

**DERİN ÖĞRENME YAKLAŞIMI İLE DÖVİZ KURU TAHMİNİ:  
TÜRKİYE ÖRNEĞİ**

**Pamukkale Üniversitesi  
Sosyal Bilimler Enstitüsü  
Doktora Tezi  
İktisat Anabilim Dalı  
İktisat Programı**

---

**Cihat KARADEMİR**

**Danışman: Prof. Dr. Reşat CEYLAN**

**Şubat 2025  
DENİZLİ**

## **ETİK**

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bilimsel etiğe ve akademik kurallara özenle riayet edildiğini; bu çalışmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etiğe uygun olarak kaynak gösterildiğini ve alıntı yapılan çalışmalara atıfta bulunulduğunu beyan ederim.

İmza

Cihat KARADEMİR

## ÖN SÖZ

Hayatım boyunca bana rehberlik eden, ilham veren ve bu akademik yolculukta şevkle ilerlememi sağlayan bütün kişilere en içten teşekkürlerimi sunuyorum.

Başta, büyük önder Gazi Mustafa Kemal Atatürk'e, bilim ve aklı ön plana koyan vizyonu ile bu ülkede bilim insanı olarak katkı sağlayabilmeme imkân tanıdığı için sonsuz minnettarlık duyuyorum.

Bu tez, akademik hayatım boyunca bana rehberlik eden, fikirleri ve desteğiyle yolumu aydınlatan değerli hocam Prof. Dr. Reşat Ceylan'ın katkıları olmadan tamamlanamazdı. Kendisine engin bilgisi, sabrı ve yol göstericiliği için teşekkür ederim. Ayrıca, akademik gelişimime katkı sağlayan ve tez sürecinde kıymetli görüşleriyle bana destek olan Prof. Dr. M. Erdinç Telatar'a, Prof. Dr. Türkmen Göksel'e, Prof. Dr. Mehmet İvrendi'ye, Doç. Dr. M. Ozan Yıldırım'a ve Dr. Öğr. Üyesi Halil Uçal'a en derin teşekkürlerimi sunarım.

Bu uzun ve zorlu akademik yolculukta yanımda olan ve her daim manevi desteğini esirgemeyen sevgili eşime, fedakârlıkları ve özverisiyle bana yol gösteren kıymetli anneme ve her zaman yanımda olan değerli ağabeylerime teşekkür ederim.

Son olarak, hayatımda en derin iz bırakan, ne yazık ki bu gururu birlikte paylaşma şansını yakalayamadığım sevgili babama sonsuz teşekkürlerimi ve minnet duygularımı sunuyorum. Onun bana bıraktığı değerler ve öğütler, hayatımın her alanında bana rehber olmaya devam edecek.

## ÖZET

### DERİN ÖĞRENME YAKLAŞIMI İLE DÖVİZ KURU TAHMİNİ: TÜRKİYE ÖRNEĞİ

Karademir, Cihat

Doktora Tezi

İktisat ABD

Tez Yöneticisi: Prof. Dr. Reşat Ceylan

Şubat 2025, ix+138 sayfa

Bu tez, Türkiye ekonomisi bağlamında döviz kuru tahmini için derin öğrenme modellerinin etkinliğini incelemektedir. Döviz kuru, ekonomik istikrar ve makroekonomik politika kararlarında kritik bir değişken olup doğrusal olmayan dinamiklere sahip karmaşık bir süreçle belirlenmektedir. Geleneksel ekonometrik yöntemlerin bu karmaşıklığı yeterince yakalayamaması nedeniyle derin öğrenme teknikleri son yıllarda döviz kuru tahmininde giderek daha fazla tercih edilmektedir. Çalışmada, USD/TL ve EUR/TL döviz kurlarının tahmini için LSTM, GRU, Bi-LSTM, Bi-GRU gibi RNN tabanlı modellerin yanı sıra, CNN ile birleştirilmiş hibrit modeller kullanılmıştır. Araştırmada kullanılan veri seti, Türkiye Cumhuriyet Merkez Bankası'nın günlük kapanış fiyatlarından oluşmakta olup, Türkiye ekonomisindeki yapısal dönüşümlere göre üç dönemde analiz edilmiştir: 2001'de esnek kur rejimine geçiş, 2010'da finansal istikrar politikalarının uygulanmaya başlanması ve 2016 sonrası ekonomik dalgalanmalar. Bulgular, kısa vadeli analizlerde ani dalgalanmaların eğitim setine dahil edilmesinin modellerin performansını artırdığını, uzun vadeli analizlerde ise modellerin ani değişimlere daha duyarsız kaldığını göstermektedir. Özellikle uzun ve orta vadeli analizlerde CNN tabanlı hibrit modellerin özellik çıkarma yetenekleri sayesinde geleneksel RNN tabanlı modellere göre daha yüksek doğruluk sağladığı belirlenmiştir. Modellerin performansı MAE, MSE, RMSE ve  $R^2$  metrikleri ile değerlendirildiğinde, CNN/Bi-LSTM ve CNN/Bi-GRU gibi hibrit yaklaşımların en iyi tahmin sonuçlarını verdiği tespit edilmiştir. Bu çalışma, döviz kuru tahmininde derin öğrenmenin potansiyelini ortaya koymakta ve gelecekte bu alanda yapılacak çalışmalara ışık tutmaktadır.

**Anahtar Kelimeler:** Döviz Kuru, Döviz Kuru Tahmini, Derin Öğrenme, Hibrit Modeller

## ABSTRACT

### FOREIGN EXCHANGE RATE FORECASTING WITH DEEP LEARNING APPROACH: THE CASE OF TURKEY

Karademir, Cihat

Ph. D. Thesis

Department of Economics

Adviser of Thesis: Prof. Dr. Reşat Ceylan

February 2025, ix+138 pages

This thesis investigates the effectiveness of deep learning models for exchange rate forecasting in the context of the Turkish economy. The exchange rate is a critical variable in economic stability and macroeconomic policy decisions and is determined by a complex process with nonlinear dynamics. Since traditional econometric methods cannot adequately capture this complexity, deep learning techniques have been increasingly preferred in exchange rate forecasting in recent years. In this study, RNN-based models such as LSTM, GRU, Bi-LSTM, Bi-GRU as well as hybrid models combined with CNN are used to predict USD/TL and EUR/TL exchange rates. The data set used in the study consists of the daily closing prices of the Central Bank of the Republic of Turkey and is analyzed in three periods according to the structural transformations in the Turkish economy: The transition to a flexible exchange rate regime in 2001, the introduction of financial stability policies in 2010 and the economic fluctuations after 2016. The findings show that the inclusion of sudden fluctuations in the training set improves the performance of the models in short-term analyses, while in long-term analyses, the models are more insensitive to sudden changes. Especially in long-term and medium-term analyses, CNN-based hybrid models provide higher accuracy than traditional RNN-based models thanks to their feature extraction capabilities. When the performance of the models is evaluated with MAE, MSE, RMSE and  $R^2$  metrics, it is found that hybrid approaches such as CNN/Bi-LSTM and CNN/Bi-GRU provide the best prediction results. This study reveals the potential of deep learning in exchange rate forecasting and sheds light on future studies in this field.

**Keywords:** Exchange Rate, Exchange Rate Forecasting, Deep Learning, Hybrid Models

## İÇİNDEKİLER

|                          |      |
|--------------------------|------|
| ÖN SÖZ .....             | i    |
| ÖZET .....               | ii   |
| ABSTRACT.....            | iii  |
| İÇİNDEKİLER .....        | iv   |
| ŞEKİLLER DİZİNİ.....     | vii  |
| TABLolar DİZİNİ .....    | viii |
| KISALTMALAR DİZİNİ ..... | ix   |
| GİRİŞ .....              | 1    |

## BİRİNCİ BÖLÜM

### DÖVİZ KURU TANIMLARI VE DÖVİZ KURU DEĞİŞİMLERİNİ AÇIKLAYAN YAKLAŞIMLAR

|                                                    |    |
|----------------------------------------------------|----|
| 1.1.Döviz Kuru Tanımı.....                         | 4  |
| 1.1.1.Nominal Döviz Kuru .....                     | 4  |
| 1.1.2.Reel Döviz Kuru.....                         | 5  |
| 1.1.3.Reel Efektif Döviz Kuru.....                 | 5  |
| 1.2.Döviz Kuru Sistemleri.....                     | 6  |
| 1.2.1.Esnek Kur Sistemi .....                      | 6  |
| 1.2.2.Sabit Kur Sistemi.....                       | 7  |
| 1.2.3.Gözetimli Dalgalanma.....                    | 7  |
| 1.2.4.Aralık İçerisinde Dalgalanma.....            | 7  |
| 1.2.5.Kaygan Aralık.....                           | 8  |
| 1.2.6.Yönlendirilmiş Sabit Aralık.....             | 8  |
| 1.2.7.Yönlendirilmiş Sabit Parite .....            | 8  |
| 1.2.8.Ayarlanabilir Sabit Kur.....                 | 8  |
| 1.2.9.Para Kurulu.....                             | 8  |
| 1.2.10.Tam Dolarizasyon.....                       | 9  |
| 1.3.Döviz Kuru Değişimini Açıklayan Teoriler ..... | 9  |
| 1.3.1.Dış Ticaret Akımları Yaklaşımı .....         | 9  |
| 1.3.2.Satın Alma Gücü Paritesi Yaklaşımı.....      | 10 |
| 1.3.3.Faiz Oranı Paritesi Yaklaşımı .....          | 13 |
| 1.3.4.Parasalcı Yaklaşım.....                      | 17 |
| 1.3.5.Portföy Dengesi Yaklaşımı .....              | 21 |
| 1.3.6.Spekülatif Kabarcıklar Yaklaşımı.....        | 23 |
| 1.3.7.Döviz Kuruna Mikro Yaklaşım .....            | 24 |

## İKİNCİ BÖLÜM LİTERATÜR İNCELEMESİ VE VERİ SETİ

|                                 |    |
|---------------------------------|----|
| 2.1. Literatür İncelemesi ..... | 26 |
| 2.2. Veri Seti .....            | 50 |

## ÜÇÜNCÜ BÖLÜM YÖNTEM VE MODELLER

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| 3.1. Yapay Zekâ Nedir? .....                                                           | 56 |
| 3.2. Makine Öğrenmesi Nedir? .....                                                     | 57 |
| 3.3. Yapay Sinir Ağları Nedir? .....                                                   | 58 |
| 3.3.1. YSA Sisteminin İşleyişi .....                                                   | 60 |
| 3.4. Derin Öğrenme .....                                                               | 64 |
| 3.4.1. Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN) .....                  | 65 |
| 3.4.2. Uzun-Kısa Süreli Bellek (Long-Short Term Memory) .....                          | 67 |
| 3.4.3. Kapılı Tekrarlayan Ünite (Gated Recurrent Unit) .....                           | 69 |
| 3.4.4. Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long-Short Term Memory) ..... | 71 |
| 3.4.5. Çift Yönlü Kapılı Tekrarlayan Ünite (Bidirectional Gated Recurrent Unit) .....  | 72 |
| 3.5. Hibrit Modeller .....                                                             | 74 |
| 3.5.1. Evrişimli Sinir Ağları (Convolutional Neural Network) .....                     | 74 |
| 3.5.2. CNN/LSTM Hibrit Modeli .....                                                    | 76 |
| 3.5.3. CNN/GRU Hibrit Modeli .....                                                     | 76 |
| 3.5.4. CNN/Bi-LSTM Hibrit Modeli .....                                                 | 77 |
| 3.5.5. CNN/Bi-GRU Hibrit Modeli .....                                                  | 78 |
| 3.6. Model Başarı Ölçüm Metrikleri .....                                               | 79 |
| 3.6.1. Ortalama Mutlak Hata (Mean Absolute Error) .....                                | 79 |
| 3.6.2. Ortalama Kare Hata (Mean Squared Error) .....                                   | 80 |
| 3.6.3. Kök Ortalama Kare Hata (Root Mean Squared Error) .....                          | 80 |
| 3.6.4. Açıklama Katsayısı ( $R^2$ ) .....                                              | 80 |
| 3.7. Modeller .....                                                                    | 80 |

## DÖRDÜNCÜ BÖLÜM BULGULAR VE DEĞERLENDİRME

|                                               |     |
|-----------------------------------------------|-----|
| 4.1. Uzun Vadeli Sonuçlar .....               | 86  |
| 4.1.1. USD/TL İçin Uzun Vadeli Sonuçlar ..... | 88  |
| 4.1.2. EUR/TL İçin Uzun Vadeli Sonuçlar ..... | 93  |
| 4.2. Orta Vadeli Sonuçlar .....               | 98  |
| 4.2.1. USD/TL İçin Orta Vadeli Sonuçlar ..... | 100 |

|                                               |            |
|-----------------------------------------------|------------|
| 4.2.2. EUR/TL İçin Orta Vadeli Sonuçlar ..... | 104        |
| 4.3. Kısa Vadeli Sonuçlar .....               | 108        |
| 4.3.1. USD/TL İçin Kısa Vadeli Sonuçlar ..... | 110        |
| 4.3.2. EUR/TL İçin Kısa Vadeli Sonuçlar ..... | 114        |
| 4.4. Değerlendirme ve Öneriler.....           | 118        |
| <b>SONUÇ.....</b>                             | <b>122</b> |
| <b>KAYNAKLAR.....</b>                         | <b>126</b> |
| <b>ÖZ GEÇMİŞ.....</b>                         | <b>137</b> |

## ŞEKİLLER DİZİNİ

|                                                                            |     |
|----------------------------------------------------------------------------|-----|
| Şekil 1: Faiz Oranı Paritesi Yaklaşımı .....                               | 15  |
| Şekil 2: USD/TL ve EUR/TL Döviz Kurlarının Zaman İçerisindeki Seyri .....  | 51  |
| Şekil 3: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi..... | 56  |
| Şekil 4: Makine Öğrenimi Algoritmaları .....                               | 57  |
| Şekil 5: Yapay Sinir Ağı Nöronu.....                                       | 59  |
| Şekil 6: Yapay Sinir Ağlarının Yapısı.....                                 | 61  |
| Şekil 7: İleri Beslemeli ve Geri Beslemeli Mimari.....                     | 61  |
| Şekil 8: Yapay Zekânın Katmanları .....                                    | 64  |
| Şekil 9: Tekrarlayan Sinir Ağı (RNN) Mimarisi .....                        | 66  |
| Şekil 10: LSTM Modeli Hücre Yapısı .....                                   | 67  |
| Şekil 11: GRU Modeli Hücre Yapısı.....                                     | 69  |
| Şekil 12: Bi-LSTM Model Yapısı .....                                       | 71  |
| Şekil 13: Bi-GRU Model Yapısı.....                                         | 73  |
| Şekil 14: CNN Model Yapısı.....                                            | 75  |
| Şekil 15: CNN/LSTM Hibrit Model Yapısı .....                               | 76  |
| Şekil 16: CNN/GRU Hibrit Model Yapısı.....                                 | 77  |
| Şekil 17: CNN/Bi-LSTM Hibrit Model Yapısı .....                            | 77  |
| Şekil 18: CNN/Bi-GRU Hibrit Model Yapısı .....                             | 78  |
| Şekil 19: USD/TL Uzun Vadeli Sonuçlar .....                                | 92  |
| Şekil 20: EUR/TL Uzun Vadeli Sonuçlar.....                                 | 97  |
| Şekil 21: USD/TL Orta Vadeli Sonuçlar .....                                | 103 |
| Şekil 22: EUR/TL Orta Vadeli Sonuçlar .....                                | 107 |
| Şekil 23: USD/TL Kısa Vadeli Sonuçlar.....                                 | 113 |
| Şekil 24: EUR/TL Kısa Vadeli Sonuçlar.....                                 | 117 |

## TABLOLAR DİZİNİ

|                                                                                            |     |
|--------------------------------------------------------------------------------------------|-----|
| Tablo 1: Dış Ticaret Akımları Yaklaşımı.....                                               | 9   |
| Tablo 2: Literatür Özeti.....                                                              | 29  |
| Tablo 3: Tanımlayıcı İstatistikler.....                                                    | 54  |
| Tablo 4: Derin Öğrenme Model Parametreleri.....                                            | 81  |
| Tablo 5: Hibrit Derin Öğrenme Model Parametreleri .....                                    | 83  |
| Tablo 6: Uzun Dönem USD/TL ve EUR/TL Döviz Kurları Tanımlayıcı İstatistikleri ...          | 87  |
| Tablo 7: USD/TL Uzun Vadeli Sonuçlar.....                                                  | 89  |
| Tablo 8: EUR/TL Uzun Vadeli Sonuçlar.....                                                  | 95  |
| Tablo 9: Orta Vadeli Dönem USD/TL ve EUR/TL Döviz Kurları Tanımlayıcı İstatistikleri ..... | 100 |
| Tablo 10: USD/TL Orta Vadeli Sonuçlar .....                                                | 101 |
| Tablo 11: EUR/TL Orta Vadeli Sonuçlar .....                                                | 105 |
| Tablo 12: Kısa Vadeli Dönem USD/TL ve EUR/TL Döviz Kurları Tanımlayıcı İstatistikleri..... | 109 |
| Tablo 13: USD/TL Kısa Vadeli Sonuçlar .....                                                | 111 |
| Tablo 14: EUR/TL Kısa Vadeli Sonuçlar .....                                                | 115 |

## KISALTMALAR DİZİNİ

|         |                                           |
|---------|-------------------------------------------|
| ARIMA   | Otoregresif Bütünleşik Hareketli Ortalama |
| ARMA    | Otoregresif Hareketli Ortalama            |
| Bi-GRU  | Çift Yönlü Kapılı Tekrarlayan Ünite       |
| Bi-LSTM | Çift Yönlü Uzun Kısa Dönemli Bellek       |
| CNN     | Evrişimli Sinir Ağı                       |
| ECB     | Avrupa Merkez Bankası                     |
| FED     | Amerika Merkez Bankası                    |
| GRU     | Kapılı Tekrarlayan Ünite                  |
| LSTM    | Uzun Kısa Dönemli Bellek                  |
| MAE     | Ortalama Mutlak Hata                      |
| MSE     | Ortalama Kare Hata                        |
| RDK     | Reel Döviz Kuru                           |
| REDK    | Reel Efektif Döviz Kuru                   |
| RMSE    | Kök Ortalama Kare Hata                    |
| RNN     | Tekrarlayan Sinir Ağı                     |
| SAGP    | Satın Alma Gücü Paritesi                  |
| TCMB    | Türkiye Cumhuriyet Merkez Bankası         |
| YSA     | Yapay Sinir Ağı                           |

## GİRİŞ

Döviz kuru, ülkenin ekonomik dengesi üzerinde oldukça etkili olan bir makroekonomik değişken olarak hem teorik hem de pratik anlamda büyük önem taşımaktadır. Ulusal para birimleri arasındaki değeri ifade eden döviz kuru, sadece sermaye ve dış ticaret hareketlerini değil, aynı zamanda ekonomik birimlerin beklentilerini ve karar alma süreçlerini de doğrudan etkilemektedir. Bu özellikleri nedeniyle döviz kuru, ülkelerin makroekonomik politikalarının şekillenmesinde önemli bir araç haline gelmiştir.

Döviz kuru hareketlerini anlamak için çeşitli teoriler geliştirilmiştir. Satın Alma Gücü Paritesi yaklaşımı, ülkeler arasındaki fiyat düzeyi farklılıklarının döviz kurlarını belirlediğini ileri sürerken Faiz Oranı Paritesi yaklaşımı, döviz kurlarının iki ülke arasındaki faiz oranı farklılıklarına dayalı olarak belirlendiğini savunmaktadır. Parasalcı yaklaşım, para arzı ve para talebi çerçevesinde döviz kurlarını açıklarken Portföy Dengesi Yaklaşımı ise döviz kurlarını finansal varlıkların dengesi bağlamında ele almakta ve ekonomik birimlerin risk tercihlerine göre varlıklarını çeşitlendirerek döviz kuru hareketlerini etkilediğini öne sürmektedir. Bunlara ek olarak Spekülatif Kabarcıklar Teorisi piyasa aktörlerinin geleceğe yönelik öngörülerini dikkate alarak aşırı fiyat hareketlerini açıklamaktadır. Döviz kuruna Mikro Temelli Yaklaşım ise döviz piyasasında işlem yapan birimlerin davranışlarına, asimetric bilgiye ve alım-satım işlemlerine odaklanarak kısa vadeli dalgalanmaların incelenmesinde önemli katkılar sunmaktadır. Bu teoriler, döviz kurunun ekonomik değişkenlerle olan ilişkisini anlamada temel teşkil etmekte ve döviz kuru tahminine yönelik modelleme süreçlerine rehberlik etmektedir.

Döviz kurlarının dinamiklerini anlamak ve gelecekte alacağı değeri tahmin etmek, finans piyasalarının ve ekonomik birimlerin karşılaştığı en büyük zorluklardan biridir. Döviz kurlarını etkileyen faktörler arasında fiyat düzeyleri, dış ticaret hareketleri, faiz oranları, para arzı ve talebi, risk algısı ve beklentiler ön plana çıkarken, bu değişkenlerin çok yönlülüğü ve doğrusal olmayan karmaşık yapısı, tahmin süreçlerinde birtakım zorluklara neden olmaktadır. Geleneksel ekonometrik modellerin bu zorluklar karşısında başarılı olamadığı durumlarda, yapay zekâ, makine öğrenmesi ve derin öğrenme yaklaşımları devreye girmiş ve tahmin performansının artmasında yeni imkânlar sunmuştur. Son yıllarda, özellikle derin öğrenme algoritmalarının, döviz kuru tahmininde doğrusal olmayan ilişkileri ve karmaşık örüntüleri çözebilme yeteneği, geleneksel

modelleme tekniklerine göre önemli avantajlar sağlamaktadır. Bu avantajlar, makine öğrenmesi tekniklerinin döviz kuru tahmininde doğruluğu artırmasına olanak tanımaktadır.

Bu tez, döviz kuru tahmininde derin öğrenme algoritmalarının etkinliğini araştırmak ve tutarlı bir model inşa etmeyi amaçlamaktadır. Özellikle RNN tabanlı LSTM, GRU, Bi-LSTM ve Bi-GRU gibi modellerin yanı sıra bu modellerin CNN modeli ile birleştirildiği hibrit yaklaşımlar incelenip USD/TL ve EUR/TL döviz kurları için farklı parametrelerin kullanıldığı modeller oluşturularak öngörüler yapılmıştır. Derin öğrenme modellerinin başarısı, zaman serisi analizlerinde karşılaşılan doğrusal olmayan ilişkileri çözebilme kabiliyetlerinden kaynaklanmaktadır. LSTM ve GRU gibi modeller uzun vadeli bağımlılıkları yakalamada üstünlük sağlarken, CNN modeli mekânsal özelliklerin çıkarımında oldukça başarılıdır. Hibrit modeller ise, RNN tabanlı modellerin zaman bağımlılığını yakalama gücünü, CNN'in özellik çıkarma kabiliyeti ile birleştirerek, tahmin süreçlerinde daha yüksek doğruluk ve tutarlılık elde etmeyi mümkün kılmaktadır.

USD/TL ve EUR/TL döviz kurları, Türkiye ekonomisi için iç ve dış ekonomik dinamikleri anlamakta kritik bir rol almaktadır. USD/TL döviz kuru, Türkiye'nin ithalat ve ihracat işlemlerinde büyük ölçüde ABD Doları kullanılması nedeniyle önemlidir. EUR/TL kuru ise Avrupa Birliği ülkeleriyle yapılan dış ticaret işlemleri ve dış borçlanma açısından belirleyici bir rol oynar. Bu bağlamda, USD/TL ve EUR/TL hareketlerinin incelenmesi, ekonomik dinamiklerin yanı sıra küresel piyasalarda meydana gelen dalgalanmaların Türkiye ekonomisine etkilerini de anlamayı mümkün kılmaktadır. Bu döviz kurlarındaki hareketlilik, aynı zamanda Türkiye'nin küresel ekonomik ilişkilerdeki pozisyonunu ve uluslararası ticaretin sürdürülebilirliğini de doğrudan etkilemektedir.

Araştırmada kullanılan veri seti, TCMB EVDS veri tabanından günlük kapanış verileri olarak derlenmiş ve Türkiye'deki ekonomik ve politik dönüşümlere bağlı olarak üç farklı dönemde incelenmiştir. İlk analiz dönemi, Şubat 2001'den Ekim 2024'e kadar uzanan uzun vadeli süreci kapsamaktadır. Bu dönem, 2001 ekonomik krizinin etkileriyle şekillenmiş, finansal piyasalarda köklü değişiklikler yaşanmış ve Türkiye'nin esnek kur sistemine geçişiyle başlamıştır. İkinci analiz dönemi, Ocak 2010 ile Ekim 2024 tarihleri arasındaki orta vadeli dönemi içermektedir. Bu süreçte, 2008 küresel finans krizinin yansımaları görülmüş, enflasyon hedeflemesi ve finansal istikrar politikaları eş zamanlı olarak uygulanmaya başlanmış ve küresel likiditede önemli değişimler yaşanmıştır. Kısa

vadeli son analiz dönemi ise Temmuz 2016 ile Ekim 2024 tarihleri arasını kapsamaktadır. Bu dönem, Türkiye ekonomisinde yoğun dalgalanmaların yaşandığı kritik bir süreci temsil etmektedir. Darbe girişiminin yarattığı ekonomik ve siyasi belirsizlikler, Brunson krizi sürecinde yaşanan kur şokları ve ardından gelen COVID-19 pandemisinin neden olduğu küresel ekonomik türbölans, piyasalarda önemli oynaklıklara yol açmıştır. Bu dönemsel analiz, farklı ekonomik ve siyasi gelişmelerin döviz kurları üzerindeki etkilerini değerlendirme açısından büyük bir öneme sahiptir.

Seçilen üç dönem, döviz kurlarının farklı ekonomik ve politik koşullarda nasıl şekillendiğini anlamak için önemli bir analiz fırsatı sunmaktadır. Her dönemde meydana gelen ekonomik ve politik değişimlerin döviz kurları üzerindeki etkilerinin incelenmesi, çalışmanın bulgularının daha kapsamlı yorumlanmasına olanak tanımaktadır. Ayrıca, bu dönemsel analiz, derin öğrenme modellerinin farklı dinamiklerin hâkim olduğu zaman dilimlerindeki performansının değerlendirilmesine imkân vermektedir. Özellikle, bu dönemler arası karşılaştırmalar, modelin başarısını değerlendirmek ve iyileştirme alanlarını belirlemek için kritik bir yöntem sunmaktadır.

Bu çalışmada, döviz kuru tahmininde derin öğrenme modellerinin etkinliğini ortaya koymak ve literatüre katkı sağlamak amacıyla kullanılan yöntem ve modellerin seçim nedenleri ile başarılarının değerlendirilme kriterleri detaylı şekilde ele alınmıştır. Analizler, derin öğrenme modellerinin bu alandaki potansiyelini ve gelecekteki uygulama alanlarını göstermeyi hedeflemektedir.

Bu bağlamda, belirlenen araştırma hedeflerine ulaşmak için çalışma sistematik bir şekilde yapılandırılmıştır. Tezin devam eden bölümlerinde öncelikle döviz kuru tanımları ve döviz kuru teorileri kapsamlı bir şekilde açıklanmış ve literatürdeki çalışmalar detaylı bir şekilde değerlendirilmiştir. Yöntem bölümünde, veri setinin hazırlanma süreci ve kullanılan derin öğrenme modellerinin mimarileri ayrıntılı olarak ele alınmıştır. Bulgular ve tartışma bölümünde ise analiz sonuçları dönemsel olarak değerlendirilmiştir.

Sonuç olarak, döviz kuru tahmininde derin öğrenme modellerinin sağladığı avantajlar ortaya konulmuş ve bu alanda gelecekteki çalışmalar için öneriler sunulmuştur. Bu çalışma, döviz kuru tahmini alanına hem teorik hem de uygulamalı açıdan katkıda bulunmayı hedeflemektedir.

## **BİRİNCİ BÖLÜM**

### **DÖVİZ KURU TANIMLARI ve DÖVİZ KURU DEĞİŞİMLERİNİ AÇIKLAYAN YAKLAŞIMLAR**

#### **1.1. Döviz Kuru Tanımı**

Bir birim yabancı para ile değiştirilebilen ulusal para miktarı veya bir birim ulusal paranın karşılığı olan yabancı para tutarı biçiminde tanımlanan döviz kuru, sadece dış ticareti, sermaye akımlarını ve portföy yönetimini değil, aynı zamanda yatırım kararlarını ve beklentilerini de etkilemesi nedeniyle reel ekonomik aktivite üzerinde oldukça etkilidir (Feenstra ve Taylor, 2011: 26; Yılmaz ve Arabacı, 2021: 218). Uygulamada ülke banknotları, döviz poliçeleri, ödeme emirleri ve ulusal paraya dönüştürülebilir banka havaleleri gibi ülkeler tarafından kabul edilen ödeme araçlarının tamamına döviz adı verilmektedir (Çelik, 2004: 225).

Tanım itibarıyla döviz kuru, bir birim yabancı para birimi karşılığı ulusal para veya ulusal paranın yabancı para cinsinden bir değeridir. Buna kotasyon adı verilmektedir. Genel olarak Avrupa ülkelerinde kullanılan bir birim yabancı paranın ulusal para cinsinden ifade edilmesine doğrudan kotasyon (1 USD=35,40 TL), Amerika Birleşik Devletleri ve Kanada gibi ülkelerde kullanılan bir birim ulusal paranın yabancı para cinsinden değerine dolaylı kotasyon (1 TL=0,028 \$) denilmektedir. Avrupa ülkeleri gibi Türkiye’de de döviz kuru doğrudan kotasyon şeklinde açıklanmaktadır (Feenstra ve Taylor, 2011: 27).

Döviz kurları içerdiği bilgi farklılığından kaynaklı olarak nominal döviz kuru, reel döviz kuru ve reel efektif döviz kuru olmak üzere üç farklı şekilde hesaplanmakta ve tanımlanmaktadır.

##### **1.1.1. Nominal Döviz Kuru**

Nominal döviz kuru, bir birim yabancı paranın ulusal para birimi cinsinden değerini ifade etmektedir. Bu tanım neticesinde Türkiye Cumhuriyet Merkez Bankası (TCMB) tarafından açıklanan ABD dolar satış kuru 35,40 TL ise bir dolar satın alabilmek için birimlerin 35,40 TL ödemesi gerekmektedir. Nominal döviz kurunda meydana gelen artış, bir birim yabancı para satın almak için ödenmesi gereken ulusal para miktarının arttığını ifade etmektedir. Tersine nominal döviz kurundaki düşüş, bir birim yabancı paranın daha az miktarda ulusal para ödenerek alınabileceğini göstermektedir. Bu doğrultuda nominal döviz kuru, ülkelerin mal ve hizmet alım-satımlarında ödenmesi

gereken miktarı belirlemesi açısından önem arz etmektedir. Ancak nominal döviz kuru, parasal bir kavram olup, enflasyonist etkileri içermemektedir (MacDonald, 2007: 2).

### 1.1.2. Reel Döviz Kuru

Toplumun önemli bir kısmı ulusal paranın yabancı para cinsinden parasal değeri olan nominal döviz kuru ile ilgilenmektedir. Ancak nominal döviz kuru, ulusal paranın satın alım gücü hakkında net bir bilgi vermemektedir. Bu durumu ortadan kaldırmak için Reel Döviz Kuru (RDK) kavramı kullanılmaktadır. RDK, nominal döviz kurunun yurtiçi ve yurtdışı fiyat düzeylerinden arındırılması olarak tanımlanmaktadır. Dolayısıyla RDK, ülkeler arası enflasyonist etkileri ortadan kaldırarak bir birim ulusal paranın satın alım gücünü ifade etmektedir (Hsieh, 1982: 355). RDK şöyle hesaplanmaktadır;

$$RDK = E \frac{P_f}{P_d} \quad (1.1)$$

Denklem (1.1)'e göre,  $E$  nominal döviz kurunu,  $P_f$  yurtdışı fiyat düzeyini,  $P_d$  yurtiçi fiyat düzeyini ifade etmektedir. Buna göre nominal döviz kuru ve yurtdışı fiyat düzeyinde meydana gelen artışlar RDK'yı artırırken, yurtiçi fiyat düzeyindeki artışlar RDK'yı azaltmaktadır.

RDK, özellikle ülkelerin dış ticaret davranışlarının açıklanmasından oldukça önemlidir. RDK'ta meydana gelen artışlar sonucunda yurtdışındaki mallar yurtiçi mallara göre pahalılaşmaktadır. Böylece, diğer her şey sabitken, yurtiçi mallara karşı talebin artacağı dolayısıyla yurtiçinde üretilen malların yabancı mallarla olan rekabet gücünün artacağı sonucuna ulaşılmaktadır (Dornbusch, Fisher ve Startz 2011: 293).

### 1.1.3. Reel Efektif Döviz Kuru

Reel Efektif Döviz Kuru (REDK), ulusal para birimi reel değerinin, ülkenin ticaret ortaklarından oluşan bir sepet karşısındaki değişimini gösteren döviz kuru kavramıdır. REDK, fiyat ve maliyet rekabetindeki değişimi, dış ticaret işlemlerindeki itici güçleri ve sektörler arası üretimin tahsisi gibi çok çeşitli konularda kullanılmaktadır (Darvas, 2012: 2). REDK aşağıdaki gibi formüle edilmektedir.

$$REDK = \prod_{i=1}^N \left( E_i \times \frac{P_i^*}{P} \right)^{w_i} \quad (1.2)$$

Denklemde,  $N$  ticaret yapılan ülke sayısını,  $E_i$  ulusal para biriminin  $i$  ülkesinin para birimi karşısındaki döviz kuru değerini,  $P_i^*$   $i$  ülkesine ait fiyatlar genel düzeyini,  $P$  yurtiçi fiyatlar genel düzeyini ve  $w_i$  ticaret yapılan ülkelerin ağırlıklarını ifade etmektedir.

REDK'nin bir önceki döneme göre düşmesi ulusal para biriminin yabancı ülke para birimlerine kıyasla değer kazandığını ve yurtiçi malların yabancı mallara oranla pahalılaştığını ifade etmektedir (TCMB, 2018: 71).

## **1.2. Döviz Kuru Sistemleri**

Döviz kurunun para otoritesi tarafından ilan edilmesi veya piyasa koşulları altında belirlenmesi konusuna döviz kuru sistemi adı verilmektedir. Döviz kuru sistemleri genel olarak esnek ve sabit döviz kuru altında iki başlığa ayrılrsa da uygulamada esnek kur sistemi uygulanan bir ülkede döviz piyasasına yaygın şekilde müdahale edildiği ya da sabit kur sisteminin geçerli olduğu ekonomide dönemsel devalüasyonların uygulanması, esnek ve sabit kur ayrımının daha detaylı bir hale getirilmesini zorunlu kılmaktadır. Bu doğrultuda IMF tarafından 1998 ve 2009 yıllarında döviz kuru sistemleri sınıflandırması yapılmıştır. Genel olarak döviz kuru sistemleri literatürde esnek kur sisteminden en katı sistem olan tam para ikamesine doğru olacak şekilde sınıflandırılmaktadır (Levy-Yeyati ve Sturzenegger, 2005: 1604).

### **1.2.1. Esnek Kur Sistemi**

Tam esnek döviz kuru sistemi, döviz kurlarının hareket yönü konusunda herhangi bir kamu müdahalesi olmaksızın, piyasada yer alan birimlerin arz ve talep kararlarına göre anlık olarak belirlenmesidir (Johnson, 1969: 12). Döviz kuru piyasa güçleri tarafından belirlendiği için döviz arzı sabitken döviz talebinin artması döviz kurunun yükselmesine dolayısıyla ulusal para biriminin değer kaybetmesine neden olurken, döviz talebi sabitken döviz arzında meydana gelen bir artış döviz kurunun düşmesine, ulusal para biriminin değer kazanmasına yol açacaktır.

Tam esnek kur sisteminin uygulanmasında bir takım avantaj ve dezavantajlar bulunmaktadır. Sistemde kurun piyasa güçleri tarafından belirleniyor olması kaynakların etkin dağılımını sağlamaktadır. Bu rejim altında para otoritesi bağımsız karar alma hakkına sahip olmaktadır. Ayrıca kura müdahale edilmediği için yüksek miktarda döviz rezervi bulundurma zorunluluğu ortadan kalkmaktadır. Esnek kur sisteminin dezavantajı ise döviz kurunun gelecekte izleyeceği yol hakkında bir belirsizliğin ortaya çıkmasıyla piyasanın istikrarsız bir yapıya sahip olması ve bu durum sonucunda ortaya çıkacak döviz kuru dalgalanmalarının enflasyon, dış ticaret ve yatırımlar gibi reel ekonomik aktivite üzerinde yıpratıcı etkiler yaratabilmesidir (Müslümov vd., 2003: 15).

### 1.2.2. Sabit Kur Sistemi

Sabit döviz kuru sistemi, para otoritesinin ulusal para biriminin yabancı ülke para birimleri karşısındaki değerini belirlediği, kurun belirlenen düzeyde sabit kaldığı, arz ve talep değişimlerine göre dalgalanmaya bırakılmadığı döviz kuru sistemidir (Dornbusch, Fisher ve Startz, 2011: 288). Bu sistemde para otoritesi tarafından belirlenen kur değerinin artırılmasına devalüasyon, düşürülmesine revalüasyon denilmektedir.

Sabit kur sisteminin ülkeler tarafından kullanılmasındaki en temel gerekçe döviz kurunun değerinde meydana gelecek herhangi bir değişim beklentisini kırmaktır. Bu sayede yüksek enflasyon sorunu yaşayan ekonomilerde enflasyonist beklentileri kırmak adına bir çipa olarak kullanılmaktadır. Sabit kur sistemi uygulayarak beklentileri yönetmek sadece enflasyonu değil tüketim, tasarruf ve yatırım kararları gibi birçok makroekonomik değişkeni etkilemektedir. Böylece ekonomide iç dengeyi sağlama konusunda sabit kur sistemi avantaj sağlamaktadır. Ancak tüm bu avantajları kullanmanın en temel şartı, para otoritesinin belirlediği döviz kurunu sürdürebilecek genişlikte döviz rezervine sahip olması ve piyasaya güven vermesidir. Bu sistemde para otoritesi ilan ettiği kur seviyesini korumak adına önemli miktarda rezerv bulundurarak ekonomik birimlerin taleplerini karşılama yeterliliğine sahip olmalıdır. Bu doğrultuda sistemin dezavantajı önemli miktarda dövizin ekonomik faaliyet alanından çekilip, para otoritesine sunulmasıdır. Ayrıca bu sistemde para otoritesi kur taahhüdünde bulunduğu için bağımsız para politikası uygulama imkânı güçleşmektedir.

### 1.2.3. Gözetimli Dalgalanma

Bu kur sisteminde para otoritesi, önceden belirlenmiş kurallar olmaksızın döviz kurlarına müdahale etmektedir. Para otoritesi döviz kuruna müdahale ederken, o andaki ekonomik koşullar altında en iyi olduğuna inandığı kararları uygulamaya koymaktadır. Böylece, döviz kuru üzerindeki dalgalanmaları dizginleyerek şoklara karşı savunma mekanizmasını harekete geçirmektedir (Özdemir ve Şahinbeyoğlu, 2000: 2; Müslümov vd., 2002: 20).

### 1.2.4. Aralık İçerisinde Dalgalanma

Bu rejimde, para otoritesi para biriminin değerini daha önce açıklanmış döviz kuru aralığında ( $\pm\%1$ ) aşağı ve yukarı hareketine izin vermektedir. Döviz kuru bu aralığın dışına çıktığına para otoritesi döviz kuruna müdahale etmektedir. Böylece, döviz kuru piyasasında esneklik ve öngörülebilirlik sağlanır (IMF, 2008: 3).

### **1.2.5. Kaygan Aralık**

Kaygan aralık sisteminde, döviz kuru aralığı sabit olarak belirlenmemekte, bu değer belli olmayan aralıklarla değiştirilmektedir. Sistem, özellikle yüksek enflasyon yaşayan ülkelerde döviz kurundaki spekülâtif hareketlere karşı önlem almak için yaygın olarak kullanılmaktadır. Ancak kaygan aralık sisteminde döviz kuru aralığının belirlenmesinde netlik olmadığı için piyasalarda belirsizliğin artmasına yol açabilmektedir (Edwards ve Savastano, 1999: 6).

### **1.2.6. Yönlendirilmiş Sabit Aralık**

Yönlendirilmiş sabit aralık sistemi, faiz oranı ve dış ödemeler dengesi gibi makroekonomik değişkenlerdeki gelişmelere bağlı olarak ulusal para biriminin önceden açıklanmış sabit bir değer etrafında dalgalanmaya bırakılması olarak tanımlanmaktadır. İlan edilen sabit değer üzerinde herhangi bir baskı olduğu durumda gerekli ayarlama ve müdahaleler bir anda değil, belirli aralıklarla yapılmaktadır (Ghosh, Gulde ve Wolf, 2003: 3).

### **1.2.7. Yönlendirilmiş Sabit Parite**

Para otoritesi tarafından belirlenen döviz kuru, ufak ölçülerle ve sürekli olarak, enflasyon farkı ve enflasyon hedefi gibi göstergelerdeki değişimler dikkate alınarak ayarlanmaktadır. Bu sistemde döviz kuru dar bir bant içerisinde hareket etmektedir. Dolayısıyla döviz kuru kaynaklı yüksek enflasyon yaşayan ülkelerde, fiyat istikrarını sağlamak için para otoriteleri tarafından sıklıkla kullanılmaktadır (Frankel, 1999: 4).

### **1.2.8. Ayarlanabilir Sabit Kur**

Sistemde döviz kuru sabittir ancak para otoritesinin kur düzeyini süresiz şekilde sürdürme zorunluluğu yoktur. Döviz kuru düzeyi ekonomik göstergeler ile uyumsuz hale gelirse, otorite gerekli ayarlamaları yapacak yetkidedir (Frankel, 1999: 3).

### **1.2.9. Para Kurulu**

Para kurulu sisteminde ulusal para biriminin bir yabancı ülke para birimine karşı sabit döviz kuru üzerinden değişimi sağlanmaktadır. İlgili sistemde para otoritesi para arzını yabancı para girişi gerçekleştiğinde değiştirebilmektedir. Böylece döviz kuru, bir kamu hukuku meselesi olarak garanti altına alınmaktadır (Tavlas, Dellas ve Stockman, 2008: 943).

### 1.2.10. Tam Dolarizasyon

Tam dolarizasyon, ülkenin yabancı bir para birimini benimsemesi durumudur. Sistem parasal disiplini artırmakta ve döviz kurundaki belirsizlikleri ortadan kaldırmaktadır. Sistem devalüasyon riskini ortadan kaldırdığı için diğer ülkelerde meydana gelebilecek krizlere karşı daha az duyarlı faiz oranlarının oluşmasına neden olmaktadır. Ancak bu sistemde para otoritesi tarafından bağımsız para politikası uygulanamamaktadır (Calvo, 1999: 2; Frankel, 1999: 3).

### 1.3. Döviz Kuru Değişimini Açıklayan Teoriler

Sabit kur sisteminin yaygın olarak kullanıldığı, uluslararası sermaye hareketlerinin kısıtlı olduğu ve bu nedenle kısa dönemdeki dalgalanmaları incelemenin aksine uzun dönemde denge döviz kurunun nasıl belirlendiğine yönelik ortaya atılan teorilere geleneksel döviz kuru yaklaşımları adı verilmektedir. Geleneksel yaklaşımlardan ilki dış ticaret akımları teorisidir. Teori döviz kuru değişimlerini cari işlemler bilançosuna göre açıklamaktadır. Geleneksel yaklaşımlardan ikincisi ise Satın Alma Gücü Paritesi yaklaşımıdır. Bu yaklaşımda döviz kuru değişimleri ülkeler arasındaki fiyat farklılıklarından hareketle açıklanmaktadır. Geleneksel döviz kuru yaklaşımlarının ardından, uluslararası sermaye hareketlerinin serbestleştiği ve finansal piyasalardaki entegrasyonun arttığı dönemlerde modern döviz kuru teorileri geliştirilmiştir. Bu teoriler, döviz kuru değişimlerini finansal piyasalardaki dengeler, beklentiler ve spekülasyon gibi daha karmaşık faktörler üzerinden açıklamaktadır.

#### 1.3.1. Dış Ticaret Akımları Yaklaşımı

Dış ticaret akımları yaklaşımına göre döviz kurunu belirleyen unsur ülkenin dış ticaret bilançosu dolayısıyla ithalat ve ihracat değerleridir. Yaklaşımına göre ülkenin ihracatı ithalattan büyük ise ülkeye döviz girişi sağlanacağı için ulusal para birimi değer kazanacaktır. Tersine ithalat ihracattan büyük ise ülkeden döviz çıkışı yaşanacağı için ulusal para birimi değer kaybedecektir.

**Tablo 1: Dış Ticaret Akımları Yaklaşımı**

|                   |                     |                                    |
|-------------------|---------------------|------------------------------------|
| İhracat > İthalat | Dış ticaret fazlası | Ulusal para birimi değer kazanır.  |
| İthalat > İhracat | Dış ticaret açığı   | Ulusal para birimi değer kaybeder. |

Dış ticaret akımları yaklaşımına göre ülkenin ihracat ve ithalatını etkileyen her bir faktör aynı zamanda ulusal para biriminin değerini de etkilemektedir. Dolayısıyla yerli ve yabancı malların görelî fiyatları, ülkeler arasındaki görelî reel gelir değişimleri, tüketici tercihleri, teknolojik gelişmeler gibi faktörler döviz kurunun değişimi hakkında bilgi vermektedir. Örneğin, ülkedeki reel gelir artışları ithal mallara olan talebin artmasına böylece döviz kurunun yükselmesine yol açacaktır. Diğer yandan, ticaret yapılan ülkelerde reel gelir artışının yaşanması ihraç mallarına olan talebi artıracak için, yurtiçi döviz arzı artacak, döviz kuru düşüş eğiliminde olacaktır (Marshall, 1923; Lerner, 1946; Seyidoğlu, 2015: 454-455).

Dış ticaret akımları yaklaşımı temel olarak dış ticaret bilançosu açık veren ekonomide döviz kurunun yükseleceğini ifade etmesine rağmen, dış ticaret açığı veren ekonomilerde döviz kurunun değişmediği hatta düşebildiği gözlemlenmektedir. Bu durum dış ticaret akımları teorisinin sermaye akımlarının etkisini göz ardı etmesinden kaynaklı açıklama gücü eksikliğini göstermektedir (Canterbury, 1965: 20). Bu nedenle ilerleyen süreçte döviz kuru değişimlerinin açıklanmasında sermaye akımlarını dikkate alan yeni teoriler geliştirilmiştir.

### 1.3.2. Satın Alma Gücü Paritesi Yaklaşımı

Gustav Cassel (1918) tarafından teorik temeli oluşturulan Satın Alma Gücü Paritesi (SAGP-Purchasing Power Parity), iki ülkedeki görelî fiyat farklılıklarının uzun dönemde nominal döviz kurlarıyla birlikte hareket ettiğini ileri sürmektedir.

SAGP yaklaşımının temelini tek fiyat kanunu (*law of one price*) oluşturmaktadır. Tek fiyat kanunu, çok sayıda alıcı ve satıcının bulunduğu, piyasaya ait bilgilerin çok düşük maliyetlerle elde edildiği ve taşıma giderlerinin önemsiz olduğu bir piyasada ticarete konu olan herhangi bir homojen malın, mevcut döviz kurundan ulusal paraya çevrilmiş fiyatının dünyanın her yerinde aynı olması gerektiğini ifade etmektedir (Rogoff, 1996: 649).

Tek fiyat kanunu, arbitraj işlemlerinin bir sonucudur. Birimler belli bir anda ortaya çıkan fiyat farklılıklarından kâr elde etmeye çalışarak “ucuz olan yerden al, pahalı olan yerde sat” ilkesine göre hareket ederler. Böylece fiyatın yüksek olduğu ülkede mal arzının artması, fiyatın düşük olduğu ülkede mala ait talebin artması sonucunda ilgili mal tek bir fiyat üzerinden satışa konu olacaktır. Tek fiyat kanunu sadece mal ve hizmet piyasaları

için değil, sermaye ve döviz piyasalarında da geçerli olmaktadır. (Feenstra ve Taylor, 2011: 65).

SAGP yaklaşımı iki başlık altında incelenmektedir. Bunlar; Mutlak SAGP ve Nispi SAGP yaklaşımıdır.

### 1.3.2.1. Mutlak Satın Alma Gücü Paritesi Yaklaşımı

Mutlak Satın Alma Gücü Paritesi Yaklaşımı (Absolute Purchasing Power Parity), bir ülkedeki fiyatların, mevcut döviz kurlarından diğer ülke para birimlerine dönüştürüldüğünde tüm diğer ülkelerde aynı olması gerektiğini ifade etmektedir. Dolayısıyla bu durum herhangi bir ülkede ulusal para biriminin satın alma gücünün, diğer tüm ülkelerde aynı olması gerektiğini ileri sürmektedir. Bu sonuç, mal ve hizmet arbitrajı sonucu ortaya çıkan tek fiyat kanununa dayanmaktadır. Denklem (1.3) bu durumun matematiksel ifadesini göstermektedir.

$$P_t^i = S_t P_t^{i*} \quad (1.3)$$

Denklem (1.3)'te yer alan  $P_t^i$  homojen  $i$  malının yurtiçi fiyat düzeyini,  $S_t$  nominal döviz kurunu ve  $P_t^{i*}$  homojen  $i$  malının yurtdışı fiyat düzeyini göstermektedir. Denklem (1.3)  $n$  mallı bir ekonomide yurtiçi fiyatlar genel düzeyini ifade etmek için genelleştirildiğinde denklem şu hali almaktadır:

$$P_t = \sum_{i=1}^n a^i P_t^i \quad (1.4)$$

Yurtdışı fiyatlar genel düzeyi ise şöyle formüle edilmektedir:

$$P_t^* = \sum_{i=1}^n a^i P_t^{i*} \quad (1.5)$$

Denklem (1.4) ve denklem (1.5)'te yer alan  $a^i$  terimi yurtiçi ve yurtdışı ekonomiler için  $i$  malının mal sepetleri içerisindeki oranını göstermektedir. Burada  $i$  malının yurtiçi ve yurtdışı ekonomilerin mal sepetlerindeki ağırlığının eşit olduğu ve ağırlıkları toplamının bire eşit olduğu varsayılmaktadır.

Mutlak SAGP yaklaşımında, piyasada çok sayıda mal ve hizmetin olması ülke ulusal paralarının satın alım gücünün tespitinde zorluklar yaşanmasına neden olduğu için nominal döviz kuru, ülkelerin fiyat endeksleri oranı şeklinde hesaplanmaktadır. Bu durumda nominal döviz kuru;

$$\sum_{i=1}^n a^i P_t^i = S \sum_{i=1}^n a^i P_t^{i*} \quad (1.6)$$

şeklinde hesaplanmaktadır. Böylece nominal döviz kuru yurtiçi fiyat düzeyinin yurtdışı fiyat düzeyine oranı olarak hesaplanmaktadır (MacDonald, 2007: 40-41).

$$S_t = \frac{P_t}{P_t^*} \quad (1.7)$$

Denklem (1.7)'den hareketle döviz kuru, ülkelerin fiyat endekslerine bağlı olarak değişmektedir. Buna göre, yurtiçi fiyat endeksi yurtdışı fiyat endeksinden ne kadar yüksekse döviz kuru o oranda artış göstermektedir.

Mutlak SAGP yaklaşımı döviz kuru değişimini yansıtan önemli göstergelerden biri olmasına rağmen bazı nedenlerden ötürü açıklama gücü düşmektedir. Uygulamada Tüketici Fiyat Endeksi (TÜFE), Üretici Fiyat Endeksi (ÜFE) ve Gayri Safi Milli Hasıla (GSMH) deflatörü gibi farklı özellikleri içinde bulunduran endeksler kullanılmaktadır. Bu nedenle döviz kuru değişiminde hangi endeksin kullanılacağı ve ülkelere göre endeksin içeriğindeki farklılıklar mutlak SAGP yaklaşımının açıklama gücünü zayıflatmaktadır. Ayrıca uluslararası ticarete konu olmayan doktor, terzi ve danışmanlık gibi hizmet sektörleri ve önemli taşıma maliyeti içeren çimento, beton gibi mallar söz konusu olduğunda mutlak SAGP denge döviz kurunu açıklamada güçlükler yaşamaktadır. Bu ve benzeri problemleri ortadan kaldırmak adına döviz kuru değişimini açıklamada nispi SAGP yaklaşımı geliştirilmiştir.

#### 1.3.2.2. Nispi Satın Alma Gücü Paritesi Yaklaşımı

Nispi Satın Alma Gücü Paritesi (Relative Purchasing Power Parity) yaklaşımında, Mutlak SAGP'ten farklı olarak fiyat endeksi mutlak büyüklüğü yerine görece değişimler dikkate alınmaktadır. Dolayısıyla Nispi SAGP, kurlardaki değişimi enflasyon oranları arasındaki farka göre açıklamaktadır. Bu durumda döviz kuru değişimini açıklayan denklem şu hali almaktadır;

$$\Delta s_t = \Delta p_t - \Delta p_t^* \quad (1.8)$$

Denklem (1.8)'de  $\Delta s_t$  nominal döviz kurundaki yüzde değişimi,  $\Delta p_t$  yurtiçi fiyat düzeyindeki yüzde değişimi,  $\Delta p_t^*$  yurtdışı fiyat düzeyindeki yüzde değişimi ifade etmektedir. Fiyat düzeyindeki yüzde değişim ülkedeki enflasyon oranını verdiği için denklem (1.8) şu şekilde de yazılabilmektedir:

$$\Delta s_t = \pi_t - \pi_t^* \quad (1.9)$$

Denklem (1.9)'da yer alan  $\pi_t$  yurtiçi enflasyon oranını,  $\pi_t^*$  yurtdışı enflasyon oranını göstermektedir.

Sonuç olarak Nispi SAGP yaklaşımında döviz kuru değişimleri ülkelerin enflasyon oranları arasındaki fark tarafından belirlenmektedir. Yurtiçi enflasyon oranı yurtdışı enflasyon oranından ne kadar yüksek ise döviz kuru o oran kadar yükselmektedir (Rogoff, 1996: 650).

Mutlak ve Nispi SAGP yaklaşımları döviz kuru değişimlerini ülkeler arasındaki fiyat düzeyi/enflasyon oranı farklılıklarına bağlı olarak açıklayan önemli yaklaşımlardır. Ancak söz konusu iki yaklaşımda da döviz kuru değişiminde sadece mal ve hizmet ticareti dikkate alınırken, sermaye hareketleri ihmal edilmektedir. Bu durum her iki yaklaşımın da döviz kuru değişimlerini açıklamada güçlük yaşamasına neden olmaktadır.

### **1.3.3. Faiz Oranı Paritesi Yaklaşımı**

Döviz kuru değişimini açıklayan bir diğer yaklaşım Faiz Oranı Paritesi (Interest Rate Parity)'dir. Bu yaklaşım, sermaye hareketleri dikkate alınarak döviz kuru değişim sürecini ülkeler arası faiz oranı farklılıklarının forward (vadeli) ve spot (bugünkü) kur arasındaki farka göre eşitleneceğini ileri sürmektedir. SAGP yaklaşımında olduğu gibi bu yaklaşımın temelinde de tek fiyat kanunu bulunmaktadır. Ancak tek fiyat kanunu SAGP'te mal ve hizmet piyasaları için geçerli iken bu yaklaşımda tek fiyat kanunu mal ve hizmet piyasasına ilaveten sermaye piyasasını da kapsamaktadır. Ekonomik birimler ülkeler arası faiz oranı farklılıklarından yararlanarak kâr elde etme davranışı sergilemektedir. Kısaca birimler faiz oranının yüksek olduğu ülkelere satın aldığı menkul kıymetleri faiz oranının düşük olduğu ülkelere satmaktadır. Dolayısıyla menkul kıymetler homojen özellik taşımaktadır. Kâr güdüsüyle hareket eden birimler, düşük faiz oranının olduğu ülkelere faiz oranının yükselmesine, yüksek faiz oranının olduğu ülkelere faiz oranının düşmesine sebep olarak dengenin sağlanmasına katkı sağlamaktadır (Krugman ve Obstfeld, 2009: 336).

Faiz Oranı Paritesi yaklaşımı Kapsanmış Faiz Oranı Paritesi ve Kapsanmamış Faiz Oranı Paritesi olarak iki alt başlık altında incelenmektedir.

#### **1.3.3.1. Kapsanmış Faiz Oranı Paritesi Yaklaşımı**

Kapsanmış Faiz Oranı Paritesi (Covered Interest Rate Parity - CIRP) yaklaşımı, Keynes (1923) ve Einzing (1937) tarafından teorik temelleri atılmış bir yaklaşımdır. Bu teoriye göre, farklı ülkelere aynı risk ve vade özelliklerine sahip menkul kıymetlerin,

sermaye hareketleri üzerinde herhangi bir kısıtlama olmadığı ve bilgi ile işlem maliyetlerinin bulunmadığı durumlarda, her iki ülkede de menkul kıymetlerin getirileri eşit olmalıdır. Bu durumda, faiz oranı farkları döviz kuru beklentilerine göre ayarlanır ve ülkeler arasındaki menkul kıymetlerin getirileri birbirini dengeleyen bir seviyeye ulaşır.

Kapsanmış Faiz Oranı Paritesi yaklaşımında, sermaye hareketleri üzerinde bir kısıtlamanın ve işlem maliyetinin olmaması nedeniyle arbitraj işlemi önem kazanmaktadır. Ekonomik birimler kendi ülkesindeki finansal varlıklara yatırım yapması halinde  $(1 + i_t)$  kadar, yabancı ülkeye yatırım yapması durumunda ulusal para birimi cinsinden  $(1 + i_t^*)Fr_t/S_t$  kadar getiri elde etmektedir. Burada  $i_t$  yurtiçi faiz oranını,  $i_t^*$  yurtdışı faiz oranını,  $Fr_t$  forward döviz kurunu,  $S_t$  spot döviz kurunu göstermektedir. Dolayısıyla yurtiçi finansal varlıklara yapılan yatırım sadece faiz oranı ile ilişkiliyken, yurtdışı finansal varlıklara yapılan yatırımın getirisi faiz oranı, forward döviz kuru ve spot döviz kuruna bağlı olarak değişmektedir (Sarno ve Taylor, 2003: 6-8).

Ekonomik birimlerin faiz oranı farklılıklarından yararlanmak amacıyla yaptığı arbitraj işlemi nedeniyle iki ülke finansal varlıklarına ait getirilerin eşitlenmesi gerekmektedir. Bu doğrultuda iki getiri oranının eşitlenmesi denge durumunu gösterecektir (Sarno ve Taylor, 2003: 6-8; MacDonald, 2007: 13-14).


$$(1 + i_t) = (1 + i_t^*)Fr_t/S_t \quad (1.10)$$

$$\frac{(1+i_t)}{(1+i_t^*)} = \frac{Fr_t}{S_t} \quad (1.11)$$

Denklem (1.11) iki ülkeye ait finansal varlıkların getiri oranlarının eşitlediği durumdaki denge değerini göstermektedir. Denklem (1.11)'de her iki taraftan bir çıkarılıp yeniden düzenlendiğinde Kapsanmış Faiz Oranı Paritesi eşitliğine ulaşılmaktadır.

$$\frac{Fr_t - S_t}{S_t} = \frac{i_t - i_t^*}{1 + i_t^*} \quad (1.12)$$

Denklem (1.12)'de yer alan terimler arasındaki ilişki kurulduğunda, faiz oranı paritesi ilkesini temsil eden doğrusal faiz oranı paritesi doğrusu elde edilmektedir.



**Şekil 1: Faiz Oranı Paritesi Yaklaşımı**

**Kaynak:** Seyidoğlu (2015).

Şekil 1'in yatay ekseninde ülkeler arasındaki faiz oranı farkı, dikey ekseninde vadeli piyasada ulusal para biriminin yabancı para birimi karşısında yaptığı iskonto/prim oranı gösterilmektedir.

Ekonomik birimler yatırım kararı alırken sadece faiz oranı farkını değil vadeli kurun değerini de dikkate almaktadır. Kapsanmış Faiz Oranı Paritesi yaklaşımına göre birimler faiz oranı farkından yararlanıp yabancı menkul kıymetlere yatırım yaptığında mevcut döviz kuru düşerse yatırımdan elde edilecek kâr azalacaktır. Şekil 1'e göre eğrinin sol tarafında  $(Fr_t - S_t)/S_t > \frac{(i_t - i_t^*)}{(1 + i_t^*)}$  durumu geçerlidir. Yani ülkeler arası faiz oranı farkı vadeli döviz kuru farkından küçüktür. Bu durumda yabancı menkul kıymetlere yapılacak yatırımlar kârlı olacaktır. Eğrinin sağ tarafında ise  $(Fr_t - S_t)/S_t < \frac{(i_t - i_t^*)}{(1 + i_t^*)}$  durumu söz konusudur. Bu durumda ülkeler arası faiz oranı farkı vadeli döviz kuru farkından büyük olduğu için yatırımların yurtiçi menkul kıymetlere yapılması daha kârlı olacaktır. Dolayısıyla faiz oranı paritesi doğrusunun sağ tarafında yatırımlar yurtiçine doğru, sol

tarafında yatırımlar yabancı ülkeye doğru kayacak ve arbitraj nedeniyle getiri oranları eşitlenerek faiz oranı paritesi doğrusu üzerinde dengeye ulaşacaktır

Oransal olarak ifade edilen Kapsanmış Faiz Oranı Paritesi (denklem 1.11) logaritmik formda da gösterilmektedir ve istatistiksel araştırmalarda bu denklem üzerinden analizler gerçekleştirilmektedir (MacDonald, 2007: 14).

$$Fr_t - S_t = i_t - i_t^* \quad (1.13)$$

Denklem (1.13)'ten hareketle yatırımcılar, ülkeler arasındaki faiz oranı farkına bağlı olarak yatırım kararı vermektedir. Birimlerin kâr fırsatlarını değerlendirmek amacıyla yaptığı arbitraj işlemi sonucunda, forward döviz kuru ile spot döviz kuru arasındaki fark ülkeler arası faiz oranı farkına eşit olacaktır.

### 1.3.3.2. Kapsanmamış Faiz Oranı Paritesi Yaklaşımı

Kapsanmamış Faiz Oranı Paritesi (Uncovered Interest Rate Parity) yaklaşımı, yurtiçi ve yurtdışı faiz oranı arasındaki farkın, döviz kurunun beklenen değerine eşit olacağını ifade etmektedir. Dolayısıyla cari döviz kurunu, beklenen döviz kuru değeri ile yurtiçi ve yurtdışı faiz oranı farklılığı belirlemektedir (Visser, 2004: 10-12; Özatay, 2019:140).

Kapsanmamış Faiz Oranı Paritesi yaklaşımında Kapsanmış Faiz Oranı Paritesi yaklaşımında olduğu gibi sermaye hareketleri üzerinde herhangi bir engel bulunmamakta, farklı ülkelere ait menkul kıymetler aynı risk ve vade yapısına sahip olmakta ve piyasada herhangi bir işlem ve bilgi maliyeti bulunmamaktadır. Kapsanmamış Faiz Oranı Paritesi yaklaşımından farklı olarak cari döviz kurunun belirlenmesinde beklenen döviz kuru değeri modele eklenmektedir.

Matematiksel olarak ifade etmek gerekirse Kapsanmış Faiz Oranı Paritesi'nde denge durumu  $Fr_t - S_t = i_t - i_t^*$  şeklindedir. Kapsanmamış Faiz Oranı Paritesi yaklaşımında beklenen döviz kuru değişkeni modele eklendiği için denge durumu şu şekildedir,

$$s_{t+k}^e - s_t = i_t - i_t^* \quad (1.14)$$

Kapsanmamış Faiz Oranı Paritesi yaklaşımına rasyonel beklentilerin dahil edilmesi durumunda ise denklem (1.15) elde edilmektedir.

$$E_t(\Delta s_{t+k}) = (E_t s_{t+k} - s_t) = (i_t - i_t^*) \quad (1.15)$$

Denklem (1.15)'e göre, ulusal para birimlerinin değeri ülkeler arası faiz oranı farkı kadar değişmelidir. Faiz oranı yüksek olan ülkede döviz kurunun faiz oranı farkı kadar düşmesi dolayısıyla ulusal para biriminin değer kazanması beklenmektedir (MacDonald, 2007: 18).

Faiz Oranı Paritesi yaklaşımında ülkelere ait menkul kıymetlerin aynı risk düzeyine sahip olması ve bilgi ve işlem maliyetlerinin olmaması varsayımları teoremin geçersiz olduğunu değil, teoriyi açıklamada güçlük çekmesine neden olmaktadır. Bununla birlikte Faiz Oranı Paritesi yaklaşımı Esnek ve Katı Fiyatlı Parasalcı yaklaşım ve Portföy Dengesi yaklaşımının temellerini oluşturması açısından döviz kuru belirleme modellerinin gelişimini sağlaması nedeniyle büyük önem arz etmektedir.

#### **1.3.4. Parasalcı Yaklaşım**

1971 yılında Bretton Woods sisteminin geçerliliğini yitirmesiyle birlikte ülkelerde sabit kur sisteminin yerini esnek kur sistemine bırakması, dış ticarete dayalı geleneksel döviz kuru belirleme yaklaşımlarının yetersiz kalmasına neden olmuştur. 1970'li yıllardan sonra döviz kurunun uzun dönemli denge seviyesini açıklamak yerine, esnek döviz kuru sisteminde kısa dönemdeki dalgalanmaları açıklamaya yönelik çalışmalar hız kazanmaya başlamıştır. Bu durum sermaye akımları, faiz oranları ve beklentilere dayalı yeni yaklaşımları gündeme getirmiştir. Bu doğrultuda geliştirilen modern döviz kuru teorilerden birisi Parasalcı yaklaşımdır. Parasalcı yaklaşım esnek fiyat ve katı fiyat durumlarının geçerli olduğu şartlarda döviz kuru değişimini açıklayan iki alt başlıktan oluşmaktadır.

##### **1.3.4.1. Esnek Fiyatlı Parasalcı Yaklaşım**

Esnek Fiyatlı Parasalcı yaklaşımın teorik temellerini Frenkel (1976) ve Bilson (1978) tarafından yapılan çalışmalar oluşturmaktadır. Yaklaşım, belli varsayımlar altında denge döviz kurunun para piyasasındaki arz ve talep güçleri tarafından belirlendiğini açıklamaktadır. Yaklaşımdaki varsayımlar şöyledir: Sermaye hareketleri üzerinde herhangi bir engel yoktur. Yurtiçi ve yurtdışı finansal varlıklar tam ikamedir. Ulusal para birimi sadece yurtiçi ekonomik birimleri tarafından talep edilmektedir. Son olarak reel gelir ve para arzı dışsal olarak belirlenmektedir.

Esnek Fiyatlı Parasalcı yaklaşım, mal ve hizmet piyasaları, işgücü piyasası, para piyasası, döviz piyasası, yurtiçi ve yurtdışı finansal varlıklar olmak üzere altı piyasa üzerine kuruludur. Ancak yaklaşım sadece para piyasası dengesi üzerine

odaklanmaktadır. Yurtiçi ve yurtdışı finansal varlıkların tam ikame olması bu iki piyasasının tek bir piyasa olarak kabul edilmesine neden olmaktadır. İlaveten döviz kuru, döviz piyasası arz ve talep durumuna bağlı olarak hızla değişmektedir. Uyum hızının yüksek olmasının ardında yatan neden ise mal ve hizmet piyasasında fiyatların, işgücü piyasasında ücretlerin tam esnek olması, bu piyasalarda herhangi bir dengesizlik durumunun olmamasıdır (Güney, 2015: 82).

Yaklaşımda iki ülkenin, iki ülkeye ait ulusal para biriminin, dikey toplam arz eğrisinin ve ticareti yapılan tek bir homojen malın olduğu, sermaye hareketleri ve dış ticaret üzerinde herhangi bir kısıtlamanın (vergi, kota vb.) olmadığı, ülkelere ait finansal varlıkların tam ikame olduğu varsayımından hareketle Faiz Oranı Paritesi geçerli olmaktadır. Buradan hareketle denklem (1.16) ulusal para biriminin beklenen değer kaybını göstermektedir.

$$E_t(\Delta s_{t+k}) = (E_t s_{t+1} - s_t) = (i_t - i_t^*) \quad (1.16)$$

Denklem (1.16)'ya göre, ulusal paranın beklenen değer kaybı ülkeler arası faiz oranı farkına eşit olmaktadır.

Parasalcı yaklaşımda yurtiçi ve yurtdışı finansal araçlar tam ikame varsayıldığı için iki piyasa tek bir piyasa altında değerlendirilmektedir. Ayrıca yaklaşım tahvil piyasasını göz ardı ederek para piyasası dengesi üzerine odaklanmaktadır. Bu doğrultuda modele ait para talebi fonksiyonu şöyle türetilmektedir:

$$m_t^D - p_t = \beta_0 y_t - \beta_1 i_t \quad (1.17)$$

$$m_t^{D*} - p_t^* = \beta_0 y_t^* - \beta_1 i_t^* \quad (1.18)$$

Denklem (1.17) yurtiçi para talebi, denklem (1.18) yurtdışı para talebi fonksiyonunu ifade etmektedir.  $m_t^D$  logaritmik yurtiçi para arzını,  $p_t$  logaritmik yurtiçi fiyatlar genel düzeyini,  $y_t$  logaritmik yurtiçi gelir seviyesini,  $i_t$  yurtiçi faiz oranını,  $\beta_0$  para talebinin gelir esnekliğini,  $\beta_1$  para talebinin faiz esnekliğini, \* ile işaretliler yurtdışı değişkenleri ifade etmektedir. Para talebinin gelir esnekliği  $0 < \beta_0 < 1$ , para talebinin faiz esnekliği  $\beta_1 > 0$  olduğu kabul edilmektedir (MacDonald, 2007: 95).

Parasalcı yaklaşımda SAGP'nin geçerli olduğu ve bu durumda  $s_t = p_t - p_t^*$  koşulundan hareketle denklem (1.17) ve (1.18)

$$s_t = p_t - p_t^* = m_t - m_t^* - \beta_0(y_t - y_t^*) + \beta_1(i_t - i_t^*) \quad (1.19)$$

şeklinde yazılabilmektedir. Denklem (1.19)'a göre, döviz kuru ulusal paralara ait arz ve talep güçleri tarafından belirlenmektedir. Buradan hareketle döviz kuru, ulusal para arzının yabancı ülke para arzına göre daha fazla artması, ulusal gelir düzeyinin yabancı ülke gelir düzeyine göre daha yüksek oranda azalması ve yurtiçi faiz oranının yurtdışı faiz oranından daha fazla artması durumunda artış göstermektedir. Aktarım mekanizması açısından değerlendirildiğinde ulusal para arzındaki artışlar faiz oranını düşürmekte, bu durum yurtiçi tahvillere olan talebi azaltmakta ve yurtdışı tahvillere talep artırmaktadır. Böylece döviz kuru yükselmektedir.

SAGP varsayımı sonucunda  $s_t = p_t - p_t^*$  durumunun geçerli olduğu ortaya çıkmaktadır. Buradan hareketle döviz kuru ülkeler arası fiyat düzeylerinde meydana gelen değişimler sonucunda belirlenmektedir. Dolayısıyla döviz kurunda meydana gelen değişimler ülkelerin beklenen enflasyon oranı farkı tarafından belirlenmektedir. Faiz oranı ile beklenen enflasyon oranı arasındaki ilişki Fisher Etkisi'ne bağlı olarak yeniden düzenlenirse yani faiz oranı farkı yerine beklenen enflasyon oranı farkı yazılırsa

$$s_t = m_t - m_t^* - \beta_0(y_t - y_t^*) + \beta_1(E(\Delta p_t) - E(\Delta p_t^*)) \quad (1.20)$$

eşitliği elde edilir. Elde edilen bu eşitlik neticesinde yurtiçi para arzındaki artış, yurtiçi gelir düzeyindeki azalış ve beklenen enflasyon oranındaki artış döviz kurunun yükselmesine neden olmaktadır (Sarno ve Taylor, 2003: 108-110).

#### 1.3.4.2. Katı Fiyatlı Parasalcı Yaklaşım

Esnek Fiyatlı Parasalcı yaklaşımda SAGP'nin kısa ve uzun vadede geçerli olduğu ve dolayısıyla nominal döviz kurunun dengede olduğu kabul edilmektedir. Ancak ekonomik birimlerin eksik bilgiye sahip olması, ücret sözleşmeleri ve tüketici alışkanlıkları gibi etmenler fiyatların uyum sağlama hızının azalmasına yol açmaktadır. Bu durum uzun ve kısa dönemin ayrı ayrı ele alındığı iki farklı analiz yapılması gerektiği sonucunu ortaya çıkarmaktadır. Bu doğrultuda Rudiger Dornbusch (1976) tarafından ortaya atılan döviz kurunda hedefi aşma (*overshooting*) yaklaşımı, fiyatların katı olduğu durumda döviz kuru dengesini açıklamaya yönelik geliştirilen en önemli teorik açıklamayı oluşturmaktadır (Pilbeam, 1992: 176). Dornbusch geliştirdiği teorisinde, emtia fiyatlarının kısa vadede katı olduğunu bu nedenle denge değerine yaklaşmak için belli bir zamanın geçmesi gerektiğini vurgulamaktadır. Buna karşılık, varlık fiyatları (tahvil fiyatları ve döviz kuru) esnek bir yapıya sahiptir. İki piyasa arasında uyum

hızından kaynaklı asimetri durumu bir hedef aşımı durumunu gerçekleştirmektedir (MacDonald, 2007: 114-115).

Model, küçük ülke varsayımı altında kurgulanmaktadır. Yabancı ülke fiyatlar genel düzeyi ve faiz oranı veri olarak kabul edilir. Döviz kuru değişiminde Faiz Oranı Paritesi yaklaşımının geçerli olduğu varsayılmaktadır.

Modelin temel uyum denklemi (1.21), Esnek Fiyatlı Parasalcı yaklaşım da olduğu gibidir.

$$s_t = (i_t - i_t^*) \quad (1.21)$$

Uzun dönemde fiyatlar tamamen esnektir ve para piyasası koşulları altında belirlenmektedir.

$$m_t - p_t = \beta_0 y_t - \beta_1 i_t \quad (1.22)$$

Faiz Oranı Paritesi yaklaşımının geçerliliği kapsamında  $i_t = i_t^*$  koşulu ve fiyatların tam esnek yapısı varsayımı eklendiğinde;

$$m_t - \bar{p}_t = \beta_0 y_t - \beta_1 i_t \quad (1.23)$$

uzun dönem para piyasası denge koşulu elde edilmektedir. SAGP'nin uzun dönemde geçerli olduğu varsayımı altında ( $\bar{s}_t = \bar{p}_t - \bar{p}_t^*$ ), denge döviz kuru ülkeler arası fiyatlar genel seviyesi farklılıkları tarafından belirlenmektedir. Bu eşitlik denklem (1.20)'de ilgili yerlere yerleştirildiğinde ve kolaylık sağlaması açısından beklentilerin rasyonel olduğu kabul edildiğinde;

$$\bar{s}_t = (m_t - m_t^*) - \beta_0 (y_t - y_t^*) + \beta_1 (\pi - \pi^*) \quad (1.24)$$

eşitliği elde edilmektedir. Fiyatların katı olmasından kaynaklı SAGP geçersiz olmakta ve uzun dönemde denge seviyesinden sapmaktadır (MacDonald, 2007: 115-116).

Mal piyasasında fiyatların uyum hızı ( $\sigma$ ) döviz kurunun uzun dönem denge değerine yakınsama sürecini belirlemektedir. Uzun dönem denge döviz kuru patikası ile  $E_t(\Delta s_{t+k}) = -\sigma(s_t - \bar{s}_t) + \pi - \pi^*$  Faiz Oranı Paritesi koşulunun  $E_t(\Delta s_{t+k}) = (i_t - i_t^*)$  birleştirilmesi sonucunda uzun dönem parasal denklemi elde edilmektedir.

$$s_t - \bar{s}_t = -\left(\frac{1}{\sigma}\right) [(i_t - \pi) - (i_t^* - \pi^*)] \quad (1.25)$$

Denklem (1.25)'ten hareketle döviz kurundaki hedefi aşma durumu ülkeler arası reel faiz oranı farklılığından kaynaklanmaktadır. Ülkenin sıkı para politikası uygulaması, reel para arzının azalmasına, faiz oranının yükselmesine, ülkeye sermaye girişi yaşanmasına neden olmaktadır. Bu durumda döviz kuru düşmekte ve uzun dönem denge değerinden sapma göstermektedir. Böyle bir durumda döviz kurunda meydana gelen değişim para arzında meydana gelen değişimden daha büyük olmaktadır. Kısa dönemde SAGP koşulunun sağlanamaması durumuna döviz kurunda hedefi aşma (overshooting) denilmektedir (Güney, 2015: 90-91).

Katı Fiyatlı Parasalcı yaklaşımın genel denklemi ise şöyle oluşturulmaktadır. Denklem (1.25) ve denklem (1.24) birleştirildiğinde;

$$s_t - \bar{s}_t = (m_t - m_t^*) - \beta_0(y_t - y_t^*) + \beta_1(\pi - \pi^*) - \left(\frac{1}{\sigma}\right)[(i_t - \pi) - (i_t^* - \pi^*)] \quad (1.26)$$

elde edilmektedir. Modele göre uzun dönemde beklenen enflasyon farkı sıfıra eşit olacağı için;

$$s_t = (m_t - m_t^*) - \beta_0(y_t - y_t^*) - \left(\frac{1}{\sigma}\right)(i_t - i_t^*) \quad (1.27)$$

eşitliği elde edilir. Bu eşitlik Dornbusch modelinin temel denklemini oluşturmaktadır. Bu denkleme göre, yurtiçi para arzındaki artış yabancı ülke para arzından daha büyük ise veya yurtiçi gelir düzeyi yabancı ülke gelir düzeyinden daha fazla düşüş gösterirse döviz kuru düşme eğiliminde olacaktır. Dornbusch modeli, Esnek Fiyatlı Parasalcı yaklaşımdan farklı olarak, kısa dönemde fiyatlardaki katılıklar nedeniyle yurtiçi faiz oranındaki artışların, uyum hızı katsayısı ( $\sigma$ ) kadar döviz kuru üzerinde değer kazancı yaratacağını ifade etmektedir (MacDonald, 2007: 115-123; Güney, 2015: 92).

### 1.3.5. Portföy Dengesi Yaklaşımı

Portföy Dengesi yaklaşımı, Markowitz (1952) ve Tobin (1958)'in çalışmalarına dayanmaktadır. Markowitz daha önceki çalışmalardan farklı olarak, döviz kuru belirlenme sürecinde risk unsurunun yer almadığını ve geleceğin belirsizlik içerdiği görüşünden hareketle riski dağıtmak için yatırım araçları arasında çeşitlendirme yapılması gerektiğini ifade etmiştir. Tobin ise Markowitz'in görüşüne en likit ve risksiz finansal araç olan nakit parayı dahil ederek, birimlerin kendi risk tercihlerine göre yatırım kararlarını riskli ve risksiz varlıklar arasında çeşitlendirdiğini ifade etmektedir (Pentecost, 1993: 151; Öztürk ve Bayraktar, 2010: 171).

Portföy Dengesi yaklaşımında parasalcı yaklaşımdaki menkul kıymetlerin tam ikame olma varsayımı reddedilerek finansal varlıklar arasındaki risk farklılığı dikkate alınmaktadır. Böylece ekonomik birimler, portföyünden elde etmek istediği maksimum geliri kendilerine göre kabul edilebilir bir risk düzeyinde menkul kıymetler arasında dağıtmaktadır. Yaklaşımına göre, yatırım kararlarının farklı olmasındaki en temel gerekçe birimlerin risk iştahının farklı olmasıdır. Bazı yatırımcılar getirisi yüksek olsa bile daha az riskli araçlara yatırım yaparak riskten kaçınıırken, bazı yatırımcılar getirisi daha yüksek olmak şartıyla daha riskli araçlara yatırım yaparak risk almaktan hoşlanırlar. Bu durum ekonomik birimlerin farklı davranışlar sergilemesine ve farklı finansal araçlardan oluşan portföyler oluşturmalarına neden olmaktadır (Sarno ve Taylor, 2003: 115).

Portföy Dengesi yaklaşımı döviz kurlarının, yabancı menkul kıymetlerin arz ve talebinde meydana gelen değişmelere bağlı olarak açıklamaktadır. Birimler maksimum getiriyi sağlamak adına portföylerini yerli ve yabancı menkul kıymetler ve ulusal ve yabancı para birimleri arasında dağıtarak oluşturmaktadır. Birimlerin portföy oluşturma süreçleri ve daha sonrası portföyde meydana gelen değişimler döviz kurunu etkilemektedir.

Denklem (1.28) birimlerin yurtiçi veya yabancı varlık edinme durumunu ifade etmektedir.

$$W_t = M_t + B_t + E_t B_t^* \quad (1.28)$$

Denklem (1.28)'de yer alan  $W_t$  net serveti,  $M_t$  nakit parayı,  $B_t$  birimler tarafından tutulan yurtiçi varlıkları,  $E_t$  döviz kurunu ve  $B_t^*$  birimler tarafından tutulan yabancı varlıkları ifade etmektedir. Denklemde yer alan üç varlığa ( $M_t$ ,  $B_t$  ve  $B_t^*$ ) olan talep, servete ve risk primine bağlıdır. Bu durumda varlıklara ait talep denklemleri şu şekilde olmaktadır:

$$\frac{M_t^D}{W_t} = \beta_0 + \beta_1 \rho_t \quad (1.29)$$

$$\frac{B_t^D}{W_t} = \beta_2 + \beta_3 \rho_t \quad (1.30)$$

$$\frac{E_t B_t^{*D}}{W_t} = \beta_4 + \beta_5 \rho_t \quad (1.31)$$

$\beta_0, \beta_2, \beta_4 > 0$ 'dır.  $\beta_1 < 0$ , risk primi arttıkça nakit para talebi azalmaktadır.  $\beta_3 > 0$ , yurtiçi finansal varlıkların getirisi yurtdışı finansal varlıkların getirisine göre arttıkça

yurtiçi finansal varlıklara talep artmaktadır.  $\beta_5 < 0$ , yurtiçi finansal varlıkların getirisi yurtdışı finansal varlıkların getirisine göre arttıkça yurtdışı finansal varlıklara talep azalmaktadır (Moosa ve Bhatti, 2010: 225-230, Özataş, 2019: 169-170).

Özetlemek gerekirse Portföy Dengesi yaklaşımında denge döviz kuru, yurtiçi ve yurtdışı finansal varlıkların dengeye gelmesiyle oluşmaktadır. Yurtiçi faiz oranında bir artış olması durumunda ulusal para birimi talebi artacak, ulusal para birimi değer kazanacak döviz kuru düşecektir. Tersine yurtdışı faiz oranı arttığında yurtdışı finansal varlıklara olan talep artacak, bu durum sermaye çıkışına yol açacak, ulusal para birimi değer kaybedecek, döviz kuru yükselecektir. Servetin artması durumunda ise her finansal varlığa olan talep artış göstermekte, portföy dengesi değişmemektedir.

### 1.3.6. Spekülatif Kabarcıklar Yaklaşımı

Döviz kuru belirlenme sürecine ait beklentilerle yakından ilişkili olan yaklaşım, Spekülatif Kabarcıklar yaklaşımıdır. Spekülatif Kabarcıklar, Frankel ve Froot (1990) tarafından, ekonomik ilkeler tarafından belirlenemeyen, aksine kendini doğrulayan piyasa beklentilerinin bir sonucu olarak tanımlanmaktadır.

Spekülasyon, herhangi bir ekonomik varlığın gelecekteki değeri hakkında tahminde bulunarak ve bu durumdan kâr etmek amacıyla alım satım işlemi gerçekleştirmektedir. Dolayısıyla spekülasyonu doğuran en temel etken fiyatların gelecekteki belirsizliğidir. Örneğin, birimler yaptığı tahmin sonucunda herhangi bir para biriminin değer kazanacağını düşünüyorsa para biriminin düşük olduğu noktada satın alacak, tahmini gerçekleştiğinde satarak kâr elde edecektir. Profesyoneller tarafından yapılan alım satım işlemine ek olarak piyasada spekülâtorleri takip eden ekonomik birimler, para birimine talep artışının hızlanmasına ve döviz kurunun denge düzeyinin üzerine çıkmasına neden olmaktadır. Kurun denge düzeyinin üzerinde fiyatlanmasına spekülâtif kabarcık denilmektedir (Frankel, 1996: 153).

Spekülâtif Kabarcıklar yaklaşımında nominal döviz kuru denklemi şöyledir:

$$s_t = \frac{1}{1+\lambda} \sum_{i=0}^{\infty} \left[ \frac{\lambda}{1+\lambda} \right]^i E_t(x_{t+i}) \quad (1.32)$$

$\forall = \frac{\lambda}{1+\lambda}$  için yeniden düzenlenirse;

$$s_t^n = (1 - \forall) \sum_{i=0}^{\infty} [\forall]^i E_t(x_{t+i}) \quad (1.33)$$

Denklemlerde yer alan  $\lambda$  terimi iskonto faktörünü ifade etmektedir.  $(1 - \forall) > 1$  ise döviz kurunda kabarcık süreci oluşmaktadır. Denklem limiti sıfıra yaklaşan bir katsayıyı zorunlu kıldığı için döviz kurunda spekülasyon kaynaklı kabarcığın olmadığı durumu ifade etmektedir. Spekülatif kabarcıkların olduğu durumda  $(b_t)$  nominal döviz kuru denklemi şu şekilde olmaktadır:

$$s_t = s_t^n + b_t, \quad b_t = \frac{E_t b_{t+1}}{\lambda} \quad (1.34)$$

Spekülatörlerin geleceğe dair mükemmel öngöründe bulundukları varsayımı altında spot kur  $s_t^n = E_t s_t^*$  olur. Bu denkleme hata terimi eklendiğinde  $s_t^* = s_t^n + u_t$  elde edilir. Kabarcıkların varlığını incelemek amacıyla varyans ayrıştırma yöntemi kullanılırsa;  $Var(s_t^*) = Var(s_t^n) + Var(u_t)$ ;  $Var(s_t^*) > Var(s_t^n)$  olur. Döviz kuru denklemine spekülatif kabarcık değişkeni eklendiğinde  $s_t^* = s_t^n - b_t + u_t$  elde edilir. Bu denklem için de varyans ayrıştırma işlemi uygulanırsa döviz kurunda yüksek oynaklığın varlığı ortaya çıkmaktadır (Sarno ve Taylor, 2003: 24-26, MacDonald, 2007: 96-97).

Spekülatif Kabarcıklar yaklaşımı, birimlerin ekonomik verileri dikkate almaksızın yabancı bir para biriminin değer kazanacağı/kaybedeceği beklentisiyle ilgili para birimine yönelmesi/ayrılması durumunda döviz kurunun artacağını/azalacağını, bu durumda birimlerin beklentilerinin gerçekleşeceği (*kehanetin gerçekleşmesi*) ve dolayısıyla piyasanın etkin duruma geleceğini ifade etmektedir.

### 1.3.7. Döviz Kuruna Mikro Yaklaşım

Bu başlığa kadar olan yaklaşımlarda döviz kuru belirlenme süreci, cari işlemler dengesi, fiyatlar genel düzeyi, faiz oranı farklılıkları, reel gelir seviyesi ve para piyasası dengesi gibi makroekonomik değişkenler üzerinden açıklanmaya çalışılmıştır. Ancak 1990'lı yılların başından itibaren döviz kurunu açıklamaya yönelik makro yaklaşımların kısa vadeli sonuçlarda yaşadıkları başarısızlıklar, bu alanda yeni bir arayışın ortaya çıkmasına neden olmuştur. Meese (1990) ve Frankel ve Rose (1995) makro yaklaşımların döviz kuru değişimlerini kısa dönemde açıklamada önemli bir katkı sağlamadığını ifade etmişlerdir. Makro yaklaşımların durumu açıklamada yaşadığı başarısızlıklar neticesinde ortaya çıkan mikro yapısal yaklaşım (*microstructure*) kuramı, döviz kuru teorileri içerisinde yerini almıştır (Özatay, 2019: 157).

Mikro yapısal yaklaşım, döviz kuru piyasasında işlem yapan ekonomik birimlerin davranışları, beklenti farklılıkları, asimetrik bilgi durumu ve alım satım emirlerinin döviz

kuru üzerindeki etkilerine odaklanmaktadır (Sarno ve Taylor, 2003: 264). Yaklaşım, makro yaklaşımda yer alan tüm birimlerin aynı bilgi kümesine dahil olduğu ve benzer davranış gösterdiği, döviz piyasasındaki alım satım işlemlerinin farklı mekanizmalar yoluyla döviz kurunu etkilemeyeceği görüşünü reddederek bilgi farklılıkları, ekonomik birimlerin heterojen davranışları ve alım satım emirleri üzerinden yeni bir yaklaşım ortaya koymaktadır (Berke, 2014: 31; Özatay, 2019: 158).

Mikro yaklaşım, döviz kuru piyasasında asimetrik bilginin var olduğunu ve bu durumdan kaynaklı olarak piyasa yapısının eksik rekabetçi olduğunu ifade etmektedir. Makro modellere yapılan bir başka eleştirisi ise ekonomik birimlerin homojen davranış biçimlerinin gerçek hayatta geçersiz olduğu, birimlerin heterojen tepkiler verdiğidir. Son olarak makro yaklaşımlarda alım satım işlemlerine önem verilmezken, mikro yaklaşım alım satım işlemlerini fiyat intibakının bir nedeni olarak ifade edilmektedir (Galac vd., 2006: 3). Birimlerin heterojen olması, piyasada asimetrik bilgi durumunun varlığı ve alım satım emirleri ve alım satım emirleri arasındaki fiyat farklılıklarının döviz piyasasındaki önemli etkisi, döviz kurundaki oynaklığın en önemli sebepleridir (Evans ve Lyons, 2002).

## İKİNCİ BÖLÜM LİTERATÜR İNCELEMESİ ve VERİ SETİ

### 2.1. Literatür İncelemesi

Döviz kuru piyasası, hisse senedi piyasasıyla birlikte, tahmin nesnesi olarak literatürde sıklıkla incelenen alanlardan biridir. Bunun temel nedenleri, bu piyasalara ait veri setlerinde gözlenen doğrusal olmayan yapılar ve bu yapıların piyasa dinamiklerinin karmaşıklığı ile katılımcıların farklı ekonomik koşullara verdiği tepkilerden kaynaklanan tahmin zorluklarıdır. Döviz kurlarının doğru bir şekilde tahmin edilmesi, yalnızca kâr fırsatlarının değerlendirilmesi açısından değil, aynı zamanda hane halkları, firmalar ve kamu kesiminin ekonomik karar alma süreçlerini optimize etmesi açısından da büyük bir öneme sahiptir. Hane halkları, döviz kurundaki olası değişimleri önceden tahmin ederek birikimlerini enflasyonist etkilerden koruyabilir ve döviz bazlı yatırımlarını daha bilinçli bir şekilde yönetebilir. Firmalar ise ithalat ve ihracat faaliyetlerini daha etkin planlayarak maliyetlerini optimize edebilir ve kur riskinden kaynaklanan olumsuz etkileri minimize edebilir. Kamu kesimi açısından bakıldığında, doğru tahmin edilen döviz kurları, maliye ve para politikalarının daha etkin bir şekilde tasarlanmasını ve uygulanmasını sağlar.

Literatürde döviz kuru tahmininde kullanılan geleneksel ekonometrik modellerin doğrusal olmayan yapıları tam olarak yakalayamaması ve ani değişimlere duyarlı olmaması gibi sınırlamaları mevcuttur. Bu nedenle, derin öğrenme modellerinin kullanımı son yıllarda yaygınlık kazanmıştır. Ancak, bu alandaki bazı açık noktalar hâlâ çözüm beklemektedir. Özellikle, uzun dönemli tahminlerde derin öğrenme modellerinin performansının daha detaylı incelenmesi gerekmektedir.

Döviz kuru hareketlerinin tahmin edilmesi zor olsa da ekonometrik ve istatistiksel yöntemler döviz kurlarını tahmin etmek için yaygın olarak kullanılmaktadır. Bu doğrultuda Fama (1970)'nin ufuk açıcı çalışmasından başlayarak geniş bir literatür, döviz kuru piyasasının yapısını incelemiştir. Ampirik literatürün ilk dönemlerinde ele alınan tahmin yöntemleri çok geniş bir yelpazede yayılmakta, Otoregresif Hareketli Ortalama (Autoregressive Moving Average, ARMA), Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Moving Integrated Average, ARIMA), Otoregresif Koşullu Değişen Varyans (Autoregressive Conditional Heteroskedasticity, ARCH), Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (Generalized Autoregressive Conditional Heteroskedasticity, GARCH) ve türevleri gibi ekonometrik modelleri içermektedir. Ancak bu yöntemler, döviz kuru serilerindeki doğrusal olmayan yapılar nedeniyle tahmin

performansını olumsuz etkileyen ve zayıf sonuçlara yol açan kısıtlayıcı dağılım varsayımlarına dayanmaktadır. Özellikle son yıllarda döviz kuru serilerindeki durağan olmayan yapı, küresel ekonomik dalgalanmalar, politika belirsizlikleri, finansal piyasalardaki ani şoklar ve piyasa katılımcılarının heterojen davranışlarından kaynaklanmaktadır. Geleneksel zaman serisi tekniklerinin, özellikle doğrusal olmayan ilişkileri yakalamada, ani değişimleri modellemede ve serilerin yüksek oynaklıklarını açıklamada yetersiz kalması, araştırmacıları ve uygulayıcıları yapay zekâ temelli tahmin yöntemlerine yöneltmiştir. Bu yöntemler, döviz kuru serilerinin karmaşık ve dinamik yapısını daha esnek bir şekilde modelleyebilme potansiyeli sunmaktadır. Son yıllarda, derin öğrenme yöntemlerindeki gelişmeler ve bu modellerin döviz kuru tahmin süreçlerinde etkin bir şekilde kullanılması dikkat çekmektedir. Özellikle, TensorFlow ve PyTorch gibi açık kaynaklı derin öğrenme kütüphanelerinin yaygınlaşması, araştırmacıların bu alanda daha esnek ve güçlü modeller geliştirmesine olanak tanımıştır. Bu nedenle, çalışmanın bu kısmında döviz kuru tahmininde derin öğrenme modellerinin kullanıldığı çalışmalara odaklanılmıştır. (Anastasakis ve Mort, 2009: 12001-12003; Sun, Wang ve Wei, 2020).

Derin öğrenme modellerinden Yapay Sinir Ağları (Artificial Neural Network, ANN), birbirine bağlı birçok yapay sinir hücresinden (nöronlardan) oluşan ve bu nöronlar aracılığıyla girdiyi işleyerek çıktıya ulaştıran, insan beynine benzeyen katmanlı bir yapıdır. Döviz kuru tahmininde ANN modelinin kullanıldığı çalışmalar Yao ve Tan (2000), Kamruzzaman ve Sarker (2003), Panda ve Narasimhan (2007), Altan (2008), Anastasakis ve Mort (2009), Özkan (2011), Babu ve Reddy (2015), Wang vd. (2016), Galeshchuk (2016), Nwosu vd. (2021), Tripathi vd. (2021) ve Erem (2023) dikkate alındığında ANN modelinin en popüler derin öğrenme modellerinden biri olduğu görülmektedir.

Finansal zaman serilerinin tahmininde yaygın olarak kullanılan bir diğer derin öğrenme yöntemi Tekrarlayan Sinir Ağı (Recurrent Neural Network, RNN) modelidir. RNN mimarisi ANN'den farklı olarak önceki girdileri hatırlama ve işleme yeteneğine sahiptir (Deng ve Yu, 2014: 220-223). Bu sebeple zamana bağlı verilerin işlenmesinde RNN mimarisinin sıklıkla kullanıldığı dikkat çekmektedir. Tenti (1996), Leung vd. (2000), Kiani ve Kastens (2008), Dautel vd. (2019), Lin vd. (2020), Sun vd. (2020) ve Birdi vd. (2023)'nin çalışmaları RNN modeli ile döviz kuru tahmininin yapıldığı çalışmalara örnektir.

Derin öğrenme modelleriyle ilgili çalışmaların gelişmesiyle RNN modelinde ortaya çıkan uzun süreli bağımlılık ve bu bağımlılığın yol açtığı uzun zaman aralığındaki bilgiyi korumakta zorlanma sorununu çözmek veya azaltmak için Uzun Kısa Dönemli Hafıza (Long Short Term Memory, LSTM) ve Kapılı Tekrarlayan Ünite (Gated Recurrent Unit, GRU) modelleri tasarlanmıştır (Kaya, 2022: 41-45). Bu modeller uzun vadeli bağlamsal ilişkileri daha etkili şekilde öğrenerek daha tutarlı modellerin inşa edilmesine katkı sağlamaktadır. Finansal zaman serileri analizinde sıklıkla kullanılan bu yöntemler döviz kuru tahmin literatüründe Ni vd. (2019), Dautel vd. (2019), Kaushik ve Giri (2020), Lin vd. (2020), Putri ve Halim (2020), Islam ve Hossain (2020), Sun vd. (2020), Yıldırım vd. (2021), Abedin vd. (2021), Jung ve Choi (2021), Telatar (2022), Birdi vd. (2023), Biswas vd. (2023), Vika ve Çollaku (2023) çalışmalarında kullanılmıştır.

Bu literatür taramasının amacı, döviz kuru tahmini konusunda yapılmış çalışmaların kapsamlı bir incelemesini sunarak, alan yazındaki durumu ve boşlukları belirlemektir. Ayrıca, çalışmanın bir sonraki aşamasında kullanılacak yöntemlerin belirlenmesine zemin hazırlamaktır.

Yukarıda kısaca açıklandığı üzere son yıllarda yapay zekâ yöntemlerinin hızla gelişmesi ve geliştirilen modellerin döviz kuru tahmin sürecinde sıklıkla kullanılıyor olması sürecin yakından takip edilmesini zorunlu kılmaktadır. Yapay zekâ temelli yöntemler, döviz kuru serilerinin karmaşık ve dinamik yapısını daha esnek bir şekilde modelleyebilme potansiyeli sunmakta ve geleneksel yöntemlerin kısıtlayıcı dağılım varsayımlarından bağımsız olarak daha doğru tahminler üretebilmektedir. Bu bağlamda, son yıllarda yapılan çalışmalar, yapay zekâ modellerinin tahmin doğruluğunu artırarak finansal karar alma süreçlerine önemli katkılar sağladığını göstermektedir. Bu sebeple çalışmanın bu kısmında döviz kuru tahmini ile ilgili ulusal ve uluslararası literatürde yer alan yapay zekâ yöntemlerinin kullanıldığı çalışmalara ait yöntem ve bulgular özetlenecek, bir sonraki bölüm olan yöntem kısmında derin öğrenme modelleri hakkında ayrıntılı açıklamalar yapılacaktır. Bu doğrultuda öncelikle incelenen çalışmalara ait özet bilgiler tabloda sunulmakta, devamında ilgili çalışmalara ait ayrıntılı bilgiler verilmektedir. Bu çerçevede elde edilecek bilgilerin, çalışmada kullanılacak yöntemlerin belirlenmesine katkı sağlayacağı beklenmektedir.

**Tablo 2: Literatür Özeti**

| Yazarlar                     | Örneklem          | Para Birimi                                 | Yöntem            | Sonuç                                                                                                                                                                                                                                                                                            |
|------------------------------|-------------------|---------------------------------------------|-------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Tenti (1996)                 | 1990:M01-1994:M12 | DEM/USD                                     | RNN               | Farklı özellikleri içinde barındıran RNN mimarilerinin kullanıldığı çalışmada, yazar derin öğrenme mimarilerinin döviz piyasası dinamiklerini yakalamada başarılı sonuçlar verdiğini, bu nedenle derin öğrenme mimarilerinin döviz piyasası tahmininde uygulanabilir olduğu sonucuna ulaşmıştır. |
| Leung vd. (2000)             | 1974:M01-1995:M07 | CAD, GBP, JPY                               | GRNN, MLFN, ARIMA | GRNN mimarisi, MLFN ve ARIMA modellerine göre daha güçlü sonuçlar vermektedir.                                                                                                                                                                                                                   |
| Yao ve Tan (2000)            | 1984:M05-1995:M07 | JPY/USD, DEM/USD, GBP/USD, CHF/USD, AUD/USD | ANN, ARIMA        | ANN modelleri, ABD Doları ile çalışmada kullanılan diğer para birimleri arasındaki döviz kurunu tahmin etmede ARIMA modeline göre çok daha güçlü sonuçlar vermektedir.                                                                                                                           |
| Kamruzzaman ve Sarker (2003) | 1991:M01-2002:M07 | USD/AUD, GBP/AUD, JPY/AUD, SGD/AUD,         | ANN, ARIMA        | Üç farklı ANN modelinin kullanıldığı çalışmada tüm ANN modelleri ARIMA modelinden daha iyi performans göstermiştir.                                                                                                                                                                              |

|                               |                        |                                                                     |                                                                   |                                                                                                                                                                          |
|-------------------------------|------------------------|---------------------------------------------------------------------|-------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                               |                        | NZD/AUD,<br>CHF/AUD                                                 |                                                                   |                                                                                                                                                                          |
| Cao vd. (2005)                | 2003:M01-2005:M01      | USD/GBP                                                             | SVM                                                               | SVM modeli, finansal zaman serileri üzerinde tahmin gücüne sahiptir.                                                                                                     |
| Panda ve<br>Narasimhan (2007) | 1994:M01-2003:M07      | INR/USD                                                             | AR Model,<br>Rassal<br>Yürüyüş,<br>ANN                            | ANN mimarisi, AR model ve rassal yürüyüş modellerinden daha üstün tahmin sonuçları vermektedir.                                                                          |
| Altan (2008)                  | 1987:M01-2007:M09      | USD/TL                                                              | VAR, ANN                                                          | ANN, VAR modeline göre daha güçlü sonuçlar vermektedir.                                                                                                                  |
| Kiani ve Kastens<br>(2008)    | 1972:M05-2005:M02      | GBP/USD<br>CAD/USD<br>JPY/USD                                       | ARMA,<br>FFNN, RNN                                                | RNN modeli GBP/USD ve USD/JPY döviz kurlarını tahmin etmede ARMA modellerinden daha iyi performans gösterirken, USD/CAD döviz kurunu tahmin etmede başarılı olamamıştır. |
| Anastasakis ve<br>Mort (2009) | 1996:M01-2001:M05      | GBP/USD,<br>DEM/USD,<br>GBP/DEM,<br>JPY/USD,<br>JPY/DEM,<br>JPY/GBP | Parametrik<br>ve parametrik<br>olmayan<br>analog<br>karşılaştırma | Parametrik ve parametrik olmayan yöntemin birleştirildiği grup yaklaşım, bireysel yaklaşımlara göre daha umut verici sonuçlar üretmiştir.                                |
| Özkan (2011)                  | 1986-2010<br>1999-2010 | USD/TL<br>EUR/TL                                                    | ANN                                                               | Üç farklı modelin (gecikmeli değerler modeli, SAGP modeli, parasal model) uygulandığı çalışmada döviz kurunun                                                            |

|                         |                                                               |                                             |                                                           |                                                                                                                     |
|-------------------------|---------------------------------------------------------------|---------------------------------------------|-----------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------|
|                         |                                                               |                                             |                                                           | gecikmeli değerlerinin kullanıldığı model, SAGP modeli ve parasal modele kıyasla daha tutarlı sonuçlar vermektedir. |
| Korol (2014)            | 2005-2011                                                     | JPY/USD,<br>GPY/USD,<br>CHF/USD             | Bulanık<br>Mantık                                         | Yazar tarafından geliştirilen bulanık mantık modeli yüksek verimliliğe sahiptir.                                    |
| Babu ve Reddy<br>(2015) | 2010:M01-2015:M04                                             | USD/INR,<br>GBP/INR,<br>EUR/INR,<br>JPY/INR | ARIMA,<br>ANN,<br>Bulanık<br>Model                        | ARIMA modeli, diğer iki modele göre döviz kurlarını en iyi tahmin eden modeldir.                                    |
| Shen vd. (2015)         | 1976-1993,<br>2000:M01-2004:M01,<br>1994:M01-2003:M07         | GBP/USD,<br>BRL/USD,<br>INR/USD             | DBN, FFNN                                                 | DBN modeli, beş karşılaştırma metriğinin tamamında FFNN modeline göre daha iyi performans göstermektedir.           |
| Wang vd. (2016)         | 2010-2013                                                     | USD/EUR                                     | Bulanık<br>Mantık,<br>ANN, ANN-<br>ARMA,<br>ANN-<br>ARIMA | Çalışmada önerilen ANN-ARIMA modeli döviz kurlarını tahmin etmedeki etkinliği önemli ölçüde artırmaktadır.          |
| Galeshchuk (2016)       | 2014:M01-2014:M04,<br>2009:M05-2014:M05,<br>1999:M05-2014:M05 | USD/EUR,<br>JPN/USD,<br>USD/GBP             | ANN                                                       | Kısa vadeli tahmin yöntemi daha güçlü tahmin sonuçları doğurmaktadır.                                               |

|                                |                   |                                                                                 |                                             |                                                                                                                                                                             |
|--------------------------------|-------------------|---------------------------------------------------------------------------------|---------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Galeshchuk ve Mukherjee (2017) | 2010-2015         | EUR/USD, GBP/USD, JPY/USD                                                       | ARIMA, ES, SVM, CNN,                        | CNN modeli, örneklem dışı tahminde diğer modellere göre daha tatmin edici sonuçlar vermektedir.                                                                             |
| Göncü (2019)                   | 2007:M01-2019:M05 | USD/TL                                                                          | DTR, SVM, Ridge Regresyon, Lineer Regresyon | Ridge regresyonu, çalışmada kullanılan diğer modellere göre daha iyi performans göstermektedir.                                                                             |
| Ni vd. (2019)                  | 2008:M06-2018:M05 | EUR/USD, AUD/USD, XAU/USD, GBP/JPY, EUR/JPY, GBP/USD, USD/CHF/ USD/JPY, USD/CAD | CNN, LSTM, C-RNN                            | C-RNN modeli ortalama kare hata değeri diğer modellere göre daha düşüktür. Bu neden yazarlar, C-RNN modelinin bu tür tahminlerde kullanıma uygun olduğunu ifade etmektedir. |
| Dautel vd. (2019)              | 1971:M01-2017:M08 | USD/JPY, USD/EUR, USD/GBP, USD/CHF                                              | FFNN, RNN, LSTM, GRU                        | LSTM ve GRU gibi yeni algoritmalar geleneksel RNN modellerine göre daha üstün performans göstermektedir.                                                                    |

|                         |                   |                               |                                                                            |                                                                                                                        |
|-------------------------|-------------------|-------------------------------|----------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------|
| Kaushik ve Giri (2020)  | 1994:M04-2018:M12 | USD/INR                       | VAR, SVM, LSTM                                                             | LSTM modeli çalışmada kullanılan diğer modellere göre daha yüksek başarı oranına sahiptir.                             |
| Lin vd. (2020)          | 1971:M01-2017:M08 | GBP/USD<br>USD/AUD            | ARIMA,<br>SVM, RNN,<br>MRNN,<br>LSTM,<br>MLSTM,<br>CEEMDAN-<br>MLSTM       | Yazarlar tarafından önerilen CEEMDAN-MLSTM modeli diğer modellere göre daha yüksek doğruluğa sahiptir.                 |
| Putri ve Halim (2020)   | 2014:M01-2020:M03 | EUR/USD                       | ARIMA,<br>LSTM                                                             | LSTM modeli ARIMA modeline kıyasla daha tutarlı sonuçlar vermektedir.                                                  |
| Dash (2020)             | 2014:M01-2015:M05 | USD/AUD<br>USD/GBP<br>USD/INR | ISFL-<br>RLPNN,<br>LPNN,<br>FLANN,<br>RBFNN,<br>MLP, LR,<br>KGANN,<br>ARMA | Yazar tarafından önerilen hibrit ISFL-RLPNN modeli diğer modellere göre yüksek derece tahmin doğruluğuna ulaşmaktadır. |
| Islam ve Hossain (2020) | 2017:M01-2020:M06 | EUR/USD,<br>GBP/USD,          | MA,                                                                        | Yazarlar tarafından önerilen hibrit GRU-LSTM modeli tüm modellerden daha iyi performans göstermiştir.                  |

|                     |                   |                                                       |                                                                                       |                                                                                                                                                                                                                                                    |
|---------------------|-------------------|-------------------------------------------------------|---------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                     |                   | USD/CAD,<br>USD/CHF                                   | LSTM, GRU,<br>GRU-LSTM                                                                |                                                                                                                                                                                                                                                    |
| Sun vd. (2020)      | 2011:M01-2017:M12 | USD/GBP,<br>USD/JPY,<br>USD/EUR,<br>USD/CNY           | Rassal<br>Yürüyüş,<br>ARMA,<br>MLP,<br>RBFNN,<br>WNN,<br>GRNN,<br>ELM, Elman,<br>LSTM | Yazarlar tarafından önerilen LSTM-B modeli, tahmin performansı ve potansiyel ticaret kârlılığı açısından diğer kıyaslama modellerine göre daha iyi performans sergilemektedir.                                                                     |
| Yıldırım vd. (2021) | 2013:M01-2018:M01 | EUR/USD                                               | LSTM                                                                                  | Makroekonomik göstergelerin kullanıldığı ME-LSTM ve teknik göstergelerin yer aldığı TI-LSTM modellerinin yazarlar tarafından birleştirilmesi sonucunda önerilen hibrit modelin yapılan deneyler sonucunda başarılı sonuçlar verdiği görülmektedir. |
| Abedin vd. (2021)   | 2000:M01-2020:M12 | 21 ülke para biriminin ABD Doları karşısındaki değeri | SVM,<br>Regresyon Ağacı, Rassal Orman,<br>LSTM, Bi-                                   | Yazarlar tarafından önerilen Bi-LSTM BR modeli diğer modellere kıyasla daha tutarlı sonuçlar vermektedir.                                                                                                                                          |

|                     |                   |                           |                                    |                                                                                                                                                                                    |
|---------------------|-------------------|---------------------------|------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                     |                   |                           | LSTM, Bi-LSTM BR                   |                                                                                                                                                                                    |
| Jung ve Choi (2021) | 2010:M01-2019:M12 | FXVIX                     | LSTM, autoencoder-LSTM             | Yazarlar tarafından önerilen autoencoder-LSTM modeli, geleneksel LSTM modeline göre daha iyi performans göstermiştir.                                                              |
| Nwosu vd. (2021)    | 2020:M09-2021:M03 | GBP/NGN                   | ARIMA, Rassal Orman, ANN           | ANN modeli, ARIMA ve Rassal Orman modellerine göre daha tutarlı sonuçlar ortaya çıkarmıştır.                                                                                       |
| Tripathi vd. (2021) | 2009:M01-2016:M05 | EUR/USD, GBP/USD, JPY/USD | MF, ARIMA, ANN,                    | MF, ARIMA ve ANN tekniklerinin birleştirilmesi sonucu yazarlar tarafından önerilen hibrit model, modellerin ayrı ayrı tahmin edilmesine kıyasla daha tutarlı sonuçlar vermektedir. |
| Zheng vd. (2021)    | 1997-2016         | INR/USD, CNY/USD          | DBN, FFNN                          | DBN modeli FFNN modeline göre döviz kurunu daha iyi tahmin etmiştir.                                                                                                               |
| Telatar (2022)      | 2003:M01-2022:M08 | USD/TL, BİST100           | SARIMA, LSTM                       | LSTM modeli, SARIMA modeline göre daha iyi performans göstermektedir.                                                                                                              |
| Birdi vd. (2023)    | 2022:M02-2023:M02 | INR/USD                   | RNN, LSTM                          | RNN modeli, LSTM modeline kıyasla daha yüksek doğruluğa sahiptir.                                                                                                                  |
| Biswas vd. (2023)   | 2000-2019         | USD/BDT                   | LSTM, Bi-LSTM, Yığılmış LSTM, GRU, | Zaman Dağılımlı MLP modeli, çalışmada kullanılan diğer modellere kıyasla daha düşük hata oranına sahiptir.                                                                         |

|                        |                   |                                 |                                                              |                                                                                                                                                                 |
|------------------------|-------------------|---------------------------------|--------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                        |                   |                                 | CNN, CNN-LSTM,<br>Zaman<br>Dağılımlı<br>MLP, SVM,<br>XGBoost |                                                                                                                                                                 |
| Vika ve Çollaku (2023) | 1992:M01-2022:M12 | LEK/EUR                         | DFNN, LSTM, 1D-CNN                                           | 3 ve 6 aylık tahmin döneminde LSTM modeli en iyi tahminci iken, 12 aylık tahmin döneminde 1D-CNN modelinin en iyi tahmin modeli olduğu sonucuna ulaşılmaktadır. |
| Erem (2023)            | 2020M:01-2020:M12 | CHF/EUR,<br>GBP/EUR,<br>USD/EUR | ANN, ARMA, ARIMA                                             | Tek Gizli Katmanlı ANN modeli, ARMA ve ARIMA gibi geleneksel modellerle kıyaslandığında önemli oranda avantaja sahiptir.                                        |

Tenti (1996), 1990:M01-1994:M12 döneminde Alman Markı'nın vadeli işlem tahminlerinin doğruluğunu üç farklı Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN) mimarisi kullanarak ölçmüştür. İlk mimari RNN1, sıralı ağ olarak bilinen, sıralı görevleri çözmek için kullanılan mimaridir. RNN2, gizli katman ve ekstra bir tekrarlayan nöron katmanı ile kendi içine geri beslenmektedir. Üçüncü mimari RNN3'te ise örüntüler giriş katmanından tekrarlayan bir nöron katmanı aracılığıyla işlenmekte ve sonra giriş katmanı tekrar beslenmektedir. Çalışmada, farklı özellikleri içinde barındıran bu üç mimari içerisinde RNN2 mimarisinin en iyi genel kârlılığı sağladığı, fiyat hareketlerini tahmin etmede daha yüksek doğruluğa sahip olduğu sonucuna ulaşılmaktadır. Yazar elde ettiği bu sonuç çerçevesinde, yapay sinir ağları yönteminin doğrusal olmayan özellikleri içinde barındırması ve piyasalarda bulunan küçük değişikliklere olan hassasiyeti nedeniyle döviz piyasası tahminlerinde kullanımın uygun olduğunu ifade etmektedir.

Leung vd. (2000), hızlı öğrenme, basit ve anlaşılır eğitim algoritmasıyla aykırı değerlere ve hatalı gözlemlere karşı ayırt edici özellikleri içinde barındıran Genel Regresyon Sinir Ağı (General Regression Neural Network, GRNN), parametrik olmayan sinir ağı tahmininde GRNN modeliyle birlikte sıklıkla kullanılan Çok Katmanlı İleri Beslemeli Ağ (Muti-Layer-Feedforward Neural Network, MLFN) ve zaman serisi yöntemi olan Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average, ARIMA) teknikleri ile Kanada Doları, Japon Yeni ve İngiliz Sterlini'ni tahmin ettikleri çalışmalarında, Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE) metrikleri dikkate alındığında, GRNN modelinin MLFN ve ARIMA modellerine kıyasla daha iyi tahminler sağladığı sonucuna ulaşmışlardır.

Yao ve Tan (2000), ABD Doları ile Japon Yeni, Alman Markı, İngiliz Sterlini, İsviçre Frangı ve Avustralya Doları arasındaki döviz kurlarını eğitilmiş sinir ağları tarafından tahmin etmiştir. Çalışmada teknik göstergelerin sinir ağına girdi olarak verilmesi halinde Japon Yen'i haricindeki tüm para birimleri için güçlü sonuçlar elde edildiği görülmektedir. ARIMA modelinin de kullanıldığı çalışmada para birimleri için yine benzer sonuçlar elde edilmiş, ancak Yapay Sinir Ağları (YSA) modelinin ARIMA modeline kıyasla daha doğru sonuçlar verdiği gözlemlenmiştir. Yazarlar, Japon Yen'inin diğer para birimlerine göre farklı sonuç vermesinde; Yen piyasasının daha büyük ve etkin olma ihtimalini ve bu nedenle ekonomik birimlerin herhangi bir işaret durumunda hızlı hareket etmelerinden kaynaklı olduğunu ifade etmektedir.

Kamruzzaman ve Sarker (2003), üç farklı YSA modeli (Standart Geri Yayılım-SBP, Ölçeklendirilmiş Eşlenik Gradyan-SCG ve Bayesyen Düzenlemeli Geri Yayılım-BPR) ile Avustralya Doları'nın altı para birimi (ABD Doları, İngiliz Sterlini, Japon Yeni, Singapur Doları, Yeni Zelanda Doları, İsviçre Frangı) karşısındaki değerini tahmin ettikleri çalışmalarında ARIMA modelini de kullanarak modeller arasında karşılaştırma yapmışlardır. Beş hareketli ortalama (MA5, MA10, MA20, MA60 ve MA120) teknik göstergenin kullanıldığı çalışmada, beş performans ölçütü üzerinden yapılan değerlendirme sonucunda tüm YSA modellerinin ARIMA modelinden daha iyi performans gösterdiği, SCG mimarisinin en yaygın kullanılan iki ölçüt olan Normalize Edilmiş Ortalama Kare Hata (Normalised Mean Squared Error, NMSE) ve MAE metrikleri üzerinden değerlendirildiğinde en iyi performans gösteren model olduğu, diğer üç ölçüt üzerinde SCG modelinin BPR tabanlı model ile rekabetçi sonuçlar verdiği gözlemlenmiştir.

Cao vd. (2005), doğrusal olmayan transferler uygulayarak girdi uzayını yüksek boyutlu özellik uzayına eşlemek ve en uygun hiperdüzlemi bulma şeklinde çalışan Destek Vektör Makineleri (Support Vector Machine, SVM) modelinden hareketle USD/GBP döviz kurunu tahmin etmişlerdir. Günlük olarak kapanış fiyat verisinin kullanıldığı çalışmada elde edilen 517 serinin ilk 350 serisi eğitim seti, sonraki 100 seri doğrulama seti ve kalan 67 seri tahmin gücü için kullanılan test serisi olarak ayrılmıştır. Elde edilen sonuçlar SVM modelinin, döviz kuru eğilimini açıklamada önemli bir tahmin gücüne sahip olduğunu göstermektedir.

Panda ve Narasimhan (2007), Hint Rupisi'nin ABD Doları karşısındaki değerini tahmin etmek için zaman serisi tekniğine dayalı otoregresif model (Autoregressive, AR) ve rassal yürüyüş modeli ile yapay zekâ temelli ANN modelinin kullanıldığı çalışmada, ANN'nin her iki model karşısında da daha üstün örneklem içi tahminlere sahip olduğu, örneklem dışı tahminde ise ANN'nin rassal yürüyüş modelinden Pearson korelasyon katsayısı haricindeki tüm değerlendirme kriterlerine göre daha iyi performans gösterdiği sonucuna ulaşılmaktadır. Yazarlar, ANN'nin rassal yürüyüş modeline göre daha üstün sonuçlar vermesini döviz piyasasının etkin olmadığını gösterdiği şeklinde yorumlarken, yine ANN'nin doğrusal otoregresif modelden daha güçlü sonuçlar vermesini döviz kurunun doğrusal öngörülemezliğinin iyileştirilebileceği şeklinde yorumlamaktadır. Bu iki yorumdan hareketle yazarlar, döviz kuru serilerindeki gizli bilgilerin ANN modelleri kullanılarak ortaya çıkarılabileceğini ifade etmektedir.

Altan (2008), 1987 Ocak-2007 Eylül dönemi verilerinden hareketle USD/TL kurunun gelecekte alacağı değerleri öngörmek adına zaman serisi yöntemlerinden Vektör Otoregresyon (Vector Autoregressive, VAR) modeli ve ANN modelini kullandığı çalışmada, toptan eşya fiyat endeksi, mevduat faiz oranı, para arzı ve GSYH değişkenlerini modele dahil etmiştir. Yazar ANN modelini 4 adet girdi nöronu ve tek gizli tabakada 6 adet nöron kullanarak, VAR modelinde ise Schwarz bilgi kriterine göre modelin gecikme uzunluğu 2 seçerek oluşturmuş, bu şekilde tahmin kısmına geçmiştir. Uygulama sonucunda ANN modelinin VAR modeline göre daha güçlü sonuçlar verdiğini gözlemlemiştir. Özellikle 1994 ve 2001 krizi dönemlerinde VAR modeli öngörü hatasının ANN modeline göre oldukça yüksek olduğu sonuçlarına erişildiği çalışmada, ANN tekniğinin hem örneklem içi hem de örneklem dışı öngörülerde oldukça başarılı sonuçlar verildiği görülmektedir. Yazar elde ettiği bu sonuç çerçevesinde VAR ve ANN modeli öngörülerinin birleştirilmesini önermekte ve bunu ağırlıklandırılmış ortalamaları kullanarak hesaplamaktadır. Hesaplama sonucunda öngörü başarı sonucunun arttığı, bu sebeple tek bir model seçimi yaklaşımına ek olarak kullanılan modellerden performansları yüksek olanların birleştirilmesi yaklaşımının dikkate alınması gerektiğini ifade etmektedir.

Kiani ve Kastens (2008), Chicago Ticaret Borsası'nda ABD Doları karşısında işlem gören İngiliz Sterlini, Kanada Doları ve Japon Yeni döviz kurlarına ait vadeli işlem sözleşme verilerinden hareketle, bu para birimlerine ait döviz kurunu tahmin etmek için ARMA, FFNN ve RNN modelinin üç farklı versiyonunu (RNN1, RNN2 ve RNN3) kullanmışlardır. Uygulamalarında RNN modellerinin GBP/USD ve JPY/USD döviz kurlarını tahmin etmede ARMA kıyaslama modelinden istatistiksel olarak daha iyi performans gösterdiği, RNN modellerinin CAD/USD döviz kurunu tahmin etmede başarılı olmadığı sonucuna ulaşılmaktadır. Ayrıca kullanılan modellerden hangisinin belirli bir seri için döviz kurlarındaki değişimi tahmin etmede en uygun olduğunu test etmek için parametrik ve parametrik olmayan tahmin denkliği ölçütleri kullanılmıştır. Yapılan testler RNN modellerinin İngiliz Sterlini için en doğru tahmin sunan model olduğunu, FFNN ve RNN modellerinin Kanada Doları ve Japon Yeni kur değişikliklerini tahmin etmek için üstün tahminler sunan model olduğunu ortaya koymaktadır.

Anastasakis ve Mort (2009), araştırma dönemi olan Ocak 1996-Mayıs 2001 döneminde en baskın dört para birimi (İngiliz Sterlini, ABD Doları, Alman Markı ve Japon Yeni) üzerinde günlük kur tahmini için parametrik model (aktif nöronlu ANN),

parametrik olmayan model (analog karmaşıklıklaştırma) ve bu modellerin birlikte kullanıldığı birleşik bir yaklaşım uygulamışlardır. Sonuçlar, parametrik ve parametrik olmayan modellerin genel performansının zayıf olduğunu, ancak bu modellerin birlikte kullanıldığı birleşik modelin bireysel modellere kıyasla daha tutarlı ve üstün olduğunu göstermektedir. Yazarlar, birleşik yöntemin tahmin aralığı genişledikçe performansının iyileşebileceğini, bu nedenle gelecekteki çalışmaların optimal tahmin aralığını belirlemeye yönelik olması gerektiğini önermektedir.

Özkan (2011), zaman serisi yöntemindeki gecikmeli değerler, döviz kuru belirleme teorilerinden SAGP ve parasal modeli kullanarak oluşturduğu üç farklı ANN modelinin USD/TL ve EUR/TL kurları üzerindeki tahmin performansını incelemiştir. Birinci modelde girdi verisi olarak döviz kuru değerlerinin gecikmeli değerleri, SAGP modelinde yerli ve yabancı fiyat endeksi girdi verisi, çıktı verisi olarak döviz kuru verileri kullanılmıştır. Parasal modelde ise yerli ve yabancı ülke enflasyon oranı, M1 para arzı, faiz ve milli gelir verileri girdi verisi, çıktı verisi olarak da döviz kurları kullanılmıştır. Model performansı ölçümünde 6 farklı metriğin kullanıldığı çalışmada, USD/TL ve EUR/TL tahmininde gecikmeli değerler kullanılarak oluşturulan ANN modelinin parasal model ve SAGP modelinden daha güçlü sonuçlar verdiği ifade edilmektedir.

Korol (2014), bulanık mantık tahmin yöntemi kullanarak 2008 küresel kriz öncesi 3 yıl (2005, 2006 ve 2007) ve sonraki üç yıl (2009, 2010 ve 2011) olmak üzere üç aylık ortalama döviz kuru serisinden hareketle döviz kurlarının tahmin edilmesini amaçladığı çalışmada üç döviz çifti (JPY/USD, GBP/USD ve CHF/USD) seçmiştir. Çalışmada tahmin yöntemi olarak bulanık mantık kullanılmakta ve teknik analizin yanı sıra temel analizden de faydalanılmaktadır. Ülkeler arasındaki göreceli faiz oranı farklılıkları, büyüme oranları ve kredi notları gibi faktörlerin dikkate alındığı çalışma, literatürde yer alan diğer modeller ile kıyaslandığında en iyi tahmin özellikleriyle karakterize olduğu görülmektedir.

Babu ve Reddy (2015), Ocak 2010-Nisan 2015 tarihleri arasında 1.284 günlük veriden hareketle Hindistan Rupisi'nin ABD Doları, İngiliz Sterlini, Euro ve Japon Yeni karşısındaki değerini ARIMA, ANN ve bulanık sistem yöntemleri kullanarak karşılaştırmışlardır. Akaike Bilgi Kriteri (AIC) ve Schwarz Bayezyen Bilgi Kriteri (BIC) dikkate alındığında literatürde yer alan diğer çalışmalardan farklı olarak ARIMA

modelinin, ANN ve bulanık sistem yöntemlerine kıyasla Hindistan döviz kurlarını açıklamada daha iyi sonuçlar verdiği gözlemlenmiştir.

Shen vd. (2015), GBP/USD, BRL/USD ve INR/USD serilerinin tahmin edilmesinde Sürekli kısıtlanmış Boltzman makineleri (continuous restricted Boltzmann machines, CRBM) ve Eşlenik Gradyan (Conjugate Gradient) metodunu kullanarak oluşturdukları geliştirilmiş Derin İnanç Ağı (Deep Belief Network, DBN) modeli ile İleri Beslemeli Sinir Ağı (Feed Forward Neural Network, FFNN) modelini kullanarak karşılaştırmalı bir analiz gerçekleştirmişlerdir. Çalışmada derin öğrenme modellerinin seçilme nedeni sinir ağlarının doğrusal olmayan yapıları yakalama yeteneği, parametrik olmayan veriye dayalı bir model olması nedeniyle kısıtlayıcı varsayımlara ihtiyaç duymaması ve son olarak modelin yanlış belirlenme problemine karşı çoğu parametrik yöntemle kıyasla daha az duyarlı olmasıdır. Haftalık verilerin kullanıldığı çalışmada DBN ve FFNN mimarileri iki geleneksel yöntem olan rassal yürüyüş ve ARMA modelleriyle karşılaştırılmıştır. Çalışmanın ampirik sonuçları beş ölçütün tamamında DBN modelinin FFNN modelinden daha iyi performans gösterdiğini, DBN modelinin hem yüksek tahmin doğruluğuna hem de yüksek kararlılığa sahip olduğunu ortaya koymaktadır.

Wang vd. (2016), USD/EUR döviz kurunu tahmin etmede tutarlı bir model ortaya koymak için ARIMA sürecinden gelen girdileri kullanarak üç katmanlı sinir ağına sahip hibrit bir model önerisinde bulunmuşlar ve bu modeli bulanık mantık, ANN ve ANN-ARMA modelleri ile karşılaştırmışlardır. Yazarlar, çalışmada ANN modelinin kullanılmasında döviz kuru serilerinin yüksek oynaklığını ve karmaşık piyasa ortamını neden olarak göstermekte, ampirik literatürde bu tür durumlar karşısında ANN tekniğinin sıklıkla kullanıldığını ve faydalı sonuçlar verdiğini ifade etmektedir. 2010-2013 dönemine ait USD/EUR kuru, döviz kuru getirisi, döviz kuru getirisinin karesi, getiri mutlak değeri, Nasdaq endeksi, ham petrol fiyatı ve spot altın değişkenlerine ait verilerin kullanıldığı çalışmanın sonuçları, üç farklı değerlendirme metriği dikkate alındığında, önerilen hibrit ANN-ARIMA modelinin döviz kuru tahmin etmedeki etkinliği önemli ölçüde artırdığını göstermektedir.

Galeshchuk (2016), döviz kurlarını tahmin etmede en uygun modeli bulmak için USD/EUR, JPN/USD ve USD/GBP olmak üzere üç döviz çifti için günlük, aylık ve üç aylık olmak üzere üç farklı aşamada ANN modeli kullanarak tahminde bulunmuştur. Bu doğrultuda ANN modelinin uygulandığı çalışmanın ampirik sonuçları, günlük

tahminlerde tutarlı sonuçlar verdiğini, döviz kurunu bir adım sonrası için tahmin etmede pratik sistemlerde kullanılabileceğini göstermektedir. Yazar, sinir ağlarının kendi kendini eğitme, kendi kendini uyarlama özellikleri nedeniyle tahmin sorunları sınıfı içerisinde modelin evrenselliğini sağladığını ve bu sebeple finansal zaman serileri tahmininde ekonometrik ve istatistiksel yöntemlerden daha iyi performans gösterdiğini ifade etmektedir.

Galeshchuk ve Mukherjee (2017), Euro ve ABD doları (EUR/USD), İngiliz sterlini ve ABD doları (GBP/USD) ve ABD doları ve Japon yeni (USD/JPY) arasındaki günlük kapanış oranları verisinden hareketle ARIMA, Üstel Düzeltme (Exponential Smoothing, ES), SVM ve Evrişimli Sinir Ağı (Convolutional Neural Networks, CNN) modellerini kullandıkları çalışmalarında döviz kurlarının değişim yönünü tahmin etmişlerdir. Çalışma sonucunda CNN modelinin tahmin değerleri %75'lik bir doğruluğa sahipken, ARIMA, ES ve SVM modelleri yaklaşık %65 doğruluk oranına ulaşmıştır. Bu sonuç, CNN modelinin çalışmada uygulanan diğer modellere göre daha tutarlı sonuçlar verdiğini göstermektedir.

Göncü (2019), faiz oranı paritesi koşuluna dayalı USD/TL döviz kurunu Karar Ağacı Regresyonu (Decision Tree Regressor, DTR), SVM, Ridge Regresyonu ve Lineer Regresyon modellerini kullanarak test etmiştir. Yazar, verilerin karmaşık olması ve potansiyel durağan olmayan süreçler nedeniyle model oluşturmanın zor olduğunu ayrıca çoğu makroekonomik değişkenin aylık frekansta olduğu göz önüne alındığında derin öğrenme modellerinin kullanmanın mümkün olmadığını ifade etmektedir. Açıklanan bu nedenlerden dolayı çalışmada denetimli makine öğrenimi teknikleri kategorisinde yer alan sınıflandırma ve regresyon yöntemlerinin dikkate alınabileceği ifade edilmektedir. Yurt içi para arzı, reel faiz oranları, ABD Federal Fon oranı ve önceki ayın ortalama döviz kurunu içeren makroekonomik bir model kurgulanarak gelecek ayın ortalama döviz kuru tahmin edilen çalışma, Ridge Regresyonu algoritmasının diğer modellere göre daha iyi performans gösterdiğini ortaya koymaktadır. Yazar, Ridge regresyonunun DTR ve SVM modellerine kıyasla daha güçlü sonuçlar vermesinde tahmin probleminde doğrusal olmama durumunun zayıf olmasını gerekçe olarak göstermektedir.

Ni vd. (2019), dokuz değişken döviz çiftine ait Haziran 2008-Mayıs 2018 dönemi günlük verilerinden hareketle RNN ve CNN algoritmalarına dayalı C-RNN tahmin yöntemi önererek tahmin çalışması yapmışlardır. Beş katmandan oluşan (giriş katmanı,

gizli katman, çıkış katmanı, ağ eğitimi ve ağ tahmini) C-RNN modeli, ortalama kare hata metriği baz alındığında CNN ve Uzun-Kısa Süreli Hafıza (Long Short Term Memory, LSTM) modeline göre daha düşük hata değeri ortaya çıkarmaktadır. Dolayısıyla çalışmada önerilen C-RNN modelinin CNN ve LSTM modeline göre tahmin etkisinin daha iyi olduğu sonucuna ulaşılmaktadır.

Dautel vd. (2019), dört büyük para biriminin (Euro, İngiliz Sterlini, Japon Yeni ve İsviçre Frangı) ABD doları karşısındaki değişimini tahmin etmek amacıyla Ocak 1971-Ağustos 2017 dönemine ait günlük verilerden hareketle geleneksel RNN modelleri ve RNN modelinde ortaya çıkan kaybolan gradyan problemine bir çözüm olarak geliştirilen LSTM ve Kapılı Tekrarlayan Ünite (Gated Recurrent Unit, GRU) gibi yeni modelleri çalışmada uygulayarak tutarlı bir model inşa etmek istemişlerdir. Ayrıca çalışmada, önceki çalışmaların döviz kurlarının uzun vadeli hafızaya sahip olduğunu gösterdiğini bu nedenle yeterli uzunlukta girdi dizilerinin olması durumunda (LSTM ve GRU modellerinin uzun vadeli bilgileri saklama yeteneklerine sahip olması nedeniyle) seçilen modellerin tahmin yöntemi açısından uygun olduğunu ifade etmektedir. Ampirik sonuçlar eğitim kaybı açısından LSTM ve GRU modellerinin FFNN ve SRNN daha iyi performans gösterdiğini, ancak tahmin performansında hiçbir modelin pozitif getiri sağlamadığını, getiriler açısından SRNN modelinin GRU ve LSTM gibi geliştirilmiş özelliklere sahip modellerle rekabetçi bir performans sergilediğini göstermektedir.

Kaushik ve Giri (2020), üç çok değişkenli modelleme tekniğinin performansını karşılaştırdıkları çalışmalarında, USD/INR döviz kurunu tahmin etmek için çok değişkenli bir yaklaşım bulmayı amaçlamışlardır. Kullanılan üç çok değişkenli model, zaman serisi tekniğine dayalı VAR modeli, makine öğrenmesi tekniği SVM modeli ve modern derin öğrenme tekniği LSTM modelidir. Nisan 1994-Aralık 2018 döneminde fiyat endeksi, Sanayi Üretim Endeksi, faiz oranları, para arzı, toplam rezervler, borsa endeksi ve net ihracat değişkenlerine ait aylık verilerin kullanıldığı çalışma, LSTM modelinin en yüksek başarı oranını yakaladığını (%97,83), sonrasında SVM modeli (%97,17) ve VAR modelinin (%96,31) takip ettiği sonuçlarını göstermektedir.

Lin vd. (2020), döviz kuru eğilimini tahmin etmek için Uyarlanabilir Gürültü ile Tam Topluluk Ampirik Mod Ayırıştırma (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN) temelli çok katmanlı LSTM (MLSTM) mimariyi birlikte kullandıkları ve CEEMDAN-MLSTM adını verdikleri

modellerini farklı özellikleri içinde barındıran teknikler ile karşılaştırmışlardır. Önerilen bu model, farklı zaman ölçeklerindeki dalgalanmaları derinlemesine araştırabilen, sinyal yapılandırma problemini çözen, uzun zaman aralığında veri bağımlılıklarını öğrenebilen dolayısıyla karmaşık sorunları çözme yeteneğine sahip bir modeldir. GBP/USD ve USD/AUD kurlarına ait geçmiş verilerden hareketle yapılan çalışmada, önerilen CEEMDAN-MLSTM modeli ARIMA, SVM, RNN, MRNN ve MLSTM modelleri karşılaştırmıştır. Elde edilen deneysel sonuçlar CEEMDAN-MLSTM modelinin diğer modellere göre daha iyi olduğunu göstermektedir.

Putri ve Halim (2020), tahmin yaparken kayıpları en aza indiren modeli belirlemek ve ekonomik birimlerin karar verme sürecini hızlandırmak amacıyla yaptıkları çalışmada, tahmin çalışmalarında sıklıkla kullanılan zaman serisi tekniği ARIMA modeli ve RNN modelinde yaşanan kaybolan gradyan sorununu çözmek için geliştirilmiş LSTM modelini kullanmıştır. EUR/USD döviz kurunun baz alındığı çalışmada, LSTM modelinin ARIMA yöntemine göre daha düşük hata değerlerine sahip olduğu sonucuna ulaşmışlardır. Yazarlar, LSTM modelinin ARIMA modeline göre daha iyi sonuçlar vermesinde LSTM modelinin büyük veri kullanımı ve bu veriyi kullanabilecek öğrenme yeteneğine sahip olma özelliklerinden kaynaklandığını ifade etmektedir.

Dash (2020), geliştirilmiş karışık kurbağa sıçraması (improved shuffled frog leaping, ISFL) stratejisi ile tekrarlayan Legendre polinom sinir ağı (recurrent Legendre polynomial neural network, RLPNN) kullanarak hibrit ISFL-RLPNN döviz kuru tahmin modelini geliştirmiştir. Geliştirilen model, parametreleri tahmin etmek için doğadan ilham alan bir öğrenme stratejisine ve doğrusal olmama durumunun haritalandırılmasına olanak sağlamaktadır. Çalışmada önerilen modelin doğrulamasını yapmak için LPNN, Fonksiyonel Bağlantı Yapay Sinir Ağı (Functional Link Artificial Neural Network, FLANN), Radyal Tabanlı Fonksiyon Sinir Ağı (Radial Basis Function Neural Network, RBFNN), Çok Katmanlı Algı Ağı (Multi Layer Perception Network, MLP), LR, Bilgi Güdümlü Yapay Sinir Ağı (Knowledge Guided Artificial Neural Network, KGANN), ARMA modelleri ile karşılaştırma yapılmıştır. Ampirik sonuçlar, önerilen ISFL-RLPNN modelinin diğer modellere kıyasla daha yüksek öngörülebilirliğe sahip olduğunu göstermektedir.

Islam ve Hossain (2020), zaman serisi tahminlerinde sıklıkla kullanılan derin öğrenme modellerinden daha az eğitim parametresi gerektiren ve daha az belleğe ihtiyaç duyan GRU modeli ve daha uzun seriler kullanıldığında tutarlı sonuçlar veren LSTM modellerini birleştirerek, ilk katmanı 20 gizli nöronlu GRU katmanı ve ikinci katmanı 256 gizli nöronlu LSTM katmanlı hibrit GRU-LSTM modelini önermektedir. Ayrıca MA, GRU ve LSTM modelleri de çalışmada kullanılmakta böylece önerilen modelin performansı karşılaştırılmaktadır. Modeller, EUR/USD, GBP/USD, USD/CAD ve USD/CHF para birimlerinin gelecekte alacağı yönü tahmin etmek için Ocak 2017-Haziran 2020 dönemine ait verilerle 10 dakika ve 30 dakikalık zaman dilimlerinde uygulanmıştır. 4 performans ölçütü (MSE, RMSE, MAE ve R2) dikkate alındığında önerilen GRU-LSTM modeli, her iki zaman diliminde de daha iyi performans ortaya koymuştur.

Sun vd. (2020), döviz kuru tahmininde doğru sonuçlar elde etmek ve döviz kuru ticaretinin kârlılığını artırmak için LSTM modeline torbalama topluluk öğrenme stratejini entegre ederek yeni bir derin öğrenme yaklaşımı olarak LSTMB modelini önermekte ve bu yaklaşımı Rassal Yürüyüş, ARMA, MLP, RBFNN, dalgacık sinir ağı (wavelet neural network, WNN), GRNN, ekstrem öğrenme makinesi (extreme learning machine, ELM), Elman yapay sinir ağları ve bu modellerin topluluk öğrenme yaklaşımıyla entegre edildiği modellerle kıyaslamaktadır. Yazarlar torbalama topluluk öğrenme stratejisinin veri belirsizliği, model belirsizliği ve parametre belirsizliği olmak üzere üç belirsizlik kaynağını aynı anda ele alma özelliğine sahip olduğunu ve uygulanan daha önceki çalışmalarda tahmin doğruluğunu önemli oranda artırdığını bu nedenle tahmin sürecinde kullanımının faydalı olacağını ifade etmektedir. Deneysel sonuçlar, torbalama topluluk öğrenme stratejisinin uygulandığı çalışmaları destekler niteliktedir. Yazarlar tarafından önerilen LSTM-B derin öğrenme yaklaşımının istatistiksel testler ve ticari kârlılık açısından diğer kıyaslama modellerinden önemli ölçüde daha iyi performans gösterdiğini ortaya koymaktadır.

Yıldırım vd. (2021), çalışmalarında temel analiz ve teknik analiz veri setlerini kullanarak EUR/USD döviz kurunun yönünü tahmin etmek için LSTM modelini kullanmıştır. Yazarlar makroekonomik veri setini kullandıkları ve ME-LSTM adını verdikleri modelde Almanya, AB ve ABD faiz oranları, AB ve ABD enflasyon oranları ve S&P 500 ile DAX endekslerine ait verileri kullanırken, TI-LSTM adını verdikleri teknik analiz modeline Hareketli Ortalama (Movement Average, MA), Hareketli

Ortalama Yakınsama Iraksama (Moving Average Convergence Divergence, MACD), Değişim Oranı (Rate of Change, ROC), Görelî Güç Endeksi (Relative Strength Index, RSI) ve Emtia Kanal Endeksi (Commodity Channel Index, CCI) serilerini dahil etmişlerdir. Çalışmada bu iki veri setine karşılık gelen iki ayrı LSTM modelini birleştiren hibrit bir model önerilmiştir. İleriye yönelik yapılan bir günlük, üç günlük ve beş günlük deneysel sonuçlar, önerilen hibrit modelin diğer modellere göre daha iyi performansa sahip olduğunu göstermektedir.

Abedin vd. (2021), 21 ülke para biriminin ABD Doları karşısındaki değişimini tahmin etmek için Bagging Ridge (BR) regresyonunu hem ileri hem de geri yönlü LSTM hücrelerini kullanan Çift Yönlü Uzun Kısa Süreli Hafıza (Bidirectional Long Short Term Memory, Bi-LSTM) yöntemiyle birleştiren bir derin öğrenme yaklaşımı önermektedir. Önerilen model, COVID-19 öncesi ve COVID-19 sonrası dönemde seçilen ülke para birimlerinin ABD Doları karşısındaki değerini tahmin etmek için kullanılmıştır. Yazarlar, modelin geçerliliğini test etmek için SVM, Regresyon Ağacı, Rassal Orman, LSTM ve Bi-LSTM gibi derin öğrenme tabanlı modellerle karşılaştırmışlardır. Çalışmada COVID-19 sonrası dönem 31 Ocak-11 Mart 2020, 12 Mart-25 Temmuz 2020, 26 Temmuz-8 Eylül 2020 ve 9 Eylül-14 Aralık dönemleri olacak şekilde 4 küme halinde incelenmiştir. Elde edilen bulgular genel olarak kullanılan modelin tahmin performansının COVID-19 döneminde kötüleştiğini göstermektedir. Özellikle pandemiden en olumsuz etkilenen ülkelerin döviz kurlarında performans daha da kötüleşmiştir. Bu duruma rağmen yazarlar tarafından önerilen hibrit Bi-LSTM BR modeli COVID-19 öncesi ve sonraki dönemde de diğer modellere kıyasla daha üstün tahmin etkinliğine sahiptir.

Jung ve Choi (2021), derin öğrenme yöntemlerini kullanarak döviz kuru oynaklığını etkin bir şekilde tahmin etmeyi amaçladığı çalışmalarında, LSTM ve zaman serisi verilerini tahmin etmede yaygın olarak kullanılan, girdi verilerindeki özellikleri otomatik olarak çıkarma yeteneğine sahip autoencoder (otomatik kodlayıcı) modelini birleştiren hibrit bir model önerisinde bulunmaktadırlar. Döviz kuru oynaklığının bir ölçüsü olarak Döviz Oynaklık Endeksi (Foreign Exchange Volatility Index, FXVIX) 2010-2019 verilerinin dikkate alındığı çalışmada, Brexit hareketinin yarattığı belirsizliğin neden olduğu dalgalanmalara göre veriler 2010'dan 2015'e, 2016 başlangıcından 2016 yıl sonuna ve 2017'den 2019'a kadar alt kümelerle ayrılmıştır ve bu şekilde gelecekteki fiyatlar önerilen hibrit autocoender-LSTM modeli ve karşılaştırma yapabilmek için geleneksel LSTM modeli kullanılarak tahmin edilmiştir. Deneysel sonuçlar, ikinci

dönemdeki (Ocak 2016-Aralık 2016) aykırı değerlerin modelin performansını düşürmesine rağmen autoencoder-LSTM hibrit modelinin geleneksel LSTM modeline göre tahmin doğruluğu performansının daha iyi olduğunu, autoencoder yönteminin modelin tahmin performansını artırdığını göstermektedir.

Nwosu vd. (2021), ANN, ARIMA ve Rassal Orman modellerini kullanarak ve model karşılaştırma sürecini benimseyerek, COVID-19 salgını döneminde Nijerya Nairası (NGN)'nın İngiliz Sterlini (GBP) karşısındaki değerinin modellenmesine odaklanmaktadır. Yazarlar tarafından döviz kuru serilerinde trend döngüsü ve düzensizlikler olduğundan, geleneksel zaman serisi yöntemlerinin bu tür veriler üzerinde iyi performans göstermeyeceği düşünülmüş, bu nedenle makine öğrenme algoritmalarının kullanılması gerektiğine karar verilmiştir. Seçilen ANN modelinde en iyi uyumu sağlamak için gizli katmanda 1-8 arasında değişen farklı düğüm boyutları denenmiş, gizli katmandaki beş düğüm boyutunun en iyi olduğuna karar verilmiştir. Çalışmada ANN modelinin tutarlılığını karşılaştırmak için Rassal Orman ve ARIMA modelleri kullanılmıştır. Uygulama sonucunda iki makine öğrenimi modeli ANN ve Rassal Orman, ARIMA modeline kıyasla daha iyi performans gösterdiği görülmektedir. İki makine öğrenmesi modeli karşılaştırıldığında ise Rassal Orman modeli eğitim setinde, ANN modeli test setinde daha güçlü sonuçlar verdiği görülmektedir.

Tripathi vd. (2021), en çok işlem gören üç döviz çiftinin (EUR/USD, GBP/USD ve JPY/USD) günlük döviz kurlarını tahmin etmek için bir zaman serisinin hem doğrusal hem de doğrusal olmayan yapı içerebilmesi nedeniyle ARIMA ve ANN tekniklerini bir arada kullanan yeni bir topluluk tekniği önermektedir. Bu doğrultuda ortalama tahmin (mean forecast, MF), ARIMA ve ANN teknikleri kullanılarak ayrı ayrı tahmin yapılmakta ve daha sonra bu teknikleri uygun ağırlık ile birleştirerek oluşturulan hibrit model uygulaması yapılarak modeller arasında karşılaştırma yapılmaktadır. Ocak 2009-Mayıs 2016 dönemine ait veriler kullanılarak yapılan çalışmanın deneysel sonuçları, önerilen hibrit modelin, diğer modellerin ayrı ayrı tahmin edildiği duruma kıyasla tahmin doğruluğu performansının daha yüksek olduğunu göstermektedir.

Zheng vd. (2021), 2006-2016 dönemi INR/USD ve 1997-2016 dönemi CNY/USD döviz kurlarını, geri bildirim sağlayan birden fazla gizli katmana sahip DBN yöntemi ve geleneksel FFNN yöntemlerini kullanarak tahmin etmişlerdir. Ampirik bulgular, DBN modelinin FFNN modeline kıyasla döviz kuru tahmininde daha güçlü sonuçlar verdiğini

göstermektedir. Yazarlar elde edilen bu sonucun DBN modelinin yüksek frekanslı ticaret tahminlerinde de kullanılabileceğine dair fikirler ortaya çıkardığını ifade etmektedir.

Telatar (2022), USD/TL ve BİST100 endeksinin gelecekte alacağı seyri tahmin etmeyi amaçladığı çalışmada, analiz edilen veri setinin mevsimsellik etkisi barındırdığı için Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average, SARIMA) modelini ve büyük boyutlu verilerde daha iyi sonuçlar üreten LSTM modelini kullanmıştır. Araştırma sonucunda döviz kuru için SARIMA modeli RMSE değeri 0,405 LSTM modeli RMSE değeri 0,147 olarak bulunmuştur. Elde edilen bu sonuca göre LSTM modelinin SARIMA modeline göre daha iyi performans gösterdiği görülmüştür. Yazar, LSTM modelinin ileri beslemeli bir ağ olduğunu veriler eğitilirken hangi verinin tutulacağı konusunda karar verme yeteneğine sahip olduğunu bu özelliğinden kaynaklı olarak da durağan olmayan ve ani değişimler içeren veri setinde SARIMA modeline kıyasla daha doğru sonuçlar verdiğini ifade etmiştir.

Birdi vd. (2023), gelecekteki trendleri tahmin edebilme ve sıralı bilgileri inceleyebilme yeteneğine sahip, döviz piyasasının özelliklerini analiz etmede sıklıkla başvurulmuş derin öğrenme modellerinden RNN ve LSTM tekniklerini kullanarak döviz piyasasında karar alma sürecini geliştirmeyi ve INR/USD döviz kurunun trendini tahmin etmeyi amaçlamışlardır. Elde edilen verilerin işlenmesi, eğitim ve test setlerine bölünmesinden sonra gerçekleştirilen uygulama sonucunda 10 Şubat 2023 tarihi için RNN modeli 82.44, LSTM modeli 82.01'lik bir fiyat öngörüsünde bulunmuştur. Genel olarak ise, RNN modeli %99,89 oranında doğruluğa sahip iken, LSTM modelinin %99,36 oranında doğruluğa sahip olduğu görülmüştür.

Biswas vd. (2023), Bangladeş Takası'nın ABD Doları karşısındaki değerini tahmin etmek için literatürde sıklıkla kullanılan derin öğrenme modellerini (LSTM, Bi-LSTM, Yığılmış LSTM, GRU, CNN, CNN-LSTM, Zaman Dağılımlı MLP, SVM ve XGBoost) kullandıkları çalışmalarında, GSYH, ithalat/ihracat, kamu gelirleri, para arzı, faiz oranı ve enflasyon oranı vb. gibi temel makroekonomik faktörleri dikkate almışlardır. Deneysel sonuçlar, Zamana Dağılımlı MLP modelinin tüm modeller arasında 0,1984 RMSE ile en iyi performansa sahip model olduğunu göstermiştir. Ayrıca yazarlar tarafından önerilen bir tahmin hattı ile tüm modellerin hata oranının azaldığı gözlemlenmiştir.

Vika ve Çollaku (2023), Arnavutluk Lekı'nın Euro karşısındaki değeri (LEK/EUR) gelecekte alacağı seyri Derin İleri Beslemeli Sinir Ağı (Deep Feed-Forward Neural Network, DFNN), LSTM ve 1D-CNN derin öğrenme modellerini kullanarak incelemişlerdir. Her mimari için aşırı uyum sorununu ortadan kaldırmak için farklı yapılandırma tekniklerini kullanan yazarlar, COVID-19 pandemisi öncesi ve sonrası dönemde model tahminini analiz ederek, 3, 6 ve 12 aylık ufuklarda örneklem dışı tahmine odaklanmışlardır. Model karşılaştırması sonucunda, LSTM modelinin 3 ve 6 ay sonrası tahminlerde en iyi model iken, tahmin ufku 12 ay olduğunda 1D-CNN modelinin en iyi tahmin yöntemi olduğu görülmüştür.

Erem (2023), CHF/EUR, GBP/EUR ve USD/EUR döviz kurlarının günlük, haftalık ve aylık frekanslarını tahmin etmek için Tek Gizli Katmanlı Sinir Ağı modelini uygulamıştır. Sonuçlar, özellikle günlük verilerde düşük MAE ve RMSE ile kanıtlanmış ve modelin doğruluğunu ispatlamıştır. Ayrıca günlük ve haftalık tahminlerde CHF/EUR döviz çifti için örneklem dışı tahminlerde en iyi performansa sahipken, GBP/EUR çifti aylık frekans söz konusu olduğunda en iyi performansı gösteren döviz kuru olmuştur. Son olarak çalışmada uygulanan model ARMA ve ARIMA gibi geleneksel modeller ile kıyaslandığında açık bir avantaja sahip olduğu sonucuna ulaşılmıştır.

Döviz kuru tahmininde derin öğrenme yaklaşımlarının kullanıldığı ilgili literatür incelendiğinde, ilk dönemlerde çoğunlukla ANN ve RNN modellerinin kullanıldığı, daha sonrasında gelişen derin öğrenme literatürüyle birlikte CNN, GRU, LSTM ve Bi-LSTM mimarilerinin kullanımının yoğunlaştığı, son yıllarda ise farklı özellikleri içerisinde barındıran modellerin birleştirilmesi sonucu önerilen hibrit model kullanımının artış gösterdiği sonucuna ulaşılmaktadır. Yine çoğunlukla çalışmalarda kullanılan modellerin, farklı derin öğrenme teknikleri ve/veya zaman serisi yöntemleriyle (ARMA, ARIMA vb.) birlikte kullanılarak kıyaslama yapıldığı ve Babu ve Reddy (2015)'nin çalışması haricindeki tüm çalışmalarda derin öğrenme yöntemlerinin zaman serisi yöntemlerine kıyasla daha güçlü sonuçlar verdiği görülmektedir. Ancak, mevcut literatür incelendiğinde, döviz kuru tahmininde yapay zekâ ve derin öğrenme yöntemlerinin kullanımı üzerine yapılan çalışmaların çoğunlukla ABD Doları, Euro, Japon Yeni ve İngiliz Sterlini gibi majör para birimlerine odaklandığı; buna karşın Türk Lirası'nı konu alan çalışmaların (Altan, 2008; Özkan, 2011; Göncü, 2019; Telatar, 2022) oldukça sınırlı kaldığı dikkat çekmektedir. Bu eksiklik, Türkiye gibi gelişmekte olan ülkelerin döviz piyasalarına ilişkin modelleme çalışmalarını daha önemli hale getirmektedir.


Bu çalışma, USD/TL ve EUR/TL döviz kurlarını temel alarak Türk Lirası'nı ön plana çıkaran özgün bir katkı sunmayı amaçlamaktadır. Çalışmanın bir diğer önemli yönü ise döviz kurlarını tahmin etmek üzerine yapılan analizlerin ülke özelindeki farklı ekonomik ve politik şartlara duyarlı olacak şekilde tasarlanmasıdır. Bu kapsamda, çalışma özellikle şu üç dönemi ele almaktadır:

1. **Esnek Kur Sistemi'ne Geçiş Dönemi (2001 ve Sonrası):** Şubat 2001 krizinin ardından Türkiye'nin esnek kur sistemine geçişi, döviz piyasalarının yapısında önemli değişikliklere yol açmıştır.
2. **Enflasyon ve Finansal İstikrar Hedeflemesinin Başladığı Dönem (2010 ve Sonrası):** Bu dönem, Merkez Bankası'nın para politikası stratejilerinin değişimini ve piyasalara olan etkisini yansıtmaktadır.
3. **Politik ve Ekonomik Belirsizliklerin Yoğunlaştığı Dönem (2016 ve Sonrası):** 15 Temmuz darbe girişimi sonrası yaşanan siyasi ve ekonomik belirsizliklerin etkileri bu dönemde belirgin bir şekilde hissedilmiştir.

Bu yaklaşım, tahmin modellerinin farklı ekonomik ve politik koşullara duyarlılığını test etmeye ve döviz kuru dinamiklerini daha iyi anlamaya olanak sağlamaktadır. Bu bilgiler çerçevesinde, bu çalışmanın kullanılacak farklı derin öğrenme yöntemleri ve bu yöntemlerin birlikte kullanılacağı hibrit yaklaşımlarla USD/TL ve EUR/TL döviz kurunun gelecekteki seyri hakkında tutarlı bir model ortaya koymayı hedeflemesi sebebiyle literatüre katkı sağlayacağı düşünülmektedir.

## 2.2. Veri Seti

Bu çalışmada Türkiye Cumhuriyet Merkez Bankası (TCMB) Elektronik Veri Dağıtım Sistemi'nde (EVDS) yer alan USD/TL ve EUR/TL alış döviz kuru verileri kullanılmıştır. Kullanılan veriler 5 iş günü şeklinde derlenmiş olup, 1 Şubat 2001 ile 04 Ekim 2024 tarihleri arasındaki 6166 veriyi kapsamaktadır. USD/TL ve EUR/TL döviz kurunun ilgili dönemdeki seyri Şekil 2'de gösterilmektedir.



**Şekil 2: USD/TL ve EUR/TL Döviz Kurlarının Zaman İçerisindeki Seyri**

**Kaynak:** TCMB EVDS veri tabanının derlenmiştir.

Şekil 2, USD/TL ve EUR/TL döviz kurlarının zaman içerisindeki seyrini ve ilgili dönemde küresel ölçekte ve Türkiye’de yaşanan siyasi ve ekonomik gelişmeleri göstermektedir. Şekil 2 genel olarak değerlendirildiğinde, döviz kurlarının belli dönemlerde ani hareketler gösterse de 2000-2016 yılları arasında düşük bir yükseliş eğilimine sahip olduğu, 2016 yıl sonundan itibaren yükseliş eğiliminin hızlandığı

görülmektedir. Ayrıca USD/TL kurunun 2002 yılının ortalarına kadar EUR/TL kurundan daha yüksek olduğu, bu dönemden itibaren ise EUR/TL kurunun daha yüksek bir değere sahip olduğu görülmektedir.

Şekil 2, siyasi ve ekonomik kriz tarihleriyle birlikte incelendiğinde, ilk dikkat çeken tarih 2001 yılı olmaktadır. 2001 yılı Şubat ayında meydana gelen siyasi gelişmeler ülkede, siyasi belirsizliğe ve spekülasyon saldırılarına yol açmıştır. Bu durum bankacılık sektöründe önemli bir kriz yaratmış ve bankaların batmasına yol açmıştır. Döviz kurları açısından değerlendirildiğinde ise TL'nin %40'ı aşan bir oranda değer kaybetmesine neden olmuştur. Bu dönemden sonra ekonomide meydana gelen krizden çıkmak adına yeni bir program hazırlanmıştır. Uluslararası Para Fonu (International Monetary Fund, IMF) desteğiyle hazırlanan yeni programla birlikte birçok yapısal ve kurumsal değişiklik yapılmış, devam eden süreçte program sürdürülmüş, Avrupa Birliği (AB) ile üyelik müzakereleri başlamış, ülkeye önemli miktarda yabancı sermaye girişi yaşanmıştır. Bu durum makroekonomik istikrarın sağlanmasına katkı sağlamış, 2008 yılı sonlarına doğru patlak veren 2008 Küresel Finans Krizi'ne kadar istikrarlı bir ortamın oluşmasına katkı sağlamıştır (Pamuk, 2012: 285-289).

2007 yılında ABD'de ortaya çıkan finansal kriz, Türkiye'yi 2008 yılının ikinci yarısını izleyen dönemde önemli ölçüde etkilemiştir. Ortaya çıkan bu krizin kaynağı ABD'de finans piyasası olsa da Türkiye'de bu durum reel ekonomi üzerinde etki yaratmış, 2008 yılı büyüme oranı %0,8, 2009 yılı büyüme oranı %-4,8 olarak gerçekleşmiştir (Kazgan, 2017:353-361; World Bank, 2023). Döviz kurları açısından değerlendirildiğinde ise 2008 Eylül ayından 2009 Aralık ayına kadar değer kaybı %30'a yakın bir oranda gerçekleşmiştir. Döviz kurlarında meydana gelen önemli artış, devam eden süreçte sönümlenmiş, istikrarlı bir hâl almış, uygulanan finansal istikrar ve makroekonomik politikalar ekonomik aktivite üzerinde olumlu etkiler yaratmıştır. Bu politikalar kapsamında Merkez Bankası, faiz oranlarını düşürerek finansal sisteme likidite sağlamış ve döviz piyasalarına müdahalelerde bulunmuştur. Aynı zamanda kamu harcamalarının artırılması, vergi teşvikleri ve sosyal yardımlar yoluyla toplam talep desteklenmiş, ekonomik büyümenin yeniden canlanması hedeflenmiştir.

Analiz edilen dönemde dikkat çeken önemli gelişmelerden biri, 15 Temmuz 2016'da gerçekleşen darbe girişimi, bir diğeri ise 2018 yılının Temmuz ayında patlak veren Brunson Krizi'dir. Her ne kadar her iki olay da siyasi nitelikte olsa da döviz kurları

üzerinde ciddi etkiler yaratmıştır. Darbe girişimi sonrasında, 15 Temmuz 2016 ile 30 Aralık 2016 arasındaki dönemde döviz kurları yaklaşık %20 oranında artış göstermiştir. 2018 yılındaki Brunson Krizi'nde ise döviz piyasaları daha sert bir tepki vermiş ve iki ay gibi kısa bir sürede kurlarda %30'a yakın bir artış yaşanmıştır.

11 Mart 2020 tarihinde Dünya Sağlık Örgütü tarafından küresel pandemi olarak ilan edilen COVID-19 salgını analiz edilen dönem içerisinde meydana gelen önemli şoklardan birisi olmuştur. Salgını önlemek amacıyla hükümetler tarafından ilan edilen kapanmalar, firmaların üretim ve yatırım, hane halklarının tüketim, hükümetlerin de harcama kararları üzerinde değişiklikler yaratarak ekonomik aktiviteyi derinden etkilemiştir. İlgili dönemde Türk Lirası'nın ABD Doları ve Euro karşısındaki değerine bakıldığında 11 Mart 2020'den 31 Aralık 2020 tarihine kadar döviz kurları %20'yi aşan bir oranda yükseliş göstermiştir.

Analiz edilen dönemde meydana gelen bir diğer gelişme 23 Eylül 2021'de TCMB Para Politikası Kurulu'nda bir hafta vadeli repo ihale faiz oranının %19'dan %18'e indirilmesi kararıdır (TCMB, 2021). Alınan bu karar, ekonomi politikasında bir değişim yaşandığını göstermektedir. Politika faizini düşürme yönünde alınan bu karar ve devamında atılan adımlar öncelikle döviz piyasasında hızlı bir etki yaratmıştır. Bu durum 23 Eylül 2021'den 31 Aralık 2021 tarihine kadar geçen yaklaşık üç aylık dönemde döviz kurlarında %50'ye yaklaşan bir oranda artışın yaşanmasıyla sonuçlanmıştır. Devam eden süreçte Kur Korumalı Mevduat uygulamasının hayata geçirilmesiyle döviz kurlarında meydana gelen oynaklık düşürülmeye çalışılmıştır.

14 Mayıs 2023 tarihinde gerçekleşen meclis ve cumhurbaşkanlığı seçiminde cumhurbaşkanlığı için geçerli oy oranının sağlanamaması ve bu sebeple 28 Mayıs 2023 tarihinde yapılan cumhurbaşkanlığı seçimi süreci, analiz edilen dönemde meydana gelen son gelişmedir. Seçim sürecinin bittiği bu tarihten itibaren döviz kurlarının seyrine bakıldığında USD/TL ve EUR/TL kurlarının kısa süre içerisinde %50'ye yakın bir oranda artış gösterdiği görülmektedir.

Yukarıda açıklanan bilgilere ek olarak analiz edilen seriye ait tanımlayıcı istatistiklerin elde edilmesi seriye ait bilgilerin edinilmesine katkı sağlayacaktır. USD/TL ve EUR/TL döviz kurlarına ait tanımlayıcı istatistikler Tablo 3'te sunulmuştur.

**Tablo 3: Tanımlayıcı İstatistikler**

|                       | EUR/TL               | USD/TL               |
|-----------------------|----------------------|----------------------|
| <b>Ortalama</b>       | 5,7778               | 5,1127               |
| <b>Medyan</b>         | 2,3800               | 1,8086               |
| <b>Maksimum</b>       | 38,1714              | 34,1538              |
| <b>Minimum</b>        | 0,6229               | 0,6730               |
| <b>Standart Sapma</b> | 7,7754               | 7,2540               |
| <b>Skewness</b>       | 2,5550               | 2.5489               |
| <b>Kurtosis</b>       | 8,9355               | 8,7937               |
| <b>Jarque-Bera</b>    | 15760.09<br>[0.0000] | 15300.75<br>[0.0000] |
| <b>Gözlem Sayısı</b>  | 6166                 | 6166                 |

Tablo 3’te yer alan tanımlayıcı istatistik değerlerinden hareketle USD/TL ve EUR/TL döviz kurları standart sapma değerlerinin ortalamadan daha büyük olduğu görülmektedir. Bu sonuç, döviz kuru serilerinin oldukça değişken bir özellik gösterdiğini, serilerde şiddetli dalgalanmaların yaşandığını göstermektedir. Skewness (çarpıklık) değeri, bir veri setinin simetrik veya asimetrik dağılımını göstermektedir. Döviz kurlarına ait skewness değerlerine bakıldığında her iki seri için de değerin pozitif olduğu dolayısıyla serilerin sağa çarpık olduğu sonucuna ulaşılmaktadır. Bu durum veri setindeki değerlerin çoğunluğunun düşük değerlerde, az sayıda değerin yüksek değerlerde olduğunu ifade etmektedir. Kurtosis (basıklık) değeri, bir dağılımın sivrililiği ya da basıklığını ölçen bir istatistiktir. Tablo 3’te yer alan bilgiler çerçevesinde her iki döviz kuru için kurtosis değerinin 3’ten büyük olduğu dolayısıyla serilerin sivri olma özelliği gösterdiği yani veri setinde ortalamadan daha uzak gözlemlerin olduğu sonucuna ulaşılmaktadır. Serilerin normal dağılım özelliği gösterip göstermediğini test eden Jarque-Bera istatistiğine bakıldığında ise her iki seri için de “ $H_0$ : Seriler normal dağılmıştır” boş hipotezi reddedilmekte, serilerin normal dağılım özelliği göstermediği bilgisine ulaşılmaktadır.


Türkiye ekonomisinde döviz kurlarının 1 Şubat 2001-04 Ekim 2024 tarihleri arasındaki seyri incelendiğinde dönem içerisinde meydana gelen birçok ekonomik ve siyasi gelişmelerin döviz kurları üzerinde önemli bir etki yarattığı, ciddi dalgalanmalara yol açtığı ve bu nedenle serilerin normal dağılım özelliği göstermediği açıkça görülmektedir. Bu sebeple döviz kuru tahmin sürecinde bu tür sorunlara karşı daha yüksek doğruluğa sahip olan, ekonomik birimlerin öngörü ufkunu genişletecek derin öğrenme modellerinin kullanılması faydalı olacaktır.

## ÜÇÜNCÜ BÖLÜM YÖNTEM ve MODELLER

### 3.1. Yapay Zekâ Nedir?

Yapay zekâ (Artificial Intelligence, AI), 1950'li yıllarda, bilgisayar biliminin öncülerinden birtakım bilim insanlarının bilgisayarların düşünebilir olup olamayacağını sorgulamasıyla ortaya çıkmıştır. Bu konudaki ilk çalışma, Turing'in 1950 yılında yayımladığı “Hesaplama Makineleri ve Zekâ” makalesidir. Turing, bu çalışmada yapay zekânın felsefi temellerini açıklamıştır. 1955 yılında John McCarthy, düzenlediği bir yaz atölyesinde yapay zekâ terimini kullanarak, bu alanın bağımsız bir disiplin olarak gelişmesinin önünü açmıştır (Chollet, 2021:3). Bu çalışmaların ardından yapay zekâ tanımlanmaya ve gelişmeye başlamıştır.

McCarthy vd. (1955), yapay zekâyı “Eğer zekâ ve öğrenme tüm yönleriyle tanımlanabilirse, bilgisayarlar bu tanımları kullanarak insan gibi düşünebilir” şeklinde tanımlamıştır. Günümüzde ise yapay zekâ, insanın bilişsel yeteneklerini bilim, teori ve teknikler kullanarak taklit etmeyi amaçlayan bir disiplin olarak kabul edilmektedir. Yapay zekânın bu temel tanımları, teknolojinin gelişimiyle birlikte evrilmiş ve farklı alt dalların ortaya çıkmasına yol açmıştır.



**Şekil 3: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi**


**Kaynak:** Kayaalp ve Süzen (2018).

20. yüzyılın ikinci yarısında gelişmeye başlayan yapay zekâ teknolojisi, 1980’lerde makine öğrenmesi (Machine Learning, ML) ve 21. yüzyılın başında derin

öğrenme (Deep Learning, DL) gibi alt dalların ortaya çıkmasıyla genişlemiştir. Son yıllarda bilgisayar işlem gücündeki artış, büyük veri (Big Data) teknolojilerinin gelişimi ve ileri algoritmaların tasarımı sayesinde yapay zekâ, makine öğrenmesi ve derin öğrenme alanlarında önemli ilerlemeler kaydedilmiştir. Yapay zekâ ile başlayan, makine öğrenmesi ve derin öğrenme ile devam eden bu tarihsel süreç Şekil 3'te gösterilmektedir.

### 3.2. Makine Öğrenmesi Nedir?

Yapay zekânın bir alt dalı olan makine öğrenmesi, bilgisayarların deneyim yoluyla belirlenen görevlerdeki performanslarını geliştirerek öğrenmesini amaçlamaktadır. Makine öğrenimi genellikle büyük ve yüksek boyutlu veri kümelerine odaklanarak tahmin doğruluğunu yükseltmeyi hedefler. Makine öğrenmesi, özellikle denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme gibi farklı yaklaşımları içermektedir.



**Şekil 4: Makine Öğrenimi Algoritmaları**

Denetimli öğrenme, etiketlenmiş veri (belirlenmiş sonuç değerine sahip veri) kullanarak tahmin ve sınıflandırma problemlerini çözerken, denetimsiz öğrenme, veri setindeki gizli örüntüleri keşfetmeyi amaçlar. Pekiştirmeli öğrenme ise, bir ajanı ödül ve ceza mekanizmaları aracılığıyla eğiterek, karmaşık görevleri yerine getirmesini

sağlamaktadır. Günümüzde bu yöntemler sağlık hizmetlerinden finans sektörüne, otomotiv endüstrisinden eğlenceye kadar geniş bir uygulama yelpazesinde kullanılarak inovasyonu ve verimliliği artırmaktadır.

Son yıllarda, makine öğrenmesinin bir alt dalı olan yapay sinir ağları (Artificial Neural Network), özellikle dikkat çekici başarılar elde etmektedir. Yapay sinir ağları, büyük ve karmaşık veri setlerinden anlamlı örüntüler çıkarabilen bir öğrenme yöntemi olarak pek çok farklı alanda etkili çözümler sunmaktadır. Bu yöntem, görüntü işleme, doğal dil işleme ve ses tanıma gibi birçok uygulamada önemli ilerlemeler kaydetmiştir.


### 3.3. Yapay Sinir Ağları Nedir?

Yapay Sinir Ağları (YSA), insan beynindeki özelliklerden esinlenerek makineler öğrenme yetisi kazandırmayı amaçlayan modellerdir. Bu modeller, deneyimlerden öğrenerek yeni veriler üzerinde tahmin ve analiz yapabilir, kararlar alabilir. Biyolojik sinir ağlarında bulunan sinir hücrelerine benzer şekilde, yapay sinir ağları da yapay nöronlardan oluşmaktadır. YSA'lar, birbirine ağırlıklı bağlantılarla bağlanan işlem elemanlarından oluşan paralel ve dağıtılmış veri işleme yapılarıyla karmaşık problemlere yönelik güçlü çözümler sunmaktadır (Uğur ve Kınacı, 2006: 363).

YSA fikri, 1943 yılında Warren McCulloch ve Walter Pitts'in "Sinirsel aktiviteye ilişkin fikirlerin mantıksal bir hesabı" adlı makalelerinde ortaya atılmıştır. Bu çalışmayla birlikte sinir hücreleri matematiksel olarak modellenmiş ve modern YSA'ların temelini oluşturan bir sistem tasarımı ortaya çıkmıştır. Ancak günümüz YSA sistemleri, o dönemde önerilen modellere kıyasla çok daha karmaşık ve gelişmiş yapıdadır (Bishop, 2006: 226).

YSA'ların karmaşık problemlerin çözümünde yüksek tahmin gücü ve mantıklı karar verme yeteneğine sahip olması, daha az varsayım altında çalışması ve aktivasyon fonksiyonları aracılığıyla doğrusal olmayan problemlerin çözümünü başarıyla sonuçlandırması gibi özellikleri nedeniyle diğer istatistiksel yöntemlere kıyasla önemli avantajlara sahiptir. (Kızılkaya, 2017: 2198).

Yapay sinir ağlarının genel yapısı incelendiğinde, bazı temel bileşenler öne çıkmaktadır ve bu bileşenler Şekil 5'te gösterilmektedir.



**Şekil 5: Yapay Sinir Ağı Nöronu**

**Kaynak:** Zhang vd. (2021).


Şekil 5'e göre her bir girdi hücresi ( $X_1, X_2, \dots, X_n$ ), modelde kullanılan her bir veriyi ifade etmektedir. Sisteme giren her bir veri, bir ağırlık oranıyla ( $W_1, W_2, \dots, W_n$ ) çarpılarak toplam fonksiyonuna gönderilmektedir. Basit bir toplama işleminin kullanıldığı bu toplam fonksiyonuna lineer kombinasyon adı da verilmektedir (Haykin, 2008: 10). Girdilerden gelen bilginin ağırlıklarla çarpımının toplamı sonucu elde edilen bu değer bir aktivasyon fonksiyonundan (eşik fonksiyon, Tanh fonksiyonu, ReLU vb.) geçerek çıktıyı oluşturmaktadır. Sistemde kullanılan aktivasyon fonksiyonu nöronda üretilen çıktıyı belli bir aralık içerisinde sınırlandırmakta ve doğrusal olmayan ilişkilerin çözümüne katkı sağlamaktadır. Bununla birlikte, toplam fonksiyonu için yalnızca basit bir lineer kombinasyon kullanılmak zorunda değildir. Alternatif olarak, çekirdek fonksiyonları veya daha karmaşık ağırlıklandırma mekanizmaları gibi farklı yöntemler de toplam fonksiyonunun yerine kullanılabilir.

YSA sisteminin temel yapı taşı olan nöronun işleyiş mantığı modellerin öğrenme ve bu doğrultuda karar alma yeteneklerini anlama açısından kritik bir başlangıç noktası olarak kabul edilmektedir. Ancak YSA sistemi, yalnızca bireysel nöronların çalışmasından ibaret görülmemelidir. Çünkü nöronların katmanlar halinde düzenlenmesi ve bu katmanlar arasındaki bağlantılar aracılığıyla verilerin işlenmesi, sistemde bulunan karmaşık problemlerin çözüme kavuşmasına önemli katkı sağlamaktadır. Dolayısıyla YSA sisteminin genel işleyişi, katman yapıları, ileri-geri yayılım süreçleri ve gradyan inişi (gradient descent) gibi mekanizmaları ele almak modelin problemlere karşı ürettiği çözümleri anlamakta faydalı olacaktır.

### 3.3.1. YSA Sisteminin İşleyişi

Yapay Sinir Ağları (YSA), biyolojik sinir ağlarının işleyişinden esinlenerek geliştirilmiş yapay öğrenme modelleridir. Bu ağlar, çok sayıda bağlı yapay nörondan (sinir hücresinden) oluşur ve bu nöronlar, girdileri işleyerek belirli çıktılar üretir. Yapay Sinir Ağlarının işleyişi genel olarak şu adımlarla açıklanabilir:


- **Girdi Katmanı (Input Layer):** Girdi katmanı, dış dünyadan gelen verileri alır ve ağına içine iletir. Bu katman, her bir girdi özelliğini bir nöron olarak temsil eder. Örneğin, bir tahmin probleminde her nöron bir girdiyi temsil eder. Dolayısıyla girdi katmanında yer alan nöronlar modeldeki bağımsız değişkenleri ifade etmektedir. Girdi katmanı Şekil 6'da yer alan  $x_1, x_2, x_3, x_4$  nöronları ile gösterilmektedir.
- **Gizli Katman (Hidden Layer):** Gizli katmanlar, girdileri işleyen ve dönüştüren ara katmanlardır. Bir YSA, bir veya daha fazla gizli katmana sahip olabilir. Her gizli katman, önceki katmandan gelen girdileri alır, ağırlıklarla çarpar, toplar ve bir aktivasyon fonksiyonuna uygular. Bu işlemler, girdilerin daha karmaşık özellikleri öğrenmesini sağlar. Gizli katmanların sayısı ve her katmandaki nöron sayısı, ağına kapasitesini ve öğrenme yeteneğini belirler. Gizli katman, gerekli nöron bağlantı setleri eklendiğinde üst düzey istatistiklerin çıkarılmasında kritik bir öneme sahip olmaktadır (Churchland ve Sejnowski, 1992: 77). Gizli katmanlar Şekil 6'da yer alan  $h_1, h_2, h_3, h_4, h_5$  nöronları ile gösterilmektedir.
- **Çıktı Katmanı (Output Layer):** Çıktı katmanı, ağına nihai sonuçlarını üretir. Çıktı nöronlarının sayısı, problem türüne bağlı olarak değişmektedir. Çıktı katmanı Şekil 6'da yer alan  $o_1, o_2, o_3$  nöronları ile gösterilmektedir (Zhang vd., 2021: 133-135).



**Şekil 6: Yapay Sinir Ağlarının Yapısı**

**Kaynak:** Zhang vd. (2021).

YSA, temel yapı taşı olan nöronlardaki bilgiyi doğrusal olmayan ve dağıtılmış bir şekilde işleyerek karmaşık problemleri çözme yeteneğine sahiptir. Bireysel nöronların birbirine bağlanma şekline YSA topolojisi, mimarisi veya sistemi denilmektedir. Nöronlar arasındaki bağlantının çok sayıda yapılabilmesi iki temel sınıfa ayrılan çok sayıda olası mimari ile sonuçlanmaktadır. Bu iki temel mimari, ileri beslemeli mimari ve geri yayımlı mimaridir (Krenker vd., 2011: 6). Şekil 7, sol taraf ileri beslemeli, sağ taraf ise geri yayımlı mimarilere ait yapıyı göstermektedir.



**Şekil 7: İleri Beslemeli ve Geri Beslemeli Mimari**

**Kaynak:** Krenker vd. (2011)

İleri beslemeli bir mimariye sahip olan YSA'da geri döngü olmaksızın giriş katmanından çıkış katmanına doğru yalnızca bir yönde aktarım gerçekleşir. Bu mimaride giriş katmanında sunulan veriler ağırlıklandırılmayla birlikte aktivasyon fonksiyonu

aracılığıyla gizli katmana iletilir. Son gizli katmanda elde edilen bilgiler çıktı katmanına iletilerek probleme uygun sonuçlar üretilmektedir. Çıkış katmanında elde edilen sonuçlar ile gerçek değerler karşılaştırılarak iki değer arasındaki hata hesaplanır. Bu fark bir kayıp fonksiyonu (loss function) aracılığıyla hesaplanmaktadır. Gerçek değerler ile mimarinin ürettiği değerler arasındaki farkı en aza indirmek için geri yayılım (backpropagation) algoritması kullanılarak başlangıçta seçilen ağırlıklar güncellenir ve mimari tekrar yeni ağırlıklarla birlikte yeni bir çıktı üretir. Bu durum modelde kullanılan epochs sayısı kadar devam eder. Epochs ileri besleme, hata hesaplama ve ağırlıkların güncellenmesi işleminin bir kez tamamlanmasıdır. Dolayısıyla epochs, eğitim verisinin tamamının ağ tarafından işlenmesidir. Epochs sayısının artmasıyla tüm bu işlemler daha fazla sayıda tekrarlanarak en düşük hata değerine ulaşılmaya çalışılmaktadır (Bishop, 2006: 227-245; Haykin, 2008:22).

Geri beslemeli sinir ağlarında geri döngülerle ilgili bir sınırlama olmaksızın ileri beslemeli sinir ağı yapısına benzemektedir. Bu mimaride bilgi artık sadece giriş katmanından çıkış katmanına doğru ilerlemez, aynı zamanda geriye doğru aktarılmaktadır. Burada gizli katman hem mevcut girdiyi hem de önceki adımdaki çıktıları dikkate almaktadır. Bu özellik ağı, geçmişteki bilgileri hatırlamasına olanak tanımaktadır (Krenker vd., 2011: 8).

Her iki ağ mimarisinde de eğitim sürecinde karşılaşılabilecek en önemli sorun olan aşırı öğrenme (overfitting), modelin eğitim verisine çok sıkı bir uyum sağlaması sonucunda, modelin genelleme yeteneğinin azalması ve yeni veri setlerine karşı zayıf bir performans göstermesi sorunudur. Bu sorunun önüne geçilmesi için YSA eğitiminde dikkat edilmesi gereken kritik birkaç yöntem bulunmaktadır. Bu yöntemlerden ilki olan dropout (seyreltme), Hinton vd. (2012) tarafından önerilmiştir ve bir sinir ağındaki nöronların bir kısmının devre dışı bırakılması anlamına gelmektedir. Sinir ağında hangi birimlerin çıkarılacağı rastgele seçilmektedir. Devre dışı bırakılan nöronlar sayesinde her eğitim iterasyonunda farklı bir ağ eğitilmektedir. Böylece model, bir nörona ya da ağa aşırı bağımlı hale gelmez ve farklı nöronların öğrenmesi sağlanır. Bunun yanında modelin aşırı uyum sorunu yaşamasının önüne geçilmiş olunur (Srivastava vd., 2014: 1930, Chollet, 2021: 150). YSA eğitimi sırasında aşırı uyum sorununu önlemek adına kullanılan bir diğer düzenleme yöntemi erken durdurma (early stopping)'dır. Genellikle eğitim hatası iterasyon boyunca azalırken, doğrulama hatası önce azalış gösterir bir noktadan sonra artmaya başlayabilir. Bu durumun gerçekleşmesi modelin aşırı uyum sorunu

yaşamaya başladığını gösterir. Erken durdurma yönteminde, eğitim sırasında modelin hem eğitim hem de doğrulama veri setindeki hataları sürekli olarak izlenir. Doğrulama hatasında bir eşiğe ulaşp artmaya başladığında eğitim süreci durdurulur. Buna erken durdurma denilmektedir (Bishop, 2006: 259, Chollet, 2021: 144). Bunlara ek olarak batch size (yığın boyutu) da modelin aşırı öğrenme riskini etkileyen önemli hiperparametrelerden biridir. Model eğitimi sırasında veriler, model ağırlıklarının güncellenmesi için belirli büyüklükteki yığınlar halinde işlenmektedir. Küçük bir batch size değeri, modelin sık güncellenmesine katkı sağlayarak genelleme kabiliyetinin artırabilir, ancak fazla küçük değerler model kararsızlığına da neden olabilir. Büyük batch size değeri ise daha dengeli bir güncelleme süreci yaratırken aşırı öğrenme riskinin doğmasına yol açabilmektedir. Bu nedenle batch size, modelin genelleme performansını koruyacak şekilde dikkatle seçilmelidir (Goodfellow, 2020: 279).

YSA modellerinde aşırı uyum sorununa karşı modellerin ağırlıklarını kontrol altına tutmaya yönelik L1 Cezalandırması (Lasso Regularization) ve L2 Cezalandırması (Ridge Regularization) yöntemleri de kullanılmaktadır.

L1 cezalandırmasında kayıp fonksiyonuna ağırlıkların mutlak değerleri eklenerek modelin genelleştirme kabiliyetinin artırılması hedeflenmektedir.

$$J = Kayıp + \lambda \sum |w_i|$$

Burada  $\lambda$  cezalandırmanın büyüklüğünü belirler. L1 cezalandırması, bazı ağırlıkların sifıra eşitlenmesine neden olabilmektedir. Bu durum daha seyrek bir modelin oluşmasına yol açabilir.

L2 cezalandırmasında kayıp fonksiyonuna ağırlıkların kare toplamı eklenmektedir.


$$J = Kayıp + \lambda \sum w_i^2$$

Burada da  $\lambda$  cezalandırmanın büyüklüğünü belirlemektedir. Ancak L1 cezalandırmadan farklı olarak L2 cezalandırması ağırlıkları sifıra doğru yaklaştırır, sifır yapmaz. Bu nedenle de daha dengeli bir düzenlemenin ortaya çıkmasına neden olur (Moore ve DeNero, 2011: 1-4; Goodfellow vd., 2020: 230-237).

YSA genellikle sınırlı sayıda katmandan oluşan ve basit problemleri çözmede başarılı sonuçlar veren bir sistemdir. Ancak daha karmaşık yapılarındaki sorunları çözmek, büyük veri setlerinden bilgi çıkarımında bulunmak veya zaman serisi gibi daha zor problemleri çözmek için sinir ağı sisteminin derinleştirilmesi gerekmektedir. Derin öğrenme (Deep Learning, DL) YSA'daki bu tür eksikliklerin giderilmesi amacıyla geliştirilmiş, çok katmanlı ağ mimarilerine dayanan bir öğrenme yöntemidir. Bu çerçevede derin öğrenme yöntemleri geleneksel YSA modellerine kıyasla daha geniş bir uygulama alanına hitap ederken büyük ve sıralı veriler üzerinde başarılı sonuçlar üretebilmektedir.

### 3.4. Derin Öğrenme

YSA sisteminin bir alt dalı olan derin öğrenme, çok katmanlı sinir ağlarını kullanarak, büyük, karmaşık ve sıralı veri setlerinden anlamlı örüntüler çıkarabilen bir öğrenme sistemi olarak, özellikle son yıllarda sıklıkla kullanılmaktadır.



**Şekil 8: Yapay Zekânın Katmanları**

**Kaynak:** Kaya (2022).

Derin öğrenme ile makine öğrenmesinin farklılaştığı durum, algoritmaların öğrenme yöntemidir. Derin öğrenme algoritmalarında öğrenme kısmı önemli ölçüde otomatik olarak gerçekleşmekte, dolayısıyla insan müdahalesi ortadan kalkmaktadır. Derin öğrenmede bir dizi algoritma (girdiler, ağırlıklar, eşik ve çıktı) kullanılarak insan bilişi taklit edilmeye çalışılmaktadır. Bu özelliklerinden kaynaklı olarak derin öğrenme


yöntemi, yüksek tutarlılığa sahip modellerin oluşturulmasına olanak tanımaktadır (Kaya, 2022: 20).

YSA ile derin öğrenmenin arasındaki fark katman derinliği, büyük veri setlerinin işlenmesi, özellik çıkarımı ve performans gücü gibi unsurlarda ortaya çıkmaktadır. Derin öğrenme, YSA'dan farklı olarak çok sayıda gizli katmanın bulunduğu derin ağ sistemlerinden oluşmaktadır. Bu durum derin öğrenme yöntemlerinin büyük veri setlerinde daha başarılı performans göstermesine, görüntü, ses, doğal dil işleme ve sıralı veri setlerinde karşılaşılan karmaşık problemlerin çözümüne önemli katkı sağlamaktadır. Bu tür avantajlardan dolayı, finans ve ekonomi alanlarında derin öğrenme, piyasa tahminleri, portföy optimizasyonu ve müşteri segmentasyonu gibi kritik görevlerde sıklıkla kullanılmaktadır. Örneğin, derin öğrenme algoritmaları, hisse senedi fiyatlarını ve piyasa eğilimlerini tahmin etmek için büyük veri setlerini analiz edebilmekte ve yatırımcılara daha doğru ve zamanında bilgi sunabilmektedir. Ayrıca, müşteri davranışlarını ve tercihlerini anlamak için derin öğrenme teknikleri kullanılmakta, böylece kişiselleştirilmiş bankacılık hizmetleri ve pazarlama stratejileri geliştirilmektedir. (<https://www.ibm.com/topics/machine-learning>).

Derin öğrenme yapılarındaki çok katmanlı yapıların yüksek başarı oranı elde ettiği bir diğer alan sıralı verilerin işlenmesidir. Sıralı veriler, ardışık bir yapıda ve zaman bağımlılığına sahip olduğu için, geleneksel YSA, bu tür veri setlerinden çıkarımda bulunmakta zorlanmaktadır. Bu durumda, tekrarlayan sinir ağları, uzun-kısa süreli bellek ve kapılı tekrarlayan ünite vb. gelişmiş ağ mimarileri devreye girmektedir. Bu mimariler, sıralı verilerin geçmiş bilgilerini öğrenerek tahminlerde bulunabilmektedir.

#### **3.4.1. Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN)**

Sıralı veya zamana bağlı örüntüleri öğrenmek için tasarlanan Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN), 1990'lı yıllardan itibaren araştırma yöntemleri içerisinde sıklıkla kullanılan bir yöntem olmuştur. İleri beslemeli sinir ağlarından farklı olarak zaman bağımlılıklarını çözümlemek için RNN'de model geri beslemeli olarak tasarlanmıştır. Şekil 9, RNN mimarisinin güçlü bir öğrenme ağı yaratmak için bir dizi özellik eklenerek formüle edildiği sistemi göstermektedir (Unadkat vd., 2001).



**Şekil 9: Tekrarlayan Sinir Ağı (RNN) Mimarisi**

**Kaynak:** Murugaiyan ve Lakshmi (2022)

RNN mimarisi, bir döngü aracılığıyla önceki girdiden elde ettiği çıktıyı hatırlama üzerine kurulmuştur. Mimaride kullanılan döngü, önceki zaman damgasından gelen bilgileri alır ve bu bilgileri geçerli zaman damgasının girdisine ekler. Süreç, Şekil 9 dikkate alınarak şöyle açıklanabilir: Mimari giriş dizisinden  $X_0$ 'ı alır ve bu bilgiyle  $h_0$  çıktısını üretir. Bu çıktı  $X_1$  ile birlikte bir sonraki adım için girişi oluşturur. Daha sonra, bir sonraki adımdaki  $h_1$  sonraki adım için  $X_2$  ile birlikte girdiyi oluşturur. Süreç böyle devam eder. Bu döngüyle birlikte mimari eğitim sırasında önceki bilgileri hatırlamaya devam etmiş olur. Bu bağlamda RNN, aynı ağın birden fazla kopyası olarak düşünülebilir. Yani her bir ağ bir sonraki ağa mesaj iletmektedir.

Matematiksel olarak bu süreç şöyle ifade edilebilir:

$$h_t = \phi(Wx_t + Uh_{t-1}) \quad (3.1)$$

Denklemden yer alan  $h_t$ , t zamanındaki gizli durum,  $h_{t-1}$  t-1 zamanındaki gizli durum,  $W$  ve  $U$  ağırlıklandırmaları,  $\phi$  aktivasyon fonksiyonunu (genellikle Tanh veya sigmoid),  $x_t$  girdiyi ifade etmektedir. RNN mimarisi yukarıda anlatılan sistemin işlemesiyle birlikte  $W$  ve  $U$  ağırlıklarını öğrenir. Bu ağırlıklar, önceki zaman damgasındaki bilginin ve geçerli girdinin önemini belirler. Bir başka ifadeyle gizli durumdan ve mevcut girdiden ne kadarlık bir değer geçeri girdiyi oluşturmak için yeterli olduğuna karar verir (Goodfellow vd., 2020: 379-382).


RNN mimarisi, sıralı verilerdeki örüntüleri çözmede oldukça başarılı sonuçlar verse de bu mimarinin uzun dizilerdeki örüntüleri öğrenmede karşılaştığı önemli bir sorun gradyan kaybolması (vanishing gradient) sorunudur. RNN'de kullanılan geriye yayılım algoritması gradyanların son zaman diliminden en önceki zaman dilimine doğru işlemesi

sebebiyle geçmiş bilginin çoğalması gradyanların yavaş yavaş küçülmesine ve kaybolmasına neden olmaktadır. Bu durum mimarinin uzun dönemli öğrenme kapasitesinin azalmasına yol açmaktadır. Bu nedenle RNN, zaman serisi problemlerinde genel olarak daha kısa bir zaman dizisi için kullanılmaktadır (Hochreiter ve Schmidhuber, 1997: 1).

### 3.4.2. Uzun-Kısa Süreli Bellek (Long-Short Term Memory)

Hochreiter ve Schmidhuber (1997) tarafından tanıtılan Uzun-Kısa Süreli Bellek (Long-Short Term Memory, LSTM), uzun vadeli bağımlılıkları öğrenme yeteneğine sahip özelleştirilmiş bir RNN modelidir. LSTM, özellikle uzun vadeli bağımlılıkları etkin şekilde çözmek ve gradyan kaybolması sorunlarının üstesinden gelmek amacıyla tasarlanmış, bu sebeple de doğal dil işleme, konuşma tanıma ve zaman serileri tahmini gibi konularda sıklıkla kullanılan modellerden birisi olmuştur.

RNN modelinde, uzun süreli bellek özelliği bulunmadığı için en son bilgiye dayanarak tahminde bulunmaktadır. LSTM modeli, RNN modelinden farklı olarak kaybolan gradyan problemine çözüm arayarak uzun dizileri işleyebilmektedir. LSTM bunu tek bir sinir ağı katmanını yerine, bir hücre durumu ve üç kapıdan oluşan ve katmanlar arası özel ilişkinin bulunduğu yapısıyla yapabilmektedir. LSTM modeline ait özel yapı Şekil 10'da gösterilmektedir.



**Şekil 10: LSTM Modeli Hücre Yapısı**

**Kaynak:** Radfar (2024)

LSTM modeli bir hücre durumu ve farklı özelliklere sahip üç kapıdan oluşmaktadır. Bunlar; unutma kapısı, giriş kapısı ve çıkış kapısıdır. Şekilde  $x_t$ , mevcut zaman anında modele giren veriyi,  $h_{t-1}$  bir önceki zamandan aktarılan gizli durumu,  $C_{t-1}$  ise bir önceki hücreden gelen hücre durumunu ifade etmektedir. Modelde  $h_{t-1}$  kısa dönemli hafızayı,  $C_{t-1}$  ise uzun dönemli hafızayı temsil eder. Hücre durumu ( $C_t$ ), modele ait uzun vadeli bilgileri taşır ve sürekli olarak güncellenir. Bu akış yatay bir çizgi şeklinde gösterilmektedir.

*Unutma kapısı (forget gate,  $f_t$ )*, modelin önceki bilgilerden ne kadarlık kısmını unutacağını, yani hücre durumundan ne kadarının atılacağını belirler. Sigmoid fonksiyonunun ( $\sigma$ ) kullanıldığı bu kapıda  $C_{t-1}$  üzerinden çarpma ( $\times$ ) işlemi uygulanır. Sigmoid fonksiyonu, bilgileri 0-1 arasında normalize eder.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.2)$$

*Giriş kapısı (input gate,  $i_t$ )*, modele gelen yeni bilgilerden ne kadarının hücre durumuna ekleneceğini kontrol eder. Giriş kapısı, sigmoid fonksiyonu aracılığıyla hangi değerlerin güncelleneceğine karar verir ve tanh fonksiyonu ile çalışan bir aday hücre durumu ( $\tilde{C}_t$ ) yaratır.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.4)$$

Güncellenen hücre durumu, unutma kapısı ( $f_t \cdot C_{t-1}$ ) ve giriş kapısından ( $i_t \cdot \tilde{C}_t$ ) gelen bilgilerle birleştirilir.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (3.5)$$

*Çıktı kapısı (output gate,  $o_t$ )*, hücre durumundaki hangi bilgilerin çıktı olarak üretileneğine karar verir. Sigmoid fonksiyonu ve hücre durumuna bağlı tanh fonksiyonu aracılığıyla çıktı oluşturulur (Olah, 2015; Greff vd., 2017: 2222-2225).

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.6)$$


$$h_t = o_t * \tanh(C_t) \quad (3.7)$$

LSTM modeli, hücrelerinde barındırdığı üç kapı ve hücre durumu sayesinde sıralı verilerle çalışan esnek bir mimaridir. Uzun ve kısa vadeli bağımlılıkları öğrenme yeteneği

ve kaybolan gradyan sorununa ürettiği çözümler nedeniyle zaman serileri ve doğal dil işleme uygulamalarında sıklıkla kullanılan bir mimari olmuştur.

### 3.4.3. Kapılı Tekrarlayan Ünite (Gated Recurrent Unit)

Cho vd. (2014) tarafından geliştirilen Kapılı Tekrarlayan Ünite (Gated Recurrent Unit, GRU), RNN modelinin özelleştirilmiş bir hali olup, uzun vadeli ilişkileri öğrenme ile kaybolan ve patlayan gradyan problemlerine çözüm aramak için geliştirilmiştir. GRU mimarisi, daha basit ve verimli yapısıyla LSTM modeline bir alternatiftir. GRU, LSTM modelindeki unutma ve giriş kapılarını tek bir güncelleme kapısı (update gate) altında birleştirmekte, böylece daha basit bir yapıya sahip olmaktadır. Basit ve rekabetçi yapısı nedeniyle GRU modeli, zaman serisi tahminleri ve metin çevirileri gibi sıralı veri çalışmalarında sıklıkla kullanılmaktadır. GRU modelinin basit verimli yapısı Şekil 11’de gösterilmiştir.



**Şekil 11: GRU Modeli Hücre Yapısı**

**Kaynak:** Olah (2015)

GRU modelinde, LSTM modelinden farklı olarak unutma ve giriş kapılarının yerine tek bir güncelleme kapısı kullanılmaktadır. Bu kapı sayesinde model, daha basit ve verimli bir şekilde çalışarak daha az parametreyle daha hızlı sonuçlar üretebilmektedir.

*Güncelleme kapısı (update gate,  $z_t$ )*, ağıın geçmiş bilgilerden ne kadarını unutacağına ve ne kadarını hatırlayacağına karar vermektedir. Bu kapı sayesinde model, önceki gizli durumları hatırlaması gerektiğinde geçmişteki önemli bilgileri tutarak daha

etkili bir öğrenme yöntemi kullanmış olur. Güncelleme kapısının matematiksel gösterimi şöyledir:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (3.8)$$

Burada  $z_t$  güncelleme kapısının çıktısını,  $h_{t-1}$  önceki zamana ait gizli durumu,  $x_t$  mevcut giriş verisini,  $W_z$  ve  $b_z$  modelin öğrenme parametrelerini ve  $\sigma$ , kapıda kullanılan sigmoid fonksiyonunu temsil etmektedir. Kapı, bu yapıyı kullanarak önceki bilgilerden ne kadarının saklanıp ne kadarının yeni bilgilerle güncelleyeceğine karar vermektedir (Zhang vd., 2021: 349-351).

*Reset kapısı (reset gate,  $r_t$ )*, geçmiş bilgilerden ne kadarının atılacağını belirler. Reset kapısı, yüksek bir değer üretmişse model önceki durumları yok sayar ve mevcut girişe dayalı bir çıktı üretir. Böylece model geçmiş bilgileri unutarak yeni bilgilere odaklanmıştır. Reset kapısı matematiksel olarak şöyle ifade edilebilir:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (3.9)$$

Burada  $r_t$  reset kapısı çıktısını,  $W_r$  ve  $b_r$  parametre değerlerini  $\sigma$  sigmoid fonksiyonunu temsil etmektedir. Kapı, geçmiş gizli durum  $h_{t-1}$  bilgisini mevcut giriş verisi  $x_t$  ile birleştirerek ne kadarlık kısmın unutulacağını belirler. Bu durum uzun vadeli bağımlılıkları öğrenmede modele önemli katkı sağlamaktadır.

Mimari, gizli durumu ( $h_t$ ) hesaplamadan önce bir aday gizli durum  $\tilde{h}_t$  hesaplar.

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \quad (3.10)$$

Devam eden süreçte güncelleme ve reset kapılarını kullanarak yeni bir gizli durum ( $h_t$ ) hesaplanır. Hesaplama şu şekilde gerçekleşmektedir:


$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (3.11)$$

Burada  $h_t$  modelin mevcut gizli durumunu ifade etmektedir (Chung vd., 2014: 3-5).

GRU modeli, RNN modelinin uzun vadeli bağımlılıkları yakalamadaki başarısızlığı ve kaybolan gradyan sorununu çözmek için geliştirilmiş, basit ve verimli yapısı ile zaman serisi tahminleri, dil modelleme ve konuşma tanımlama gibi alanlarda sıklıkla kullanılan ve başarılı sonuçlar veren bir mimari olmuştur.

### 3.4.4. Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long-Short Term Memory)

Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long-Short Term Memory, Bi-LSTM) modeli, LSTM modelinin özelleştirilmiş halidir. LSTM, doğal dil işleme, zaman serisi tahminleri ve konuşma tanımlama alanlarında etkin şekilde kullanılan özel bir RNN mimarisidir. Ancak LSTM modeli, verilerin çift yönlü özelliklerini yakalamada birtakım sınırlara tabidir. Çünkü LSTM modelinde veriler ileri yönde işlenmektedir. Bi-LSTM modeli bu kısıtlamanın üstesinden gelmek için giriş dizilerindeki iki ayrı LSTM katmanı aracılığıyla verileri hem ileriye hem de geriye doğru işlemek üzerine modellenmiştir. Bu özelliği sayesinde mimari, verileri iki yönde de işleyerek geçmiş ve gelecek bilgilerden faydalanarak daha kapsamlı analizler gerçekleştirebilmektedir. Bu özellikler Bi-LSTM modelini dil çevirisi, ileri zaman serisi tahminleri ve duygu analizi gibi sıralı verilerin olduğu birçok alanda popüler bir mimari olmasına yol açmıştır (Graves ve Schmidhuber, 2005: 602-604; Pavlatos vd., 2023: 4). Bi-LSTM modelinin çift yönlü yapısı Şekil 12’de gösterilmektedir.



Şekil 12: Bi-LSTM Model Yapısı

**Kaynak:** Aras (2023)

Şekil 12’de görüldüğü üzere Bi-LSTM modeli LSTM modelinden farklı olarak verileri hem ileri hem de geri yönde işlemektedir. Giriş verileri ( $x_t, x_{t+1}, x_{t+2}, x_{t+3}$ ) hem ileri hem de geri yönde işlenip aktivasyon fonksiyonlarından geçerek ( $h_t, h_{t+1}, h_{t+2}, h_{t+3}$ ) çıktıları oluşturumaktadır. Matematiksel olarak açıklamak gerekirse model LSTM modelindeki gibi öncelikle ileri yönde işlenmektedir:

$$\vec{h}_t = \sigma(\vec{W}_o \cdot [\vec{h}_{t-1}, x_t] + \vec{b}_o) \tanh(\vec{c}_t) \quad (3.12)$$

Model geriye doğru işlendiği zamanda ise şu işlem gerçekleştirilmektedir:

$$\overleftarrow{h}_t = \sigma(\overleftarrow{W}_o \cdot [\overleftarrow{h}_{t-1}, x_t] + \overleftarrow{b}_o) \tanh(\overleftarrow{c}_t) \quad (3.13)$$

Sonraki süreçte ileri ve geri yönde hesaplanan gizli durum değerleri zaman adımlarının tamamı için birleştirilir:


$$h_t = \vec{h}_t + \overleftarrow{h}_t \quad (3.14)$$

Bu birleştirme işlemiyle birlikte tüm zaman adımları için geçmiş ve gelecek değerlere ait bilgiler elde edilmiş olur (Zhang vd., 2021: 370).

Sonuç olarak Bi-LSTM modeli, ileri ve geri yönlü LSTM hücrelerini birleştirerek her zaman adımı için daha zengin bilgi kümesi üretebilmektedir. Bu durum modele, zaman serisi tahminleri, doğal dil işleme, metin çevirisi ve duygu analizi gibi alanlarda büyük avantaj sağlamaktadır.

#### **3.4.5. Çift Yönlü Kapılı Tekrarlayan Ünite (Bidirectional Gated Recurrent Unit)**

Çift Yönlü Kapılı Tekrarlayan Ünite (Bidirectional Gated Recurrent Unit, Bi-GRU) modeli ileri ve geri sinir ağlarına sahip çift katmanlı Bi-LSTM'ye benzer bir modeldir. Bi-GRU modelinde veriler ileri yönde işlenen GRU ve geri yönde işleyen GRU yapılarından geçerek nihai çıktı üretilmektedir. Mimarının hem ileri hem de geri yönde işlemesi geçmiş ve gelecek bilgilerin birlikte kullanılarak daha tutarlı modeller inşa edilmesine olanak tanımaktadır (Raj vd., 2021: 11). Şekil 13 Bi-GRU mimarisinin çalışma şeklini göstermektedir.



**Şekil 13: Bi-GRU Model Yapısı**

**Kaynak:** Aras (2023)

Bi-GRU modeli Bi-LSTM modelinde olduğu gibi giriş verilerini ( $x_t, x_{t+1}, x_{t+2}, x_{t+3}$ ) hem ileri hem geri yönde işleyerek ( $h_t, h_{t+1}, h_{t+2}, h_{t+3}$ ) çıktılarını meydana getirmektedir. Model önce GRU modelinde olduğu gibi ileri yönde işletilerek bilgi çıkarımında bulunmaktadır. İleri yönlü işleyiş şu şekildedir:

$$\vec{h}_t = (1 - \vec{z}_t) \cdot \vec{h}_{t-1} + \vec{z}_t \cdot \vec{\tilde{h}}_t \quad (3.15)$$

Burada  $\vec{h}_t$  gizli durumu,  $\vec{z}_t$  güncelleme kapısı çıktısını,  $\vec{\tilde{h}}_t$  ise aday gizli durumu ifade etmektedir. GRU modeli geriye doğru işletildiğinde ise matematiksel gösterim şöyle olacaktır:

$$\tilde{h}_t = (1 - \tilde{z}_t) \cdot \tilde{h}_{t-1} + \tilde{z}_t \cdot \tilde{\tilde{h}}_t \quad (3.16)$$

İleri ve geri yönlü gizli durum bilgileri birleştirildiğinde ise Bi-GRU modeli elde edilmiş olur.

$$h_t = \vec{h}_t + \tilde{h}_t \quad (3.17)$$

Bi-GRU modelinde giriş vektörü ( $x_t$ ) ileri ve geri yönlü GRU hücrelerine gönderilir. Her hücre kendi yönünde gizli durumları hesaplar ve bu gizli durumlar birleştirilerek Bi-GRU modelinin çıktısı elde edilir. Bu şekilde hem geçmiş hem de gelecek bilgileri modele dahil ettiği için Bi-GRU modeli zaman serisi analizi, dil

modelleme ve duygu analizi gibi alanlarda sıklıkla kullanılmaktadır (Chauhan vd., 2024: 9185).

### 3.5. Hibrit Modeller

Daha önceki bölümde LSTM, GRU, Bi-LSTM ve Bi-GRU modellerinin çalışma prensipleri ve yapısal özellikleri ayrıntılı bir şekilde aktarılmıştır. Açıklanan bu modeller sıralı verilerin işlenmesinde ve zaman serisi tahminlerinde güçlü performans gösteren modeller olarak öne çıkmaktadır. Ancak RNN tabanlı derin öğrenme modelleri, zaman bağımlılıklarını işlemekte başarılı olsa da yerel özelliklerin çıkarılmasında birtakım sınırlamalara tabi olmaktadır. Bu durum, farklı derin öğrenme modellerinin güçlü yönleri birleştirilerek daha kapsamlı hibrit modellerin geliştirilmesi gerektiği sonucunu doğurmuştur.

Hibrit modeller, farklı derin öğrenme modellerinin güçlü özelliklerini bir araya getirerek daha yüksek başarı oranı yakalamayı amaçlamaktadır. Örneğin, Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) modelinin yerel ve mekânsal özellikleri öğrenme yeteneğiyle, RNN tabanlı modellerin zaman bağımlılıklarındaki güçlü performansının birleştirilmesiyle oluşturulan hibrit modeller, sıralı verilerin hem zamansal hem de mekânsal yönlerini öğrenerek daha güçlü tahmin performansı sağlayabilir.


Bu bölümde CNN/LSTM, CNN/GRU, CNN/Bi-LSTM ve CNN/Bi-GRU modellerine odaklanılarak, bu modellere ait teorik temeller incelenecektir.

#### 3.5.1. Evrişimli Sinir Ağları (Convolutional Neural Network)

Evrişimli Sinir Ağları (Convolutional Neural Network, CNN), girişten çıkışa doğru bilgi aktaran ileri beslemeli bir derin öğrenme modelidir. CNN mimarisi, özellikle görüntü işleme ve tanımlama, sınıflandırma ve tahminleme gibi uygulama alanlarında sıklıkla kullanılmaktadır. Bu model diğer derin öğrenme modellerinden farklı olarak yerel ve mekânsal ilişkileri öğrenme yeteneği ile öne çıkmaktadır.

CNN modelleri veri türlerine bağlı olarak farklı şekillerde tasarlanmaktadır. İki boyutlu CNN (2D-CNN) mimarisi genellikle görüntü verileriyle çalışmakta ve uzaysal özellikleri öğrenmek için iki boyutlu filtreler kullanmaktadır. Tek boyutlu CNN (1D-CNN) mimarisi ise zaman serileri gibi sıralı verilerdeki mekânsal özellikleri öğrenmek için bir boyutlu filtrelerle analiz gerçekleştirmektedir. Bu çalışmada zaman serisi verisiyle çalışıldığı için 1D-CNN modeli tercih edilmiştir.

CNN modelinin işleyişi diğer derin öğrenme modellerinde olduğu gibi giriş verilerinin bir dizi katman aracılığıyla işlenmesine dayanmaktadır. Giriş katmanındaki bir veri matrisi bulunmaktadır. CNN, veriyi filtre matrisi aracılığıyla inceler ve özellik çıkarımında bulunur. Çıkarılan özellikler bir özellik haritasında kümelenir. Bu uygulama CNN modeline bağlı birtakım prensiplerle desteklenir ve modelin daha az parametre kullanarak güçlü öğrenme kapasitesine ulaşmasını sağlar (Goodfellow vd., 2020: 331). CNN modeli çalışma prensibi Şekil 14’te gösterilmektedir.



**Şekil 14: CNN Model Yapısı**


**Kaynak:** Gilik vd., (2022)

CNN modeli, girdi katmanı, evrişimli katman, havuzlama katmanı, tam bağımlı katman ve çıktı katmanından oluşmaktadır. Girdi katmanı, modele veri sağlayan ilk katmandır. Bu katmanda veri olduğu gibi alınıp işlenmek üzere evrişimli katmana iletilir. Evrişimli katman, filtre adı verilen matrisler aracılığıyla giriş verisi üzerinde işlem yaparak bir özellik haritası oluşturur. Havuzlama katmanı, özellik haritasının boyutunu düşürür ve model doğruluğunu artırır. Tam bağımlı katman, evrişim ve havuzlama katmanlarında elde edilen bilgileri alır ve tahminde bulunur. Yapılan tahminler bir aktivasyon fonksiyonu aracılığıyla çıktı katmanına iletilir ve nihai tahmin elde edilir (İnik ve Ülker, 2017: 88-96; Amidi ve Amidi, 2019; Gilik vd., 2022: 11926-11928).

CNN modeli, mekânsal ve yerel özellikleri yakalamada oldukça başarılı sonuçlar vermesine rağmen zaman serilerindeki uzun vadeli bağımlılıkları öğrenmede hücre yapısı nedeniyle tam bir başarı gösteremez. Bu nedenle, CNN modeli zaman serisi tahminlerinde tek başına değil, LSTM ve GRU gibi RNN tabanlı modellerle birlikte hibrit bir yapıda kullanılmaktadır.

### 3.5.2. CNN/LSTM Hibrit Modeli

CNN/LSTM modeli, derin öğrenme modelleri içerisinde sıklıkla kullanılan bir hibrit modeldir. Model, CNN ve LSTM yapılarını birlikte kullanarak hem mekânsal hem de zamansal özellikleri etkili bir şekilde öğrenebilmektedir. Bu özelliği nedeniyle CNN/LSTM modeli zaman serisi analizleri, görüntü işleme ve metin çevirisi gibi alanlarda yaygın bir şekilde tercih edilmektedir.




**Şekil 15: CNN/LSTM Hibrit Model Yapısı**

**Kaynak:** Gilik vd. (2022)

CNN/LSTM hibrit modelinde, girdi verilerinin özniteliklerinin çıkartılması için ilk olarak evrişimli katman kullanılmaktadır. Elde edilen yararlı öznitelik bilgilerinin oluşturduğu özellik haritasının boyutu havuzlama katmanında küçültülür ve LSTM katmanına iletilir. LSTM katmanı gelen bilgilerin zaman bağımlılıklarını çözmek için kullanılır ve işlem sonucunda bilgi üretilir, tam bağımlı katmana iletilir. Tam bağımlı katman LSTM katmanından gelen bilgileri işler tahmin, sınıflandırma veya karar verme işlemini yapar ve çıktı katmanında nihai sonuç belirlenir. Bu yapı, karmaşık veri setlerindeki bilgilerin çözülmesinde tutarlı sonuçlar üretilmesine katkıda bulunur.

### 3.5.3. CNN/GRU Hibrit Modeli

CNN/GRU modeli, derin öğrenme modelleri içerisinde sıklıkla kullanılan bir diğer hibrit modeldir. Model, CNN modelinin mekânsal özellikleri ile GRU modelinin zamansal özelliklerini birlikte kullanabilmektedir. Karmaşık veri setlerindeki mekânsal ve zamansal örüntüleri çözümleme kabiliyeti nedeniyle model, görüntü işleme, metin çevirisi ve zaman serisi tahminleri gibi birçok alanda kullanılmaktadır.




**Şekil 16: CNN/GRU Hibrit Model Yapısı**

CNN/GRU modelinde, mekânsal örüntüleri çözümlemek için öncelikle CNN yapısı kullanılmaktadır. CNN yapısı içerisinde veri setindeki öznelitik evrişimli katmanda çözülmekte, elde edilen bilgiler havuzlama katmanında küçültülerek GRU katmanına iletilmektedir. GRU, havuzlama katmanından gelen bilgiler üzerinde basit ve verimli yapısıyla zaman bağımlılıklarını çözerek bulduğu sonuçları tam bağımlı katmana göndermektedir. Tam bağımlı katman bu bilgileri işleyerek sınıflandırma, tahmin veya karar verme işlemi yaparak çıktı katmanına nihai sonuç olarak iletmektedir. Böylece yapı, karmaşık veri setleri üzerinde mekânsal ve zamansal çözümler yaparak güçlü sonuçlar üretebilmektedir.

#### 3.5.4. CNN/Bi-LSTM Hibrit Modeli

CNN/Bi-LSTM modeli, CNN ve Bi-LSTM ağlarının birleştirilmesiyle oluşturulmuş hibrit bir modeldir. Bu model hem yerel hem de çift yönlü zamansal özelliklerin etkili şekilde işlenmesine imkân sağlamaktadır.




**Şekil 17: CNN/Bi-LSTM Hibrit Model Yapısı**

CNN/Bi-LSTM hibrit modelinde CNN yapısının veri setindeki uzamsal ilişkiyi çözmek için evrişim ve havuzlama katmanları kullanılmaktadır. Bu katmanlardan üretilen öznitelikler, zaman bağımlılıklarını öğrenmek için Bi-LSTM yapısına aktarılır. Bu yapı hem geçmiş hem de gelecek bilgilerden faydalanarak güçlü bir temsil oluşturur. Bi-LSTM katmanının oluşturduğu çıktılar, tam bağımlı katmana iletilir ve bu katmanın vereceği karar, çıktı katmanına iletilerek nihai sonuca ulaşılır. Hem yerel hem de zaman bağımlılıklarını etkili bir şekilde öğrenebilen bu model, genellikle doğal dil işleme, zaman serisi tahmini ve görüntü analizlerinde kullanılmaktadır.

### 3.5.5. CNN/Bi-GRU Hibrit Modeli

CNN/Bi-GRU modeli, CNN ve Bi-GRU modellerinin kombinasyonu olarak tasarlanan hibrit bir modeldir. Bu yapı, özellikle karmaşık veri kümeleri ve zaman serisi analizlerinde sıklıkla kullanılmaktadır. CNN modelinin mekânsal özellikleri yakalama kapasitesi ile Bi-GRU modelinin zaman ilişkileri öğrenme yeteneğinin birleştirildiği bu hibrit model, güçlü analiz yeteneği sunmaktadır.



**Şekil 18: CNN/Bi-GRU Hibrit Model Yapısı**

CNN/Bi-GRU hibrit modelinde, ham giriş verilerindeki mekânsal ve kısa vadeli bağımlılıkları öğrenmek için CNN yapısı kullanılmaktadır. CNN yapısı evrişimli ve havuzlama katmanlarını kullanarak elde ettiği bilgileri Bi-GRU yapısına iletmektedir. Bi-GRU yapısı hem geçmiş hem de gelecek bilgilerden faydalanarak zaman bağımlılıklarını analiz eder. Bi-GRU modelinin ürettiği bu bilgiler tam bağımlı katman aracılığıyla işlenir ve çıktı katmanında nihai sonuç elde edilir. Mekânsal ve zamansal özelliklerin derinlemesine incelendiği bu yapı, karmaşık ve dinamik sistemler üzerinde oldukça etkili bir yöntemdir.

Derin öğrenme modelleri, zaman serisi tahmini ve özellikle karmaşık süreçlerin yaşandığı döviz kuru serilerinin analizinde güçlü araçlar sunmaktadır. Bu çalışmada, LSTM, GRU, Bi-LSTM ve Bi-GRU gibi RNN tabanlı derin öğrenme modellerine ek olarak, CNN modelinin özelliklerini içeren CNN/LSTM, CNN/GRU, CNN/Bi-LSTM ve CNN/Bi-GRU hibrit modelleri detaylı bir şekilde incelenmiştir. Her bir model, kısa ve uzun bağımlılıkları öğrenme yeteneğiyle dikkat çekerek özellik çıkarımında güçlü sonuçlar üretmek amacıyla tasarlanmıştır.

LSTM ve GRU modelleri, uzun süreli bağımlılıkları yakalamada etkili araçlardır. Çift yönlü versiyonları olan Bi-LSTM ve Bi-GRU modelleri hem geçmiş hem de gelecek bilgileri kullanılması yönüyle geniş bir bağlam sunmaktadır. Bu modellerin CNN ile geliştirilmiş hibrit versiyonlarında ise hem yerel örüntüler hem de anlamlı zamansal ilişkiler çözümlenmektedir. Her bir model, farklı veri yapıları ve bağımlılık türleri için özelleşmiş avantajlar sunarak, zaman serisi tahmin analizleri için model seçiminde önemli bir esneklik ve derinlik sağlamaktadır.

### 3.6. Model Başarı Ölçüm Metrikleri

Çalışmada kullanılan modellerin performansını doğru bir şekilde değerlendirmek, hangi modelin daha başarılı sonuç verdiğini bilmek oldukça önemlidir. Bu doğrultuda kullanılacak farklı metrikler, modellerin çeşitli yönlerini ölçerek hata büyüklüğü ve açıklama gücü hakkında bilgi sağlamaktadır. Özellikle Ortalama Mutlak Hata (Mean Absolute Error, MAE), Ortalama Kare Hata (Mean Squared Error, MSE), Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE) ve Açıklama Katsayısı ( $R^2$ ) gibi metrikler modellerin başarısını ölçmekte sıklıkla kullanılmaktadır. Bu metriklerin her biri, model başarısını farklı bir açıdan değerlendirerek, sonuçları kapsamlı bir şekilde anlamaya fayda sağladığı için, birden fazla metriğin kullanılması modelleri değerlendirmek için önemli olacaktır.

#### 3.6.1. Ortalama Mutlak Hata (Mean Absolute Error)

MAE, model tahmini ile gerçek değerler arasındaki farkların mutlak değerinin ortalamasıdır. MAE değeri kolay yorumlanabilir olduğu için zaman serisi analizlerinde sıklıkla kullanılmaktadır. MAE değeri küçüldükçe modelin başarı oranı artmaktadır (Chicco vd., 2021: 4). Denklemden  $X_i$  gerçek değerleri,  $Y_i$  modelin tahmin ettiği değerleri temsil etmektedir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (3.18)$$

### 3.6.2. Ortalama Kare Hata (Mean Squared Error)

MSE, tahmin hatalarının karelerinin ortalamasıdır. MSE, büyük hata değerlerine daha fazla ceza veren, aykırı değerlere daha duyarlı bir metriktir. MSE değeri sıfıra yaklaştıkça modelin başarı oranı artmaktadır (Chicco vd., 2021: 4). Denklemde  $X_i$  gerçek değerleri,  $Y_i$  modelin tahmin ettiği değerleri temsil etmektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2 \quad (3.19)$$

### 3.6.3. Kök Ortalama Kare Hata (Root Mean Squared Error)

RMSE, MSE'nin karekökünün alınmasıyla elde edilen, tahmin edilen değerin gerçek değere ne kadar yakın olduğunu ifade eden popüler bir metriktir. Denklemde  $X_i$  gerçek değerleri,  $Y_i$  modelin tahmin ettiği değerleri temsil etmektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (3.20)$$

### 3.6.4. Açıklama Katsayısı ( $R^2$ )

$R^2$ , model tahminlerinin gerçek veri noktalarını ne kadar açıkladığını ölçmektedir.  $R^2$  değeri 0-1 arasında değişir.  $R^2$  değeri bire doğru yaklaştıkça modelin açıklama gücü artmaktadır. Denklemde  $X_i$  gerçek değerleri,  $Y_i$  modelin tahmin ettiği değerleri,  $\bar{X}$  gerçek değerlerin ortalamasını temsil etmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (3.21)$$

## 3.7. Modeller

Çalışmada kullanılan modeller, farklı parametre kombinasyonları ve ağ mimarileri üzerinden tasarlanmıştır. Bu bölümde, her bir modelin uygulama sürecinde kullanılan katman ve nöron sayısı, optimizier türü, öğrenme oranı (learning rate), yığın boyutu (batch size), epochs (iterasyon) sayısı ve seyreltme oranı (dropout) gibi hiperparametre bilgileri sunulacaktır. Bununla birlikte derin öğrenme literatürü doğrultusunda her model için veri setinin %75'i eğitim, %25'i test seti olarak ayrılmıştır. Bu bilgiler, modelin yapısı ve performansını anlamaya yönelik bir çerçeve oluşturacaktır.

**Tablo 4: Derin Öğrenme Model Parametreleri**

| <b>Modeller</b>    | <b>Katman Sayısı</b> | <b>Nöron Sayısı</b> | <b>Optimizer</b> | <b>Epochs</b> | <b>Seyreltme Oranı</b> |
|--------------------|----------------------|---------------------|------------------|---------------|------------------------|
| <b>LSTM (1)</b>    | 2                    | 32-32               | Adam             | 50            | 0,5                    |
| <b>LSTM (2)</b>    | 2                    | 32-64               | Adam             | 50            | 0,5                    |
| <b>LSTM (3)</b>    | 2                    | 64-64               | Adam             | 50            | 0,5                    |
| <b>LSTM (4)</b>    | 2                    | 64-32               | Adam             | 50            | 0,5                    |
| <b>GRU (1)</b>     | 2                    | 32-32               | Adam             | 50            | 0,5                    |
| <b>GRU (2)</b>     | 2                    | 32-64               | Adam             | 50            | 0,5                    |
| <b>GRU (3)</b>     | 2                    | 64-64               | Adam             | 50            | 0,5                    |
| <b>GRU (4)</b>     | 2                    | 64-32               | Adam             | 50            | 0,5                    |
| <b>Bi-LSTM (1)</b> | 2                    | 32-32               | Adam             | 50            | 0,5                    |
| <b>Bi-LSTM (2)</b> | 2                    | 32-64               | Adam             | 50            | 0,5                    |
| <b>Bi-LSTM (3)</b> | 2                    | 64-64               | Adam             | 50            | 0,5                    |
| <b>Bi-LSTM (4)</b> | 2                    | 64-32               | Adam             | 50            | 0,5                    |
| <b>Bi-GRU (1)</b>  | 2                    | 32-32               | Adam             | 50            | 0,5                    |
| <b>Bi-GRU (2)</b>  | 2                    | 32-64               | Adam             | 50            | 0,5                    |
| <b>Bi-GRU (3)</b>  | 2                    | 64-64               | Adam             | 50            | 0,5                    |
| <b>Bi-GRU (4)</b>  | 2                    | 64-32               | Adam             | 50            | 0,5                    |

Tablo 4, çalışmada kullanılan geleneksel derin öğrenme modellerine ait temel parametreleri göstermektedir. Parametreler, modellerin yapısal özelliklerini ve tahmin sonuçlarını etkileyen en önemli unsurlardır. Derin öğrenme modellerinin döviz kuru tahminlerindeki performansı kullanılan parametrelerin seçime bağlı olarak önemli ölçüde farklılık göstereceği için farklı kombinasyonlar belirlenerek en doğru sonuca ulaşılacak istenmiştir.

Çalışmada kullanılan tüm modellerde, katman sayısı iki olarak belirlenmiştir. Her modelde, nöron sayıları katmanlar arasında farklı kombinasyonlarda kullanılmıştır. Böylece, modelin öğrenme kapasitesi artırılarak döviz kuru serilerindeki karmaşık bağımlılıkların yakalanması amaçlanmıştır. Tüm modellerde, ağırlıkların güncellenmesi için Adam optimizieri kullanılmıştır. Adam, hızlı ve etkili yapısıyla derin öğrenme modellerinde SGD, AdaGrad, RMSprop gibi diğer optimizierlere kıyasla oldukça iyi sonuçlar vermektedir (Opperman, 2023; Yadav, 2023). Modeller, veri setindeki örüntüleri daha iyi öğrenebilmesi için her bir veri noktası üzerinde 50 iterasyon gerçekleştirmiştir.

Bu sabit epochs sayısı, öğrenme sürecinde aşırı uyum veya eksik uyum sorunu yaşanmaması için belirlenmiştir. Yine modellerde aşırı uyum sorunuyla karşılaşmamak için bazı nöronları geçici olarak devre dışı bırakılmış ve 0,5 seyreltme oranı (dropout) uygulanmıştır. Seyreltme oranı, her iterasyonda farklı nöronları devre dışı bırakarak, model genelleme yeteneğinin artmasına katkı sağlamaktadır. İlaveten, model ağırlıklarının aşırı büyük değerler alarak öğrenme sürecini olumsuz etkilemesini engellemek için L2 (Ridge) düzenleme yöntemi de kullanılmıştır. Tüm modeller için yığın boyutu (batch size) 64 olarak belirlenmiştir.

Çalışmada LSTM, GRU, Bi-LSTM ve Bi-GRU modelleri farklı nöron sayısı kombinasyonları kullanılarak incelenmiş, modellerin her biri döviz kuru serilerindeki kısa ve uzun vadeli bağımlılıkları yakalamayı hedeflemiştir.

Çalışmada kullanılan hibrit modeller, CNN ile LSTM, GRU, Bi-LSTM ve Bi-GRU modellerini birleştirerek hem yerel hem de zamansal bağımlılıkların daha etkili bir şekilde öğrenilmesini amaçlamaktadır. Kullanılan modeller, farklı parametre ayarları ve ağ mimarileri üzerinden tasarlanmıştır. Bununla birlikte, derin öğrenme literatüründe yaygın olarak kullanılan yaklaşımlar doğrultusunda, her model için veri setinin %75'i eğitim, %25'i test seti olarak ayrılmıştır. Her bir modelin uygulama sürecinde kullanılan filtre sayısı, nöron sayısı, optimizör türü, öğrenme oranı (learning rate), yığın boyutu (batch size), epochs (iterasyon) sayısı ve seyreltme oranı (dropout) değerleri Tablo 5'te sunulmuştur.

**Tablo 5: Hibrit Derin Öğrenme Model Parametreleri**

| <b>Modeller</b>        | <b>Katman Sayısı</b> | <b>Filtre ve Nöron Sayısı</b> | <b>Optimizer</b> | <b>Epochs</b> | <b>Seyreltme Oranı</b> |
|------------------------|----------------------|-------------------------------|------------------|---------------|------------------------|
| <b>CNN/LSTM (1)</b>    | 2                    | 64f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/LSTM (2)</b>    | 2                    | 64f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/LSTM (3)</b>    | 2                    | 32f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/LSTM (4)</b>    | 2                    | 32f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/GRU (1)</b>     | 2                    | 64f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/GRU (2)</b>     | 2                    | 64f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/GRU (3)</b>     | 2                    | 32f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/GRU (4)</b>     | 2                    | 32f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-LSTM (1)</b> | 2                    | 64f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-LSTM (2)</b> | 2                    | 64f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-LSTM (3)</b> | 2                    | 32f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-LSTM (4)</b> | 2                    | 32f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-GRU (1)</b>  | 2                    | 64f-32                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-GRU (2)</b>  | 2                    | 64f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-GRU (3)</b>  | 2                    | 32f-64                        | Adam             | 50            | 0,5                    |
| <b>CNN/Bi-GRU (4)</b>  | 2                    | 32f-32                        | Adam             | 50            | 0,5                    |

Tablo 5, çalışmada kullanılan hibrit derin öğrenme modellerine ait temel parametreleri göstermektedir. Tüm hibrit modellerde, iki katmanlı bir yapı tasarlanmıştır. İlk katman CNN filtrelerinden oluşurken, ikinci katmanda RNN tabanlı mimariler (LSTM, GRU, Bi-LSTM ve Bi-GRU) yer almaktadır. Modellerde, filtre sayısı ve nöron sayısı farklı kombinasyonlarda kullanılarak model öğrenme kapasitesinin artırılması hedeflenmiştir. Tüm modellerde, ağırlıkların hızlı ve verimli bir şekilde güncellenmesini sağlayan Adam optimizieri kullanılmış, modelin veri setindeki örüntüleri daha iyi öğrenebilmesi için 50 epochs gerçekleştirilmiştir. Aşırı öğrenme riskini azaltmak amacıyla bazı nöronlar geçici olarak devre dışı bırakılmış, 0,5 seyreltme oranı uygulanmıştır. Bunun yanı sıra, model ağırlıklarının aşırı büyümesini engellemek ve dengeli bir öğrenme süreci sağlamak için L2 (Ridge) düzenleme yöntemi modele dahil edilmiştir. Tüm modellerde, işlem verimliliğine ve öğrenme sürecini dengelemek için yığın boyutu (batch size) 64 olarak belirlenmiştir. Tüm parametre ayarları, model performansını artırmak için sistematik şekilde optimize edilmiştir.

## **DÖRDÜNCÜ BÖLÜM**

### **BULGULAR ve DEĞERLENDİRME**

Çalışmada USD/TL ve EUR/TL nominal döviz kurlarının tahmini için döviz kurlarına ait geçmiş değerler kullanılarak 8 farklı derin öğrenme mimarisi (LSTM, GRU, Bi-LSTM, Bi-GRU, CNN/LSTM, CNN/GRU, CNN/Bi-LSTM ve CNN/Bi-GRU) üç ayrı analiz dönemi üzerinden incelenmiştir. Analiz edilen dönemler, Türkiye'nin esnek kur rejimine geçtiği Şubat 2001'den Ekim 2024'e kadar olan uzun vadeli süreç, enflasyon hedeflemesi ve finansal istikrar politikalarının birlikte kullanıldığı 1 Ocak 2010'dan 04 Ekim 2024'e kadar olan orta vadeli süreç ve 15 Temmuz 2016 darbe girişiminden 04 Ekim 2024'e kadar olan kısa vadeli dönem olarak belirlenmiştir. Her bir modele ait tahmin performansı MSE, MAE, RMSE ve  $R^2$  hata metrikleri kullanılarak karşılaştırmalı bir şekilde değerlendirilmiştir. RMSE'nin formülasyon gereği büyük hata değerlerine daha yüksek bir ağırlık vermesi nedeniyle başarı değerlendirmesinde temel metrik olarak seçilmiştir.

Uzun vadeli analiz dönemi olan 1 Şubat 2001'den 04 Ekim 2024'e kadar geçen süreç, Türkiye ekonomisinde yapısal değişimlerin ve önemli politika dönüşümlerinin yaşandığı bir dönemdir. Bu dönem içerisinde, 2001 Ekonomik Krizi sonrası uygulamaya konulan Güçlü Ekonomiye Geçiş Programı, Türkiye ekonomisinde makroekonomik istikrarı sağlamayı ve finansal sistemi güçlendirmeyi amaçlamıştır. Bu doğrultuda, önce örtük enflasyon hedeflemesi, daha sonra açık enflasyon hedeflemesi politikasına geçilmiş, finansal sektör reformları gerçekleştirilmiş ve Merkez Bankası'nın bağımsız politika uygulaması sağlanmıştır. Bu dönemde ayrıca esnek döviz kuru sistemine geçilmiş ve döviz piyasalarının serbest piyasa koşullarında şekillenmesi sağlanmıştır (Pamuk, 2012: 285-289). Bu durum döviz kuru hareketlerinin küresel gelişmelere daha duyarlı hale gelmesine de yol açmıştır. 2008 Küresel Finans Krizi'nin patlak vermesiyle birlikte sermaye akışları ve döviz kuru doğrudan etkilenmiş, Türkiye ekonomisi finansal sistemdeki reformların da desteğiyle güçlü bir direnç gösterebilmiştir. Küresel kriz sonrası dönemde FED ve ECB gibi merkez bankaları finansal piyasaları rahatlatmak ve durgunluğu dindirmek için geniş çaplı varlık alım politikaları uygulamış, bu süreçte gelişmekte olan ülkelere yüksek miktarda sermaye girişi olmuş, döviz kurları görece istikrar kazanmıştır. Türkiye'de bu dönemde küresel likiditeden yararlanarak döviz piyasasındaki dalgalanmaları sınırlayabilmiştir (Karahan ve İpek, 2013: 305; Bulut ve Şahin, 2023: 223-226).

2010'lu yıllarda TCMB hem enflasyon hedeflemesi hem de finansal istikrar politikalarını bir arada uygulama stratejisine geçmiştir (Başçı ve Kara, 2011: 5). Özellikle 2013 yılında FED'in varlık alımlarını kademeli olarak azaltmayı hedeflemesiyle küresel piyasalarda dolar değer kazanmaya başlamış, bu durum dış borç ve cari açık sorunları belirgin hale getirirken döviz kurundaki oynaklığın artmasına neden olmuştur (Bulut vd., 2017: 41).

15 Temmuz 2016 darbe girişimi sonrasındaki dönemde, artan belirsizlikler ve ekonomik kırılganlıklar döviz piyasalarını daha volatil hale getirmiş, döviz kurları hem iç hem de dış faktörlerden yoğun şekilde etkilenmiştir. Bu dönemde, döviz kurlarındaki ani dalgalanmaları kontrol edebilmek için rezerv kullanımı, swap mekanizmaları devreye sokulmuştur. Bu çerçevede çalışma, döviz piyasalarında meydana gelen bu yapısal değişimlerin etkilerine odaklanarak, döviz kuru dalgalanmalarının uzun vadede ne kadar başarılı tahmin edilebileceğine odaklanmıştır.

Orta vadeli analiz dönemi olarak belirlenen 1 Ocak 2010 tarihinden sonraki süreç, Türkiye'de enflasyon hedeflemesiyle birlikte finansal istikrar programlarının birlikte uygulandığı dönemi ifade etmektedir. Bu dönemin başlangıcında, özellikle FED ve ECB varlık alımları programlarını başlatarak küresel likiditede muazzam bir artışa yol açmış, TCMB de para politikaları aracılığıyla bu durumu avantaja çevirerek döviz kuru oynaklığını azaltmaya yönelik adımlar atmıştır. Böylece küresel likidite koşullarının da etkisiyle 2010'lu yılların başında döviz piyasalarında göreceli bir istikrar dönemi yaşanmıştır. Dolayısıyla döviz kurları ekonomi politikalarından doğrudan etkilenmiş ve piyasalarda kısa süreli bir istikrar dönemi yaşanmıştır. Ancak 2013 yılı ortalarında FED tarafından tahvil alımlarının azaltılacağına duyurulmasıyla birlikte Türkiye'de döviz kurları yükselmeye başlamıştır (Orhangazi ve Yeldan, 2023: 175-176).

Uzun vadeli analiz döneminden farklı olarak orta vadeli analiz dönemi, daha dar bir zaman dilimini kapsamaktadır. Bu durum döviz kurlarının bu döneme özgü küresel ve yerel dinamiklerini daha iyi öğrenebilme fırsatı sunmaktadır. Uzun vadeli analiz, daha geniş bir dönemi kapsadığı için kısa vadeli dalgalanmalar uzun vadeli trendler içerisinde baskılanmıştır. Bu sebeple orta vadeli analiz, döviz kurlarında öngörülebilir trendleri ve döneme özgü volatilitiyi net bir şekilde ortaya koymaktadır.

Kısa vadeli analiz dönemi olan 18 Temmuz 2016'dan 04 Ekim 2024'e kadar geçen süreç, ekonomik ve politik belirsizliklerin artış gösterdiği, döviz kuru piyasalarında

volatilitenin yükseldiği ve ani değişimlerin yaşandığı bir dönemi ifade etmektedir. İlgili dönemde, 15 Temmuz 2016 darbe girişimi ve sonrası artan siyasi belirsizlikler, küresel finans koşullarındaki değişimler, Brunson Krizi, COVID-19 pandemisi ve 2021 sonbaharında TCMB'nin politika faizini düşürmesi gibi olaylar döviz kurlarında öngörülmesi zor dalgalanmalara yol açmıştır (Orhangazi ve Yeldan, 2023: 176-179).

Bu zorlu tahmin koşulları, derin öğrenme modellerinin dönem içerisinde yaşanan belirsizlikler karşısındaki esnekliğini ve başarısını ölçmek için önemli bir fırsat doğurmuştur. Bu analiz, ani dalgalanmaların sıklaştığı dönemlerde tahmin modellerinin etkinliğini ölçerek, bu dönemde uygulanabilecek stratejilerin belirlenmesine katkı sağlamak amacıyla gerçekleştirilmiştir.

Analiz edilen üç farklı döneminin kendine özgü ekonomik ve finansal dinamikleri, modellerin performanslarını farklılaştırıcı bir etken olarak öne çıkmaktadır. Bu sebeple çalışmada sadece model performansları değerlendirilmemekte, ayrıca modellerin dönem koşullarına uyum yetenekleri de değerlendirilmektedir.

Aşağıdaki bölümlerde, üç dönem boyunca her bir döviz kuru için elde edilen sonuçlar detaylı tablo ve grafikler aracılığıyla sunulmuş, modeller karşılaştırmalı olarak değerlendirilmiştir. Çalışmada RNN tabanlı LSTM, GRU, Bi-LSTM ve Bi-GRU ve CNN tabanlı hibrit CNN/LSTM, CNN/GRU, CNN/Bi-LSTM ve CNN/GRU modelleri uygulanmıştır. Modeller, Google Colab üzerinde Python programlama dili ve TensorFlow kütüphanesi kullanılarak geliştirilmiş ve eğitilmiştir.

#### **4.1. Uzun Vadeli Sonuçlar**

Uzun vadeli analiz için seçilen 1 Şubat 2001-04 Ekim 2024 döneminde USD/TL döviz kurunda önemli değişimler yaşanmıştır. Bu dönem içerisinde Türkiye'de esnek kur sistemine geçilmiş, döviz piyasaları daha dinamik hale gelmiştir. Bu sebeple modellerin uzun vadeli kur seviyelerini ne derecede yakalayabildiği araştırılmak istenmiş, bu doğrultuda USD/TL ve EUR/TL döviz kurları için 32 farklı derin öğrenme modeli kurulmuştur. Bu kapsamda öncelikle uzun vadeli analiz dönemi için tanımlayıcı istatistikler sunulmuş ve USD/TL ve EUR/TL döviz kuru serilerindeki özellikler incelenmiştir. Döviz kurlarına ait tanımlayıcı istatistikler Tablo 6'da sunulmuştur.

**Tablo 6: Uzun Dönem USD/TL ve EUR/TL Döviz Kurları Tanımlayıcı İstatistikleri**

|                       | USD/TL               | EUR/TL               |
|-----------------------|----------------------|----------------------|
| <b>Ortalama</b>       | 5,1127               | 5,7778               |
| <b>Medyan</b>         | 1,8086               | 2,3800               |
| <b>Maksimum</b>       | 34,1538              | 38,1714              |
| <b>Minimum</b>        | 0,6730               | 0,6229               |
| <b>Standart Sapma</b> | 7,2540               | 7,7754               |
| <b>Skewness</b>       | 2.5489               | 2,5550               |
| <b>Kurtosis</b>       | 8,7937               | 8,9355               |
| <b>Jarque-Bera</b>    | 15300.75<br>[0.0000] | 15760.09<br>[0.0000] |
| <b>Gözlem Sayısı</b>  | 6166                 | 6166                 |

1 Şubat 2001-04 Ekim 2024 dönemine ait USD/TL ve EUR/TL döviz kuru serilerine ait tanımlayıcı istatistikler, döviz kuru serilerinde önemli dalgalanmaların yaşandığını göstermektedir. Her iki döviz kuru serisi için de medyan değerleri ortalama değerlerden oldukça küçüktür. Bu durum, döviz kuru değerlerinin uzun zaman boyunca düşük seviyelerde seyrettiğini, artışların son yıllarda meydana geldiğini göstermektedir. Ayrıca yüksek standart sapma değerleri, döviz kurlarında ani ve şiddetli değişimlerin yaşandığını teyit etmektedir. Pozitif skewness (çarpıklık) değerleri ve 3'ten büyük kurtosis (basıklık) değerleri, dağılımın sağa çarpık ve sivri olduğunu işaret etmektedir. Serilerin normal dağılım özelliği gösterip göstermediğini test eden Jarque-Bera istatistiği ise her iki döviz kuru serisinin dağılımının normalden önemli ölçüde saptığını ortaya koymaktadır. Veri setinden elde edilen bu bilgiler, döviz kurlarının dalgalı yapısını ortaya koyarak derin öğrenme modellerinin performansını değerlendirme sürecine önemli katkı sağlamaktadır. Bu doğrultuda çalışmada kurulan 32 farklı derin öğrenme modeliyle döviz kuru serilerinin uzun vadeli değerlerini ne ölçüde tahmin edebildiği araştırılmıştır. Aşağıda, USD/TL ve EUR/TL döviz kuru serilerine ait uzun vadeli tahmin sonuçları detaylı olarak incelenmiştir.

#### **4.1.1. USD/TL İin Uzun Vadeli Sonular**

USD/TL dvız kuru iin uzun vadeli analiz, 2001-2024 yıllarını kapsayan bir inceleme dnemi olarak ele alınmıřtır. Bu dnemde Trkiye ekonomisinde esnek dvız kuru sistemine geilmiř, ekonomi politikasında birtakım yapısal deėiřiklikler yařanmıřtır. Ortaya ıkan bu geliřmeler ıřıėında derin ėrenme yntemlerinin USD/TL dvız kuru seviyesini ne derece tahmin edebildiėi 32 farklı derin ėrenme modeli kurularak tahmin edilmiřtir. Bu doėrultuda uygulanan 32 farklı modele ait test seti sonuları Tablo 7’de sunulmuřtur.

**Tablo 7: USD/TL Uzun Vadeli Sonuçlar**

| Sıralama | Model Adı       | MSE     | MAE    | RMSE   | R2    |
|----------|-----------------|---------|--------|--------|-------|
| 1        | CNN/Bi-LSTM (2) | 0,2366  | 0,2807 | 0,4864 | 99,73 |
| 2        | CNN/Bi-GRU (2)  | 0,2867  | 0,2710 | 0,5354 | 99,68 |
| 3        | CNN/Bi-LSTM (4) | 0,2935  | 0,2914 | 0,5417 | 99,67 |
| 4        | CNN/Bi-LSTM (3) | 0,3227  | 0,3235 | 0,5681 | 99,64 |
| 5        | CNN/Bi-GRU (3)  | 0,3518  | 0,3316 | 0,5931 | 99,60 |
| 6        | CNN/GRU (3)     | 0,3606  | 0,3140 | 0,6005 | 99,59 |
| 7        | CNN/GRU (2)     | 0,4483  | 0,3649 | 0,6695 | 99,49 |
| 8        | CNN/LSTM (2)    | 0,4795  | 0,3829 | 0,6925 | 99,46 |
| 9        | CNN/LSTM (3)    | 0,5116  | 0,4759 | 0,7152 | 99,42 |
| 10       | GRU (3)         | 0,5403  | 0,4782 | 0,7351 | 99,39 |
| 11       | CNN/LSTM (4)    | 0,8409  | 0,5870 | 0,9170 | 99,05 |
| 12       | LSTM (2)        | 0,8985  | 0,6204 | 0,9478 | 98,99 |
| 13       | CNN/LSTM (1)    | 0,9552  | 0,6421 | 0,9773 | 98,92 |
| 14       | Bi-GRU (1)      | 0,9834  | 0,6158 | 0,9917 | 98,89 |
| 15       | Bi-LSTM (2)     | 1,2418  | 0,6156 | 1,1143 | 98,60 |
| 16       | CNN/Bi-GRU (4)  | 1,3773  | 0,8514 | 1,1736 | 98,44 |
| 17       | CNN/Bi-LSTM (1) | 2,0124  | 1,0456 | 1,4185 | 97,73 |
| 18       | LSTM (1)        | 2,0665  | 0,8747 | 1,4375 | 97,67 |
| 19       | GRU (2)         | 2,6765  | 1,0530 | 1,6360 | 96,98 |
| 20       | CNN/GRU (4)     | 2,7942  | 1,2700 | 1,6716 | 96,85 |
| 21       | GRU (1)         | 3,053   | 1,1176 | 1,7472 | 96,55 |
| 22       | CNN/Bi-GRU (1)  | 3,8786  | 1,4180 | 1,9694 | 95,62 |
| 23       | Bi-GRU (3)      | 5,8033  | 1,4553 | 2,4090 | 93,45 |
| 24       | GRU (4)         | 7,8156  | 1,6410 | 2,7956 | 91,18 |
| 25       | Bi-GRU (2)      | 9,4419  | 1,8325 | 3,0727 | 89,34 |
| 26       | CNN/GRU (1)     | 10,0665 | 2,3350 | 3,1727 | 88,64 |
| 27       | LSTM (3)        | 13,5961 | 2,1936 | 3,6872 | 84,65 |
| 28       | Bi-LSTM (1)     | 15,5445 | 2,3271 | 3,9426 | 82,45 |
| 29       | Bi-GRU (4)      | 18,9312 | 2,4688 | 4,3510 | 78,63 |
| 30       | LSTM (4)        | 27,7166 | 3,2267 | 5,2646 | 68,71 |
| 31       | Bi-LSTM (3)     | 38,7774 | 3,9148 | 6,2271 | 56,22 |
| 32       | Bi-LSTM (4)     | 62,706  | 4,9565 | 7,9187 | 29,21 |


USD/TL döviz kuru için uzun vadeli analizde 8 farklı model ailesine sahip toplamda 32 modelin performansı değerlendirilmiştir. Model başarı performansında MSE, MAE, RMSE ve  $R^2$  gibi temel metrikler kullanılmış, başarı sıralaması RMSE kriterine göre yapılmıştır. Sonuçlar evrişim katmanı ve çift yönlü yapı ile donatılmış CNN/Bi-LSTM ve CNN/Bi-GRU modellerinin ilk beş sırada yer aldığını, hata metrik değerleri dikkate alındığında bu modellerin diğer modellere kıyasla daha üstün bir performans gösterdiğini ortaya koymaktadır.

En başarılı model olan CNN/Bi-LSTM (2) modeli ilk katmanında 32 filtre, ikinci katmanın 64 nöronun kullanıldığı model yapısıdır. CNN/Bi-LSTM (2) modeli, MSE 0,2366, MAE 0,2807 ve RMSE 0,4864 değerleri ile en düşük hata metriklerine ve %99,73  $R^2$  değeri ile en yüksek açıklama katsayısı değerlerine sahiptir. Yine benzer şekilde ilk katmanında 32 filtre, ikinci katmanında 64 nöronun bulunduğu CNN/Bi-GRU (2) modeli %99,68'lik açıklama katsayı değerine ulaşmış, hata metriklerinde de başarılı sonuçlar elde etmiştir. İlk beş modele ait metrik değerleri değerlendirildiğinde, CNN tabanlı hibrit modellerin uzun vadeli kur tahminlerinde hem yerel hem de zamansal bağımlılıkları yakalamada başarılı sonuçlar ürettiği görülmektedir. Yerel bağımlılıklar, döviz kuru hareketlerindeki kısa vadeli trendler (örneğin, döviz kuru bir hafta boyunca artış gösteriyorsa bu artışın devam etme olasılığı nispeten daha yüksektir, çünkü önceki hareketler doğrudan bir sonraki döneme etki edebilir) ve ani dalgalanmalar gibi kısa süreli örüntüleri ifade eder. CNN katmanları bu tür yerel bağımlılıkları öğrenerek ekonomik olayların (faiz değişikliği, MB açıklamaları gibi) etkisini hızlı bir şekilde yakalayarak ve dalgalanmaları doğru şekilde tahmin edebilmektedir. Zamansal bağımlılıklar, geçmişten gelen ekonomik olayların etkileri (2008 Küresel Finans Krizi gibi büyük ekonomik bir olay uzun zaman süren bir etki yaratabilir) ve mevsim etkileri (örneğin turizm sezonu sonrası) gibi uzun vadeli etkilerin gelecekteki döviz kuru değerleri üzerindeki etkisini göstermektedir. Bi-LSTM ve Bi-GRU katmanları uzun vadeli kur hareketlerini etkileyen bu tür yapısal faktörleri öğrenerek uzun vadeli trendleri doğru şekilde yansıtmaktadır. Bu nedenle CNN/Bi-LSTM ve benzer hibrit modeller, kısa vadeli ani dalgalanmalardan uzun vadeli ekonomik trendlere kadar geniş bir yelpazede yerel ve zamansal bağımlılıkları başarıyla öğrenerek döviz kuru tahminlerinde yüksek doğruluk sağlamaktadır.

Sıralamanın sonlarında yer alan modeller değerlendirildiğinde hata metrik değerlerinin yükseldiği ve  $R^2$  değerinin düştüğü ve modeller arasındaki farkın belirgin bir şekilde kötüleştiği dikkat çekmektedir. Bu durum uzun vadeli tahmin modellerinin

performans kaybı sorununa açık olduđu, bu nedenle de model belirlemede uygun yapının seçilmesinin önem taşıdığını ortaya koymaktadır.

Bununla birlikte, en başarılı on modelin eğitim ve test seti üzerindeki performansları aşağıdaki grafikte sunulmuştur. Grafikler en yüksek başarıya sahip ve belirgin farkla öne çıkan ilk on model performansına bağlı olarak düzenlenmiştir. Bu durum, model başarısını göstermek için faydalı olacaktır.



**Şekil 19: USD/TL Uzun Vadeli Sonuçlar**

Şekil 19'da yer alan grafikler en başarılı on modelin eğitim ve test verisi üzerindeki performanslarını göstermektedir. Modellerin öğrenme kapasitesi ve genelleme yeteneğini değerlendirmek için orijinal veri ile tahmin değerleri arasındaki farklar önemli bilgiler sunmaktadır. Grafiklerde eğitim seti tahminleri kırmızı renk, test seti tahminleri siyah renk ve orijinal veriler mavi renk ile temsil edilmektedir.

Eğitim seti için yapılan tahminlerde genellikle kırmızı çizgiyle temsil edilen eğitim tahminlerinin orijinal veriye (mavi) yakın olduğu görülmektedir. İki değer arasındaki yakınlık, modelin veri setine uyum sağlama konusunda başarılı sonuçlar ürettiğini göstermektedir. Test tahminleri ile orijinal veri arasındaki yakınlık incelendiğinde ise özellikle CNN/Bi-LSTM (2) modeliyle CNN/Bi-GRU (2) modelinin genelleme kapasitesinin yüksekliği göze çarpmaktadır. Bu modeller diğer modellere kıyasla en düşük hata metriklerine ve  $R^2$  değerlerine sahiptir. Bu durum modellerin gelecekteki veriler üzerinde tutarlı tahminler yapabileceğini göstermektedir.

Başarı sırası düştükçe modellerin test seti üzerindeki tahminlerinde bir bozulma yaşandığı ve hata metrik değerlerinde artış olduğu gözlemlenmektedir. Bu durum, uzun vadeli tahmin problemlerinde model genelleme yeteneğinin sınırlandığını ve model seçiminde dikkatli bir yaklaşımın gerekliliğini ortaya koymaktadır. Modellerde yaşanan bu sorunun ana kaynağı, eğitim ve test setleri arasındaki farklılıklardır. Özellikle döviz kuru serilerinde eğitim setindeki verilerin test setindeki verilerden eğilim ve yapısal değişimler sonucu farklılaşması, modeller arasındaki bozulmayı açıklamaktadır. Analiz edilen 2001-2024 döneminin özellikle son yıllarında yaşanan döviz kuru dalgalanmaları bu duruma örnek olarak gösterilebilir. Bu durum modelin yeni yapıya uyum sağlamasını zorlaştırırken, test seti hatalarını artırmaktadır.

Özetle, uzun vadeli USD/TL tahmin sonuçları, CNN/Bi-LSTM ve CNN/Bi-GRU modellerinin uzun vadeli trendleri yakalamasının yanı sıra kısa vadeli dalgalanmaları da doğru şekilde yakaladığını göstermektedir. Ancak diğer modellerin başarı sırasının önemli oranda azalıyor olması test tahminleri uyumunun azaldığını, bu nedenle de model seçiminin çok daha önemli bir hal aldığını ortaya koymaktadır.

#### 4.1.2. EUR/TL İçin Uzun Vadeli Sonuçlar

Uzun vadeli analiz için seçilen 1 Şubat 2001-04 Ekim 2024 döneminde EUR/TL döviz kurunda önemli değişimler yaşanmıştır. İlgili dönemde, Türkiye'de esnek kur sistemine geçilmiş, döviz piyasaları daha dinamik hale gelmiştir. Bu sebeple modellerin

uzun vadeli kur seviyelerini ne derecede yakalayabildiđi arařtırılmak istenmiřtir. Bu dođrultuda uygulanan 32 farklı modele ait test seti sonuçları Tablo 8’de sunulmuřtur.


**Tablo 8: EUR/TL Uzun Vadeli Sonuçlar**

| Sıralama | Model Adı       | MSE     | MAE    | RMSE   | R2    |
|----------|-----------------|---------|--------|--------|-------|
| 1        | CNN/Bi-LSTM (2) | 0,3519  | 0,3574 | 0,5932 | 99,65 |
| 2        | CNN/Bi-GRU (4)  | 0,4536  | 0,3984 | 0,6735 | 99,55 |
| 3        | CNN/GRU (3)     | 0,5158  | 0,4323 | 0,7182 | 99,49 |
| 4        | CNN/Bi-LSTM (3) | 0,5644  | 0,4615 | 0,7512 | 99,44 |
| 5        | CNN/Bi-GRU (3)  | 0,5695  | 0,4571 | 0,7546 | 99,43 |
| 6        | Bi-LSTM (2)     | 0,6123  | 0,5667 | 0,7824 | 99,39 |
| 7        | CNN/LSTM (2)    | 0,7051  | 0,5002 | 0,8397 | 99,30 |
| 8        | LSTM (2)        | 0,8598  | 0,6132 | 0,9272 | 99,14 |
| 9        | CNN/LSTM (3)    | 0,8826  | 0,6328 | 0,9394 | 99,12 |
| 10       | GRU (3)         | 0,9778  | 0,6993 | 0,9886 | 99,02 |
| 11       | Bi-GRU (1)      | 1,0337  | 0,6294 | 1,0167 | 98,97 |
| 12       | CNN/Bi-LSTM (4) | 1,2890  | 0,8010 | 1,1353 | 98,71 |
| 13       | CNN/Bi-LSTM (1) | 1,7506  | 0,9502 | 1,3231 | 98,25 |
| 14       | CNN/GRU (2)     | 1,7569  | 0,9122 | 1,3254 | 98,25 |
| 15       | CNN/LSTM (4)    | 1,8745  | 0,9833 | 1,3691 | 98,13 |
| 16       | LSTM (1)        | 2,2975  | 0,9153 | 1,5157 | 97,71 |
| 17       | CNN/Bi-GRU (2)  | 2,4933  | 1,1230 | 1,579  | 97,51 |
| 18       | GRU (2)         | 3,6849  | 1,2206 | 1,9196 | 96,32 |
| 19       | GRU (1)         | 3,7898  | 1,2297 | 1,9467 | 96,22 |
| 20       | CNN/LSTM (1)    | 4,1295  | 1,5296 | 2,0321 | 95,88 |
| 21       | CNN/Bi-GRU (1)  | 5,8849  | 1,7378 | 2,4258 | 94,13 |
| 22       | Bi-GRU (3)      | 7,6957  | 1,7245 | 2,7741 | 92,32 |
| 23       | Bi-LSTM (1)     | 9,0142  | 1,6608 | 3,0023 | 91,01 |
| 24       | GRU (4)         | 9,2046  | 1,7284 | 3,0339 | 90,82 |
| 25       | CNN/GRU (1)     | 10,1672 | 2,3535 | 3,1886 | 89,86 |
| 26       | Bi-GRU (2)      | 10,8546 | 1,9212 | 3,2946 | 89,17 |
| 27       | LSTM (3)        | 13,0755 | 2,0766 | 3,616  | 86,95 |
| 28       | CNN/GRU (4)     | 15,0972 | 2,8539 | 3,8855 | 84,94 |
| 29       | Bi-GRU (4)      | 23,3689 | 2,7152 | 4,8341 | 76,68 |
| 30       | LSTM (4)        | 32,8291 | 3,4509 | 5,7296 | 67,25 |
| 31       | Bi-LSTM (3)     | 43,124  | 4,1248 | 6,5668 | 56,97 |
| 32       | Bi-LSTM (4)     | 70,5726 | 5,2752 | 8,4007 | 29,59 |

Tablo 8’de yer alan bilgiler çerçevesinde, EUR/TL döviz kuruna ait uzun vadeli tahmin modellerinde en başarılı model CNN/Bi-LSTM (2) olmuştur. CNN/Bi-LSTM (2) modeli MSE (0,3519), MAE (0,3574), RMSE (0,5932) ve  $R^2$  (%99,65) değeriyle diğer modellere kıyasla daha üstün bir performans göstermiştir. Düşük MSE, MAE, RMSE ve yüksek  $R^2$  değerleri, modelin tahminlerdeki hata oranının oldukça düşük olduğunu, gerçek verilere yakın sonuçlar ürettiğini göstermektedir. İkinci sırada yer alan CNN/Bi-GRU (4) modeli de benzer şekilde düşük hata metrikleri (MSE: 0,4536, MAE: 0,3984, RMSE: 0,6735) ve yüksek  $R^2$  (%99,55) değeriyle önemli bir tahmin başarısı gerçekleştirmiştir. Yüksek başarı yakalayan bu modeller, CNN ve çift yönlü yapının kombinasyonlarının uzun vadeli tahminlerde güçlü sonuçlar ürettiğini göstermektedir.

Tablonun alt sıralarında yer alan modeller incelendiğinde ise hata metriklerinin arttığı  $R^2$  değerinin düştüğü görülmektedir. Dolayısıyla bu modellerin yaptığı tahminlerin gerçek değerler ile ciddi oranda sapma gösterdiği yorumu yapılabilir. Bu sonucun ortaya çıkmasında temel neden USD/TL döviz kuru uzun vadeli tahmin sonuçlarında olduğu gibi eğitim ve test seti arasındaki yapısal farklılıklardır. Eğitim seti ile test seti arasındaki eğilim ve dalgalanma farklılıkları bazı modellerin genel uyum oranının azalmasına yol açmıştır.

Model başarısını daha iyi görebilmek için en başarılı modellerin eğitim ve test seti üzerindeki performanslarının grafik üzerinde incelenmesi modellerin genelleme kabiliyetini değerlendirmek adına katkı sağlayacaktır. Bu sebeple aşağıda yer alan Şekil 20 belirgin farkla en yüksek başarıya sahip ilk on modele ait grafikleri göstermektedir.



Şekil 20: EUR/TL Uzun Vadeli Sonuçlar

Şekil 20, EUR/TL döviz kuru uzun vadeli tahminler için en başarılı on modelin tahmin performanslarını göstermektedir. Genel bir değerlendirme yapmak gerekirse, tüm modellerin hem eğitim hem de test seti tahminlerinde önemli uyum oranı yakaladığı görülmektedir. Eğitim setindeki tahminler (kırmızı çizgi) ve test seti tahminleri (siyah çizgi), orijinal verilere (mavi çizgi) oldukça yakın seyretmiş, özellikle CNN tabanlı Bi-LSTM ve Bi-GRU kombinasyonları diğer modellere kıyasla daha yüksek doğruluğa ulaşmıştır. Bu modeller karmaşık yapıların bulunduğu veri setinde kısa ve uzun vadeli bağımlılıkları yakalamada yüksek bir başarı sağlamıştır.

Test verisi tahminlerine odaklanıldığında, geleneksel LSTM ve GRU modellerinde eğitim verisine kıyasla birtakım sapmalar olduğu görülmektedir. Ancak bu farklar uzun vadeli tahminler için kabul edilebilir seviyededir. Genel olarak en başarılı ilk on modelin EUR/TL tahminlerinde %99 ve üzeri  $R^2$  değerleri ile güçlü bir performans göstermiştir.

Özetlemek gerekirse EUR/TL uzun vadeli tahmin sonuçları, CNN tabanlı ve genellikle çift yönlü modellerin hem kısa hem de uzun vadeli trendleri doğru bir şekilde yakaladığını, modellerin genelleme yeteneğinin yüksek olduğunu göstermektedir. Test ve eğitim setleri arasındaki yapısal farklılıklar bazı modellerin genelleme kabiliyetinin azalmasına neden olsa da tahmin sonuçları uzun vadeli dönem için kabul edilebilir seviyede gerçekleşmiştir. Bu sonuçlar, uzun vadeli tahminlere ait model seçiminin kritik öneme sahip olduğunu ortaya koymaktadır.

Uzun vadeli analizlerde, CNN tabanlı hibrit modellerin daha dengeli ve tutarlı bir performans gösterdiği açıkça görülmektedir. Bu doğrultuda, bu modellerin oluşturduğu projeksiyonlar temel alınarak 3-5 yıllık döviz kuru tahminleri geliştirilebilir. Söz konusu projeksiyonlar, kamu borçlanma stratejilerinin optimize edilmesinde kullanılabilir ve döviz cinsi borçlanmalara yönelik daha öngörülebilir bir planlama yapılmasını sağlayabilir. Ayrıca, uzun vadeli analizlerde kur oynaklığının ithalat ve ihracat üzerindeki etkileri dikkate alınarak, kamu teşvik politikaları bu projeksiyonlara dayandırılabilir. Özellikle, döviz kazandırıcı sektörlerle yönelik teşviklerin etkinliği artırılabilir ve ithalat bağımlılığını azaltacak sanayi politikaları daha stratejik bir şekilde oluşturulabilir.

#### 4.2. Orta Vadeli Sonuçlar

Çalışmada seçilen orta vadeli analiz dönemi, 1 Ocak 2010 ile 04 Ekim 2024 arasındaki dönemi kapsamaktadır. Bu dönem, TCMB'nin hem enflasyon hedeflemesi

hem de finansal istikrar politikasını uyguladığı yılları içermektedir. İlgili dönemde döviz kurları, küresel ekonomik gelişmeler, yerel ekonomik koşullar ve iç ve dış finansal şoklardan doğrudan etkilenmiştir.

Küresel ekonomik gelişmeler döviz kuru hareketlerini etkileyen en önemli faktörlerden biridir. Özellikle FED ve ECB gibi büyük merkez bankalarının politikaları döviz kurları üzerinde doğrudan etki bırakmaktadır. Örneğin 2013 yılında FED'in varlık alım programını kademeli olarak azaltması gelişmekte olan ülkelere yönelik sermaye akımlarını etkilemiş, bu durum döviz kurları üzerinde baskı yaratmıştır. Ayrıca analiz döneminde ortaya çıkan COVID-19 pandemisi ekonomik faaliyetlerin yavaşlamasına neden olmuştur. Küresel petrol fiyatlarındaki dalgalanmalar da döviz kuru hareketlerini etkilemiştir.

Yerel ekonomik koşullar da döviz kurlarını doğrudan etkileyen faktörlerden biridir. Enflasyon oranları, dış ticaret açığı, büyüme oranları gibi makroekonomik göstergeler döviz kurları üzerinde baskı oluşturmaktadır. Özellikle yüksek cari açık, döviz talebini artırarak yerel para biriminin değer kaybetmesine neden olmaktadır. Bunlara ek olarak özellikle son yıllarda meydana gelen iç ve dış şoklar (15 Temmuz darbe girişimi, Brunson Krizi, 2018 FED faiz artırımını gibi) Türkiye ekonomisinde döviz piyasalarını doğrudan etkilemiş, döviz kurlarındaki volatilitiyi artırmıştır.

Bu bilgiler doğrultusunda, orta vadeli analiz dönemindeki döviz kuru hareketlerini daha iyi anlayabilmek için döviz kuru serilerine ait tanımlayıcı istatistikler Tablo 9'da sunulmuştur. Bu bilgiler, döviz kuru serilerinin dönem içerisindeki davranışını anlamak ve model performansını daha iyi değerlendirebilmek için önemli bir temel sağlayacaktır.

**Tablo 9: Orta Vadeli Dönem USD/TL ve EUR/TL Döviz Kurları Tanımlayıcı İstatistikleri**

|                       | USD/TL  | EUR/TL  |
|-----------------------|---------|---------|
| <b>Ortalama</b>       | 7,3600  | 8,2436  |
| <b>Medyan</b>         | 3,5609  | 3,9647  |
| <b>Maksimum</b>       | 34,1538 | 38,1714 |
| <b>Minimum</b>        | 1,3884  | 1,8939  |
| <b>Standart Sapma</b> | 8,4319  | 8,9952  |
| <b>Skewness</b>       | 1,8397  | 1,8641  |
| <b>Kurtosis</b>       | 5,3206  | 5,4847  |
| <b>Jarque-Bera</b>    | 3027,78 | 3211,95 |
| <b>Gözlem Sayısı</b>  | 3840    | 3840    |

Orta vadeli analiz döneminde USD/TL ve EUR/TL döviz kurlarına ait tanımlayıcı istatistikler değerlendirildiğinde medyan değerlerin ortalama değerlerden küçük olduğu, dolayısıyla kurların çoğunlukla düşük seviyelerde yoğunlaştığını, dönemsel olarak dalgalanmaların yaşandığını göstermektedir. Her iki döviz kuru serisi için standart sapma değerleri yüksek volatilitiyi işaret etmektedir. Ayrıca skewness (çarpıklık) ve kurtosis (basıklık) değerleri, kurların sağa çarpık ve uç değerlerin daha sık olduğu bir dağılım yapısına sahip olduğunu göstermektedir. Son olarak Jarque-Bera test sonuçları, döviz kuru serilerinin normal dağılımdan sapma gösterdiğini ortaya koymaktadır. Bu bilgiler neticesinde, döviz kuru hareketlerinin bu faktörlerden ne yönde etkilendiği kurulan 32 farklı derin öğrenme modeli ile incelenmek istenmiştir. Çalışmada, bu modellerin döviz kuru hareketlerini tahmin etme yetenekleri hem kısa vadeli dalgalanmaları hem de uzun vadeli trendleri anlamaya yönelik olarak detaylı bir şekilde değerlendirilecektir.

#### 4.2.1. USD/TL İçin Orta Vadeli Sonuçlar

Enflasyon hedeflemesi ve finansal istikrar politikalarının birlikte kullanıldığı orta vadeli analiz döneminde USD/TL döviz kurunu incelemek amacıyla kurulan 32 farklı derin öğrenme modeline ait test seti sonuçları Tablo 10'da sunulmuştur.


**Tablo 10: USD/TL Orta Vadeli Sonuçlar**

| Sıralama | Model Adı       | MSE     | MAE    | RMSE   | R2    |
|----------|-----------------|---------|--------|--------|-------|
| 1        | CNN/Bi-LSTM (2) | 0,4467  | 0,3679 | 0,6683 | 99,40 |
| 2        | CNN/Bi-LSTM (3) | 0,5257  | 0,3913 | 0,7250 | 99,30 |
| 3        | CNN/Bi-GRU (3)  | 0,5586  | 0,4308 | 0,7474 | 99,25 |
| 4        | Bi-GRU (2)      | 0,5822  | 0,4055 | 0,7630 | 99,22 |
| 5        | CNN/Bi-LSTM (4) | 0,6165  | 0,4715 | 0,7851 | 99,17 |
| 6        | CNN/Bi-LSTM (1) | 0,6999  | 0,5212 | 0,8366 | 99,06 |
| 7        | CNN/LSTM (2)    | 0,7076  | 0,5280 | 0,8412 | 99,05 |
| 8        | CNN/LSTM (3)    | 0,7267  | 0,4551 | 0,8524 | 99,03 |
| 9        | GRU (2)         | 0,8308  | 0,6889 | 0,9115 | 98,89 |
| 10       | Bi-GRU (1)      | 0,8492  | 0,5735 | 0,9215 | 98,86 |
| 11       | CNN/LSTM (1)    | 1,0572  | 0,7194 | 1,0282 | 98,58 |
| 12       | CNN/LSTM (4)    | 1,0877  | 0,7318 | 1,0429 | 98,54 |
| 13       | CNN/Bi-GRU (2)  | 1,1991  | 0,8481 | 1,095  | 98,39 |
| 14       | CNN/GRU (3)     | 1,3447  | 0,9046 | 1,1596 | 98,2  |
| 15       | Bi-LSTM (2)     | 1,3937  | 0,8438 | 1,1805 | 98,13 |
| 16       | CNN/GRU (2)     | 1,786   | 1,091  | 1,3364 | 97,6  |
| 17       | LSTM (2)        | 1,8326  | 0,9347 | 1,3537 | 97,54 |
| 18       | CNN/Bi-GRU (4)  | 1,8787  | 1,1398 | 1,3706 | 97,48 |
| 19       | Bi-GRU (3)      | 2,1985  | 1,1768 | 1,4827 | 97,05 |
| 20       | GRU (3)         | 2,391   | 1,2362 | 1,5463 | 96,79 |
| 21       | CNN/Bi-GRU (1)  | 3,0557  | 1,4702 | 1,748  | 95,9  |
| 22       | LSTM (1)        | 3,4776  | 1,329  | 1,8648 | 95,34 |
| 23       | CNN/GRU (1)     | 3,7477  | 1,6824 | 1,9359 | 94,97 |
| 24       | GRU (1)         | 5,1923  | 1,675  | 2,2786 | 93,04 |
| 25       | CNN/GRU (4)     | 5,2077  | 1,9897 | 2,282  | 93,02 |
| 26       | Bi-LSTM (1)     | 5,4464  | 1,6584 | 2,3337 | 92,7  |
| 27       | GRU (4)         | 7,4931  | 2,0415 | 2,7373 | 89,95 |
| 28       | Bi-GRU (4)      | 11,0196 | 2,3725 | 3,3195 | 85,22 |
| 29       | LSTM (3)        | 14,2911 | 2,9352 | 3,7803 | 80,84 |
| 30       | LSTM (4)        | 15,1396 | 2,8924 | 3,8909 | 79,7  |
| 31       | Bi-LSTM (3)     | 22,4813 | 3,5006 | 4,7414 | 69,85 |
| 32       | Bi-LSTM (4)     | 41,7051 | 4,8512 | 6,4579 | 44,08 |

Tablo 10, USD/TL döviz kuru orta vadeli (1 Ocak 2010-04 Ekim 2024) tahmin modellerine ait sonuçları göstermektedir. Tabloda yer alan bilgilere göre CNN/Bi-LSTM (2) modeli MSE (0,4467), MAE (0,3679), RMSE (0,6683) ve  $R^2$  (%99,40) değerleri ile tüm modeller arasında en yüksek doğruluğa sahip olmuştur. Metrik değerleri CNN/Bi-LSTM (2) modelinin eğitim ve test seti tahminlerinde hata oranının düşük, açıklama oranının oldukça yüksek olduğunu göstermektedir. İkinci ve üçüncü sırada yer alan CNN/Bi-LSTM (3) ve CNN/Bi-GRU (3) modelleri de benzer şekilde güçlü sonuçlar üretmiştir. Tahmin sonuçlarına göre ilk onda yer alan yedi model CNN tabanlı hibrit modellerden, geriye kalan üç model ise geleneksel derin öğrenme modelleri Bi-GRU ve GRU modellerinin farklı nöron sayısı kombinasyonlarından oluşmaktadır. Bu durum hibrit model yapılarının kısa ve uzun vadeli bağımlılıkları öğrenme konusunda daha başarılı sonuçlar verdiğini göstermektedir.

Son sıralarda yer alan modeller değerlendirildiğinde ise, Bi-LSTM ve LSTM modellerinin hata metrik değerlerinin büyük,  $R^2$  değerlerinin ise düşük olduğu dikkat çekmektedir. Bu durum, model tahminlerinin zayıf olduğunu, USD/TL döviz kurunun karmaşık yapısını çözmekte yetersiz kaldığını göstermektedir.

Genel olarak, CNN ile entegre edilmiş Bi-LSTM ve Bi-GRU hibrit modellerinin %99 ve üzeri  $R^2$  değeri ürettiği bu nedenle de diğer modellere kıyasla daha üstün sonuçlar ürettiği sonucuna ulaşılmaktadır. Bu sonuç, geleneksel derin öğrenme modellerine kıyasla hibrit modellerin kısa ve uzun vadeli bağımlılıkları yakalamada daha başarılı sonuçlar ürettiğini, model seçiminde bu tür öğrenme kabiliyeti yüksek modellerin uygulanması gerektiğini göstermektedir. Aşağıda yer alan Şekil 21’de yüksek başarı oranına sahip on modelin tahmin sonuçları grafikler üzerinde gösterilerek, bu modellerin genel uyum kabiliyeti incelenmiştir.



Şekil 21: USD/TL Orta Vadeli Sonuçlar

Şekil 21, USD/TL döviz kuru serisi için orta vadeli (1 Ocak 2010-04 Ekim 2024) analizde en iyi performans gösteren on modele ait eğitim ve test tahmin sonuçlarını göstermektedir. Modellere ait genel performans değerlendirildiğinde CNN/Bi-LSTM ve CNN/Bi-GRU hibrit modellerinin eğitim setindeki veriyi çok iyi öğrendiği ve bu bilgileri test seti üzerinde başarılı bir şekilde uyguladığı görülmektedir. Özellikle CNN/Bi-LSTM (2) ve CNN/Bi-LSTM (3) modelleri test tahminleri (siyah çizgi) orijinal veri (mavi çizgi) ile oldukça uyumludur. Bu durum modellerin genelleme kabiliyetinin diğer modellere kıyasla daha yüksek olduğunu göstermektedir. Şekil 21, özellikle GRU (2) ve Bi-GRU (1) modellerinde eğitim tahminlerindeki başarı oranının test tahmininde azaldığı, bu sebeple genelleme başarısının hibrit modellere kıyasla geride kaldığını ortaya çıkarmaktadır. Diğer bir deyişle, CNN tabanlı çift yönlü hibrit modellerin geleneksel modellere kıyasla daha tutarlı sonuçlar ürettiği dikkat çekmektedir. Elde edilen sonuçlar, USD/TL gibi karmaşık süreçlerin yaşandığı döviz kuru serisinde hibrit model kullanımının başarısını göz önüne sermektedir.

#### **4.2.2. EUR/TL İçin Orta Vadeli Sonuçlar**

Çalışmada seçilen orta vadeli analiz dönemi, 1 Ocak 2010 ile 04 Ekim 2024 arasındaki süreci kapsamaktadır. Seçilen bu dönemde TCMB, enflasyon hedeflemesiyle birlikte finansal istikrar politikalarını da aktif bir şekilde kullanmaktadır. Döviz kuru hareketlerinin küresel ve yerel dinamikler ve para politikası tarafından etkilendiği bu dönemi incelemek amacıyla 32 farklı derin öğrenme modeli kurulmuştur. Kurulan modellere ait test seti sonuçları Tablo 11’de sunulmuştur.


**Tablo 11: EUR/TL Orta Vadeli Sonuçlar**

| Sıralama | Model Adı       | MSE     | MAE    | RMSE   | R2    |
|----------|-----------------|---------|--------|--------|-------|
| 1        | CNN/Bi-LSTM (2) | 0,6382  | 0,5230 | 0,7989 | 99,24 |
| 2        | CNN/Bi-LSTM (3) | 0,6957  | 0,5544 | 0,8341 | 99,17 |
| 3        | Bi-GRU (2)      | 0,7679  | 0,5698 | 0,8763 | 99,09 |
| 4        | CNN/Bi-LSTM (4) | 0,8082  | 0,5844 | 0,8990 | 99,04 |
| 5        | Bi-GRU (1)      | 0,8455  | 0,5547 | 0,9195 | 98,99 |
| 6        | CNN/GRU (3)     | 0,9046  | 0,6392 | 0,9511 | 98,92 |
| 7        | CNN/LSTM (2)    | 0,9618  | 0,6080 | 0,9807 | 98,86 |
| 8        | CNN/LSTM (3)    | 0,9895  | 0,6338 | 0,9947 | 98,82 |
| 9        | Bi-LSTM (2)     | 1,0219  | 0,6897 | 1,0109 | 98,78 |
| 10       | CNN/Bi-GRU (3)  | 1,0301  | 0,6669 | 1,0149 | 98,77 |
| 11       | LSTM (2)        | 1,3662  | 0,7709 | 1,1688 | 98,37 |
| 12       | GRU (3)         | 1,4351  | 0,8366 | 1,1979 | 98,29 |
| 13       | CNN/Bi-LSTM (1) | 1,4490  | 0,8740 | 1,2037 | 98,28 |
| 14       | CNN/GRU (2)     | 1,5610  | 0,9145 | 1,2494 | 98,14 |
| 15       | GRU (2)         | 1,5834  | 0,9727 | 1,2583 | 98,12 |
| 16       | Bi-GRU (3)      | 1,7232  | 0,9892 | 1,3127 | 97,95 |
| 17       | CNN/Bi-GRU (2)  | 2,0914  | 1,1192 | 1,4462 | 97,51 |
| 18       | CNN/LSTM (4)    | 2,1758  | 1,1599 | 1,475  | 97,41 |
| 19       | CNN/LSTM (1)    | 2,4957  | 1,2795 | 1,5798 | 97,03 |
| 20       | LSTM (1)        | 2,6400  | 1,1163 | 1,6248 | 96,86 |
| 21       | CNN/Bi-GRU (4)  | 3,2900  | 1,4623 | 1,8136 | 96,09 |
| 22       | GRU (4)         | 4,6703  | 1,5164 | 2,1611 | 94,44 |
| 23       | Bi-LSTM (1)     | 5,4023  | 1,5968 | 2,3243 | 93,57 |
| 24       | CNN/Bi-GRU (1)  | 5,4048  | 1,9109 | 2,3248 | 93,57 |
| 25       | GRU (1)         | 6,1056  | 1,7928 | 2,4709 | 92,73 |
| 26       | CNN/GRU (4)     | 6,9884  | 2,2894 | 2,6435 | 91,68 |
| 27       | Bi-GRU (4)      | 9,0840  | 2,0569 | 3,0139 | 89,19 |
| 28       | LSTM (3)        | 10,5712 | 2,4116 | 3,2513 | 87,42 |
| 29       | LSTM (4)        | 10,9320 | 2,3190 | 3,3063 | 86,99 |
| 30       | CNN/GRU (1)     | 17,9461 | 3,5659 | 4,2362 | 78,65 |
| 31       | Bi-LSTM (3)     | 20,8596 | 3,2464 | 4,5672 | 75,18 |
| 32       | Bi-LSTM (4)     | 41,8791 | 4,7187 | 6,4714 | 50,17 |

Tablo 11, EUR/TL döviz kuru için orta vadeli analiz döneminde (1 Ocak 2010-04 Ekim 2024) MSE, MAE, RMSE ve  $R^2$  hata metrikleri aracılığıyla 32 farklı derin öğrenme modeline ait sonuçları göstermektedir. En başarılı model CNN/Bi-LSTM (2) olarak tespit edilmiştir. Model, MSE (0,6382), MAE (0,5230), RMSE (0,7989) ve  $R^2$  (%99,24) değerleri ile en düşük hata ve en yüksek açıklama oranıyla ön plana çıkmaktadır. İkinci sıradaki CNN/Bi-LSTM (3) modeli birinci modele kıyasla daha yüksek hata metriği değerine sahip olsa da benzer şekilde tutarlı sonuçlar üretmiştir.

Orta sıralarda yer alan modeller değerlendirildiğinde CNN/LSTM modelleri benzer hatalarla dikkat çekerken, GRU (3) ve LSTM (2) modelleri CNN/LSTM modellerine kıyasla daha düşük performans sergilemiş, yaklaşık %90-97 aralığında açıklama gücüne ulaşmıştır. Alt sıralardaki modellerde ise Bi-LSTM (4) ve Bi-LSTM (3) modelleri diğer modellere kıyasla yüksek hata metrik değerleri üretmiş, model açıklama gücü zayıf çıkmıştır.

Modellere ait performanslar genel olarak değerlendirildiğinde, CNN tabanlı modellerin Bi-LSTM modeli ile birleştirildiğinde yüksek tahmin performansına sahip olduğu, geleneksel LSTM ve GRU modellerinin bu hibrit modellerin gerisinde kaldığı görülmüştür. Bu durum, hibrit mimarilerin döviz kuru serileri gibi karmaşık veri setlerindeki bağımlılıkları öğrenmede daha etkili olduğunu göstermektedir.



Şekil 22: EUR/TL Orta Vadeli Sonuçlar

Şekil 22, EUR/TL döviz kuru için orta vadeli analiz döneminde (1 Ocak 2010-04 Ekim 2024) en başarılı on modele ait tahmin performans grafiklerini göstermektedir. En başarılı on modelin grafikleri, tahmin performansını daha kapsamlı şekilde değerlendirme imkânı sunmaktadır. Böylece modellerin gerçek verilere uyumları, tahmin kabiliyeti ve sapmanın olduğu tarihleri detaylı olarak göstermesi açısından oldukça önemlidir.

En başarılı model CNN/Bi-LSTM (2) modeli hem test hem de eğitim verisi üzerinde yüksek tahmin doğruluğu sergilemektedir. Model, test veri setinde ani değişimlerin olduğu dönemlerde bile orijinal veri ile uyumlu sonuçlar üretmiştir. CNN/Bi-LSTM (3) ve Bi-GRU (2) modelleri de güçlü tahminler yaparak ilk modele yakın performans sergilemiştir. Şekil 22’de yer alan diğer modeller veri setindeki eğilimlerin genel çerçevesini tahmin etse de test dönemindeki ani değişimleri yakalamada ilk üç model kadar başarı yakalayamamıştır.

Genel olarak geleneksel derin öğrenme modelleri, hibrit modellerle kıyaslandığında daha düşük bir başarı göstermiştir. Özellikle çift yönlü hibrit modeller, yüksek parametrik kapasite ve çift yönlü öğrenme mekanizması sayesinde ani değişimleri daha iyi öngörerek üstün performans sergilemiştir. Bu sonuç, hibrit modellerin kısa ve uzun vadeli dalgalanmaları daha iyi analiz ettiğini, hibrit modellerin geleneksel modellere göre karmaşık veri setlerinde önemli avantajlar barındırdığını göstermektedir.

Orta vadeli analizlerde, CNN tabanlı hibrit modellerin yüksek tahmin başarısı gösterdiği gözlemlenmiştir. Bu modeller, hem küresel hem de yerel piyasa etkilerini tahmin ederek, ortaya çıkabilecek küresel şoklara (örneğin, ECB ve FED’in faiz politikası gibi) karşı olası senaryoların simülasyonunu mümkün kılmaktadır. Ayrıca, elde edilen orta vadeli döviz tahminleri doğrultusunda, faiz oranı değişiklikleri veya swap piyasası müdahaleleri gibi para politikası araçlarının etkileri modellenabilir. Bu sayede, en uygun müdahale senaryosu belirlenerek daha etkin bir politika çerçevesi oluşturulabilir.

#### **4.3. Kısa Vadeli Sonuçlar**

Kısa vadeli dönem, Türkiye ekonomisinde önemli politik ve ekonomik dönüşümlerin yaşandığı bir zaman dilimini kapsamaktadır. 18 Temmuz 2016 tarihinde başlayan ve 04 Ekim 2024’te sona eren bu dönem, 15 Temmuz 2016’daki darbe girişimi ve sonrasında ekonomik dalgalanmaların arttığı süreci temsil etmektedir. Analiz döneminde kur şokları, enflasyonist baskı ve uluslararası gelişmeler gibi çok boyutlu değişkenler ortaya çıkmış, bu faktörler döviz kurlarında ani değişimlere ve volatilitenin

artmasına yol açmıştır. Bu durum, tahmin modellerinin performansını test etmek için uygun bir ortam sağlamıştır. Bu çerçevede, 32 farklı model oluşturulmuş ve USD/TL ile EUR/TL döviz kurları tahmin edilmiştir. Modellerin, ekonomik dalgalanmaların ve belirsizliklerin arttığı bir ortamda genel trendleri yakalama ve ani değişimlere tepki verebilme yetenekleri değerlendirilmiştir. Kısa vadeli analiz dönemine ait tanımlayıcı istatistikler Tablo 12’de sunulmuş olup, döviz kuru serilerindeki dalgalanma ve volatilitenin boyutları ayrıntılı bir şekilde incelenmiştir.

**Tablo 12: Kısa Vadeli Dönem USD/TL ve EUR/TL Döviz Kurları Tanımlayıcı İstatistikleri**

|                       | USD/TL  | EUR/TL  |
|-----------------------|---------|---------|
| <b>Ortalama</b>       | 11,6122 | 12,7769 |
| <b>Medyan</b>         | 7,0732  | 8,4918  |
| <b>Maksimum</b>       | 34,1538 | 38,1714 |
| <b>Minimum</b>        | 2,8834  | 3,2102  |
| <b>Standart Sapma</b> | 9,3308  | 9,9603  |
| <b>Skewness</b>       | 1,1332  | 1,1615  |
| <b>Kurtosis</b>       | 2,9428  | 3,0793  |
| <b>Jarque-Bera</b>    | 457,04  | 480,39  |
| <b>Gözlem Sayısı</b>  | 2134    | 2134    |

Kısa vadeli analiz dönemi için USD/TL ve EUR/TL döviz kuru serilerine ait tanımlayıcı istatistikler, döviz piyasalarında şiddetli dalgalanmaların yaşandığını ortaya koymaktadır. Medyan değerlerin ortalama değerlerden daha düşük olması kurların çoğunlukla düşük seviyelerde yoğunlaştığını, ancak dönem içerisinde şiddetli dalgalanmaların yaşandığını işaret etmektedir. Ayrıca kısa vadeli analiz döneminde maksimum ve minimum değerler arasındaki farkın büyüklüğü yüksek volatilitiyi doğrulamaktadır. Standart sapma değerleri ise her iki döviz kuru serisinde dalgalanmaların oldukça geniş bir aralığa yayıldığını açıkça göstermektedir. Uzun ve orta vadeli analiz dönemi standart sapma değerleri ile kıyaslandığında yine kısa vadeli analiz döneminde dalgalanmaların daha şiddetli olduğunu ortaya koymaktadır. Jarque-Bera test

sonuçları değerlendirildiğinde ise döviz kuru serilerinden normal dağılımdan sapma gösterdiğini ifade etmektedir. Bu bulgular çerçevesinde serilerin kısa vadede yüksek volatilité, sağa çarpıklık ve ani değişimlerle şekillendiğı görülmektedir.

Tanımlayıcı istatistiklerden elde edilen bu bilgiler, döviz kurlarındaki dalgalanmaların ve volatilitenin modellenmesinin önemini ortaya koymaktadır. Bu doğrultuda, kısa vadeli analiz dönemi için USD/TL ve EUR/TL kurlarının dinamiklerini daha iyi anlamak ve öngörebilmek amacıyla oluşturulan 32 farklı derin öğrenme modeline ait sonuçlar aşağıda ayrıntılı bir şekilde incelenmiştir.

#### **4.3.1. USD/TL İçin Kısa Vadeli Sonuçlar**

Çalışmada seçilen orta vadeli analiz dönemi 18 Temmuz 2016-04 Ekim 2024 tarihlerini kapsamaktadır. Bu dönemde, siyasi ve ekonomik gelişmelerin yanı sıra küresel ekonomik gelişmelerin etkisiyle döviz kurları ani dalgalanmalara maruz kalmıştır. Döviz kurlarının bu tür dinamiklerden sıklıkla etkilendiğı bu dönemi incelemek amacıyla 32 farklı derin öğrenme modeli kurulmuş ve analiz edilmiştir. Kurulan modellere ait test seti sonuçları Tablo 13'te sunulmuştur.


**Tablo 13: USD/TL Kısa Vadeli Sonuçlar**

| Sıralama | Model Adı       | MSE    | MAE    | RMSE   | R2    |
|----------|-----------------|--------|--------|--------|-------|
| 1        | GRU (2)         | 0,2138 | 0,2915 | 0,4624 | 99,36 |
| 2        | CNN/GRU (2)     | 0,2159 | 0,2925 | 0,4646 | 99,36 |
| 3        | CNN/GRU (4)     | 0,2340 | 0,2345 | 0,4837 | 99,31 |
| 4        | GRU (3)         | 0,2989 | 0,3963 | 0,5467 | 99,11 |
| 5        | CNN/Bi-GRU (4)  | 0,3436 | 0,3010 | 0,5862 | 98,98 |
| 6        | CNN/LSTM (1)    | 0,3634 | 0,3090 | 0,6028 | 98,92 |
| 7        | CNN/GRU (3)     | 0,3644 | 0,4508 | 0,6036 | 98,92 |
| 8        | CNN/Bi-GRU (3)  | 0,3668 | 0,3199 | 0,6056 | 98,91 |
| 9        | Bi-GRU (3)      | 0,3685 | 0,3028 | 0,6070 | 98,91 |
| 10       | Bi-GRU (2)      | 0,4001 | 0,4369 | 0,6325 | 98,81 |
| 11       | CNN/Bi-GRU (2)  | 0,4018 | 0,3857 | 0,6339 | 98,81 |
| 12       | Bi-GRU (4)      | 0,4250 | 0,3189 | 0,6519 | 98,74 |
| 13       | LSTM (3)        | 0,4262 | 0,3391 | 0,6529 | 98,73 |
| 14       | Bi-LSTM (2)     | 0,4336 | 0,5067 | 0,6585 | 98,71 |
| 15       | Bi-LSTM (3)     | 0,4416 | 0,5265 | 0,6645 | 98,69 |
| 16       | Bi-LSTM (1)     | 0,4516 | 0,3618 | 0,6720 | 98,66 |
| 17       | Bi-GRU (1)      | 0,4554 | 0,3822 | 0,6748 | 98,65 |
| 18       | CNN/Bi-GRU (1)  | 0,4773 | 0,3995 | 0,6908 | 98,58 |
| 19       | LSTM (1)        | 0,5250 | 0,4446 | 0,7245 | 98,44 |
| 20       | LSTM (2)        | 0,5489 | 0,4738 | 0,7408 | 98,37 |
| 21       | CNN/GRU (1)     | 0,5697 | 0,6103 | 0,7548 | 98,31 |
| 22       | CNN/LSTM (4)    | 0,6228 | 0,4806 | 0,7891 | 98,15 |
| 23       | GRU (4)         | 0,6589 | 0,7356 | 0,8117 | 98,04 |
| 24       | CNN/Bi-LSTM (1) | 0,6890 | 0,6386 | 0,8300 | 97,95 |
| 25       | CNN/LSTM (1)    | 0,7111 | 0,6842 | 0,8433 | 97,89 |
| 26       | CNN/Bi-LSTM (3) | 0,8169 | 0,6924 | 0,9038 | 97,57 |
| 27       | CNN/LSTM (2)    | 0,8531 | 0,7705 | 0,9236 | 97,47 |
| 28       | LSTM (4)        | 0,9013 | 0,7045 | 0,9494 | 97,32 |
| 29       | CNN/Bi-LSTM (2) | 0,9430 | 0,8163 | 0,9711 | 97,2  |
| 30       | GRU (1)         | 0,9628 | 0,9084 | 0,9812 | 97,14 |
| 31       | CNN/Bi-LSTM (4) | 1,1235 | 0,9189 | 1,0599 | 96,66 |
| 32       | Bi-LSTM (4)     | 1,2970 | 0,8729 | 1,1388 | 96,15 |

Tablo 13, kısa vadeli analiz döneminde (18 Temmuz 2016-04 Ekim 2024) USD/TL döviz kuru için uygulanan 32 farklı modele ait hata metrik değerlerini göstermektedir. Sonuçlara göre GRU (2) modeli, MSE (0,2138), MAE (0,2955), RMSE (0,4624) ve  $R^2$  (%99,36) gibi oldukça düşük hata değerleri ve yüksek açıklama oranı ile en başarılı model olmuştur. İlk on sıradaki modellerin tamamında hata metrik değerleri düşük, açıklama oranı ise yüksektir. Başarılı modeller sıralamasında GRU modelinin ilk beşte ağırlıkta olduğu görülmektedir. Bu durum, GRU modelinin kısa vadeli analizdeki değişimlere uyum sağlama konusunda güçlü performans sergilediğini göstermektedir.

Tablonun son sıralarındaki modeller değerlendirildiğinde, Bi-LSTM ve CNN/Bi-LSTM tabanlı modeller dikkat çekmektedir. Bu modellerin daha kötü sonuçlar üretmesi, Bi-LSTM modelinin kısa vadeli analizde GRU modeline kıyasla dalgalanmaları yakalamada daha az başarılı olduğunu göstermektedir.

Kısa vadeli analizde en başarılı model ile en kötü model arasındaki  $R^2$  farkı yaklaşık %3,21'dir. Bu değer, orta ve uzun vadeli analizlere göre modeller arasındaki performans farkının oldukça az olduğunu ortaya koymaktadır. Bu durumun nedeni, kısa vadeli analizde eğitim setinde döviz kurundaki ani değişimlerin yer alması olabilir. Böylece, model eğitim setinde genel değişkenliği daha iyi öğrenebilmekte ve test veri setine daha iyi uyum sağlayabilmektedir.



Şekil 23: USD/TL Kısa Vadeli Sonuçlar

Şekil 23'te USD/TL döviz kuru kısa vadeli analiz döneminde en başarılı on modele ait tahmin performanslarını gösteren grafikler yer almaktadır. Grafikler, orijinal veri ile eğitim ve test tahminlerini karşılaştırarak modellerin doğruluğunu görsel açıdan sunmaktadır.

En başarılı on modele ait grafikler incelendiğinde tüm modeller döviz kurundaki genel trendi yakalamayı başarmıştır. Hem eğitim hem de test setlerinde orijinal veriye yakın tahminler yapılmış, modeller kısa vadeli analiz döneminde etkili bir şekilde çalışmıştır. Özellikle GRU (2), CNN/GRU (2) ve CNN/GRU (4) modelleri, eğitim ve test setinde en başarılı sonuçları üretmiştir.

USD/TL döviz kurunda son yıllarda yaşanan ani dalgalanmalara rağmen modeller, değişimleri iyi bir şekilde tahmin edebilmiştir. Özellikle GRU tabanlı modeller kısa vadeli analizlerde etkin tahmin yaparak, ani değişimlere çok iyi adapte olmuştur. Bazı modellerde (CNN/GRU (3), CNN/Bi-GRU (3), Bi-GRU (3) ve Bi-GRU (2)) test setinde orijinal veriden hafif sapmalar yaşandığı görülse de bu durum modellerin tahmin performansı üzerinde ciddi olumsuz bir etki bırakmamıştır.

Genel olarak, kısa vadeli USD/TL döviz kuru analizinde, GRU tabanlı modellerin üstünlüğü açık bir şekilde görülmektedir. Veri seti gereği eğitim setinde ani dalgalanmaların yer alması, modellerin genelleme yeteneğini artırmış, kısa vadeli analizde tüm modeller belli bir aralıkta dengeli performans göstermiştir.

#### **4.3.2. EUR/TL İçin Kısa Vadeli Sonuçlar**

Çalışmada ele alınan kısa vadeli analiz dönemi 18 Temmuz 2016-04 Ekim 2024 tarihleri arasını kapsamaktadır. Bu süreçte döviz kurları siyasi ve ekonomik gelişmelerle birlikte küresel piyasalarında etkisiyle ani değişimlere uğramıştır. Döviz kurlarındaki yüksek oynaklığın daha iyi anlaşılabilmesi için EUR/TL döviz için 32 farklı derin öğrenme modeli uygulanmıştır. Modellere ait test seti sonuçları Tablo 14'te sunulmuştur.


**Tablo 14: EUR/TL Kısa Vadeli Sonuçlar**

| Sıralama | Model Adı       | MSE    | MAE    | RMSE   | R2    |
|----------|-----------------|--------|--------|--------|-------|
| 1        | GRU (2)         | 0,3370 | 0,3978 | 0,5805 | 99,24 |
| 2        | CNN/GRU (2)     | 0,4255 | 0,4045 | 0,6523 | 99,03 |
| 3        | CNN/GRU (3)     | 0,4800 | 0,4641 | 0,6928 | 98,91 |
| 4        | Bi-GRU (2)      | 0,5123 | 0,4664 | 0,7157 | 98,84 |
| 5        | GRU (3)         | 0,5226 | 0,5345 | 0,7229 | 98,81 |
| 6        | CNN/LSTM (3)    | 0,5240 | 0,4568 | 0,7238 | 98,81 |
| 7        | Bi-GRU (3)      | 0,6187 | 0,4857 | 0,7865 | 98,60 |
| 8        | CNN/Bi-GRU (2)  | 0,6332 | 0,4830 | 0,7957 | 98,56 |
| 9        | Bi-LSTM (2)     | 0,6370 | 0,5698 | 0,7981 | 98,55 |
| 10       | CNN/Bi-GRU (3)  | 0,6447 | 0,4967 | 0,8029 | 98,54 |
| 11       | CNN/LSTM (1)    | 0,6557 | 0,5196 | 0,8097 | 98,51 |
| 12       | CNN/LSTM (2)    | 0,7616 | 0,6302 | 0,8727 | 98,27 |
| 13       | CNN/Bi-LSTM (1) | 0,7855 | 0,5721 | 0,8862 | 98,22 |
| 14       | CNN/GRU (4)     | 0,8017 | 0,6803 | 0,8954 | 98,18 |
| 15       | Bi-GRU (4)      | 0,8098 | 0,5776 | 0,8998 | 98,16 |
| 16       | CNN/Bi-LSTM (2) | 0,8536 | 0,6554 | 0,9239 | 98,06 |
| 17       | CNN/Bi-GRU (4)  | 0,8648 | 0,6382 | 0,9299 | 98,04 |
| 18       | CNN/Bi-LSTM (3) | 0,8722 | 0,6272 | 0,9339 | 98,02 |
| 19       | Bi-LSTM (3)     | 0,8952 | 0,7584 | 0,9461 | 97,97 |
| 20       | Bi-LSTM (1)     | 0,9062 | 0,6100 | 0,9519 | 97,94 |
| 21       | LSTM (3)        | 0,9375 | 0,6479 | 0,9682 | 97,87 |
| 22       | Bi-GRU (1)      | 0,9669 | 0,7157 | 0,9833 | 97,81 |
| 23       | LSTM (1)        | 0,9773 | 0,6803 | 0,9886 | 97,78 |
| 24       | CNN/Bi-LSTM (4) | 1,0391 | 0,7428 | 1,0194 | 97,64 |
| 25       | GRU (4)         | 1,0865 | 0,9399 | 1,0424 | 97,53 |
| 26       | CNN/GRU (1)     | 1,1402 | 0,8813 | 1,0678 | 97,41 |
| 27       | CNN/Bi-GRU (1)  | 1,1454 | 0,7897 | 1,0702 | 97,40 |
| 28       | CNN/LSTM (4)    | 1,1645 | 0,8026 | 1,0791 | 97,36 |
| 29       | LSTM (2)        | 1,2038 | 0,7920 | 1,0972 | 97,27 |
| 30       | GRU (1)         | 1,2578 | 1,0219 | 1,1215 | 97,15 |
| 31       | LSTM (4)        | 1,8162 | 1,0782 | 1,3477 | 95,88 |
| 32       | Bi-LSTM (4)     | 2,5935 | 1,2678 | 1,6104 | 94,12 |

EUR/TL döviz kuru kısa vadeli analizinde elde edilen sonuçlar, model doğruluğu ve tahmin yeteneğini anlamak adına önemli bilgiler sunmaktadır. İlk sırada yer alan GRU (2) modeli, MSE (0,3370), MAE (0,3978), RMSE (5805) ve  $R^2$  (%99,24) hata metrik ve açıklama oranı ile tahminlerin büyük oranda gerçek verilerle uyumlu olduğu, doğru sonuçlar verdiğini göstermektedir. İkinci sırada yer alan CNN/GRU (2) modeli de biraz daha yüksek hata değerine sahip olmasına rağmen oldukça tutarlı sonuçlar üretmiştir.

Kısa vadeli analizde en başarılı model ile en kötü model arasındaki açıklama oranı farkı yaklaşık %5,12'dir. Bu değer, orta ve uzun vadeli analizlere göre modeller arasındaki performans farkının oldukça az olduğunu ortaya koymaktadır. Bu duruma eğitim setindeki ani değişimlerin yer alması ve böylece modelin genel değişikliği iyi öğrenerek, test veri setinde güçlü tahminlerde bulunmasına neden olmaktadır.

32 model sonuçları değerlendirildiğinde, GRU tabanlı modellerin en başarılı modeller olarak öne çıktığı dikkat çekmektedir. Dolayısıyla GRU mimarisinin, kısa vadeli dalgalanmaları öğrenmede oldukça etkili olduğu sonucuna ulaşılmaktadır. Bi-LSTM ve LSTM tabanlı modellerin daha düşük performans göstermesi, bu tür modellerin uzun vadeli bağımlılıkları öğrenme yeteneğinin yüksek olsa da kısa vadeli dalgalanmalarda yetersiz kaldığını ortaya koymaktadır.



Şekil 24: EUR/TL Kısa Vadeli Sonuçlar

Şekil 24, EUR/TL döviz kuru için kısa vadeli analiz döneminde en başarılı on modele ait eğitim ve test tahminlerini göstermektedir. Grafikler modellerin eğilimlerini, eğitim ve test verileri üzerindeki tahminlerini göstererek açıklama güçlerini göstermektedir.

GRU (2), CNN/GRU (2) ve CNN/GRU (3) gibi modellerin özellikle test verisinde tahmin hatalarını minimize ederek orijinal veriyle yüksek uyumlu tahminler yaptığı dikkat çekmektedir. Bu durum modellerin, kısa vadeli dalgalanmalara karşı oldukça duyarlı olduğunu ve veri setindeki dinamik yapıyı başarılı bir şekilde öğrenebildiğini göstermektedir. GRU (3) ve Bi-GRU (2) gibi modeller test tahminlerinde küçük miktarda sapma gösterse de veri setindeki eğilimi doğru şekilde yakalamıştır. Diğer yandan Bi-LSTM (2) ve CNN/Bi-GRU (3) modelleri, diğer modellere kıyasla test verisinde daha fazla sapma göstermiştir. Bu durumun nedeni, karmaşık model yapılarında kısa vadeli öngörülerin veri gürültüsüne duyarlı hale gelmesi ve bu sebeple test setinde daha büyük hatalar üretmesidir.

Sonuç olarak, grafiklerde en iyi performans gösteren modellerin GRU tabanlı modeller olduğu ve kısa vadeli analizde başarılı tahminler ürettiği kolaylıkla söylenebilir. Daha karmaşık yapıdaki modellerin veri gürültüsüne fazla duyarlı olmasından kaynaklı kısa vadeli analizlerde daha az etkili olduğu dikkat çekmektedir. Bu bilgiler, EUR/TL döviz kuru serisi kısa vadeli analizinde GRU ve CNN/GRU model kombinasyonlarının güvenilir bir seçenek olduğunu göstermektedir.

Kısa vadeli analizlerde, GRU ve CNN/GRU modellerinin döviz kurlarını yüksek doğrulukla tahmin ettiği gözlemlenmiştir. Bu modeller, özellikle ani dalgalanmaları anlamada ve tahmin etmede öne çıkmaktadır. Bu doğrultuda, Merkez Bankası, bu tür modelleri kullanarak döviz piyasası için gerçek zamanlı bir “Erken Uyarı Sistemi” geliştirebilir. Söz konusu sistem, döviz kurunda ani bir değişimin olacağını birkaç gün öncesinden tahmin ederek piyasa müdahale araçlarının (örneğin, rezerv kullanımı, swap mekanizmaları) önceden planlanmasını mümkün kılabilir. Bunun yanı sıra, döviz ihtiyacı yüksek olan sektörler için mikroekonomik araçlar (örneğin, kredi sınırlandırması, döviz alım-satım limitleri) devreye alınarak piyasa istikrarı artırılabilir.

#### 4.4. Değerlendirme ve Öneriler

Bu çalışmada, USD/TL ve EUR/TL döviz kurlarının tahmin edilmesi ve tutarlı bir model inşa edilmesi için kullanılan 32 farklı derin öğrenme modelinin performansı

Türkiye ekonomisi dinamikleri dikkate alınarak uzun, orta ve kısa vadeli üç farklı dönem için kapsamlı bir şekilde analiz edilmiştir. Her model, MAE, MSE, RMSE ve  $R^2$  metrikleri dikkate alınarak karşılaştırılmış ve bulgular genel eğilimlere göre değerlendirilmiştir.

Kısa vadeli analiz sonuçları, eğitim setinde ani dalgalanmaların da yer almasıyla model başarısının homojen bir şekilde dağıldığını göstermektedir. Bu durum model hatalarının minimize edilmesine ve tahmin doğruluğunun artmasına katkı sağlamıştır. Özellikle GRU tabanlı modellerin kombinasyonları yüksek tahmin başarısı göstermiştir. Bu sonuç, kısa vadeli tahmin döneminde derin öğrenme modellerinin geçmiş veri paternlerini daha etkin şekilde öğrenebildiğini ortaya koymaktadır.

Orta vadede, tahmin modelleri arasındaki başarı farkı kısa vadeye göre açılmıştır. Bu dönemde özellikle CNN/Bi-LSTM hibrit modeli ve kombinasyonlarının her iki döviz kurunda da daha üstün performans sergilediği tespit edilmiştir. Bu durum orta vadeli analizde veri örüntülerini daha karmaşık yapı içerdiğini ve hibrit modellerin bu yapıları yakalamada daha üstün olduğunu vurgulamaktadır.

Uzun vadeli analizlerde eğitim setinde ani dalgalanmaların daha az olması modeller arasındaki başarı oranı farkının artmasına yol açmıştır. Buna rağmen özellikle CNN/Bi-LSTM ve CNN/Bi-GRU modelleri ve kombinasyonları uzun vadede tutarlı bir performans sergilemiştir. Ancak modellerin geneli düşünüldüğünde orta ve kısa vadeli analize göre tahmin doğruluğunda bir düşüş gözlemlenmiştir. Bu durum uzun vadeli analizlerde model seçiminin önemini ortaya koymaktadır.

Üç analiz dönemi sonuçları değerlendirildiğinde, döviz kuru tahmininde kullanılan modellerin performanslarının dönemsel farklılıklara bağlı olarak değiştiğini açıkça ortaya koymaktadır. Kısa vadede dalgalanmaların etkisiyle modeller arası farklar azalırken, orta ve uzun vadede veri özelliklerinin baskınlığı nedeniyle model başarı oranları ayrılmıştır. Bu bulgular, döviz kuru tahmin problemlerinde kullanılan modellerin seçiminde dönemsel analizlerin önemini ve farklı yöntemlerin bir arada kullanmanın avantajlarını vurgulamaktadır.

Döviz kurları, ekonomik dinamiklerin çok yönlü etkilerini yansıtarak ekonomik birimler üzerinde önemli etkiler bırakmaktadır. Bu çalışmada, uzun, orta ve kısa vadeli analizlerden elde edilen bulgular ve derin öğrenme modellerinin sunduğu tahmin performansları, ekonomik birimlerin karar alma mekanizmalarına rehberlik edebilecek

politika önerilerinin geliştirilmesine katkı sağlamaktadır. Bu doğrultuda kamu kesimi, merkez bankası, dış ticaret firmaları, finansal sektör firmaları ve hane halkları için hazırlanmış politika önerileri şöyledir:

Kamu kesimi için öncelikli amaç, uzun vadeli ekonomik istikrarı sağlamak ve meydana gelebilecek dalgalanmalara karşı dirençli bir yapı oluşturmaktır. Uzun vadeli analizler, USD/TL ve EUR/TL döviz kurlarında yaşanan dalgalanmaların, ekonomik öngörülebilirliği azaltarak kamu borçlanma stratejisi üzerinde bir baskı yaratabileceğini göstermektedir. Bu kapsamda, derin öğrenme modelleri ile elde edilen tahmin sonuçlarına dayanarak, döviz cinsi borçlanmaların dikkatle planlanması ve kamu borçlanma stratejilerinin daha etkin bir şekilde oluşturulması mümkündür. Orta ve kısa vadede ise piyasalarda ortaya çıkabilecek risk senaryolarına yönelik bir “Olası Senaryo Haritaları” sistemi geliştirilmelidir. Bu sistem, kriz dönemlerinde risklerin önceden tahmin edilmesine olanak tanıyacak ve şokların etkisini azaltacak çözümlerin hızla devreye alınmasını sağlayarak piyasa istikrarını destekleyecektir.

Merkez Bankası, derin öğrenme algoritmalarını kullanarak farklı piyasa senaryolarını sürekli olarak analiz eden ve döviz işlemlerinde karar destek mekanizması sunan bir “Akıllı Rezerv Yönetim Sistemi” geliştirerek döviz rezervlerini gerçek zamanlı optimize edebilir. Ayrıca kamu kesimi için önerilen “Olası Senaryo Haritaları” uygulamasına benzer bir sistem oluşturarak piyasalarda oluşabilecek şokları önceden tahmin edip, para politikası araçlarının etkisini test edebilir. Bu uygulamalar, derin öğrenme modellerinden yararlanarak büyük veri setlerini analiz ederek politika yapıcılara piyasa dalgalanmalarına karşı hızlı uyum sağlama imkânı verecektir. Kısa vadede ise, derin öğrenme modellerinden elde edilen tahminler kullanılarak bir “Erken Uyarı Sistemi” kurgulanıp, potansiyel dalgalanmalara karşı hızlı reaksiyon verilmesi sağlanabilir.

Dış ticaret firmaları için, derin öğrenme algoritmaları kullanılarak “Döviz Risk Platformu” geliştirilebilir. Böylece, piyasa trendleri takip edilip firmalara öngörülebilir karar alma mekanizmaları sağlanacaktır. Ayrıca, geleneksel ve hibrit derin öğrenme modellerinden elde edilen projeksiyonlar doğrultusunda, uzun, orta ve kısa vadeli kur dalgalanmalarına karşı koruma mekanizmaları oluşturularak firmaların risk yönetim süreçlerine önemli katkılar sağlanabilir.

Finansal sektör firmaları için döviz piyasasında meydana gelebilecek dalgalanmalara karşı dayanıklı yapılar oluşturmak önemli bir zorunluluktur. Bu doğrultuda derin öğrenme modellerinin döviz kuru öngörülerinden faydalananarak döviz yoğunluğu ve likidite yönetimi daha etkin şekilde bir tasarlanabilir. Ayrıca derin öğrenme modellerini kullanarak geliştirilecek bir portföy optimizasyon sistemi, firmaların yatırım portföylerinin optimize edilmesine katkı sağlayarak daha verimli bir portföy yönetimi yaklaşımı sunacaktır.

Derin öğrenme modelleri hane halklarının döviz kuru dalgalanmalarına karşı daha bilinçli finansal kararlar almasına olanak tanıyacaktır. Derin öğrenme modelleri ile birimlerin finansal planlamaları döviz kuru öngörülerine dayandırılarak yatırım sepetinin yapılmasına, böylece dalgalanmalara karşı daha korunaklı bir yapının oluşturulmasına katkı sağlayacak, böylece ani dalgalanmaların olumsuz etkileri en aza indirilebilecektir.

Derin öğrenme algoritmalarının sunduğu yüksek doğruluk oranı, farklı sektörlerin karşılaştığı döviz riski yönetiminde yenilikçi çözümler üretme potansiyelini gözler önüne sermektedir. Politika önerileri, ekonomik birimlerin mevcut döviz kuru dalgalanmalarına karşı daha dirençli yapılar geliştirmelerine yardımcı olmayı ve ekonomik öngörülebilirliği artırmayı hedeflemektedir. Bu çerçevede, derin öğrenme modellerinin gelişen teknolojilerle daha etkin hale gelmesi, Türkiye ekonomisinin döviz dinamiklerini daha iyi yönetmesini sağlayacak ve sürdürülebilir bir ekonomik yapının inşa edilmesine katkıda bulunacaktır.

## SONUÇ

Döviz kuru, bir birim yabancı para karşılığı değiştirilebilen ulusal para birimi şeklinde tanımlanan önemli bir makroekonomik değişkendir. Bu kavram, dış ticaret, sermaye akımları ve ekonomik karar alma süreçlerinde belirleyici bir rol oynamaktadır. Aynı zamanda döviz kuru, ekonomik birimlerin beklentilerini ve risk algısını da şekillendirerek makroekonomik politikaların belirlenmesinde kritik bir araç haline gelmiştir. Bu sebeple döviz kurunu öngörebilmek hem politika yapıcılar hem de piyasa katılımcıları için oldukça önemli bir konu olmuştur. Bu doğrultuda döviz kuru hareketlerini anlamak için birçok teori geliştirilmiştir. Döviz kuru belirleme teorileri, zaman içerisinde farklılıklar gösterse de şu temel yaklaşımlar etrafında toplanmaktadır: Satın Alma Gücü Paritesi, Faiz Oranı Paritesi, Esnek ve Katı Fiyatlı Parasal Yaklaşım, Portföy Dengesi Yaklaşımı, Spekülatif Kabarcıklar Teorisi ve Döviz Kuruna Mikro Temelli Yaklaşım. Bu teoriler, ekonomik göstergelerin (fiyatlar genel düzeyi, faiz oranları, para arz ve talebi, varlık piyasaları, beklentiler vb.) döviz kuru üzerindeki etkilerini inceleyerek tahmin ve modellerin geliştirilmesine rehberlik etmektedir.

Geleneksel ekonometrik modeller, döviz kuru tahmininde önemli katkılar sağlasa da kısıtlayıcı dağılım varsayımlarına dayanması ve döviz kuru serilerinin çoğunlukla karmaşık ve doğrusal olmayan yapısı nedeniyle yetersiz kalmıştır. Derin öğrenme yöntemlerinin zaman serilerindeki karmaşık örüntüleri herhangi bir varsayıma dayanmaksızın çözme kapasitesine sahip olması bu tür mimarilerin son yıllarda literatürde sıklıkla kullanılmasına neden olmuştur. Özellikle tekrarlayan sinir ağları modeline dayalı LSTM, GRU, Bi-LSTM ve Bi-GRU gibi modeller, uzun vadeli bağımlılıkları yakalama yeteneğiyle tahmin performansının artmasına önemli katkıda bulunmuştur. Hibrit yaklaşımlar ise, farklı özellikleri içinde barındıran modelleri birleştirerek daha tutarlı tahminler sunmuştur.

Bu tez, USD/TL ve EUR/TL nominal döviz kurlarını tahmin etmek ve tutarlı bir model inşa etmek amacıyla derin öğrenme algoritmalarının etkinliğini kapsamlı bir şekilde değerlendirmeyi amaçlamaktadır. USD/TL döviz kuru, Türkiye ekonomisi için özellikle ithalat ve ihracat şirketleri açısından kritik bir öneme sahipken, EUR/TL döviz kuru Avrupa Birliği ile olan ticari ilişkiler ve dış borçlanma dinamiklerinde kilit bir rol oynamaktadır. Çalışmada tekrarlayan sinir ağları modeline dayalı LSTM, GRU, Bi-LSTM ve Bi-GRU modelleri ve bu modellerin CNN yapısıyla birleştirildiği hibrit yaklaşımlar kullanılmıştır. Bu yaklaşımlar, döviz kurlarındaki karmaşık örüntüleri daha

etkili bir şekilde çözümlemek için önem arz etmektedir. Ayrıca çalışmada, ekonomik ve politik değişimler dikkate alınarak özgün üç farklı dönemde USD/TL ve EUR/TL döviz kurları analiz edilmiş, elde edilen bulgular tablo ve grafikler kullanılarak değerlendirilmiştir.

Üç farklı analiz dönemi incelendiğinde, birinci analiz dönemi olan Şubat 2001'den Ekim 2024'e kadar geçen süreçte, Türkiye ekonomisinde esnek kur rejimine geçişle birlikte döviz kurlarının uzun vadeli hareketlerindeki karmaşık yapılar dikkat çekmektedir. Bu analiz dönemi, 2001 ekonomik krizinin etkileriyle şekillenmiş ve piyasalarda köklü değişimlerin yaşandığı bir süreci kapsamaktadır. Bu durum piyasalardaki köklü değişimlerin ve ekonomik yapıdaki farklılıkların döviz kurları üzerindeki etkisini daha iyi bir şekilde anlaşılmasını ve detaylı model analizlerini gerekli kılmıştır. Bu doğrultuda kurulan 32 farklı derin öğrenme modeliyle döviz kurlarının zaman içerisindeki seyri incelenmiş, test ve eğitim setleri için tahminlerde bulunulmuştur. Test setine ait bulgular CNN/Bi-LSTM ve CNN/Bi-GRU hibrit modellerinin uzun vadeli bağımlılıkları yakalamada diğer modellere kıyasla üstün performans gösterdiğini ortaya koymuştur. Bu bağlamda veri setine uygun parametrelerle düzenlenen hibrit model kullanımının önemli avantajlar gösterdiği sonucuna ulaşılmıştır.

Ocak 2010-Ekim 2024 tarihlerini kapsayan orta vadeli dönem, 2008 küresel finans krizi sonrası toparlanma, enflasyon hedeflemesi ve finansal istikrar politikalarının birlikte uygulanmaya başladığı bir dönemi temsil etmektedir. Bu dönemde döviz kurlarında hem küresel hem de yerel gelişmelerin etkisi daha çok hissedilmiştir. Bu dönemde meydana gelen gelişmelerin döviz kurları üzerindeki etkisi ve derin öğrenme modellerinin performansını test etmek için 32 farklı derin öğrenme modeli geliştirilmiş, test seti üzerinde CNN/Bi-LSTM hibrit modellerinin zamansal ve mekânsal örüntüleri daha etkili bir şekilde yakaladığı sonucuna ulaşılmıştır. Modeller arası hata değerleri çok fazla farklılaşsa da uzun ve orta vadede hibrit modellerin geleneksel modellere kıyasla daha iyi performans göstermesi elde edilen önemli bulgulardan birisi olmuştur.

Temmuz 2016'dan itibaren başlayan son analiz dönemi ise, ekonomik ve politik belirsizliklerin yoğunlaştığı bir süreci temsil etmektedir. Bu dönemde 15 Temmuz darbe girişimi sonrası süreç, Brunson krizi, COVID-19 pandemisi, Merkez Bankası faiz indirimleri ve Cumhurbaşkanlığı seçimleri gibi çeşitli şokların etkisiyle döviz kurlarında önemli dalgalanmalar meydana gelmiştir. Döviz kurlarındaki dalgalanmaları tahmin

etmek ve tutarlı bir model geliştirmek için geliştirilen 32 farklı derin öğrenme modelinin test seti sonuçları, uzun ve orta vadeli analiz sonuçlarından farklı olarak GRU ve Bi-GRU modellerinin diğer modellere kıyasla daha iyi performans sergilediği göstermiştir. Ayrıca kısa vadeli analiz döneminde ani dalgalanmalara karşı model duyarlılığının artması sebebiyle tüm modeller arasındaki farkın azaldığı tespit edilmiştir.

Çalışmanın bir diğer dikkat çekici sonucu, veri seti özelliklerinin model performansı üzerindeki etkilerini gözler önüne sunmasıdır. Tüm analiz dönemleri için %75 eğitim seti, %25 test seti ayrımı yapılmasına rağmen, uzun ve orta vadeli analiz dönemlerinde eğitim setinde ani dalgalanmaların daha az olması nedeniyle bazı modellerde duyarlılığın azalması sorunu ortaya çıkmaktadır. Buna karşın, kısa vadeli analizlerde ani dalgalanmaların eğitim setinde yer alması, modellerin öğrenme kapasitesini artırarak performans farklılıklarını azaltmıştır. Bu bulgular, dönemsel analizlerin ve model seçiminin tahmin performansı üzerinde ne kadar kritik bir rol aldığını ortaya koymaktadır.

Sonuç olarak, çalışma USD/TL ve EUR/TL döviz kurlarını tahmin etmek için derin öğrenme modellerinin etkinliğini açıkça ortaya koymaktadır. Her bir modelin avantaj ve sınırlılıkları, çalışmada önerilen hibrit yaklaşımlar ve farklı parametre değerleriyle dengelenmiş, üç farklı analiz dönemi belirlenerek dönemler arası farklılıklar dikkate alınmıştır. Böylece bu tür model ve dönem belirleme sürecinin tahmin performansını önemli ölçüde artırdığı gözlemlenmiştir. Bu sebeple çalışma, bu alanda yapılacak sonraki çalışmalar için hem teorik hem de uygulama açısından önemli bir referans oluşturmaktadır.

Bu çalışmanın bulguları, döviz kuru tahmininde derin öğrenme modellerinin başarısını vurgulayan literatürle büyük ölçüde uyumludur. Literatürde, özellikle RNN tabanlı LSTM, GRU gibi modellerin, finansal zaman serilerindeki doğrusal olmayan ilişkileri anlamada geleneksel yöntemlere göre daha üstün olduğu gösterilmiştir (Örneğin, Leung vd., 2000; Yao ve Tan, 2000; Kamruzzaman ve Sarker, 2003; Kiani ve Kastens, 2008; Putri ve Halim, 2020; Telatar, 2022; Erem, 2023). Bununla birlikte, bu çalışma, hibrit modellerin (CNN ile birleştirilmiş LSTM ve GRU gibi) performansını detaylı bir şekilde ele almasıyla mevcut çalışmalardan ayrılmaktadır. Her ne kadar hibrit modellerin kullanıldığı çalışmalar literatürde sınırlı olsa da hibrit modeller üzerine yapılan araştırmada (Ni vd., 2019), özellikle CNN tabanlı modellerin etkili olduğu görülmüştür.

Ayrıca bu çalışma, dönemsel analizlerin döviz kuru tahminine etkisini inceleyen bir yaklaşımla, özellikle literatürde daha az işlenmiş olan ani dalgalanmaların modellere olan etkisini tartışması açısından farklılık göstermektedir. Böylece, bu çalışma, literatüre hem yöntemsel bir yenilik hem de farklı dönemler arasındaki performans farklılıklarına dair yeni bir bakış açısı sunmaktadır.

Elde edilen bulgular neticesinde bu çalışma, tüm ekonomik birimler için önemli ipuçları sunmaktadır. Kamu kesimi için, derin öğrenme modelleri ile edilecek tahminler, özellikle uzun vadede kamu borçlanma stratejilerinin daha etkin bir şekilde planlanmasına katkı sağlayacaktır. Orta ve kısa vadede ise piyasalarda meydana gelebilecek risk senaryolarına yönelik bir “Olası Senaryo Haritaları” sistemi geliştirilmesi, kriz dönemlerinde risklerin önceden tahmin edilerek şokların etkisini azaltacak çözümlerin devreye alınmasına imkân tanıyacaktır. Merkez bankası açısından değerlendirildiğinde, derin öğrenme algoritmaları kullanılarak bir “Akıllı Rezerv Yönetim Sistemi” geliştirilerek uzun ve orta vadede şoklara karşı dirençli bir yapının oluşturulmasına katkı sağlanacaktır. Kısa vadede ise derin öğrenme algoritmalarının döviz kuru tahminlerine dayalı bir “Erken Uyarı Sistemi” kurulması, piyasalarda ani dalgalanmalara karşı hızlı aksiyon alınmasını sağlayarak, döviz kurlarında dengeden sapmanın önüne geçilmesine olanak sağlayacaktır.

Finans sektörü ve dış ticaret firmaları için ise, derin öğrenme modellerinin ürettiği tahminler doğrultusunda risk yönetim süreçleri etkin şekilde geliştirilebilecektir. Derin öğrenme modelleri tahminleri doğrultusunda, dış ticaret firmalarının piyasa trendlerini öngören karar alma platformlarını kullanması, kur riskine karşı koruma mekanizmalarının geliştirilmesinde kritik bir rol oynayacaktır. Finansal kurumlar için ise, derin öğrenme modellerinin ürettiği bilgilere dayandırılarak, portföy optimizasyon sistemleri ve likidite yöntemi uygulamalarının kullanımı kurumların daha etkin çalışmasına katkı sağlayacaktır.

Çalışma, bireysel yatırımcılar ve hane halkları için de önemli katkılar sunmaktadır. Derin öğrenme modellerine dayalı yapılan tahminler, bireylerin yatırımlarını daha bilinçli planlamasına ve portföylerini çeşitlendirmesine katkı sağlayarak ve ani dalgalanmalardan kaynaklanan olumsuz etkilerin en aza indirilmesine olanak tanıyarak daha korunaklı finansal yapılar oluşturulmasını destekleyecektir.

## KAYNAKLAR

- Abedin, M. Z., Moon, M. H., Hassan, M. K., & Hajek, P. (2021). Deep learning-based exchange rate prediction during the COVID-19 pandemic. *Annals of Operations Research*, 1-52.
- Alan, M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433-460.
- Altan, Ş. (2008). Döviz kuru öngörü performansı için alternatif bir yaklaşım: Yapay sinir ağı. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2), 141-160.
- Amidi A. & Amidi S. (2018). Deep Learning cheatsheet. *Stanford University*. <https://stanford.edu/~shervine/teaching/cs-229/cheatsheet-deep-learning>.
- Anastasakis, L., & Mort, N. (2009). Exchange rate forecasting using a combined parametric and nonparametric self-organising modelling approach. *Expert Systems with Applications*, 36(10), 12001-12011.
- Aras, Y. (2023). *Derin sinir ağları ile modülasyon sınıflandırma*. (Yayımlanmamış Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi.
- Babu, A. S., & Reddy, S. K. (2015). Exchange rate forecasting using ARIMA, neural network and fuzzy neuron. *Journal of Stock & Forex Trading*, 4(3), 01-05.
- Başçı, E., & Kara, H. (2011). Finansal istikrar ve para politikası. *İktisat İşletme ve Finans*, 26(302), 9-25.
- Berke, B. (2014). Döviz kurlarına mikro yapı yaklaşımı: Bir yazın incelemesi. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 32(2), 27-56.
- Bilson, J.F.O. (1978), The monetary approach to the exchange rate: Some empirical evidence. *IMF Staff Papers*, 25(2), 201-223.
- Birdi, N., Sarangi, P. K., Singla, T., Sahoo, A. K., & Subudhi, G. B. (2023). Forex trend analysis using RNN and LSTM models: Predictive analytics through neural networks. *2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES)*, 206-210.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Biswas, A., Uday, I. A., Rahat, K. M., Akter, M. S., & Mahdy, M. R. C. (2023). Forecasting the United State Dollar (USD)/Bangladeshi Taka (BDT) exchange

rate with deep learning models: Inclusion of macroeconomic factors influencing the currency exchange rates. *Plos one*, 18(2), 1-24.

Bulut, E., & Şahin, G. (2023). Cumhuriyet'ten günümüze döviz kuru politikaları. *Fiscaoeconomia*, 7(Özel Sayı), 210-238.

Bulut, E., Demirel, B., & Akar, N. Ç. (2017). 2008 krizi sonrası FED'in faiz artırımının yükselen piyasa ekonomilerindeki portföy yatırımları üzerine etkileri. *Gazi İktisat ve İşletme Dergisi*, 3(1), 35-58.

Calvo, G. A. (1999). Testimony on full dollarization.

Canterbery, E. R. (1965). *Foreign exchange, capital flows and monetary policy*. Princeton University Press

Cao, D. Z., Pang, S. L., & Bai, Y. H. (2005, August). Forecasting exchange rate using support vector machines. *2005 International Conference on Machine Learning and Cybernetics*, 6, 3448-3452.

Cassel, G. (1918). Abnormal deviations in international exchanges. *The Economic Journal*, 28(112), 413-415.

Chauhan, N. S., Kumar, N., & Eskandarian, A. (2024). A novel confined attention mechanism driven Bi-GRU model for traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 25(8), 9181-9191.

Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peerj computer science*, 7, e623.

Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2020). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv*. <https://arxiv.org/abs/1406.1078>

Chollet, F. (2021). *Deep Learning with Python*. Simon and Schuster.

Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv*. <https://arxiv.org/abs/1412.3555>

Churchland, P. S., & Sejnowski, T. J. (2016). *The computational brain*. MIT Press.

- Çelik, K. (2008). *Uluslararası iktisat*. Murathan Yayınevi.
- Darvas, Z. (2012). Real effective exchange rates for 178 countries: A new database. *Bruegel*.
- Dash, R. (2020). Performance analysis of an evolutionary recurrent Legendre Polynomial Neural Network in application to FOREX prediction. *Journal of King Saud University-Computer and Information Sciences*, 32(9), 1000-1011.
- Dautel, A. J., Härdle, W. K., Lessmann, S., & Seow, H. V. (2020). Forex exchange rate forecasting using deep recurrent neural networks. *Digital Finance*, 2, 69-96.
- Deng, L., & Yu, D. (2014). Deep learning: Methods and applications. *Foundations and trends in signal processing*, 7(3-4), 197-387.
- Dornbusch, R. (1976). Expectations and exchange rate dynamics. *Journal of Political Economy*, 84(6), 1161-1176.
- Dornbusch, R., Fischer, S. & Startz, R. (2014). *Macroeconomics*. Walter de Gruyter.
- Edwards, S. & Savastano, M. A. (1999). Exchange rates in emerging economies: What do we know? What do we need to know? *NBER Working Paper No. 7228*.
- Einzig, P. (1932). *The theory of forward exchange*. Macmillan.
- Erem, E. (2023). Forecasting exchange rates using artificial neural networks. *Journal of Finance and Economics*, 11(1), 58-67.
- Evans, M. D., & Lyons, R. K. (2002). Order flow and exchange rate dynamics. *Journal of Political Economy*, 110(1), 170-180.
- Fama, E. F. (1970). Efficient market hypothesis: A review of theory and empirical work. *Journal of Finance*, 25(2), 28-30.
- Feenstra, R. C., & Taylor, A. M. (2011). *International macroeconomics*. Macmillan.
- Frankel, J. A. (1996). Recent exchange-rate experience and proposals for reform. *American Economic Review*, 86(2), 153-158.
- Frankel, J. A. (1999). No single currency regime is right for all countries or at all times.
- Frankel, J. A. & Rose, A. K. (1995). Empirical research on nominal exchange rates. *Handbook of international economics*, 3, 1689-1729. Elsevier.

- Frankel, J. A. & Froot, K. A. (1990). Chartists, fundamentalists, and trading in the foreign exchange market. *American Economic Review*, 80(2), 181-185.
- Frenkel, J.A., (1976), A monetary approach to the exchange rate: Doctrinal aspects and empirical evidence. *Scandinavian Journal of Economics*, 78, 200-224.
- Galac, T., Buric, A. & Huljak, I. (2006). Microstructure of foreign exchange market in Croatia. *Croatian National Bank Working Paper* (15), 1-41.
- Galeshchuk, S. (2016). Neural networks performance in exchange rate prediction. *Neurocomputing*, 172, 446-452.
- Galeshchuk, S., & Mukherjee, S. (2017). Deep networks for predicting direction of change in foreign exchange rates. *Intelligent Systems in Accounting, Finance and Management*, 24(4), 100-110.
- Ghosh, A., Gulde, A. M. & Wolf, H. (2002). Exchange rate regimes: Classification and consequences. *Center for Economic Performance*, 1, 1-22.
- Gilik, A., Ogrenci, A. S., & Ozmen, A. (2022). Air quality prediction using CNN+ LSTM-based hybrid deep learning architecture. *Environmental science and pollution research*, 1-19.
- Goncu, A. (2019). Prediction of exchange rates with machine learning. *Proceedings of the International Conference on Artificial Intelligence, Information Processing and Cloud Computing*, 1-5.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6), 602-610.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
- Güney, A. (2015). *Döviz kuru teorileri ve Türkiye’de döviz kurunun belirleyicileri*. (Yayımlanmamış Doktora Tezi). İstanbul Üniversitesi.

- Güney, A. & Tunalı, H. (2017). Faiz oranı paritesi yaklaşımı üzerine bir değerlendirme. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 9(16), 35-48.
- Haykin, S. (2009). *Neural networks and learning machines*, 3/E. Pearson.
- Hochreiter, S. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Hsieh, D. A. (1982). The determination of the real exchange rate: The productivity approach. *Journal of International Economics*, 12(3-4), 355-362.
- <https://www.ibm.com/topics/machine-learning>
- IMF (2008). *Revised Classification System, 2008—Definitions of Categories*. <https://www.elibrary-areaer.imf.org/Pages/ERClassification.aspx> (Erişim Tarihi: 12/05/2023).
- Islam, M. S., & Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. *Soft Computing Letters*, 3, 100009.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Johnson, H. G. (1969). The case for flexible exchange rates, 1969. *Federal Reserve Bank of St. Louis Review*.
- Jung, G., & Choi, S. Y. (2021). Forecasting foreign exchange volatility using deep learning autoencoder-LSTM techniques. *Complexity*, 2021, 1-16.
- Kamruzzaman, J., & Sarker, R. A. (2003, December). Forecasting of currency exchange rates using ANN: A case study. *International Conference on Neural Networks and Signal Processing, 2003*. (Vol. 1, pp. 793-797).
- Karahan, Ö., & İpek, E. (2013). Türkiye'ye yönelik yabancı sermaye akımlarının hacim ve kompozisyonundaki gelişmeler. *Journal of Management and Economics Research*, 11(21), 299-316.
- Kaushik, M., & Giri, A. K. (2020). Forecasting foreign exchange rate: A multivariate comparative analysis between traditional econometric, contemporary machine learning & deep learning techniques. *arXiv*. <https://arxiv.org/abs/2002.10247>

- Kaya, M. (2022). *Derin öğrenme yöntemleri ile elektrik fiyat tahmini: Türkiye gün öncesi elektrik piyasası uygulaması*. (Yayımlanmamış Doktora Tezi). İstanbul Okan Üniversitesi.
- Kayaalp, K., & Süzen, A. A. (2018). *Derin öğrenme. Derin öğrenme ve Türkiye'deki uygulamaları*. İKSAD Yayınevi.
- Kazgan, G. (2017). *Tanzimat'tan 21. yüzyıla Türkiye ekonomisi*. İstanbul Bilgi Üniversitesi Yayınları.
- Keynes, J. M. (1923). *A tract on monetary reform*. Macmillan.
- Kızılkaya, O. (2022). Türkiye'nin enflasyon ve işsizlik oranının yapay sinir ağları ve Box-Jenkins yöntemiyle tahmini. *Social Sciences Studies Journal (Sssjournal)*, 3(12), 2197-2207.
- Kiani, K. M., & Kastens, T. L. (2008). Testing forecast accuracy of foreign exchange rates: Predictions from feed forward and various recurrent neural network architectures. *Computational Economics*, 32, 383-406.
- Korol, T. (2014). A fuzzy logic model for forecasting exchange rates. *Knowledge-Based Systems*, 67, 49-60.
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the artificial neural networks. In K. Suzuki (Ed.), *Artificial neural networks: Methodological advances and biomedical applications*. IntechOpen.
- Krugman, P. R., & Obstfeld, M. (2009). *International Economics: Theory and Policy*, 8th Ed., Boston: Pearson Education.
- Lerner, A. P. (1946). The economics of control. *Science & Society*, 10(4), 416-419.
- Leung, M. T., Chen, A. S., & Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, 27(11-12), 1093-1110.
- Levy-Yeyati, E. & Sturzenegger, F. (2005). Classifying exchange rate regimes: Deeds vs. words. *European economic review*, 49(6), 1603-1635.

- Lin, H., Sun, Q., & Chen, S. Q. (2020). Reducing exchange rate risks in international trade: A hybrid forecasting approach of CEEMDAN and multilayer LSTM. *Sustainability*, 12(6): 2451.
- MacDonald, R. (2007). *Exchange rate economics*, Routledge, Taylor & Francis Group, London and New York.
- Markowitz, H. (1952) Portfolio selection. *The Journal of Finance*, 7(1), 77-91.
- Marshall, A. (1923). Money, credit and commerce. *Journal of the Royal Statistical Society*, 86(3), 430–433.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-14.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin Of Mathematical Biophysics*, 5, 115-133.
- Meese, R. (1990). Currency fluctuations in the post-Bretton Woods era. *Journal of Economic Perspectives*, 4(1), 117-134.
- Moore, R., & DeNero, J. (2011). L1 and L2 regularization for multiclass hinge loss models. *Symposium on Machine Learning in Speech and Language Processing*.
- Moosa, I. A. & Bhatti, R. H. (Eds.). (2009). *The theory and empirics of exchange rates*. World Scientific.
- Müslümov, A., Hasanov, M., & Özyıldırım, C. (2003). *Döviz kuru sistemleri ve Türkiye'de uygulanan döviz kuru sistemlerinin ekonomiye etkileri*. Türkiye Genç İşadamları Derneği.
- Ni, L., Li, Y., Wang, X., Zhang, J., Yu, J., & Qi, C. (2019). Forecasting of forex time series data based on deep learning. *Procedia computer science*, 147, 647-652.
- Nwosu, U. I., Obite, C. P., Osuagwu, P. H., & Onukwube, O. G. (2021). Modeling the British Pound Sterling to Nigerian Naira exchange rate during the Covid-19 pandemic. *Journal of Mathematics and Statistics Studies*, 2(2), 25-35.
- Olah, C. (2015). Understanding lstm networks. *Colah's Blog*. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

- Oppermann, A. (2023). Optimization in deep learning: Adagrad, RMSprop, Adam. *Artem Oppermann*. <https://artemoppermann.com/optimization-in-deep-learning-adagrad-rmsprop-adam/>
- Orhangazi, Ö. & Yeldan, E. (2023). Türkiye modeli-2021 ve sonrası: Rastgele hedefler, gerçekleştirmeler ve bir bilanço. *ODTÜ Gelişme Dergisi*, 50,171-194.
- Özatay, F. (2019). *Parasal iktisat: Kuram ve Politika*. Efil Yayınevi.
- Özdemir, K. A. & Şahinbeyoğlu, G. (2000). Alternatif döviz kuru sistemleri. *Türkiye Cumhuriyet Merkez Bankası Araştırma Genel Müdürlüğü Tartışma Tebliği*, 1-10.
- Özkan, F. (2011). Döviz kuru tahmininde yapay sinir ağlarıyla alternatif yaklaşım. *Eskişehir Osmangazi Üniversitesi, İİBF Dergisi*, 6(2), 185-200.
- Öztürk, N. & Bayraktar, Y. (2010). Döviz kurlarını açıklamaya yönelik yeni yaklaşımlar. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 11(1), 157-191.
- Pamuk, Ş. (2012). *Türkiye'nin 200 Yıllık İktisadi Tarihi*. Türkiye İş Bankası Kültür Yayınları.
- Panda, C., & Narasimhan, V. (2007). Forecasting exchange rate better with artificial neural network. *Journal of Policy Modeling*, 29(2), 227-236.
- Pavlatos, C., Makris, E., Fotis, G., Vita, V., & Mladenov, V. (2023). Enhancing electrical load prediction using a Bidirectional LSTM neural network. *Electronics*, 12(22), 4652.
- Pentecost, E.J. (1993). *Exchange Rate Dynamics: A Modern Analysis of Exchange Rate Theory and Evidence*. Edward Elgar Publishing Limited.
- Pilbeam, K. (1992). *International finance*. Macmillan Education.
- Putri, K. S., & Halim, S. (2020). Currency movement forecasting using time series analysis and long short-term memory. *International Journal of Industrial Optimization*, 1(2), 71-80.
- Radfar, E. (2024) Stock market trend prediction using deep neural network via chart analysis: A practical method or a myth?.

- Raj, C., Agarwal, A., Bharathy, G., Narayan, B., & Prasad, M. (2021). Cyberbullying detection: Hybrid models based on machine learning and natural language processing techniques. *Electronics*, 10(22), 2810.
- Rogoff, K. (1996). The purchasing power parity puzzle. *Journal of Economic literature*, 34(2), 647-668.
- Sarno, L. & Taylor, M. P. (2003). *The economics of exchange rates*. Cambridge University Press.
- Seyidoğlu, H. (2015). *Uluslararası iktisat* (20. b.). Güzem Can Yayınları.
- Shen, F., Chao, J., & Zhao, J. (2015). Forecasting exchange rate using deep belief networks and conjugate gradient method. *Neurocomputing*, 167, 243-253.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Sun, S., Wang, S., & Wei, Y. (2020). A new ensemble deep learning approach for exchange rates forecasting and trading. *Advanced Engineering Informatics*, 46, 101160.
- Tavlas, G., Dellas, H. & Stockman, A. C. (2008). The classification and performance of alternative exchange-rate systems. *European Economic Review*, 52(6), 941-963.
- Telatar, M., (2022). *Türkiye'deki finansal yatırım araçlarına yönelik tahminlemede zaman serileri analizi ve derin öğrenme tekniklerinin karşılaştırılması*. (Yayımlanmamış Yüksek Lisans Tezi). İstanbul Okan Üniversitesi.
- Tenti, P. (1996). Forecasting foreign exchange rates using recurrent neural networks. *Applied Artificial Intelligence*, 10(6), 567-582.
- Thamizharasi, M., & Lakshmi, M. (2022, November). Alzheimer's disease detection through deep learning techniques: A Study. *2022 1st International Conference on Computational Science and Technology (ICCST)*, 429-434.
- Tobin, J. (1958). Liquidity preference as behavior towards risk. *Review of Economic Studies*, 25(2), 65-86.

- Tripathi, M., Kumar, S., & Inani, S. K. (2020). Exchange rate forecasting using ensemble modeling for better policy implications. *Journal of Time Series Econometrics*, 13(1), 43-71.
- Türkiye Cumhuriyet Merkez Bankası (TCMB) (2018). *100 Soruda Merkez Bankacılığı*. <http://www.tcmb.gov.tr> (Erişim Tarihi: 05/06/2023).
- Türkiye Cumhuriyet Merkez Bankası (TCMB) (2021). *Para Politikası Kurulu kararı*. <https://www.tcmb.gov.tr/wps/wcm/connect/be913b5b-2ecc-47fe-a55f-04c086185855/DUY2021-42.pdf?MOD=AJPERES&CACHEID=ROOTWORKSPACE-be913b5b-2ecc-47fe-a55f-04c086185855-nMij-Uj> adresinden edinilmiştir.
- Türkiye Cumhuriyet Merkez Bankası (TCMB) (2023). *Elektronik veri dağıtım sistemi (EVDS)*. <https://evds2.tcmb.gov.tr>, (Erişim: 04.10.2024).
- Uğur, A., & Kınacı, A. C. (2006). Yapay zekâ teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. XI. *Türkiye'de İnternet Konferansı (İnet-Tr'06)*, Ankara, 1(4).
- Unadkat, S. B. (2001). *ICA applications in data mining*. American University.
- Vika, B., & Çollaku, D. (2023). Forecasting LEK/EUR exchange rate: A comparative deep learning study.
- Visser, H. (2006). *A guide to international monetary economics: Exchange rate theories, systems and policies*. Edward Elgar Publishing.
- Wang, S., Tang, Z., & Chai, B. (2016, October). Exchange rate prediction model analysis based on improved artificial neural network algorithm. *2016 International Conference on Communication and Electronics Systems (ICCES)*, 1-5.
- World Bank (WB). *World Development Indicators*. <https://data.worldbank.org/indicator/NY.GDP.MKTP.CD>, (Erişim: 16.12.2023).
- Yadav, A. (2023). Taming the optimizers: Adagrad, Adam, and RMSprop in deep learning. *Medium*. <https://medium.com/@alok.yadav/taming-the-optimizers-adagrad-adam-and-rmsprop-in-deep-learning-7b0582b0ceba>
- Yao, J., & Tan, C. L. (2000). A case study on using neural networks to perform technical forecasting of forex. *Neurocomputing*, 34(1-4), 79-98.

- Yıldırım, D. C., Toroslu, I. H., & Fiore, U. (2021). Forecasting directional movement of Forex data using LSTM with technical and macroeconomic indicators. *Financial Innovation*, 7, 1-36.
- Yılmaz, F. M. & Arabaci, O. (2021). Should deep learning models be in high demand, or should they simply be a very hot topic? A comprehensive study for exchange rate forecasting. *Computational Economics*, 57(1), 217-245.
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). Dive into deep learning. *arXiv*. <https://arxiv.org/abs/2106.11342>
- Zheng, J., Fu, X., & Zhang, G. (2019). Research on exchange rate forecasting based on deep belief network. *Neural Computing and Applications*, 31, 573-582.