü modelleri büyük verileri uzun öğrenme adımları ile öğrenmek için geliştirildikleri için kısa öğrenme adımlarında daha düşük başarı göstermeleri normal karşılanmalıdır. Ancak model 100 öğrenme adımındaki bu düşük öğrenme başarısına rağmen daha yüksek öğrenme adımı sayısına sahip yirmi bir modeli geride bırakmayı başarmıştır. Aşağıdaki tabloda 100-1000 öğrenme adımlarında elde edilen metriklerin değerlerine göre, yüksek başarıdan düşüğe doğru başarı sırası ile tüm modeller içindeki genel başarı sırası verilmektedir (Tablo 5.1). Öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü (TEDSA: Transformer Encoder-Decoder with Self-Attention) modeli 700 öğrenme adımında tüm modeller arasında en yüksek başarıyı elde etmiştir. Öğrenme adımları sonrasında yapılan örnek ara tahminler aşağıdaki şekillerde verilmiştir (Şekil 5.1, Şekil 5.2).



Şekil 5.1 Pandemi Dönemi İçin Alınan Örnek Ara Tahmin




Şekil 5.2 Normal Dönem İçin Alınan Örnek Ara Tahmin

Tablo 5.1. Öz-Dikkat Tabanlı Dönüştürücü Kodlayıcı-Çözücü Modeli Sonuçları

| Öğrenme Adımı Sayısı | Öğrenme Adımı Sıralaması | Genel Sıralama | MAE  | MSE    | RMSE    | R <sup>2</sup> |
|----------------------|--------------------------|----------------|------|--------|---------|----------------|
| 700                  | 1                        | 1              | 2,82 | 9,87   | 3,1411  | 0,94           |
| 400                  | 2                        | 2              | 3,94 | 19,22  | 4,3836  | 0,91           |
| 300                  | 3                        | 3              | 3,95 | 20,35  | 4,5113  | 0,91           |
| 800                  | 4                        | 4              | 3,95 | 21,04  | 4,5864  | 0,92           |
| 1000                 | 5                        | 5              | 3,96 | 24,26  | 4,9252  | 0,91           |
| 600                  | 6                        | 6              | 3,98 | 29,92  | 5,4702  | 0,87           |
| 900                  | 7                        | 7              | 4,13 | 37,81  | 6,1492  | 0,89           |
| 500                  | 8                        | 8              | 4,13 | 41,93  | 6,4756  | 0,89           |
| 200                  | 9                        | 9              | 4,14 | 44,27  | 6,6535  | 0,89           |
| 100                  | 10                       | 109            | 5,94 | 127,39 | 11,2866 | 0,71           |

### 100 Öğrenme Adımı İçin Sonuçlar:

100 öğrenme adımında MAE skoru 5.94, MSE skoru 127.39, ve  $R^2$  skoru 0.71 ve RMSE skoru ise 11.2866 olarak hesaplanmıştır. Model, 100 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için öğrenme adımlarından elde edilen sonuçlara göre 109. sırada yer almıştır. Modelin 100 öğrenme adımındaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.3).




Şekil 5.3. 100 Öğrenme Adımı Kayıp Grafiği

Kayıp grafiğini incelediğimizde (Şekil 5.3), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sıfıra çok yakın, 0.11 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu gözlemlemekteyiz. Grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz. Ancak 100 öğrenme adımında elde edilen 11.29 RMSE skoruyla, model için çalıştırılan diğer öğrenme adımlarındaki diğer skorlara göre tahmin gücünün daha düşük olduğunu görmekteyiz.

#### 200 Öğrenme Adımı İçin Sonuçlar:

200 öğrenme adımında MAE skoru 4.14, MSE skoru 44.27,  $R^2$  skoru 0.89 ve RMSE skoru ise 6.6535 olarak hesaplanmıştır. Model, 200 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için öğrenme adımlarından elde edilen sonuçlara göre 9. sırada yer almıştır. Modelin 200 öğrenme adımıdaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.4).




Şekil 5.4. 200 Öğrenme Adımı İçin Kayıp Grafiği

200 öğrenme adımıdaki kayıp grafiğini incelediğimizde (Şekil 5.4), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sıfıra çok yakın, 0.12 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

### 300 Öğrenme Adımı İçin Sonuçlar:

300 öğrenme adımında MAE skoru 3.95, MSE skoru 20.35,  $R^2$  skoru 0.91 ve RMSE skoru ise 4.5113 olarak hesaplanmıştır. Model, 300 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 3. sırada yer almıştır. Modelin 300 öğrenme adımındaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.5).




Şekil 5.5. 300 Öğrenme Adımı İçin Kayıp Grafiği

300 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.5), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sifıra çok yakın, 0.08 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 400 Öğrenme Adımı İçin Sonuçlar:

400 öğrenme adımında MAE skoru 3.94, MSE skoru 19.22,  $R^2$  skoru 0.91 ve RMSE skoru ise 4.38 olarak hesaplanmıştır. Model, 400 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 2. sırada yer almıştır. Modelin 400 öğrenme adımındaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.6).




Şekil 5.6. 400 Öğrenme Adımı İçin Kayıp Grafiği

400 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.6), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sıfıra çok yakın, 0.12 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 500 Öğrenme Adımı İçin Sonuçlar:

500 öğrenme adımında MAE skoru 4.13, MSE skoru 41.93,  $R^2$  skoru 0.89 ve RMSE skoru ise 6.4756 olarak hesaplanmıştır. Model, 500 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 8. sırada yer almıştır. Modelin 500 öğrenme adımındaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.7).




Şekil 5.7. 500 Öğrenme Adımı İçin Kayıp Grafiği

500 denemdeki kayıp grafiğini incelediğimizde (Şekil 5.7), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sifıra çok yakın, 0.12 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 600 Öğrenme Adımı İçin Sonuçlar:

600 öğrenme adımında MAE skoru 3.98, MSE skoru 29.92,  $R^2$  skoru 0.87 ve RMSE skoru ise 5.4702 olarak hesaplanmıştır. Model, 600 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 6. sırada yer almıştır. Modelin 600 öğrenme adımındaki kayıp-öğrenme grafiği verilmiştir (Şekil 5.8).




Şekil 5.8. 600 Öğrenme Adımı İçin Kayıp Grafiği

600 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.8), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sifıra çok yakın, 0.08 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Ancak 550 denemden sonra çok düşük bir dalgalanmanın olduğunu da grafikte görmekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 700 Öğrenme Adımı İçin Sonuçlar:

700 öğrenme adımında MAE skoru 2,82, MSE skoru 9,87,  $R^2$  skoru 0.94 ve RMSE skoru ise 3.1411 olarak hesaplanmıştır. Model, 700 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 1. sırada yer almıştır. Modelin 700 öğrenme adımındaki kayıp-öğrenme grafiği verilmiştir (Şekil 5.9).




Şekil 5.9. 700 Öğrenme Adımı İçin Kayıp Grafiği

700 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.9), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sıfıra çok yakın, 0.10 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Ancak 550 denemden sonra çok düşük bir dalgalanmanın olduğunu da grafikte görmekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 800 Öğrenme Adımı İçin Sonuçlar:

800 öğrenme adımında MAE skoru 3,95, MSE skoru 21.04,  $R^2$  skoru 0.92 ve RMSE skoru ise 4,5864 olarak hesaplanmıştır. Model, 800 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 4. sırada yer almıştır. Modelin 800 öğrenme adımındaki kayıp-öğrenme grafiği verilmiştir (Şekil 5.10).




Şekil 5.10. 800 Öğrenme Adımı İçin Kayıp Grafiği

800 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.10), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sifıra çok yakın, 0.10 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Ancak 650 denemden sonra çok düşük bir dalgalanmanın olduğunu da grafikte görmekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 900 Öğrenme Adımı İçin Sonuçlar:

900 öğrenme adımında MAE skoru 4.13, MSE skoru 37.81,  $R^2$  skoru 0.89 ve RMSE skoru ise 6.1492 olarak hesaplanmıştır. Model, 900 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 7. sırada yer almıştır. Modelin 900 öğrenme adımındaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.11).




Şekil 5.11. 900 Öğrenme Adımı İçin Kayıp Grafiği

900 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.11), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra sifıra çok yakın, 0.11 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu olduğunu gözlemlemekteyiz. Ancak 850 denemden sonra çok düşük bir dalgalanmanın olduğunu da grafikte görmekteyiz. Yine grafiğe göre modelinin tahmin gücünün hem eğitim hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

#### 1000 Öğrenme Adımı İçin Sonuçlar:

1000 öğrenme adımında MAE skoru 3.96, MSE skoru 24.26,  $R^2$  skoru 0.91 ve RMSE skoru ise 4.9252 olarak hesaplanmıştır. Model, 1000 öğrenme adımında hesaplanan bu RMSE skoru ile çalışmada yer alan tüm modeller için çalıştırılan öğrenme adımlarından elde edilen sonuçlara göre 5. sırada yer almıştır. Modelin 1000 öğrenme adımındaki kayıp-öğrenme grafiği aşağıda verilmiştir (Şekil 5.12).



Şekil 5.12. 1000 Öğrenme Adımı İçin Kayıp Grafiği

1000 öğrenme adımındaki kayıp grafiğini incelediğimizde (Şekil 5.12), öğrenme ve doğrulama kayıplarının yakın bir değerden başlayıp hızlı bir düşüşten sonra 0.14 gibi bir değerden sonra dalgalanarak hareket ettiğini görmekteyiz. Modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğunun bu öğrenme adımı sayısında arttığını gözlemlemekteyiz. Ancak ilk öğrenme adımından itibaren dalgalanmanın azalarak kaybın 0.11 gibi bir değere kadar indiğini görmekteyiz. Yine grafiğe göre modelinin tahmin gücünün eğitim verisi için nispeten düşük, tahmin verisi için ise yüksek olduğunu söyleyebilmekteyiz.

## 5.2. RNN TABANLI MODELLER İÇİN ÖĞRENME ADIMLARINA GÖRE SONUÇLARIN DEĞERLENDİRİLMESİ

RNN tabanlı modellerin denemelerinden elde edilen RMSE skor sırlamasında ilk ona giren modeller yukarıdaki tabloda verilmiştir (Tablo 5.2). Başarılı ilk on model arasında yığın tabanlı modeller, model varyasyonu veya öğrenme adımı sayısı ile 7 kere yer almıştır. İlk on içerisinde en başarılı olan denemeler genelde GRU tabanlı modeller olmuştur. GRU tabanlı modeller çeşitli öğrenme adımı sayısı ve model varyasyonları ile 6 kere sıralamada yer almışlardır. Yalın olarak ilk ona girebilen tek model GRU modelidir. Bu model 500 öğrenme adımında 4. sırayı, 400 öğrenme adımında 7. sırayı almıştır. Yığın çift yönlü GRU modeli ise 100 öğrenme adımında tüm RNN modelleri arasında 7.54'lük RMSE skoru ile birinci sırada yer almıştır.


Yığın (stacked) modeller tahmin gücü yüksek olarak ilk üç sırada bulunmaktadır. İlk üç modelin 0.85 olan  $R^2$  değerleri de oldukça yüksek açıklama gücüne sahiptir. Stacked\_SimpleRNN modeli 800 ve 900 öğrenme adımlarında, sırası ile RNN tabanlı modeller arasında ikinci ve üçüncü en iyi olmuştur. Bu öğrenme adımı sayılarında model 7.57 ve 7.6 RMSE değerlerini elde etmiştir. RNN tabanlı tüm modellerinin RMSE metrikleri incelediğinde, genelde virgülden sonra ikinci hanede değişiklikler gözlemlenmiştir. Bu nedenle modeller için yakın tahmin gücüne sahiptirler denilebilir.

Tablo 5.2. RMSE Skoruna Göre İlk 10 RNN Tabanlı Modelin Sıralaması

| Sıralama | Öğrenme Adımı Sayısı | Model Adı         | MAE  | MSE   | RMSE | $R^2$ |
|----------|----------------------|-------------------|------|-------|------|-------|
| 1        | 100                  | Stacked_Bi_GRU    | 4,43 | 56,84 | 7,54 | 0,85  |
| 2        | 800                  | Stacked_SimpleRNN | 4,18 | 57,25 | 7,57 | 0,85  |
| 3        | 900                  | Stacked_SimpleRNN | 4,17 | 57,7  | 7,6  | 0,85  |
| 4        | 500                  | GRU               | 4,48 | 57,99 | 7,61 | 0,84  |
| 5        | 500                  | Stacked_GRU       | 4,15 | 57,91 | 7,61 | 0,84  |
| 6        | 100                  | Bi_GRU            | 4,54 | 58    | 7,62 | 0,84  |
| 7        | 400                  | GRU               | 4,62 | 58,09 | 7,62 | 0,84  |
| 8        | 400                  | Stacked_GRU       | 4,11 | 58,19 | 7,63 | 0,84  |
| 9        | 500                  | Stacked_SimpleRNN | 4,09 | 58,33 | 7,64 | 0,84  |
| 10       | 600                  | Stacked_SimpleRNN | 4,19 | 58,59 | 7,65 | 0,84  |

### 100 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 100 öğrenme adımında en yüksek başarı Stacked\_Bi\_GRU modelinden elde edilmiştir. Stacked\_Bi\_GRU modeli eğitim kaybı 0.8 gibi bir noktadan test kaybı ise 0.48 gibi bir değerden başlayarak hızlı bir inişle 0.18 gibi bir düzeyde beraber hareket etmeye başlamışlardır. Modellerin kayıp (öğrenme) çizgileri arasında genelleme boşluğu minimumdur. Öğrenme adımlarında aşırı dalgalanma gözlemlenmemektedir. Bu öğrenme adımında en kötü başarıyı 12.32 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıda modeller için 100 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.13. RNN Temelli Modeller: 100 Öğrenme Adımı İçin Öğrenme Eğrileri

### 200 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 200 öğrenme adımında en yüksek başarı Stacked\_SimpleRNN modelinden elde edilmiştir. Stacked\_SimpleRNN modeli eğitim kaybı 0.05 gibi bir değerden test kaybı ise 0.042 gibi bir değerden başlayarak hızlı bir inişle 0.018 (test) ile 0.014 (eğitim) gibi bir düzeyde beraber hareket etmeye başlamışlardır. Modellenin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimumdur. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim verilerinin test verilerine göre model tarafından daha iyi öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.54 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 200 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.14. RNN Temelli Modeller: 200 Öğrenme Adımı İçin Öğrenme Eğrileri

### 300 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 300 öğrenme adımında en yüksek başarı 7.69 RMSE skoru ile Stacked\_LSTM modelinden elde edilmiştir. Stacked\_LSTM modelinin eğitim kaybı 0.05 gibi bir değerden, test kaybı ise 0.036 gibi bir değerden başlayarak hızlı bir inişle, 50 öğrenme adımından sonra doğrulama eğrisi 0.017 gibi bir değerle, eğitim eğrisi ise 0.015 gibi bir değerle yatayda beraber hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim verilerinin test verilerine göre model tarafından daha iyi öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.45 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 300 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.15. RNN Temelli Modeller: 300 Öğrenme Adımı İçin Öğrenme Eğrileri

#### 400 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 400 öğrenme adımında en yüksek başarı 7.62 RMSE skoru ile GRU modelinden elde edilmiştir. GRU modelinin eğitim kaybı 0.62 gibi bir değerden test kaybı ise 0.45 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.18 gibi bir değerle doğruya ve eğitim eğrisi yatayda beraber hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.75 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 400 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.16. RNN Temelli Modeller: 400 Öğrenme Adımı İçin Öğrenme Eğrileri

### 500 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 500 öğrenme adımında en yüksek başarı 7.61 RMSE skoru ile GRU modelinden elde edilmiştir. GRU modelinin eğitim kaybı 0.075 gibi bir değerden test kaybı ise 0.054 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.018 gibi bir değerle doğruya ve eğitim eğrisi yatayda beraber hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.48 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 500 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.17. RNN Temelli Modeller: 500 Öğrenme Adımı İçin Öğrenme Eğrileri

### 600 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 600 öğrenme adımında en yüksek başarı 7.65 RMSE skoru ile Stacked\_SimpleRNN modelinden elde edilmiştir. Stacked\_SimpleRNN modelinin eğitim kaybı 0.071 gibi bir değerden test kaybı ise 0.062 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.018-0.016 gibi bir değerlerle doğrulama ve eğitim eğrisi yatayda paralel hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.23 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 600 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.18. RNN Temelli Modeller: 600 Öğrenme Adımı İçin Öğrenme Eğrileri

### 700 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 700 öğrenme adımında en yüksek başarı 7.68 RMSE skoru ile Stacked\_SimpleRNN modelinden elde edilmiştir. Stacked\_SimpleRNN modelinin eğitim kaybı 0.175 gibi bir değerden test kaybı ise 0.09 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.024 gibi bir değerle doğrulama ve eğitim eğrisi yatayda paralel hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.23 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 700 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.19. RNN Temelli Modeller: 700 Öğrenme Adımı İçin Öğrenme Eğrileri

### 800 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 800 öğrenme adımında en yüksek başarı 7.57 RMSE skoru ile Stacked\_SimpleRNN modelinden elde edilmiştir. Stacked\_SimpleRNN modelinin eğitim kaybı 0.10 gibi bir değerden test kaybı ise 0.079 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.018 gibi bir değerle doğrulama ve eğitim eğrisi yatayda paralel hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.35 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 800 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.20. RNN Temelli Modeller: 800 Öğrenme Adımı İçin Öğrenme Eğrileri

### 900 Öğrenme Adımı İçin Sonuçlar:


RNN temeli modeller için 900 öğrenme adımında en yüksek başarı 7.6 RMSE skoru ile Stacked\_SimpleRNN modelinden elde edilmiştir. Stacked\_SimpleRNN modelinin eğitim kaybı 0.032 gibi bir değerden test kaybı ise 0.026 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.016-0.0130 gibi bir değerle doğrulama ve eğitim eğrisi yatayda paralel hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum yüksek dalgali olarak gözlemlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 18.13 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 900 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.21. RNN Temelli Modeller: 900 Öğrenme Adımı İçin Öğrenme Eğrileri

### 1000 Öğrenme Adımı İçin Sonuçlar:

RNN temeli modeller için 1000 öğrenme adımında en yüksek başarı 7.76 RMSE skoru ile SimpleRNN modelinden elde edilmiştir. SimpleRNN modelinin eğitim kaybı 0.178 gibi bir değerden test kaybı ise 0.035 gibi bir değerden başlayarak hızlı bir inişle, 10 öğrenme adımından sonra 0.024 gibi bir değerle doğrulama ve eğitim eğrisi yatayda paralel hareket etmeye başlamışlardır. Modelin kayıp (öğrenme) eğrileri arasında genelleme boşluğu minimum olarak gözlemlenmiştir. Modelin kayıp (öğrenme) grafiği incelendiğinde eğitim ve doğrulama verilerinin model tarafından hemen hemen aynı düzeyde öğrenildiğini gözlemlenmiştir. Bu öğrenme adımında en kötü başarıyı 14.15 RMSE skoru ile 12. Olarak CNN-LSTM modeli elde etmiştir. Aşağıdaki şekilde RNN tabanlı modeller için 1000 öğrenme adımı için kayıp grafikleri yer almaktadır.



Şekil 5.22. RNN Temelli Modeller: 1000 Öğrenme Adımı İçin Öğrenme Eğrileri

### 5.3.RNN TABANLI MODELLERİN KENDİ EN İYİ SKORLARI

Çalışmada temel metrik olarak kullanılan RMSE metriğine göre RNN tabanlı her bir modelin en iyi skoru aşağıdaki tabloda verilmiştir.

Tablo 5.3. RNN Tabanlı Modelin RMSE Metriğine Kendi En İyi Skorları.

| Model Adı         | En İyi Öğrenme Adımı Sayısı | MAE  | MSE    | RMSE  | R <sup>2</sup> |
|-------------------|-----------------------------|------|--------|-------|----------------|
| SimpleRNN         | 600                         | 4,64 | 60,19  | 7,76  | 0,84           |
| LSTM              | 600                         | 4,49 | 59,18  | 7,69  | 0,84           |
| GRU               | 500                         | 4,48 | 57,99  | 7,61  | 0,84           |
| Stacked_SimpleRNN | 800                         | 4,18 | 57,25  | 7,57  | 0,85           |
| Stacked_LSTM      | 300                         | 4,12 | 59,17  | 7,69  | 0,84           |
| Stacked_GRU       | 500                         | 4,15 | 57,91  | 7,61  | 0,84           |
| Bi_LSTM           | 500                         | 4,59 | 60,2   | 7,76  | 0,84           |
| Bi_GRU            | 100                         | 4,54 | 58     | 7,62  | 0,84           |
| Stacked_Bi_LSTM   | 200                         | 4,96 | 69,06  | 8,31  | 0,81           |
| Stacked_Bi_GRU    | 100                         | 4,43 | 56,84  | 7,54  | 0,85           |
| CNN_LSTM          | 100                         | 7,57 | 151,87 | 12,32 | 0,59           |
| CNN_GRU           | 100                         | 6,06 | 86,15  | 9,28  | 0,77           |

SimpleRNN modelinin, 600 öğrenme adımı için MAE skoru 4.64, MSE skoru 60.19, R<sup>2</sup> skoru 0.84 ve RMSE skoru ise 7.76 olarak hesaplanmıştır. Bu RMSE skoru ile, SimpleRNN modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

LSTM modelinin, 600 öğrenme adımı için MAE skoru 4.49, MSE skoru 59.18, R<sup>2</sup> skoru 0.84 ve RMSE skoru ise 7.69 olarak hesaplanmıştır. Bu RMSE skoru ile, LSTM modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

GRU modelinin, 500 öğrenme adımı için MAE skoru 4.48, MSE skoru 57.99, R<sup>2</sup> skoru 0.84 ve RMSE skoru ise 7.61 olarak hesaplanmıştır. Bu RMSE skoru ile, GRU modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Stacked\_SimpleRNN modelinin, 800 öğrenme adımı için MAE skoru 4.18, MSE skoru 57.25, R<sup>2</sup> skoru 0.85 ve RMSE skoru ise 7.57 olarak hesaplanmıştır. Bu RMSE skoru ile, Stacked\_SimpleRNN modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Stacked\_LSTM modelinin, 300 öğrenme adımı için MAE skoru 4.12, MSE skoru 59.17,  $R^2$  skoru 0.84 ve RMSE skoru ise 7.69 olarak hesaplanmıştır. Bu RMSE skoru ile, Stacked\_LSTM modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Stacked\_GRU modelinin, 500 öğrenme adımı için MAE skoru 4.15, MSE skoru 57.91,  $R^2$  skoru 0.84 ve RMSE skoru ise 7.61 olarak hesaplanmıştır. Bu RMSE skoru ile, Stacked\_GRU modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Bi\_LSTM modelinin, 500 öğrenme adımı için MAE skoru 4.59, MSE skoru 60.20,  $R^2$  skoru 0.84 ve RMSE skoru ise 7.76 olarak hesaplanmıştır. Bu RMSE skoru ile, Bi\_LSTM modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Bi\_GRU modelinin, 100 öğrenme adımı için MAE skoru 4.54, MSE skoru 58.00,  $R^2$  skoru 0.84 ve RMSE skoru ise 7.62 olarak hesaplanmıştır. Bu RMSE skoru ile, Bi\_GRU modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Stacked\_Bi\_LSTM modelinin, 200 öğrenme adımı için MAE skoru 4.96, MSE skoru 69.06,  $R^2$  skoru 0.81 ve RMSE skoru ise 8.31 olarak hesaplanmıştır. Bu RMSE skoru ile, Stacked\_Bi\_LSTM modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

Stacked\_Bi\_GRU modelinin, 100 öğrenme adımı için MAE skoru 4.43, MSE skoru 56.84,  $R^2$  skoru 0.85 ve RMSE skoru ise 7.54 olarak hesaplanmıştır. Bu RMSE skoru ile, Stacked\_Bi\_GRU modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.


CNN\_LSTM modelinin, 100 öğrenme adımı için MAE skoru 7.57, MSE skoru 151.87,  $R^2$  skoru 0.59 ve RMSE skoru ise 12.32 olarak hesaplanmıştır. Bu RMSE skoru ile, CNN\_LSTM modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

CNN\_GRU modelinin, 100 öğrenme adımı için MAE skoru 6.06, MSE skoru 86.15,  $R^2$  skoru 0.77 ve RMSE skoru ise 9.28 olarak hesaplanmıştır. Bu RMSE skoru ile, CNN\_GRU modeli öğrenme adımları için hesaplanan metrik başarı sıralamasına göre en iyi başarıyı bu öğrenme adımında elde etmiştir.

## 5.4. EN İYİ BAŞARIYI ELDE EDEN 4 FARKLI MODELİN EN İYİ SKORLU ÖĞRENME EĞRİLERİNE GÖRE DEĞERLENDİRİLMESİ

Kayıp eğrileri, eğitim ve öğrenme kaybı değerleri arasındaki boşluğu gösterir. Bu boşluk ne kadar düşüğe ve x-düzlemindeki eğrilerin kararlılık durumları sıfıra ne kadar yakınsa, model eğitim verilerinden doğrulama verilerine o kadar iyi genellebilir. Başka bir söyleyişle modelin tahmin gücü daha yüksektir denilebilir.

En iyi dört model için verilen kayıp grafikleri incelendiğinde (Şekil 5.23) en iyi sonucu elde eden öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelinin 700 öğrenme adımı ile öğrendiğinde elde edilen kayıp grafiğini incelediğimizde, öğrenme ve doğrulama kayıplarının yakın bir değerden hızlı bir düşüşten sonra sıfıra çok yakın, 0.10 gibi bir değerde yatay ve istikrarlı olarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğu gözlemlemekteyiz. Grafiğe göre sonuç olarak inin tahmin gücünün hem eğitim verisi üzerinde hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.



Şekil 5.23. Modellere Göre En İyi İlk Dört Sonucu Veren Modeller

Tüm modeller arasındaki başarı sıralamasında 10. sırada yer alan Stacked\_Bi\_Gru modelinin 100 öğrenme adımı ile öğrendiğinde çizilen kayıp grafiğini incelediğimizde

(Şekil 5.23), öğrenme ve doğrulama kayıplarının farklı noktalardan hızlı bir düşüşten sonra sıfıra çok yakın, 0.18 gibi bir değerde hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğunun 20 öğrenme adımından sonra azaldığı gözlemlenmektedir. Grafiğe göre sonuç olarak Stacked\_Bi\_Gru modelinin tahmin gücünün hem eğitim verisi üzerinde hem de tahmin verisi üzerinde yüksek olduğunu söyleyebilmekteyiz.

Tüm modeller arasındaki başarı sıralamasında 11. sırada yer alan GRU modelinin 500 öğrenme adımı ile öğrendiğinde çizilen kayıp grafiğini incelediğimizde (Şekil 5.23) öğrenme ve doğrulama kayıplarının farklı noktalardan hızlı bir düşüşten sonra sıfıra çok yakın, 0.15 gibi bir değerde dalgalanarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğunun diğer modellere göre daha yüksek olduğu gözlemlenmektedir. Grafiğe göre sonuç olarak GRU modelinin tahmin gücünün eğitim verisi üzerinde daha yüksek, tahmin verisi üzerinde daha düşük olduğunu söyleyebilmekteyiz.

Tüm modeller arasındaki başarı sıralamasında 12. sırada yer alan Stacked\_SimpleRNN modelinin 800 öğrenme adımı ile öğrendiğinde çizilen kayıp grafiğini incelediğimizde (Şekil 5.23) öğrenme ve doğrulama kayıplarının farklı noktalardan hızlı bir düşüşten sonra sıfıra çok yakın, 0.18 gibi bir değerde dalgalanarak hareket ettiğini görmekteyiz. Ayrıca modelin doğrulama ve öğrenme eğrileri arasında minimum genelleme boşluğunun diğer 1. Sıradaki öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü ve 10. sıradaki Stacked\_Bi\_Gru modellerine göre daha yüksek 11. sıradaki GRU modelinden daha düşük olduğu gözlemlenmektedir. 100. Öğrenme adımından sonra genelleme boşluğunun miktarı artmıştır. Sonuç olarak grafiğe göre Stacked\_SimpleRNN modelinin tahmin gücünün eğitim verisi üzerinde daha düşük, tahmin verisi üzerinde daha yüksek olduğunu söyleyebilmekteyiz.

## **5.5. TÜM MODELLERİN ÖĞRENME ADIMLARINA GÖRE GENEL DEĞERLENDİRMESİ**

13 farklı model için yüz otuz farklı öğrenme adımı sonucu elde edilmiş ve bu sonuçlar RMSE ve MAE metriklerinin puanlarına göre sıralanmıştır. Eğitim doğrulama aşamalarında her deney grubu için tüm metrikler ayrı ayrı kaydedilmiştir. Bu değerlerden alınan her bir RNN modelinin en iyi puanları aşağıdaki tabloda verilmiştir (Tablo 5.4).

Elde edilen sonuçlara göre tüm modellerde önemli başarı elde edilmiştir. MAE ve RMSE değerleri sıfıra çok yakın değerlerdir. Ortalama Standart Hata (MSE) puanları makul sınırlar içindedir. Öte yandan modellerin açıklama gücünü gösteren modellerin  $R^2$  değerleri oldukça yüksektir. Tablonun ilk satırında olan öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü en iyi tahmin modelidir. 700 öğrenme adımı sonucunda 3,14 ile en düşük RMSE puanına sahipken, MAE ve MSE istatistikleri sırasıyla 2,82 ve 9,87 olup diğer tüm modellerden ayrılan çok iyi bir sonuç elde etmiştir.  $R^2$  istatistiği 0.94 gibi çok yüksek bir değerdir. Bu tabloda yer almayan diğer tüm dönemler hesaba katıldığında, ilk otuz başarılı öğrenme adımı sonucuna dokuz kez girmiştir. Sadece 100 öğrenme adımında (epoch) alınan puanlara göre tüm modeller arasında 109. sırada yer almıştır. Dönüştürücü ağlar, büyük veriyi uzun öğrenme adımı adımları ile öğrenmek için geliştirilmiştir. Bu nedenle kısa öğrenme adımı adımlarında daha düşük başarı göstermeleri normal karşılanabilir. Ancak 100 öğrenme adımındaki bu düşük öğrenme başarısına rağmen, daha yüksek öğrenme adımı sayısına sahip 21 modelden daha iyi performans göstermiştir.

Stacked\_Bi\_GRU modeli ikinci en iyi ikinci sırayı almıştır. En iyi ilk otuza sadece bir kez girebilen Stacked\_Bi\_GRU'nun RMSE değeri oldukça iyidir. Ancak öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelinin iki katı kadar bir RMSE skoru elde etmiştir. Modelin açıklama gücü 0.85'tir. Onu takip eden tüm modellerin puanları birbirine çok yakınken hiçbiri öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelinin tahmin gücüne yaklaşamamıştır.

Tablo 5.4. On Üç Modelin Kendi En İyi RMSE Skoruna Göre Genel Sırlamadaki Yeri

| Model Adı                                       | Öğrenme Adımı Sayısı | Genel Sıralama | İlk 30'da Kaç Kere Yer Aldığı | MAE  | MSE    | RMSE  | $R^2$ |
|-------------------------------------------------|----------------------|----------------|-------------------------------|------|--------|-------|-------|
| Öz-Dikkat Katmanlı Dönüştürücü Kodlayıcı-Çözücü | 700                  | 1              | 9                             | 2,82 | 9,87   | 3,14  | 0,94  |
| Yığılmış Bi_GRU                                 | 100                  | 10             | 1                             | 4,43 | 56,84  | 7,54  | 0,85  |
| Stacked_SimpleRNN                               | 800                  | 11             | 9                             | 4,18 | 57,25  | 7,57  | 0,85  |
| GRU                                             | 500                  | 14             | 3                             | 4,48 | 57,99  | 7,61  | 0,84  |
| Stacked_GRU                                     | 500                  | 13             | 3                             | 4,15 | 57,91  | 7,61  | 0,84  |
| Bi_GRU                                          | 100                  | 15             | 1                             | 4,54 | 58     | 7,62  | 0,84  |
| LSTM                                            | 600                  | 26             | 1                             | 4,49 | 59,18  | 7,69  | 0,84  |
| Stacked_LSTM                                    | 300                  | 23             | 3                             | 4,12 | 59,17  | 7,69  | 0,84  |
| BasitRNN                                        | 600                  | 36             | 0                             | 4,64 | 60,19  | 7,76  | 0,84  |
| Bi_LSTM                                         | 500                  | 35             | 0                             | 4,59 | 60,2   | 7,76  | 0,84  |
| Stacked_Bi_LSTM                                 | 200                  | 91             | 0                             | 4,96 | 69,06  | 8,31  | 0,81  |
| CNN_GRU                                         | 100                  | 103            | 0                             | 6,06 | 86,15  | 9,28  | 0,77  |
| CNN_LSTM                                        | 100                  | 111            | 0                             | 7,57 | 151,87 | 12,32 | 0,59  |

## BÖLÜM 6. SONUÇ ve ÖNERİLER

1970'lerden itibaren değişen enerji paradigması ve bu paradigma değişikliğinin enerji fiyatları üzerinde yarattığı oynaklık etkisi, tüm dünya piyasalarında yeni bir dönem açmıştır. Bu yeni dönemde, enerji reformları nedeniyle oldukça rekabetçi piyasa koşulları gelişmiş ve piyasa oyuncuları, farklı elektrik enerjisi üretim kaynaklarının değişen maliyetlerini, elektrik piyasası fiyatları ile eşleştirmek için elektrik fiyatlarını en az bir gün önceden tahmin etmeleri çok daha önemli hale gelmiştir. Bu amaçla ilk başlarda ekonometrik modeller kullanılmış olsa da bu modellerin elektrik fiyatlarındaki ani yükselişleri yeterince tahmin edemediği görülmüştür. Bu sorunu çözmek için, son bir kaç yıldır yapılan çalışmalarda derin öğrenme yöntemleri daha sık gündeme gelmiştir. Derin öğrenme yöntemlerinin, ayrıca elektrik fiyatlarındaki aşırı oynaklığı başarılı bir şekilde tahmin edebildiği de birçok araştırma ile ortaya konulmuştur. Bu araştırmalar, elektrik fiyatlarını RNN, LSTM, GRU gibi modeller kullanarak tahmin etse de (Kuo & Huang, 2018, Lago, De Ridder ve De Schutter, 2018, Zahid ve diğerleri, 2019, Cerjan ve diğerleri, 2019, Polson ve diğerleri., 2020), literatürde, öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü ağı, bugüne kadar bu alanda hiç kullanılmadığı görülmüştür.

Son yıllarda elektrik piyasalarının liberalleşmesiyle birlikte, elektriğin alınıp satılan bir emtia haline dönüşmesi ve fiyatların saatlik olarak belirleniyor olması, fiyat tahmini yapabilmenin önemini oldukça arttırmıştır. Ülkemizde özellikle YEKDEM desteklerinin bitiyor olması konunun önemini daha da arttırmaktadır. Bu çalışmada, Türkiye gün öncesi enerji piyasasında üretim yapan aktörler ve YEKDEM desteği biten küçük üreticiler için tutarlılık oranı yüksek fiyat tahmini yapabilecek toplam on üç adet derin öğrenme modeli kurulmuştur. İlk model, öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modeldir ve elektrik fiyat tahmini için literatürde ilk defa kullanılmıştır. Geriye kalan modeller (on iki model), RNN (*Recurrent Neural Network*) tabanlıdır. Karşılaştırılabilirlik amacıyla, çalışma kapsamında ele alınan bütün modeller 2017-2021 yılları arasında EPIAŞ şeffaflık platformundan elde edilen 13 özellik (*feature*) ile geliştirilmiştir. Modeller, 100 öğrenme adımından (*epoch*) başlanarak 100 adım artırılıp 1000 öğrenme adımına kadar

çalıştırılmıştır. RNN tabanlı modeller çift yönlü, yığılmış ve çift yönlü yığılmış olarak modellenmişlerdir. Ek olarak, hibrit yapıda CNN-LSTM ve CNN-GRU modelleri de kullanılmıştır. Toplamda 13 farklı model için 130 adet öğrenme adımından MAE, MSE, RMSE ve  $R^2$  skorları elde edilmiş, bulgular raporlanmıştır.

Kurulan RNN tabanlı modellerin öğrenme adımı sonuçları, verilen metriklere göre değerlendirildiğinde; RMSE skoruna göre en iyi başarıyı 7.54 ile Stacked\_Bi\_GRU (100 öğrenme adımı) modeli elde etmiştir. Bu modelin MSE skoru 56.84, MAE skoru ise 4.43 olmuştur. RMSE skoruna göre en düşük başarı ise 7.65'lik skor ile Stacked\_SimpleRNN (600 öğrenme adımı) modelinin olmuştur. Bu modelin MSE skoru 58.59 ve MAE skoru ise 4.19 olmuştur. Bu tez çalışmasında ilk onda en iyi ve en kötü başarıyı elde etmiş olan modeller, Yorulmuş ve arkadaşlarının (2018) farklı özellikler ve tarih aralığı kullanarak yaptıkları çalışmanın en iyi RMSE skoru olan 25.06 ve 17.2'lik MAE skoruna göre daha iyi sonuçlar elde etmiştir. Ayrıca, yine Türkiye elektrik piyasası için yapılan bir diğer çalışma Uğurlu ve arkadaşları (2018) tarafından farklı özellikler ve tarih aralığı kullanarak yapılmış ve GRU ağı için MAE skoru 5.71 olmuştur. Bu tez çalışmasında ilk 10 model arasına giren GRU modelinin (500 öğrenme adımı) 4.48'lik MAE skoru, literatüre göre yine daha başarılı sonuç vermiştir. Öksüz ve Uğurlu (2019) ise çalışmalarında GRU modeli için 6.857'lik RMSE 4.39'luk MAE skorları elde etmişlerdir. Bu tez çalışmasında RNN tabanlı modeller arasında 4.09'luk MAE skoru ile en iyi MAE skoruna sahip olan Stacked\_SimpleRNN (500 öğrenme adımı) skorundan daha kötü bir skor elde edilmiştir. Ancak RMSE skoru bu tez çalışmasında RNN tabanlı modellerin elde ettiği RMSE skorlarından daha iyi bir skor olmuştur.

Yukarıda tartışılan tüm bu sonuçlar ele alındığında, bu çalışmada oluşturulmuş olan öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü model (700 öğrenme adımı), ele alınan diğer tüm modellerden çok daha iyi sonuçlar vermiştir. Elde edilen sonuçlar, MAE skoru için 2.82, MSE skoru için 9.87,  $R^2$  skoru için 0.94 ve RMSE skoru için 3.14 olarak hesaplanmıştır. Ayrıca model, 100 öğrenme adımı haricindeki tüm modeller için, tüm öğrenme adımı sayılarında ilk 9 da yer almıştır. Modelin 9. sıradaki öğrenme adımı sayısı 200 ve MAE skoru 4.14, MSE skoru 44,27, RMSE skoru 6.65 ve  $R^2$  skoru ise 0.89 olmuştur. Bu skorlar, Dönüştürücü ağların Öz-Dikkat Katmanı ile ne kadar güçlendiğini göstermektedir. Bu tez çalışmasında, Öz-Dikkat katmanı olmadan elde edilen sonuçlara, düşük performans göstermeleri nedeni ile yer verilmemiştir. Ancak öz-dikkat katmanının

olması durumunda skorlarda yaklaşık 10 kat iyileşme kaydedilmiştir. Bu tez çalışması ile geliştirilen den elde edilen başarılı sonuçlar, literatürde oldukça ses getiren Vaswani arkadaşlarının (2017) kaleme aldıkları “*Attention is all you need*” isimli makalenin sonuçlarını desteklemektedir.

Bu çalışmada ulaşılan sonuçlara göre öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü model hem çok başarılı çıktılar vermiş hem de tekrarlayan katmanlardan (RNN) çok daha hızlı çalışmıştır.

Seçilen tarih aralığının Covid-19 gibi sıra dışı bir dönemi içeriyor olması çalışmanın sonuçlarını olumsuz olarak etkileyecek bir faktör olarak görünse de farklı yöntemler uygulanarak bu sorun ile başa çıkabilecek modeller oluşturulmuştur. Örneğin, bu çalışmada, COVID-19 kukla değişkenine göre gruplama yapması sağlanmış ve bu yolla modelin, alt dönem verisini de dikkate alarak daha tutarlı tahminler yapabilmesi mümkün olmuştur.

Bu alanda ileride yapılacak çalışmalar için öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü model ile enerji arz ve talep tahmininin de başarılı bir şekilde yapılabileceği düşünülmektedir. Bu modelin, hızlı çözümleme kapasitesi ve tahmin doğruluğu nedeniyle Gün İçi Piyasasında elektrik fiyat tahmini için uygulanabilirliği de tartışılmalıdır. Modele eklenen gruplama özelliği sayesinde, alt piyasaları olan elektrik piyasaları için hem üst hem de her bir alt piyasa için veriyi değiştirmeden tahmin edebileceği de ayrıca değerlendirilmelidir. Öz-dikkat katmanlı dönüştürücü kodlayıcı-çözücü modelin uygulama alanları sadece enerji alanı ile sınırlı değildir benzer yapıları nedeni ile finans, sigorta ve tedarik zinciri gibi diğer alanlardaki zaman serisi problemleri için de rahatlıkla uygulanabileceği öngörülmektedir.

## KAYNAKÇA

- Abedinia, O, Amjady, Nima, Shafie-Khah, Miadreza, & Catalão, Joao PS. (2015). Electricity price forecast using combinatorial neural network trained by a new stochastic search method. *Energy conversion and management*, 105, 642-654.
- Amjady, Nima. (2006). Day-ahead price forecasting of electricity markets by a new fuzzy neural network. *IEEE Transactions on power systems*, 21(2), 887-896.
- Angamuthu Chinnathambi, Radhakrishnan, Mukherjee, Anupam, Campion, Mitch, Salehfar, Hossein, Hansen, Timothy M, Lin, Jeremy, & Ranganathan, Prakash. (2018). A multi-stage price forecasting model for day-ahead electricity markets. *Forecasting*, 1(1), 26-46.
- Angamuthu Chinnathambi, Radhakrishnan, Mukherjee, Anupam, Campion, Mitch, Salehfar, Hossein, Hansen, Timothy M, Lin, Jeremy, & Ranganathan, Prakash. (2019). A multi-stage price forecasting model for day-ahead electricity markets. *Forecasting*, 1(1), 26-46.
- Azevedo, Filipe, & Vale, Zita A. (2006). *Forecasting electricity prices with historical statistical information using neural networks and clustering techniques*. Paper presented at the 2006 IEEE PES Power Systems Conference and Exposition.
- Bento, PMR, Pombo, JAN, Calado, MRA, & Mariano, SJPS. (2018). A bat optimized neural network and wavelet transform approach for short-term price forecasting. *Applied Energy*, 210, 88-97.
- Catalão, João Paulo da Silva, Mariano, Sílvia José Pinto Simões, Mendes, VMF, & Ferreira, LAFM. (2007). Short-term electricity prices forecasting in a competitive market: A neural network approach. *electric power systems research*, 77(10), 1297-1304.
- Cerjan, Marin, Petričić, Ana, & Delimar, Marko. (2019). HIRA model for short-term electricity price forecasting. *Energies*, 12(3), 568.
- Crevier, Daniel. (1993). *AI: the tumultuous history of the search for artificial intelligence*: Basic Books, Inc.
- Dikbaş, Tuğçe. (2019). *Türkiye elektrik piyasasında fiyat oluşumunun analizi, fiyat tahmin modelleri: Türkiye uygulaması*. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü,
- Escribano, Alvaro, Ignacio Peña, J, & Villaplana, Pablo. (2011). Modelling electricity prices: International evidence. *Oxford bulletin of economics and statistics*, 73(5), 622-650.
- Fanone, Enzo, Gamba, Andrea, & Prokopczuk, Marcel. (2013). The case of negative day-ahead electricity prices. *Energy Economics*, 35, 22-34.
- Feijoo, Felipe, Silva, Walter, & Das, Tapas K. (2016). A computationally efficient electricity price forecasting model for real time energy markets. *Energy conversion and management*, 113, 27-35.
- Gao, Gao, Lo, Kwoklun, & Fan, Fulin. (2017). Comparison of ARIMA and ANN models used in electricity price forecasting for power market. *Energy and Power Engineering*, 9(4B), 120-126.

- Georgilakis, Pavlos S. (2006). *Market clearing price forecasting in deregulated electricity markets using adaptively trained neural networks*. Paper presented at the Hellenic Conference on Artificial Intelligence.
- Gholipour Khajeh, Morteza, Maleki, Akbar, Rosen, Marc A, & Ahmadi, Mohammad H. (2018). Electricity price forecasting using neural networks with an improved iterative training algorithm. *International Journal of Ambient Energy*, 39(2), 147-158.
- Gollou, Abbas Rahimi, & Ghadimi, Noradin. (2017). A new feature selection and hybrid forecast engine for day-ahead price forecasting of electricity markets. *Journal of Intelligent & Fuzzy Systems*, 32(6), 4031-4045.
- Gökgöz, F, & Filiz, Fahrettin. (2016). Electricity price forecasting in Turkey with artificial neural network models. *Investment management and financial innovations*(13, Iss. 3 (contin. 1)), 150-158.
- Härdle, Wolfgang K, & Trück, Stefan. (2010). The dynamics of hourly electricity prices.
- Hebb, Donald O. (1949). The organization of behavior; a neuropsychological theory. *A Wiley Book in Clinical Psychology.*, 62-78.
- Huisman, Ronald, Hurman, Christian, & Mahieu, Ronald. (2007). Hourly electricity prices in day-ahead markets. *Energy Economics*, 29(2), 240-248.
- Jiang, LianLian, & Hu, Guoqiang. (2018). *Day-ahead price forecasting for electricity market using long-short term memory recurrent neural network*. Paper presented at the 2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV).
- Karakatsani, Nektaria V, & Bunn, Derek W. (2008). Forecasting electricity prices: The impact of fundamentals and time-varying coefficients. *International journal of forecasting*, 24(4), 764-785.
- Keles, Dogan, Scelle, Jonathan, Paraschiv, Florentina, & Fichtner, Wolf. (2016). Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks. *Applied Energy*, 162, 218-230.
- Korpihalkola, Joni. (2019). Forecasting Nord Pool's Day-ahead hourly spot prices in Finland.
- Kölmek, Mehmet Ali, & Navruz, İsa. (2015). Forecasting the day-ahead price in electricity balancing and settlement market of Turkey by using artificial neural networks. *Turkish Journal of Electrical Engineering & Computer Sciences*, 23(3), 841-852.
- Kristiansen, Tarjei. (2018). Forecasting Nord Pool day-ahead prices with Python. *The Python Papers*, 12(1).
- Kuo, Ping-Huan, & Huang, Chiou-Jye. (2018). An electricity price forecasting model by hybrid structured deep neural networks. *Sustainability*, 10(4), 1280.
- Lago, Jesus, De Ridder, Fjo, & De Schutter, Bart. (2018). Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221, 386-405.
- London, Ian. (2016). Encoding cyclical continuous features - 24-hour time. Retrieved from <https://ianlondon.github.io/blog/encoding-cyclical-features-24hour-time/>
- Mandal, Paras, Senjyu, Tomonobu, Urasaki, Naomitsu, Funabashi, Toshihisa, & Srivastava, Anurag K. (2007). A novel approach to forecast electricity price for PJM using neural network and similar days method. *IEEE Transactions on power systems*, 22(4), 2058-2065.

- Manner, Hans, Türk, Dennis, & Eichler, Michael. (2016). Modeling and forecasting multivariate electricity price spikes. *Energy Economics*, 60, 255-265.
- McCarthy, John, Minsky, Marvin L, Rochester, Nathaniel, & Shannon, Claude E. (1955). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- McDermott, John. (1981). R1: The formative years. *AI magazine*, 2(2), 21-21.
- Nabiyev, V. V. . (2012). *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi.*: Seçkin Yayıncılık.
- Neupane, Bijay, Perera, Kasun S, Aung, Zeyar, & Woon, Wei Lee. (2012). *Artificial neural network-based electricity price forecasting for smart grid deployment*. Paper presented at the 2012 International Conference on Computer Systems and Industrial Informatics.
- Neupane, Bijay, Woon, Wei Lee, & Aung, Zeyar. (2017). Ensemble prediction model with expert selection for electricity price forecasting. *Energies*, 10(1), 77.
- Oksuz, Ilkay, & Ugurlu, Umut. (2019). Neural network based model comparison for intraday electricity price forecasting. *Energies*, 12(23), 4557.
- Pino, Raúl, Parreno, Jose, Gomez, Alberto, & Priore, Paolo. (2008). Forecasting next-day price of electricity in the Spanish energy market using artificial neural networks. *Engineering Applications of Artificial Intelligence*, 21(1), 53-62.
- Polson, Michael, & Sokolov, Vadim. (2020). Deep learning for energy markets. *Applied Stochastic Models in Business and Industry*, 36(1), 195-209.
- Rafiei, Mehdi, Niknam, Taher, & Khooban, Mohammad-Hassan. (2016). Probabilistic forecasting of hourly electricity price by generalization of ELM for usage in improved wavelet neural network. *IEEE Transactions on Industrial Informatics*, 13(1), 71-79.
- Raviv, Eran, Bouwman, Kees E, & Van Dijk, Dick. (2015). Forecasting day-ahead electricity prices: Utilizing hourly prices. *Energy Economics*, 50, 227-239.
- Singh, Nitin, Mohanty, Soumya Ranjan, & Shukla, Rishabh Dev. (2017). Short term electricity price forecast based on environmentally adapted generalized neuron. *Energy*, 125, 127-139.
- Ugurlu, Umut, Ulengin, Burc, & Tas, Oktay. (2016). *Basic Time Series Patterns of Turkish Electricity Prices*. Paper presented at the The 2016 WEI International Academic Conference Proceedings.
- Uğurlu, Umut, Öksüz, Ilkay, & Taş, Oktay. (2018). Electricity price forecasting using recurrent neural networks. *Energies*, 11(5), 1255.
- Vaswani, Ashish, Shazeer, Noam, Parmar, Niki, Uszkoreit, Jakob, Jones, Llion, Gomez, Aidan N, . . . Polosukhin, Illia. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Wang, Jianzhou, Liu, Feng, Song, Yiliao, & Zhao, Jing. (2016). A novel model: Dynamic choice artificial neural network (DCANN) for an electricity price forecasting system. *Applied Soft Computing*, 48, 281-297.
- Weron, Rafal. (2006). Modeling and Forecasting Electricity Loads and Prices: A Statistical Approach.
- Weron, Rafał. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International journal of forecasting*, 30(4), 1030-1081.
- Weron, Rafał, & Misiorek, Adam. (2008). Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models. *International journal of forecasting*, 24(4), 744-763.

- Wu, Neo, Green, Bradley, Ben, Xue, & O'Banion, Shawn. (2020). Deep transformer models for time series forecasting: The influenza prevalence case. *arXiv preprint arXiv:2001.08317*.
- Yilmaz, Mustafa Kemal. (2018). Market efficiency and risk premium in the Turkish wholesale electricity market.
- Yorulmuş, Hakan, Uğurlu, Umut, & Taş, Oktay. (2018). *A LONG SHORT TERM MEMORY APPLICATION ON THE TURKISH INTRADAY ELECTRICITY PRICE FORECASTING*. Paper presented at the PressAcademia Procedia.
- Zahid, Maheen, Ahmed, Fahad, Javaid, Nadeem, Abbasi, Raza Abid, Zainab Kazmi, Hafiza Syeda, Javaid, Atia, . . . Ilahi, Manzoor. (2019). Electricity price and load forecasting using enhanced convolutional neural network and enhanced support vector regression in smart grids. *Electronics*, 8(2), 122.
- Ziel, Florian, & Weron, Rafał. (2018). Day-ahead electricity price forecasting with high-dimensional structures: Univariate vs. multivariate modeling frameworks. *Energy Economics*, 70, 396-420.



## EKLER

### EK A. On üç Farklı Model için Tüm Öğrenme Adımlarından Elde Edilen Sonuçlar

| Öğrenme Adımı Sayısı | Model Adı                   | Genel Başarı | Model Grubu İçin Öğrenme Adımı Başarı Sırlaması | MAE  | MSE    | RMSE   | R <sup>2</sup> |
|----------------------|-----------------------------|--------------|-------------------------------------------------|------|--------|--------|----------------|
| 700                  | Transformer Encoder-Decoder | 1            | 1                                               | 2,82 | 9,87   | 3,14   | 0,94           |
| 100                  | Stacked_Bi_GRU              | 10           | 1                                               | 4,43 | 56,84  | 7,54   | 0,85           |
| 800                  | Stacked_SimpleRNN           | 11           | 1                                               | 4,18 | 57,25  | 7,57   | 0,85           |
| 500                  | Stacked_GRU                 | 13           | 1                                               | 4,15 | 57,91  | 7,61   | 0,84           |
| 500                  | GRU                         | 14           | 1                                               | 4,48 | 57,99  | 7,61   | 0,84           |
| 100                  | Bi_GRU                      | 15           | 1                                               | 4,54 | 58     | 7,62   | 0,84           |
| 300                  | Stacked_LSTM                | 23           | 1                                               | 4,12 | 59,17  | 7,69   | 0,84           |
| 600                  | LSTM                        | 26           | 1                                               | 4,49 | 59,18  | 7,69   | 0,84           |
| 500                  | Bi_LSTM                     | 35           | 1                                               | 4,59 | 60,2   | 7,76   | 0,84           |
| 600                  | SimpleRNN                   | 37           | 1                                               | 4,64 | 60,19  | 7,76   | 0,84           |
| 200                  | Stacked_Bi_LSTM             | 91           | 1                                               | 4,96 | 69,06  | 8,31   | 0,81           |
| 100                  | CNN_GRU                     | 103          | 1                                               | 6,06 | 86,15  | 9,28   | 0,77           |
| 100                  | CNN_LSTM                    | 111          | 1                                               | 7,57 | 151,87 | 12,32  | 0,59           |
| 400                  | Transformer Encoder-Decoder | 2            | 2                                               | 3,94 | 19,22  | 4,3836 | 0,91           |
| 900                  | Stacked_SimpleRNN           | 12           | 2                                               | 4,17 | 57,7   | 7,6    | 0,85           |
| 400                  | GRU                         | 16           | 2                                               | 4,62 | 58,09  | 7,62   | 0,84           |
| 400                  | Stacked_GRU                 | 17           | 2                                               | 4,11 | 58,19  | 7,63   | 0,84           |
| 500                  | Stacked_LSTM                | 24           | 2                                               | 4,12 | 59,09  | 7,69   | 0,84           |
| 500                  | LSTM                        | 31           | 2                                               | 4,55 | 59,59  | 7,72   | 0,84           |
| 1000                 | SimpleRNN                   | 36           | 2                                               | 4,61 | 60,29  | 7,76   | 0,84           |
| 200                  | Bi_LSTM                     | 41           | 2                                               | 4,74 | 60,59  | 7,78   | 0,84           |
| 200                  | Bi_GRU                      | 46           | 2                                               | 4,65 | 60,87  | 7,8    | 0,84           |
| 200                  | Stacked_Bi_GRU              | 56           | 2                                               | 4,71 | 61,25  | 7,83   | 0,84           |
| 100                  | Stacked_Bi_LSTM             | 95           | 2                                               | 5,07 | 72,32  | 8,5    | 0,81           |
| 200                  | CNN_GRU                     | 110          | 2                                               | 7,48 | 150,81 | 12,28  | 0,6            |
| 1000                 | CNN_LSTM                    | 121          | 2                                               | 8,35 | 200,18 | 14,15  | 0,46           |

| Öğrenme Adımı Sayısı | Model Adı                   | Genel Başarı | Model Grubu İçin Öğrenme Adımı Başarı Sıralaması | MAE  | MSE    | RMSE  | R <sup>2</sup> |
|----------------------|-----------------------------|--------------|--------------------------------------------------|------|--------|-------|----------------|
| 300                  | Transformer Encoder-Decoder | 3            | 3                                                | 3,95 | 20,35  | 4,51  | 0,91           |
| 500                  | Stacked_SimpleRNN           | 18           | 3                                                | 4,09 | 58,33  | 7,64  | 0,84           |
| 600                  | Stacked_GRU                 | 19           | 3                                                | 4,1  | 58,47  | 7,65  | 0,84           |
| 900                  | GRU                         | 28           | 3                                                | 4,29 | 59,35  | 7,7   | 0,84           |
| 400                  | Stacked_LSTM                | 30           | 3                                                | 4,2  | 59,61  | 7,72  | 0,84           |
| 300                  | LSTM                        | 40           | 3                                                | 4,41 | 60,48  | 7,78  | 0,84           |
| 400                  | SimpleRNN                   | 44           | 3                                                | 4,67 | 60,62  | 7,79  | 0,84           |
| 800                  | Bi_GRU                      | 52           | 3                                                | 4,35 | 61,26  | 7,83  | 0,84           |
| 300                  | Stacked_Bi_GRU              | 63           | 3                                                | 4,67 | 62,43  | 7,9   | 0,83           |
| 400                  | Bi_LSTM                     | 67           | 3                                                | 4,86 | 62,52  | 7,91  | 0,83           |
| 600                  | Stacked_Bi_LSTM             | 94           | 3                                                | 5,06 | 72,2   | 8,5   | 0,81           |
| 300                  | CNN_GRU                     | 112          | 3                                                | 7,64 | 160,36 | 12,66 | 0,57           |
| 600                  | CNN_LSTM                    | 122          | 3                                                | 8,49 | 202,36 | 14,23 | 0,46           |
| 800                  | Transformer Encoder-Decoder | 4            | 4                                                | 3,95 | 21,04  | 4,57  | 0,92           |
| 600                  | Stacked_SimpleRNN           | 20           | 4                                                | 4,19 | 58,59  | 7,65  | 0,84           |
| 800                  | GRU                         | 32           | 4                                                | 4,58 | 59,78  | 7,73  | 0,84           |
| 200                  | Stacked_LSTM                | 33           | 4                                                | 4,27 | 59,88  | 7,74  | 0,84           |
| 900                  | Stacked_GRU                 | 34           | 4                                                | 4,29 | 60,06  | 7,75  | 0,84           |
| 700                  | LSTM                        | 43           | 4                                                | 4,62 | 60,75  | 7,79  | 0,84           |
| 500                  | SimpleRNN                   | 51           | 4                                                | 4,66 | 61,09  | 7,82  | 0,84           |
| 400                  | Stacked_Bi_GRU              | 68           | 4                                                | 4,69 | 62,78  | 7,92  | 0,83           |
| 700                  | Bi_GRU                      | 74           | 4                                                | 4,7  | 63,17  | 7,95  | 0,83           |
| 700                  | Bi_LSTM                     | 83           | 4                                                | 4,86 | 66,22  | 8,14  | 0,82           |
| 300                  | Stacked_Bi_LSTM             | 99           | 4                                                | 5,21 | 77,4   | 8,8   | 0,79           |
| 600                  | CNN_GRU                     | 113          | 4                                                | 7,9  | 170,62 | 13,06 | 0,54           |
| 800                  | CNN_LSTM                    | 123          | 4                                                | 8,47 | 205,98 | 14,35 | 0,45           |
| 1000                 | Transformer Encoder-Decoder | 5            | 5                                                | 3,96 | 24,26  | 4,93  | 0,91           |
| 400                  | Stacked_SimpleRNN           | 21           | 5                                                | 4,16 | 58,74  | 7,66  | 0,84           |
| 800                  | Stacked_GRU                 | 39           | 5                                                | 4,26 | 60,55  | 7,78  | 0,84           |
| 600                  | Stacked_LSTM                | 42           | 5                                                | 4,09 | 60,71  | 7,79  | 0,84           |
| 400                  | LSTM                        | 48           | 5                                                | 4,54 | 61,02  | 7,81  | 0,84           |
| 100                  | GRU                         | 58           | 5                                                | 4,67 | 61,5   | 7,84  | 0,84           |
| 700                  | SimpleRNN                   | 59           | 5                                                | 4,73 | 61,55  | 7,85  | 0,84           |
| 300                  | Bi_GRU                      | 76           | 5                                                | 4,78 | 63,4   | 7,96  | 0,83           |
| 500                  | Stacked_Bi_GRU              | 79           | 5                                                | 4,83 | 64,92  | 8,06  | 0,83           |
| 300                  | Bi_LSTM                     | 86           | 5                                                | 5,01 | 67,79  | 8,23  | 0,82           |

| Öğrenme Adımı Sayısı | Model Adı                   | Genel Başarı | Model Grubu İçin Öğrenme Adımı Başarı Sıralaması | MAE  | MSE    | RMSE  | R <sup>2</sup> |
|----------------------|-----------------------------|--------------|--------------------------------------------------|------|--------|-------|----------------|
| 400                  | Stacked_Bi_LSTM             | 101          | 5                                                | 5,25 | 79,13  | 8,9   | 0,79           |
| 700                  | CNN_GRU                     | 115          | 5                                                | 7,96 | 171,5  | 13,1  | 0,54           |
| 300                  | CNN_LSTM                    | 124          | 5                                                | 8,68 | 208,8  | 14,45 | 0,44           |
| 600                  | Transformer Encoder-Decoder | 6            | 6                                                | 3,98 | 29,92  | 5,47  | 0,87           |
| 700                  | Stacked_SimpleRNN           | 22           | 6                                                | 4,12 | 58,99  | 7,68  | 0,84           |
| 300                  | Stacked_GRU                 | 45           | 6                                                | 4,09 | 60,79  | 7,8   | 0,84           |
| 100                  | Stacked_LSTM                | 49           | 6                                                | 4,13 | 61,2   | 7,82  | 0,84           |
| 900                  | LSTM                        | 50           | 6                                                | 4,63 | 61,21  | 7,82  | 0,84           |
| 900                  | SimpleRNN                   | 60           | 6                                                | 4,68 | 61,74  | 7,86  | 0,83           |
| 300                  | GRU                         | 62           | 6                                                | 4,58 | 62,11  | 7,88  | 0,83           |
| 500                  | Bi_GRU                      | 78           | 6                                                | 4,78 | 64,27  | 8,02  | 0,83           |
| 600                  | Stacked_Bi_GRU              | 88           | 6                                                | 4,9  | 68     | 8,25  | 0,82           |
| 100                  | Bi_LSTM                     | 90           | 6                                                | 5    | 68,88  | 8,3   | 0,82           |
| 500                  | Stacked_Bi_LSTM             | 104          | 6                                                | 5,55 | 90,07  | 9,49  | 0,76           |
| 900                  | CNN_GRU                     | 116          | 6                                                | 7,89 | 172,3  | 13,13 | 0,54           |
| 500                  | CNN_LSTM                    | 125          | 6                                                | 8,68 | 209,59 | 14,48 | 0,44           |
| 900                  | Transformer Encoder-Decoder | 7            | 7                                                | 4,13 | 37,81  | 6,17  | 0,89           |
| 200                  | Stacked_SimpleRNN           | 25           | 7                                                | 4,33 | 59,12  | 7,69  | 0,84           |
| 700                  | Stacked_GRU                 | 47           | 7                                                | 4,18 | 61,01  | 7,81  | 0,84           |
| 200                  | LSTM                        | 55           | 7                                                | 4,66 | 61,32  | 7,83  | 0,84           |
| 600                  | GRU                         | 61           | 7                                                | 4,5  | 62,05  | 7,88  | 0,83           |
| 300                  | SimpleRNN                   | 66           | 7                                                | 4,76 | 62,61  | 7,91  | 0,83           |
| 1000                 | Stacked_LSTM                | 73           | 7                                                | 4,15 | 63,25  | 7,95  | 0,83           |
| 900                  | Bi_GRU                      | 80           | 7                                                | 4,84 | 65,32  | 8,08  | 0,82           |
| 900                  | Bi_LSTM                     | 93           | 7                                                | 4,98 | 69,87  | 8,36  | 0,81           |
| 700                  | Stacked_Bi_GRU              | 100          | 7                                                | 5,32 | 78,7   | 8,87  | 0,79           |
| 1000                 | Stacked_Bi_LSTM             | 105          | 7                                                | 5,86 | 97,91  | 9,89  | 0,74           |
| 400                  | CNN_GRU                     | 117          | 7                                                | 8    | 174,11 | 13,19 | 0,53           |
| 200                  | CNN_LSTM                    | 126          | 7                                                | 8,72 | 211,38 | 14,54 | 0,43           |
| 500                  | Transformer Encoder-Decoder | 8            | 8                                                | 4,13 | 41,93  | 6,48  | 0,89           |
| 100                  | Stacked_SimpleRNN           | 29           | 8                                                | 4,31 | 59,28  | 7,7   | 0,84           |
| 1000                 | Stacked_GRU                 | 53           | 8                                                | 4,35 | 61,23  | 7,83  | 0,84           |
| 800                  | LSTM                        | 54           | 8                                                | 4,62 | 61,32  | 7,83  | 0,84           |
| 700                  | GRU                         | 65           | 8                                                | 4,55 | 62,51  | 7,91  | 0,83           |
| 800                  | SimpleRNN                   | 69           | 8                                                | 4,83 | 62,74  | 7,92  | 0,83           |
| 400                  | Bi_GRU                      | 82           | 8                                                | 4,86 | 66,03  | 8,13  | 0,82           |

| Öğrenme Adımı Sayısı | Model Adı                   | Genel Başarı | Model Grubu İçin Öğrenme Adımı Başarı Sıralaması | MAE  | MSE    | RMSE  | R <sup>2</sup> |
|----------------------|-----------------------------|--------------|--------------------------------------------------|------|--------|-------|----------------|
| 900                  | Stacked_LSTM                | 87           | 8                                                | 4,78 | 68,11  | 8,25  | 0,82           |
| 600                  | Bi_LSTM                     | 96           | 8                                                | 5,13 | 72,67  | 8,52  | 0,81           |
| 800                  | Stacked_Bi_GRU              | 102          | 8                                                | 5,46 | 85,9   | 9,27  | 0,77           |
| 800                  | Stacked_Bi_LSTM             | 106          | 8                                                | 5,77 | 98,95  | 9,95  | 0,73           |
| 800                  | CNN_GRU                     | 118          | 8                                                | 7,96 | 177,93 | 13,34 | 0,52           |
| 700                  | CNN_LSTM                    | 127          | 8                                                | 8,63 | 212,45 | 14,58 | 0,43           |
| 200                  | Transformer Encoder-Decoder | 9            | 9                                                | 4,14 | 44,27  | 6,65  | 0,89           |
| 300                  | Stacked_SimpleRNN           | 27           | 9                                                | 4,11 | 59,28  | 7,7   | 0,84           |
| 200                  | Stacked_GRU                 | 57           | 9                                                | 4,08 | 61,4   | 7,84  | 0,84           |
| 100                  | LSTM                        | 64           | 9                                                | 4,82 | 62,49  | 7,9   | 0,83           |
| 1000                 | GRU                         | 71           | 9                                                | 4,53 | 63,11  | 7,94  | 0,83           |
| 100                  | SimpleRNN                   | 72           | 9                                                | 4,92 | 63,05  | 7,94  | 0,83           |
| 600                  | Bi_GRU                      | 84           | 9                                                | 4,95 | 66,31  | 8,14  | 0,82           |
| 800                  | Stacked_LSTM                | 89           | 9                                                | 4,47 | 68,6   | 8,28  | 0,82           |
| 800                  | Bi_LSTM                     | 97           | 9                                                | 5,25 | 74,79  | 8,65  | 0,8            |
| 900                  | Stacked_Bi_GRU              | 107          | 9                                                | 5,94 | 105,77 | 10,28 | 0,72           |
| 700                  | Stacked_Bi_LSTM             | 108          | 9                                                | 5,86 | 118,47 | 10,88 | 0,68           |
| 500                  | CNN_GRU                     | 119          | 9                                                | 8,09 | 179,76 | 13,41 | 0,52           |
| 400                  | CNN_LSTM                    | 128          | 9                                                | 8,84 | 217,47 | 14,75 | 0,42           |
| 1000                 | Stacked_SimpleRNN           | 38           | 10                                               | 4,28 | 60,34  | 7,77  | 0,84           |
| 100                  | Stacked_GRU                 | 70           | 10                                               | 4,17 | 62,89  | 7,93  | 0,83           |
| 200                  | GRU                         | 75           | 10                                               | 4,73 | 63,32  | 7,96  | 0,83           |
| 200                  | SimpleRNN                   | 77           | 10                                               | 4,93 | 63,45  | 7,97  | 0,83           |
| 1000                 | LSTM                        | 81           | 10                                               | 4,64 | 65,45  | 8,09  | 0,82           |
| 1000                 | Bi_GRU                      | 85           | 10                                               | 4,9  | 66,41  | 8,15  | 0,82           |
| 700                  | Stacked_LSTM                | 92           | 10                                               | 4,47 | 69,6   | 8,34  | 0,81           |
| 1000                 | Bi_LSTM                     | 98           | 10                                               | 5,18 | 75,3   | 8,68  | 0,8            |
| 100                  | Transformer Encoder-Decoder | 109          | 10                                               | 5,94 | 127,39 | 11,29 | 0,71           |
| 1000                 | Stacked_Bi_GRU              | 114          | 10                                               | 6,72 | 171,58 | 13,1  | 0,54           |
| 1000                 | CNN_GRU                     | 120          | 10                                               | 7,93 | 182,2  | 13,5  | 0,51           |
| 900                  | CNN_LSTM                    | 129          | 10                                               | 8,79 | 221,34 | 14,88 | 0,41           |
| 900                  | Stacked_Bi_LSTM             | 130          | 10                                               | 8,17 | 328,81 | 18,13 | 0,12           |