



**AKSARAY ÜNİVERSİTESİ**  
**SOSYAL BİLİMLER ENSTİTÜSÜ**  
**İKTİSAT ANA BİLİM DALI**

**DÖVİZ KURU TAHMİNLEMESİNDE GELENEKSEL  
YÖNTEMLERE KARŞI MAKİNE ÖĞRENMESİ: KIRILGAN  
BEŞLİ EKONOMİLERİ İÇİN UYGULAMALAR**

**DOKTORA TEZİ**

**MUHAMMED RAŞİD BAKIR**

**DANIŞMAN**  
**PROF. DR. İBRAHİM BAKIRTAŞ**

**AKSARAY-2024**



AKSARAY ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
İKTİSAT ANA BİLİM DALI

DÖVİZ KURU TAHMİNLEMESİNDE GELENEKSEL  
YÖNTEMLERE KARŞI MAKİNE ÖĞRENMESİ: KIRILGAN  
BEŞLİ EKONOMİLERİ İÇİN UYGULAMALAR

DOKTORA TEZİ

MUHAMMED RAŞİD BAKIR

DANIŞMAN: Prof. Dr. İbrahim BAKIRTAŞ  
JÜRİ ÜYESİ: Prof. Dr. Munise ILIKKAN ÖZGÜR  
JÜRİ ÜYESİ: Doç. Dr. Kemal ADEM

AKSARAY, 2024

## TELİF HAKLARI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren on iki (12) ay sonra tezden fotokopi çekilebilir.

### YAZARIN

Adı : Muhammed Raşid

Soyadı : BAKIR

Bölümü : İktisat

İmza :

Teslim Tarihi :

### TEZİN

Türkçe Adı : Döviz Kuru Tahminlemesinde Geleneksel Yöntemlere Karşı  
Makine Öğrenmesi: Kırılgan Beşli Ekonomileri İçin  
Uygulamalar

İngilizce Adı : Machine Learning versus Traditional Methods in Exchange Rate  
Forecasting: Applications for the Fragile Five Economies

## ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduđumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiđimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduđunu beyan ederim.

Yazar Adı Soyadı: Muhammed Raşid BAKIR

İmza:

**T.C.**  
**AKSARAY ÜNİVERSİTESİ**  
**SOSYAL BİLİMLER ENSTİTÜSÜ**  
**JÜRİ ONAY SAYFASI**

Muhammed Raşid BAKIR tarafından hazırlanan “Döviz Kuru Tahminlemesinde Geleneksel Yöntemlere Karşı Makine Öğrenmesi: Kırılgan Beşli Ekonomileri İçin Uygulamalar” başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Aksaray Üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

**Danışman:** Prof. Dr. İbrahim BAKIRTAŞ  
İktisat Anabilim Dalı, Aksaray Üniversitesi

İmza

.....

**Üye:** Prof. Dr. Munise ILIKKAN ÖZGÜR  
İktisat Anabilim Dalı, Aksaray Üniversitesi

.....

**Üye:** Doç. Dr. Kemal ADEM

Bilgisayar Mühendisliği Anabilim Dalı, Sivas Cumhuriyet Üniversitesi

.....

**Üye:** Doç. Dr. Nurhan HALİSDEMİR

İstatistik Anabilim Dalı, Fırat Üniversitesi

.....

**Üye:** Doç. Dr. Mümin Atalay ÇETİN

İktisat Anabilim Dalı, Aksaray Üniversitesi

.....

Tez Savunma Tarihi: 28/06/2024

Sosyal Bilimler Enstitüsü Yönetim Kurulu’nun .../.../2024 tarih ve ..... sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Prof. Dr. Aybala ÇAYIR

İmza

## TEŞEKKÜR

Öncelikle, doktora çalışmam boyunca bana rehberlik eden kıymetli danışmanım Sayın Prof. Dr. İbrahim BAKIRTAŞ'a, engin bilgisi, tükenmez sabrı ve içten desteği için sonsuz teşekkürlerimi sunarım.

Tez İzleme Komitesi'nin saygıdeğer üyeleri, Sayın Prof. Dr. Munise ILIKKAN ÖZGÜR ve Sayın Doç. Dr. Kemal ADEM'e, değerli yorumları ve yapıcı eleştirileriyle çalışmamın gelişimine sağladıkları katkılar için teşekkür ederim. Ayrıca, jüri üyelerim Sayın Doç. Dr. Nurhan HALİSDEMİR ve Sayın Doç. Dr. Mümin Atalay ÇETİN'e, titiz incelemeleri ve değerli önerileriyle çalışmama son şeklini vermemdeki katkıları için teşekkürü borç bilirim.

Bu akademik yolculuk boyunca yanımda olan eşim Ebru BAKIR'a, sürekli desteği ve anlayışı için minnettarım. Ayrıca hayatımı zenginleştiren, neşe ve renk katan sevgili kızım Bilge BAKIR'a kalbimin en derin köşesinden teşekkür ederim.

Bu çalışmayı, özlemimi her nefesimde derinden hissettiğim sevgili babam Hasan Basri BAKIR'ın aziz hatırasına adıyorum.

## ÖZET

2013 yılında Federal Rezerv Bankası (Fed), miktarsal genişleme politikasının sona ereceğini ilan ederek küresel ekonomiyi derinden etkilemiştir. Ekonomi literatüründe "Kırılgan Beşli" (Brezilya, Endonezya, Güney Afrika, Hindistan ve Türkiye) olarak adlandırılan ülkeler, finansal sermaye akışlarına büyük ölçüde bağımlı oldukları için bu karardan ciddi şekilde etkilenmişlerdir. Finansal sermaye akışlarının temel belirleyicilerinden biri olan faiz oranlarındaki dalgalanmalar, zamanla döviz kuru oynaklığının artmasına neden olmuştur. Kırılgan Beşli ülkeleri, yüksek ithalat bağımlılıkları nedeniyle döviz kurundaki yükselişlerin yurtiçi fiyatlara olumsuz yansımaları sonucunda enflasyon hedeflerinden sapmalar yaşamaktadır. Bu sapmalar, para otoriteleri açısından güvenilirlik, kredibilite ve itibar gibi kritik sorunları beraberinde getirmekte ve makroekonomik dengeyi bozmaktadır. Bu nedenle, döviz kurlarının güvenilir tahminlerini yapmak hem para otoriteleri hem de diğer finansal aktörler için hayati önem taşımaktadır. Güvenilir tahminler enflasyon hedeflemesinin başarısını artırmak, para politikasının etkinliğini sağlamak ve makroekonomik istikrarı korumak için gereklidir. Bu bağlamda, gelişmiş tahmin yöntemlerine dayalı modellemeler yapılması, döviz kuru oynaklığının etkilerini yönetmede ve ekonomi politikalarının oluşturulma süreçlerinde yol gösterici olacaktır. Bu çalışmada, döviz kurunun gecikmeli değerleri kullanılarak tek değişkenli modeller oluşturulmuş, katı fiyatlı parasalcı model temelinde ise çok değişkenli modeller geliştirilmiştir. Tek değişkenli modellerde döviz kurunun nokta ve yön tahmini esas alınırken, çok değişkenli modellerde Dornbusch'un Hedefi Aşan Döviz Kuru modelindeki makroekonomik değişkenlerin nominal döviz kuru ile etkileşimi ve tahmin sürecine katkıları incelenmiştir. Döviz kuru tahminleri; Naïve Drift, Theta, Holt's Winter Üstel Düzleştirme, ARIMA, Ridge Regresyon, RNN, LSTM, GRU, CNN ve XGBoost yöntemleriyle gerçekleştirilmiştir. Modellemelerin her aşamasında ileri optimizasyon teknikleri kullanılmıştır. Elde edilen bulgulara göre, tek değişkenli modellerde makine öğrenmesi teknikleri hem nokta hem de yön açısından üstün başarı sergilemektedir. Benzer şekilde, döviz kurunun geçmiş değerleri modele dahil edilmese bile, çok değişkenli modellerde de makine öğrenmesi teknikleri yön açısından üstün başarı göstermektedir. Sonuç olarak; hem para otoriteleri hem de diğer finansal aktörler için, iktisadi teorilerden ve rezerv paraya sahip ülkelerin makroekonomilerinden uzaklaşmadan, ileri optimizasyon teknikleri ile makine öğrenmesi yöntemleri kullanılarak güvenilir tahminler yapılabilir.

**Anahtar Kelimeler :** Döviz Kuru Tahmini, Makine Öğrenmesi, Optimizasyon, Zaman Serileri Analizi

**Bilim Kodu** : 115305, 110603, 20516

**Sayfa Adedi** : 162

**Yazar** : Muhammed Raşid BAKIR

**Danışman** : Prof. Dr. İbrahim BAKIRTAŞ

## ABSTRACT

In 2013, the Federal Reserve Bank (Fed) profoundly impacted the global economy by announcing the termination of its quantitative easing policy. The countries referred to as the "Fragile Five" in economic literature (Brazil, Indonesia, South Africa, India, and Turkey) were severely affected by this decision due to their high dependence on financial capital flows. Fluctuations in interest rates, a key determinant of financial capital flows, have led to increased exchange rate volatility over time. The Fragile Five countries experience deviations from their inflation targets due to the adverse reflection of exchange rate increases on domestic prices stemming from their high import dependencies. These deviations bring critical issues such as reliability, credibility, and reputation for monetary authorities and disrupt macroeconomic balance. Therefore, making reliable forecasts of exchange rates is vital for both monetary authorities and other financial actors. Reliable forecasts are necessary to enhance the success of inflation targeting, ensure the effectiveness of monetary policy, and maintain macroeconomic stability. In this context, modeling based on advanced forecasting methods will guide managing the effects of exchange rate volatility and in the processes of formulating economic policies. In this study, univariate models were constructed using lagged values of the exchange rate, while multivariate models were developed based on the sticky-price monetary model. In univariate models, point and directional forecasts of the exchange rate were emphasized, while in multivariate models, the interaction of macroeconomic variables from Dornbusch's Overshooting Exchange Rate model with the nominal exchange rate and their contributions to the forecasting process were examined. Exchange rate forecasts were conducted using Naïve Drift, Theta, Holt's Winter Exponential Smoothing, ARIMA, Ridge Regression, RNN, LSTM, GRU, CNN, and XGBoost methods. Advanced optimization techniques were employed at every stage of modeling. According to the findings, machine learning techniques demonstrate superior performance in both point and directional aspects in univariate models. Similarly, even when past values of the exchange rate are not included in the model, machine learning techniques exhibit superior directional performance in multivariate models as well. In conclusion, reliable forecasts can be made for both monetary authorities and other financial actors using machine learning methods with advanced optimization techniques without departing from economic theories and the macroeconomics of reserve currency countries.

**Keywords** : Exchange Rate, Machine Learning, Optimization, Time Series Analysis  
**Science Code** : 115305, 110603, 20516  
**Number of Pages** : 162  
**Author** : Muhammed Raşid BAKIR  
**Supervisor** : Prof. Dr. İbrahim BAKIRTAŞ

## İÇİNDEKİLER

|                                                              |      |
|--------------------------------------------------------------|------|
| TELİF HAKLARI VE TEZ FOTOKOPİ İZİN FORMU .....               | i    |
| ETİK İLKELERE UYGUNLUK BEYANI .....                          | ii   |
| TEŞEKKÜR.....                                                | iv   |
| ÖZET.....                                                    | v    |
| ABSTRACT .....                                               | vi   |
| İÇİNDEKİLER .....                                            | vii  |
| TABLolar LİSTESİ.....                                        | xi   |
| ŞEKİLLER LİSTESİ.....                                        | xii  |
| KISALTMALAR.....                                             | xiii |
| GİRİŞ .....                                                  | 1    |
| BİRİNCİ BÖLÜM.....                                           | 4    |
| KÜRESEL DÖVİZ PİYASASI VE YAPISAL DÖVİZ KURU MODELLERİ ..... | 4    |
| 1.1. Küresel Döviz Piyasası .....                            | 4    |
| 1.2. Döviz Kuru Modelleri .....                              | 6    |
| 1.2.1. Satınalma Gücü Paritesi .....                         | 6    |
| 1.2.2. Faiz Oranı Paritesi .....                             | 8    |
| 1.2.2.1. Örtük Faiz Oranı Paritesi .....                     | 8    |
| 1.2.2.2. Açık Faiz Oranı Paritesi.....                       | 9    |
| 1.2.3. Parasalcı Modeller .....                              | 10   |
| 1.2.3.1. Esnek Fiyatlı Parasal Modeller .....                | 11   |
| 1.2.3.2. Katı Fiyatlı Parasal Modeller.....                  | 11   |
| 1.2.4. Taylor Kuralı Modeli.....                             | 12   |
| 1.2.5. Temel Denge Döviz Kuru Modelleri.....                 | 14   |
| 1.2.6. Davranışsal Denge Döviz Kuru Modelleri (BEER) .....   | 15   |
| 1.2.7. Kalıcı Denge Döviz Kuru Modelleri (PEER).....         | 17   |
| 1.2.8. Doğal Denge Döviz Kuru (NATREX) .....                 | 17   |
| İKİNCİ BÖLÜM .....                                           | 19   |
| ZAMAN SERİLERİ VE TAHMİN MODELLERİ .....                     | 19   |
| 2.1. Zaman Serisi Kavramı.....                               | 19   |

|                                                                       |           |
|-----------------------------------------------------------------------|-----------|
| 2.1.1. Zaman Serisi Bileşenleri.....                                  | 19        |
| 2.1.2. Durağanlık ve Birim Kök Testi .....                            | 20        |
| 2.2. Geleneksel Tahmin Yöntemleri .....                               | 21        |
| 2.2.1. Naïve Drift Yöntemi.....                                       | 21        |
| 2.2.2. Theta Yöntemi .....                                            | 21        |
| 2.2.3. Üstel Düzleştirme Yöntemi (ETS) .....                          | 22        |
| 2.2.4. Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA) ..... | 23        |
| 2.2.5. Çok Değişkenli Doğrusal Ridge Regresyon.....                   | 24        |
| 2.3. Makine Öğrenimine Dayalı Tahmin Yöntemleri .....                 | 26        |
| 2.3.1. Tekrarlayan Sinir Ağları (RNN).....                            | 27        |
| 2.3.2. Uzun- Kısa Dönem Hafıza Modeli (LSTM) .....                    | 28        |
| 2.3.3. Tekrarlayan Geçitli Birim Modeli (GRU).....                    | 29        |
| 2.3.4. Evrişimsel Sinir Ağları (CNN).....                             | 30        |
| 2.3.5. Aşırı Gradyan Artırma Modeli (XGBoost) .....                   | 32        |
| 2.4. Bayesyen Optimizasyon.....                                       | 34        |
| 2.5. Performans Ölçütleri .....                                       | 35        |
| <b>ÜÇÜNCÜ BÖLÜM .....</b>                                             | <b>37</b> |
| <b>KIRILGAN BEŞLİ DÖVİZ KURLARI ÜZERİNE UYGULAMALAR.....</b>          | <b>37</b> |
| 3.1. Giriş.....                                                       | 37        |
| 3.2. Alan Yazını .....                                                | 39        |
| 3.3. Kırılgan Beşli Ülkeler .....                                     | 41        |
| 3.3.1. Brezilya.....                                                  | 42        |
| 3.3.2. Endonezya .....                                                | 43        |
| 3.3.3. Hindistan.....                                                 | 44        |
| 3.3.4. Güney Afrika .....                                             | 45        |
| 3.3.5. Türkiye .....                                                  | 47        |
| 3.4. Analiz ve Bulgular .....                                         | 48        |
| 3.4.1. Tanımlayıcı İstatistikler.....                                 | 48        |
| 3.4.2. Veri Ön İşleme Süreci .....                                    | 49        |
| 3.4.3. Naïve Drift Tahminleri .....                                   | 50        |
| 3.4.4. Theta Tahminleri .....                                         | 51        |
| 3.4.5. Holt's Winters Üstel Düzleştirme (ETS) Tahminleri.....         | 52        |
| 3.4.6. ARIMA Tahminleri .....                                         | 53        |
| 3.4.7. RNN Tahminleri.....                                            | 55        |
| 3.4.8. LSTM Tahminleri.....                                           | 57        |

|                                                                            |           |
|----------------------------------------------------------------------------|-----------|
| 3.4.9. GRU Tahminleri .....                                                | 58        |
| 3.4.10. CNN Tahminleri .....                                               | 59        |
| 3.4.11. Ridge Regresyon Tahminleri .....                                   | 60        |
| 3.4.11.1. Brezilya için Ridge Regresyon Tahminleri .....                   | 61        |
| 3.4.11.2. Endonezya için Ridge Regresyon Tahminleri .....                  | 62        |
| 3.4.11.3. Hindistan için Ridge Regresyon Tahminleri .....                  | 63        |
| 3.4.11.4. Güney Afrika için Ridge Regresyon Tahminleri .....               | 64        |
| 3.4.11.5. Türkiye için Ridge Regresyon Tahminleri .....                    | 65        |
| 3.4.12. XGBoost Tahminleri .....                                           | 66        |
| 3.4.12.1. Brezilya için XGBoost Tahminleri .....                           | 66        |
| 3.4.12.2. Endonezya için XGBoost Tahminleri .....                          | 67        |
| 3.4.12.3. Hindistan için XGBoost Tahminleri .....                          | 68        |
| 3.4.12.4. Güney Afrika için XGBoost Tahminleri .....                       | 69        |
| 3.4.12.5. Türkiye için XGBoost Tahminleri .....                            | 70        |
| 3.4.13. Karşılaştırmalı Doğruluk Ölçütleri .....                           | 72        |
| <b>SONUÇ .....</b>                                                         | <b>76</b> |
| <b>KAYNAKÇA .....</b>                                                      | <b>80</b> |
| <b>EKLER .....</b>                                                         | <b>94</b> |
| EK 1. Naive Drift Kodu .....                                               | 94        |
| EK 2. Theta Modeli Kodu .....                                              | 97        |
| EK 3. Holts Winters Üstel Düzleştirme (ETS) Modeli Kodu .....              | 100       |
| EK 4. ARIMA Modeli Kodu .....                                              | 103       |
| EK 5. Optimize Edilmiş RNN Kodu .....                                      | 106       |
| EK 6. Optimize Edilmiş LSTM Kodu .....                                     | 111       |
| EK 7. Optimize Edilmiş GRU Kodu .....                                      | 116       |
| EK 8. Optimize Edilmiş CNN Kodu .....                                      | 121       |
| EK 9. Optimize Edilmiş Ridge Regresyon Modeli ve Gecikme Algoritması ..... | 126       |
| EK 10. Optimize Edilmiş XGBoost Modeli .....                               | 130       |
| EK 11. ARIMA Modelleri .....                                               | 134       |
| EK 12. RNN Modeli İçin Optimizasyon Parametreleri .....                    | 137       |
| EK 13. LSTM Modeli İçin Optimizasyon Parametreleri .....                   | 138       |
| EK 14. GRU Modeli İçin Optimizasyon Parametreleri .....                    | 139       |
| EK 15. CNN Modeli İçin Optimizasyon Parametreleri .....                    | 140       |
| EK 16. USDBRL İçin XGBoost Modeli Optimizasyon Parametreleri .....         | 141       |
| EK 17. USDIDR İçin XGBoost Modeli Optimizasyon Parametreleri .....         | 142       |

|                                                                   |            |
|-------------------------------------------------------------------|------------|
| EK 18. USDINR İin XGBoost Modeli Optimizasyon Parametreleri..... | 143        |
| EK 19. USDZAR İin XGBoost Modeli Optimizasyon Parametreleri..... | 144        |
| EK 20. USDTRY İin XGBoost Modeli Optimizasyon Parametreleri..... | 145        |
| <b>TEZ DEĞERLENDİRME FORMU .....</b>                              | <b>146</b> |



## TABLÖLAR LİSTESİ

|                                                                          |    |
|--------------------------------------------------------------------------|----|
| Tablo 3.1. Tanımlayıcı İstatistikler.....                                | 49 |
| Tablo 3.2. Naive Drift Modeli Tahmin Metrikleri.....                     | 50 |
| Tablo 3.3. Theta Modeli Tahmin Metrikleri.....                           | 51 |
| Tablo 3.4. ETS Modeli Tahmin Metrikleri.....                             | 52 |
| Tablo 3.5. ARIMA Modeli Tahmin Metrikleri.....                           | 54 |
| Tablo 3.6. RNN Modeli Tahmin Metrikleri.....                             | 56 |
| Tablo 3.7. LSTM Modeli Tahmin Metrikleri .....                           | 57 |
| Tablo 3.8. GRU Modeli Tahmin Metrikleri.....                             | 58 |
| Tablo 3.9. CNN Modeli Tahmin Metrikleri.....                             | 60 |
| Tablo 3.10. Brezilya için Ridge Regresyon İstatistikleri.....            | 61 |
| Tablo 3.11. Brezilya için Ridge Regresyon Performans Metrikleri .....    | 62 |
| Tablo 3.12. Endonezya için Ridge Regresyon İstatistikleri.....           | 62 |
| Tablo 3.13. Endonezya için Ridge Regresyon Performans Metrikleri .....   | 63 |
| Tablo 3.14. Hindistan için Ridge Regresyon İstatistikleri.....           | 63 |
| Tablo 3.15. Hindistan için Ridge Regresyon Performans Metrikleri .....   | 63 |
| Tablo 3.16. Güney Afrika için Ridge Regresyon İstatistikleri .....       | 64 |
| Tablo 3.17. Güney Afrika için Ridge Regresyon Performans Metrikleri..... | 65 |
| Tablo 3.18. Türkiye için Ridge Regresyon İstatistikleri.....             | 65 |
| Tablo 3.19. Türkiye için Ridge Regresyon Performans Metrikleri .....     | 65 |
| Tablo 3.20. USDBRL için XGBoost Performans Metrikleri.....               | 67 |
| Tablo 3.21. USDIDR için XGBoost Performans Metrikleri.....               | 68 |
| Tablo 3.22. USDIDR için XGBoost Performans Metrikleri.....               | 69 |
| Tablo 3.23. USDZAR için XGBoost Performans Metrikleri .....              | 70 |
| Tablo 3.24. USDTRY için XGBoost Performans Metrikleri .....              | 72 |

## ŞEKİLLER LİSTESİ

|                                                                                 |    |
|---------------------------------------------------------------------------------|----|
| Şekil 2.1. RNN Mimarisi .....                                                   | 27 |
| Şekil 2.2. LSTM Mimarisi .....                                                  | 28 |
| Şekil 2.3. GRU Mimarisi .....                                                   | 30 |
| Şekil 2.4. CNN Mimarisi .....                                                   | 31 |
| Şekil 3.1. Brezilya Makroekonomik Görünüm.....                                  | 42 |
| Şekil 3.2. Endonezya Makroekonomik Görünüm.....                                 | 44 |
| Şekil 3.3. Hindistan Makroekonomik Görünüm.....                                 | 45 |
| Şekil 3.4. Güney Afrika Makroekonomik Görünüm .....                             | 46 |
| Şekil 3.5. Türkiye Makroekonomik Görünüm.....                                   | 47 |
| Şekil 3.6. Naive Drift Modeli Tahminleri.....                                   | 50 |
| Şekil 3.7. Theta Modeli Tahminleri .....                                        | 52 |
| Şekil 3.8. ETS Modeli Tahminleri .....                                          | 53 |
| Şekil 3.9. ARIMA Modeli Tahminleri.....                                         | 54 |
| Şekil 3.10. RNN Modeli Tahminleri.....                                          | 56 |
| Şekil 3.11. LSTM Modeli Tahminleri .....                                        | 58 |
| Şekil 3.12. GRU Modeli Tahminleri.....                                          | 59 |
| Şekil 3.13. CNN Modeli Tahminleri.....                                          | 60 |
| Şekil 3.14. USDBRL için Makroekonomik Değişkenlerin Önem Düzeyleri.....         | 66 |
| Şekil 3.15. USDIDR için Makroekonomik Değişkenlerin Önem Düzeyleri.....         | 68 |
| Şekil 3.16. USDINR için Makroekonomik Değişkenlerin Önem Düzeyleri.....         | 69 |
| Şekil 3.17. USDZAR için Makroekonomik Değişkenlerin Önem Düzeyleri.....         | 70 |
| Şekil 3.18. USDTRY için Makroekonomik Değişkenlerin Önem Düzeyleri.....         | 72 |
| Şekil 3.19. Tüm Modeller İçin Çoklu Performans Karşılaştırmaları .....          | 73 |
| Şekil 3.20. Tüm Modeller İçin Çoklu Performans Karşılaştırmaları (Devamı) ..... | 74 |

## KISALTMALAR

|                |                                                                                        |
|----------------|----------------------------------------------------------------------------------------|
| <b>AIC</b>     | : Akaike Bilgi Kriteri (Akaike Information Criterion)                                  |
| <b>ANN</b>     | : Yapay Sinir Ağı (Artificial Neural Network)                                          |
| <b>ARIMA</b>   | : Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average) |
| <b>BEER</b>    | : Davranışsal Denge Döviz Kuru (Behavioral Equilibrium Exchange Rate)                  |
| <b>BIC</b>     | : Bayesyen Bilgi Kriteri (Bayesian Information Criterion)                              |
| <b>CIRP</b>    | : Örtük Faiz Oranı Paritesi (Covered Interest Rate Parity)                             |
| <b>CNN</b>     | : Evrişimli Sinir Ağı (Convolutional Neural Network)                                   |
| <b>ETF</b>     | : Borsa Yatırım Fonu (Exchange Traded Fund)                                            |
| <b>ETS</b>     | : Hata-Trend-Mevsimsellik (Error-Trend-Seasonality)                                    |
| <b>FED</b>     | : Amerika Merkez Bankası (Federal Reserve)                                             |
| <b>FEER</b>    | : Temel Denge Döviz Kuru (Fundamental Equilibrium Exchange Rate)                       |
| <b>GRU</b>     | : Geçitli Tekrarlayan Birim (Gated Recurrent Unit)                                     |
| <b>IRP</b>     | : Faiz Oranı Paritesi (Interest Rate Parity)                                           |
| <b>LSTM</b>    | : Uzun Kısa Dönem Hafıza (Long Short Term Memory)                                      |
| <b>MAPE</b>    | : Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)                          |
| <b>MDA</b>     | : Ortalama Yönsel Doğruluk (Mean Directional Accuracy)                                 |
| <b>ML</b>      | : Makine Öğrenmesi (Machine Learning)                                                  |
| <b>MLP</b>     | : Çok Katmanlı Algılayıcı (Multi Layer Perceptron)                                     |
| <b>NATREX</b>  | : Doğal Denge Döviz Kuru (Natural Real Exchange Rate)                                  |
| <b>PEER</b>    | : Kalıcı Denge Döviz Kuru (Permanent Equilibrium Exchange Rate)                        |
| <b>PPP</b>     | : Satınalma Gücü Paritesi (Purchasing Power Parity)                                    |
| <b>RMSE</b>    | : Kök Ortalama Karesel Hata (Root Mean Square Error)                                   |
| <b>RNN</b>     | : Tekrarlayan Sinir Ağı (Recurrent Neural Network)                                     |
| <b>SIC</b>     | : Schwarz Bilgi Kriteri (Schwarz Information Criterion)                                |
| <b>SVR</b>     | : Destek Vektör Regresyonu (Support Vector Regression)                                 |
| <b>UIRP</b>    | : Açık Faiz Oranı Paritesi (Uncovered Interest Rate Parity)                            |
| <b>VIX</b>     | : Oynaklık Endeksi (Volatility Index)                                                  |
| <b>XGBoost</b> | : Aşırı Gradyan Artırma (Extreme Gradient Boosting)                                    |

## GİRİŞ

Döviz kuru, bir ülkenin iç ve dış dengesini farklı kanallarla doğrudan veya dolaylı olarak etkileyen temel makroekonomik değişkenlerden biridir. Döviz kurundaki hareketlilik dış ticaret dengesini, uluslararası rekabet gücünü, fiyat düzeylerini, enflasyon kontrolünü, yabancı yatırımları ve sermaye akımlarını doğrudan; maliyetlerdeki artış etkisiyle toplam çıktıyı, işsizliği, ekonominin üretim kapasitesini ve fiyat düzeylerinde meydana getirdiği oynaklıkla para talebi ve arzını dolaylı olarak etkilemektedir. Ayrıca döviz kuru uluslararası arenada ülkenin para ve mali otoritelerinin kredibilitesini, güvenilirliğini ve itibarını da belirler ve etkiler. Döviz kuru hareketlerinin makroekonomik göstergeler üzerindeki doğrudan veya dolaylı etkilerine ilişkin tartışmalar günümüzde de önemini korumaktadır. Mevcut araştırmalardan iki önemli sonuç çıkmaktadır. İlk olarak, efektif döviz kuru ile dış ticaret dengesi arasındaki ilişkiye odaklanan teorik modeller, dışa açık ekonomilerde uygulanacak farklı politikaların reel ve nominal değişkenleri nasıl etkileyebileceğini göstermektedir. İkinci olarak, 1990'lardan itibaren finansal küreselleşmenin etkisiyle hem kamu hem de özel sektörün yabancı para cinsinden yaptıkları işlemler, brüt döviz rezervlerindeki değişim nedeniyle volatilité yaratmaktadır. Bu durum hem politika yapıcılar hem de araştırmacılar için önemli bir çalışma alanı oluşturmaktadır.

2023 itibariyle tüm finansal aktörlerin döviz piyasalarında gerçekleştirdiği günlük işlem hacmi 7,5 trilyon doları aşmaktadır. Bu devasa parasal büyüklük, sisteme bütünleşik tüm ülkelere ve o ülkelerdeki ekonomik ve politik aktörlere risk yüklemektedir. Döviz kurundaki oynaklık, ulusal ekonomilerin iktisadi dengesini, sermaye akımlarını, borç servisini, rekabet gücünü ve hatta güvenlik politikalarını derinden etkilemektedir. Döviz kurundaki oynaklık, hükümetlerden hanehalkına kadar her düzeydeki karar verici aktör için bir risk anlamına gelmektedir. Bu nedenlerden dolayı, politika yapıcılar için iç ve dış şokların yanında finansal piyasalara yönelik farklı düzenlemelerin döviz kurundaki hareketlerin mikro ve makro düzeyde ekonomiyi ve iktisadi ajanların kararlarını nasıl ve hangi kanallardan etkilediğini anlamak hayati öneme sahiptir. Riskini minimize etmek isteyen her düzey aktör için en önemli husus, döviz kurunu en doğru şekilde tahmin etmektir. Yabancı para cinsinden varlık ve yükümlülüklerin yanı sıra dış ticaret açığının ve dış ticaretin yapısının her bir kanalın

görelî gücünü belirlemedeki rolünü anlamak ve böylece döviz kuru hareketlerinin ekonomi üzerindeki genel etkisini tespit etmek ve politikalar geliştirmek için, yapay zekâ ve veri yönetimindeki gelişmeleri içselleştirecek şekilde, yapısal tahmin modellerine ve çözümlemelerine ihtiyaç vardır. Döviz kuru tahminleri, iktisadi teorileri temel alarak çok değişkenli boyutta yapılabildiği gibi, sadece döviz kurunun kendi gecikmeli değerleri ile de gerçekleştirilebilmektedir. Meese ve Rogoff (1983), döviz kuru teorilerine dayanan tahmin modellerinin rassal yürüyüş modellerine kıyasla daha iyi performans göstermediğini ve yapısal modellere dayalı ekonomik teorilerin örneklem dışı tahminler olmaması nedeniyle gerçek yaşamda güçlü bir karşılığı olmadığını ileri sürmektedir. Meese ve Rogoff (1983)'e göre, döviz kurunun bir dönem sonraki tahmininin en etkin tahmin edicisi döviz kurunun cari değeridir. Bu sonuç, iktisat yazınında "Meese ve Rogoff bulmacası" olarak isimlendirilmektedir.

Günümüz bilişim teknolojilerindeki gelişmeler, tüm disiplinlerde olduğu gibi ekonomi alanında da kendine yer edinmektedir. Bu gelişmeler, makroekonomik değişkenler arası etkileşimleri ve bu değişkenlere ilişkin tahminleri, geleneksel metotların doğruluğu ve iktisadi teorilerin geçerliliğine dair tartışmaları da beraberinde getirmektedir. İktisat teorilerinin tahminden çok nedensel ilişkileri ön planda tutması, uygulamalı araştırmaların tahmin başarısını azaltmaktadır. Günümüz teknolojik gelişmelerine de uyum sağlayacak şekilde hem ekonomik teorileri hem geleneksel istatistiksel ve ekonometrik yöntemleri hem de makine öğrenmesi yöntemlerini kullanarak teorik hatalardan uzak tahminler üretmek suretiyle bu sorunun nasıl aşılabileceğini sorgulamak bu tezin ana motivasyonudur

Bu tezin amacı, döviz kuru için doğru tahminler üretmek ve bu bağlamda iktisadi teoriler ile modern veri bilimi tekniklerini bir araya getirmektir. Bu amaç doğrultusunda, hedeflenen iktisadi teoriler ve makine öğrenimi yöntemlerinin kombinasyonu ile daha sağlam ve güvenilir tahminler üretilabilmektedir. Bu çalışmanın, döviz kuru tahminlerinin yanı sıra diğer makroekonomik değişkenlerin tahmininde de yeni ufuklar açması beklenmektedir.

Bu tez çalışması üç bölümden oluşmaktadır. İlk bölümde, küresel döviz piyasası ve döviz kurunun belirlenmesine yönelik yapısal modeller açıklanmaktadır. İkinci bölümde, bu çalışmada kullanılacak olan istatistiksel, ekonometrik ve makine öğrenmesine dayalı tahmin modellerinin matematiksel arka planına yer verilmektedir. Çalışmanın üçüncü bölümünde, makine öğrenmesinin tahmin bilimi için önemi, ekonomik araştırmalar ile kesişimi, Fed'in 2013 yılındaki politika değişimi ve kırılmalı beşli ülke tanımının doğuşu ve bu ülkelere ilişkin makroekonomik görünümle ele alınmaktadır. Daha sonra bu alanla ilgili literatür

incelenmekte ve döviz kuru tahminleri, optimizasyona dayalı olarak tek değişkenli ve çok değişkenli modeller yardımıyla, örneklem dışı (out of sample) olarak yapılmaktadır. Çalışmanın son kısmında ise, tüm modeller analitik bir çerçevede değerlendirilmekte ve ekonomik aktörlere olası yansımaları tartışılmaktadır.



## **BİRİNCİ BÖLÜM**

### **KÜRESEL DÖVİZ PİYASASI VE YAPISAL DÖVİZ KURU MODELLERİ**

#### **1.1. Küresel Döviz Piyasası**

Küresel döviz piyasası konvertible bir para biriminin başka bir konvertible para birimiyle veya diğer konvertible para birimleriyle değiştirildiği piyasadır. Bir konvertible para biriminin bir başka konvertible para birimine dönüştürülme işlemi nedeniyle bu piyasa döviz (exchange) piyasası denilmektedir. Küresel döviz piyasasındaki işlemler genel olarak uluslararası mal ve hizmet ticareti, uluslararası finansal ödemeler ve borçlanma gibi ticari nedenlerle yapılır. Döviz piyasaları sadece tüccarları ya da finans uzmanlarını değil, çeşitli ülkelerde faaliyet gösteren çok uluslu şirketlerden uluslararası seyahat eden turistlere, hükümetlerden hane halklarına kadar, neredeyse küresel ölçekte herkesi, ilgilendirmekte ve etkilemektedir. 2022 yılında küresel ölçekte döviz piyasasının ortalama günlük işlem hacmi 7,5 trilyon dolar düzeyindedir ve bu işlem hacminin %23'ünden fazlası EURUSD paritesi üzerinden gerçekleşmektedir (Jones & John, 2022). Küresel piyasalarda ödemeler genellikle bir aracı kurum vasıtasıyla elektronik ortamda gerçekleşir. Küresel piyasalardaki toplam işlem hacminin %57'sinden fazlası Amerika Birleşik Devletleri ve İngiltere merkezli aracı kurumlar üzerinden takas edilmektedir (Melvin & Norrbın, 2023). Ulus devletler veya kendi paralarını benimseyen Avrupa Birliği gibi bölgesel oluşumlar varlığını devam ettirdiği sürece döviz piyasaları ulusal, uluslararası veya çokuluslu firmaların, hükümetlerin, hane halklarının ticari ve ticari olmayan hatta bazen de siyasi ihtiyaçlarına hizmet etmeye devam edecektir (Wang, 2005). Aynı zamanda döviz ödemelerinin yapılmasında karşılaşılabilecek bir sorun küresel ticaret, küresel finans ve uluslararası bankacılık sisteminde ciddi sorunlar ve ekonomide ani dalgalanmalara neden olacaktır (Kodres, 1996).

Döviz piyasası küresel finans piyasasının en eski, en büyük ve en kapsamlı piyasasıdır. Modern döviz piyasasının temelleri 1880-1914 yılları arasındaki altın standardında

atılmıştır. Bu sistemde döviz piyasasında kur otomatik-sabit olarak belirlenir. Bu sistemde referans ülkelerin para birimleri bir ons altına göre tanımlanmış ve ülkeler arası döviz işlemleri bu oranlar üzerinden yapılmıştır. Altın standardı sistemi ödemeler dengesindeki dalgalanmalar karşısında üye ülkelere dalgalanmayı hızlıca dengeleyebilme ve enflasyonun geçiş etkisini (pass-through effect) kolaylıkla kontrol edilebilme yeteneği sağlamıştır. Bu standartta, devlet uluslararası ticaretten ziyade altın rezervlerinin yönetimi üzerinde etkin role sahiptir. Bu sistemde temel iktisat politikası aracı rezerv yönetimi olup, o dönem için etkin olarak kullanılmıştır. Ancak ülkelerdeki milliyetçilik akımları ve Birinci Dünya Savaşı'nın başlaması, ülkelerin askeri harcamalarını kâğıt para basmak suretiyle finanse etmesi gibi yoğun devlet müdahaleleri, altın rezerv yönetimindeki bozulmalar, reel üretimdeki düşüş, İngiliz sterlinindeki yüksek oynaklık ve kurlar üzerindeki spekülasyon ataklar rezerv yönetimini etkinsizleştirirken, konvertibilite sorunları İngiltere'nin öncülüğünde birçok ülkeyi, dalgalı kur rejimine geçmeye zorlamış ve altın standardı 1931 yılında çökmüştür (Eichengreen, 1996; Bordo & Siklos, 2014).

İkinci Dünya Savaşı'nın sonuna kadar küresel ölçekte rezerv para birimi İngiliz sterlini olmuştur. Ancak ekonomisi savaştan ciddi manada etkilenen İngiltere, ABD'nin hem askeri, hem siyasal, hem de ekonomik anlamda lider konuma geçmesiyle birlikte döviz piyasasındaki hegemonik gücünü kaybetmiş, Amerikan doları (USD) rezerv para olma özelliğini güçlendirmiş ve tüm dünyada “çıpa” olarak kullanılmaya başlanmıştır (Wright, 1954). İkinci Dünya Savaşı'nın bitmesiyle birlikte 1944 yılında ABD'nin Bretton Woods kasabasında ekonomik, finansal ve politik açıdan küresel sistemin yeniden oluşturulması için çok önemli kararlar alınmıştır ve sürecin yönetiminde görev alacak Uluslararası Para Fonu (IMF) ve Birleşmiş Milletler (UN) gibi uluslararası örgütler kurulmuştur. Bretton Woods ile döviz piyasası da sisteme üye ülkeler için yeniden tasarlanmıştır. Bu sistemde üye ülkelerin para birimleri belirli bir değere göre USD'ye, USD ise altına sabitlenmiştir. ABD'nin bu sistemdeki sorumluluğu konvertibl yükümlülüğünü yerine getirmektir. ABD dışındaki dolar rezervinin, ABD'deki altın stokunu aşması sonucunda 1971 yılından itibaren küresel bir hiperenflasyon dalgası yaşanmaya başlanmış ve ABD konvertibl yükümlülüğünü yerine getirememeye başlamıştır. Dönemin ABD başkanı Richard M. Nixon, karşı karşıya kaldığı politik zorlukları da gerekçe göstererek, konvertibl yükümlülüğünü tek taraflı olarak iptal etmiştir. Küresel ekonomik ticarete bağlı olarak uluslararası barışın kaynağı olarak görülen ve liberal düşüncenin sistemsal bir parçası olan Bretton Woods 1973 yılında çökmüş ve

birçok ülke dalgalı kur rejimine geçmiştir (Akan, 2010; Goldstein vd.,1983; Shafer vd., 1983; Sönmez, 2016).

Bu tarihten itibaren döviz kuru piyasadaki arz ve talebe bağlı olarak belirlenmiştir. Günümüzde döviz üzerinden yapılan işlemler dünyadaki tüm hisse senedi piyasasının hacminden daha büyüktür ve küresel finans piyasasındaki her işlem son aşamada bir döviz takas işlemiyle sonlanmaktadır. 2022 yılı sonu itibariyle USD çaprazında yer alan döviz tabanlı finansal varlık sayısı 50'nin üzerindedir. Bu faaliyetlerin çoğu ETF (Electronic Traded Fund) tabanlı OTC (Over The Counter, tezgahüstü) piyasada gerçekleşmektedir. Kurlar Türkiye saati ile 03:55'te Tokyo'da, saat 16:15'te Avrupa Merkez Bankası'nda, saat 18:00'da New York'da ve saat 19:00'da WMR (WM Reuters Company) tarafından sabitlenmektedir. Bu sabitleme anlarında döviz kurunda yüksek volatiliteler gerçekleşmektedir (Chaboud vd., 2023).

Ekonomi alanındaki bu köklü dönüşüm birçok iktisatçıyı döviz kurunu tahmin etmeye yönelik teoriler geliştirme konusunda motive etmiştir. Bu motivasyon sonucunda iktisatçılar tarafından geliştirilen teoriler doğrusal ve doğrusal olmayan yöntemlerle analiz edilmiştir. Döviz kuru tahminleri başlangıçta Fama (1965), Cornell (1977), Hsieh (1984) gibi öncü isimlerce etkin piyasalar varsayımı altında; Giddy & Dufey (1975), Hakkio & Rush (1989) gibi isimlerce basit rassal yürüyüş modelleri kullanılarak yapılmıştır. Temel makroekonomik değişkenlerin kullanıldığı tahminlerin öncü isimleri ise Dornbusch, 1976; Frankel, 1979; Meese & Rogoff, 1983'tur. 1990'lı yıllardan sonra ekonometrik ve istatistiksel modellerin gelişimi ve istatistiksel verilerin daha sık ve sistematik bir şekilde derlenmesiyle birlikte, doğrusal olmayan modeller kurgulanmış ve döviz kuru bu modeller yardımıyla tahmin edilmiştir. Doğrusal olmayan modeller yardımıyla döviz kurunun tahmin etme girişimindeki öncü isimler Brooks (1996), Liew ve diğerleri (2004), Taylor & Peel (2000)'dir. Son yıllarda, doğrusal ve doğrusal olmayan döviz kuru tahmin modellerine stokastik süreçlerin de dahil edilmesiyle, modeller daha karmaşık hale gelmiştir.

## **1.2. Döviz Kuru Modelleri**

### **1.2.1. Satınalma Gücü Paritesi**

Satınalma gücü paritesini (PPP) sistematik bir çerçeveye yerleştiren, ilk olarak teorik ve uygulamalı analizini yapan İsveçli ekonomist Gustav Cassel'dir. Cassel, Milletler Cemiyeti için hazırladığı raporda Birinci Dünya Savaşı'ndan sonra, savaşın mali yükü ve savaş

tazminatından doğan yükümlülüklerin, sadece savaşa katılan ülkelerin değil, sömürge ülkelerin de ekonomik ve mali yapısını bozduğundan hareketle, döviz kurlarının ülkeler arasındaki fiyat düzeylerindeki farklılıklar esas alınarak belirlenmesi gerektiğini savunmuştur. Cassel'in asıl amacı, uluslararası ticareti daha adil ve sürdürülebilir kılacak ve arbitraj fırsatlarının önleyebilecek bir döviz piyasası dengesinin nasıl sağlanabileceğini açıklamak olmuştur. PPP, Birinci Dünya Savaşı sonrasında ülkelerin altın standardına dönerken referans kurların değerinin nasıl belirleneceğini açıklamak için geliştirilmiştir. Cassel (1918)'e göre iki ülke arasındaki döviz kuru, o ülkelerdeki göreceli fiyat değişimi oranlarının doğrusal bir fonksiyonudur. Bu açıklama, Tek Fiyat Yasası üzerine inşa edilmiştir. Tek Fiyat Yasası, birçok alıcı ve satıcının bulunduğu, uluslararası ticaret sınırlamalarının olmadığı ve bilgiye erişimin bir maliyetinin bulunmadığı rekabetçi bir piyasada, homojen bir mal veya hizmetin fiyatının tüm ülkelerde aynı olması idealine dayanmaktadır. Tek fiyat yasasının genel fiyat düzeylerine uyarlanması Mutlak PPP; döviz kurundaki değişimlerin, enflasyon farklarına göre belirlenmesi ise Nispi PPP olarak adlandırılmaktadır (Cassel, 1918; Sarno & Taylor, 2001; Lafrance & Schembri, 2002). Tek Fiyat Yasası, Mutlak PPP ve Nispi PPP matematiksel olarak (1.1), (1.2) ve (1.3) eşitlikleriyle özetlenmektedir.

$$P_{i,t} = S_t P_{i,t}^* \quad i = 1, 2, \dots, N \quad (1.1)$$

Tek fiyat yasasının matematiksel olarak gösterildiği (1.1) numaralı eşitlikte,  $P_{i,t}$ , i malının t zamanında yerel para birimi cinsinden fiyatını,  $P_{i,t}^*$ , i malının t zamanında yabancı para cinsinden fiyatını,  $S_t$  ise nominal döviz kurunu ifade etmektedir.

$$\sum_{i=1}^N \alpha_i P_{i,t} = S_t \sum_{i=1}^N \alpha_i P_{i,t}^* \quad i = 1, 2, \dots, N \quad (1.2)$$

(1.2) numaralı eşitlikte Mutlak PPP formülize edilmiştir. Eşitlikteki  $\alpha$  katsayıları ürünlerin toplamsal ağırlıklarını belirtmektedir. Genellikle bu oran 1'e eşittir ve nominal döviz kuru iki ülkenin fiyat düzeylerinin oranına eşittir. Logaritmik formda ise  $S_t = P_{i,t} - P_{i,t}^*$  olarak ifade edilebilir.

$$\frac{P_{i,t}^* S_{t+1}}{P_{i,t+1}} = \frac{P_{i,t}^* S_t}{P_{i,t}} \quad i = 1, 2, \dots, N \quad (1.3)$$

$$\frac{P_{i,t}^* S_{t+1}}{P_{i,t+1}} = \frac{P_{i,t}^* S_t}{P_{i,t}} \quad i = 1, 2, \dots, N \quad (1.3)$$

(1.3) numaralı eşitlikten de anlaşılacağı üzere, Nispi PPP'nin geçerli olduğu bir durumda, iç piyasada oluşan fiyat düzeylerindeki yukarı yönlü bir sapma kadar, yerel para biriminin değerinin düşürülmesi gerekmektedir. Döviz piyasası farklı ülkelerdeki piyasa oyuncularının satın alma gücünü transfer etme arzusunun göre işlemektedir. Bu nedenle PPP ampirik olarak günümüz döviz piyasasının işleyişini açıklamada önemli eksikliklere sahip olsa da, döviz piyasasının felsefesini anlamak açısından oldukça önemlidir.

### **1.2.2. Faiz Oranı Paritesi**

Faiz oranı paritesi (IRP) teorisi veya diğer ismiyle Varlık Yaklaşımı'na göre spot döviz kurlarındaki hareketlenmenin temel nedeni; tam ikame finansal varlıkların getiri oranlarının ülkeden ülkeye farklılık göstermesidir. Başka bir ifadeyle, bu teoriye göre bir ülkenin mali hesabındaki işlemler döviz piyasasındaki kurları belirlemektedir. IRP'nin bu temel savı, döviz kurundaki değişikliklerin ithalatçı ve ihracatçıların işlemlerine dayandığını savunan PPP ile çelişmektedir. Döviz piyasasında önemli bir rol üstlenen IRP, yabancı para birimindeki vadeli prim veya iskonto büyüklüğünün, karşılaştırma yapılan ülkelerin spot ve vadeli faiz oranları arasındaki farka eşit olduğu gerçeğini vurgulamaktadır. Teoriye göre faiz farklılıkları ortadan kalkıncaya kadar arbitraj devam etmektedir. İki ülkedeki faiz oranları eşitlendiğinde arbitraj olanağı ortadan kalkmaktadır ve denge döviz kuru belirlenmektedir. Bretton Woods sisteminin çöküşü, PPP'nin döviz kurunun denge değerinden yüksek sapmalar göstermesi, bu teorinin geliştirilmesinde etkin rol oynamıştır. Faiz oranı paritesi teorisi iki alt teoriden oluşmaktadır. Bunlar; örtük (kapsanmış) ve açık (kapsanmamış) faiz oranı pariteleridir.

#### **1.2.2.1. Örtük Faiz Oranı Paritesi**

Örtük faiz paritesi (CIRP) teoremi, farklı para birimleri cinsinden iki özdeş varlık arasındaki örtülü faiz farkının sıfır olması gerektiğini belirtir. Eğer örtülü faiz farkı sıfırdan saparsa, bu durum risksiz arbitraj fırsatları yaratacaktır. Teoreme göre döviz forward primi ilgili iki para birimi arasındaki faiz oranı farkına eşittir. CIRP teoremi birçok alıcı ve satıcının olduğu, risk ve vade yapılarının homojen olduğu, bilgiye erişimin ve yapılan işlemlerin herhangi bir maliyetinin olmadığı, sermaye hareketlerinin serbest olduğu koşullarda iki ülkeye ait finansal varlık getirilerinin aynı olduğu varsayımları üzerine inşa edilmiştir. CIRP sayesinde, döviz kurlarında meydana gelebilecek spekülasyon ataklarının etkileri, vadeli döviz opsiyon sözleşmeleri sayesinde yumuşatılabilmektedir. Günümüzde çok sayıda yatırımcı döviz kuru

riskinden kaçınmak için faiz arbitrajını güvenilir bir liman olarak görmektedir. Örneğin, Türkiye’de faaliyet gösteren uluslararası bir şirket, risklerini sigortalamak (hedge) için elindeki TL karşılığı kadar USD alıp yabancı hazine bonolarını satın alırsa, vade sonuna kadar faiz ve vade sonunda TL’nin USD’ye karşı değer kaybettiği varsayımı ile bir miktar döviz kazancı elde eder. Bu nedenle spot kur ve vadeli kur arasında ciddi farklar oluşabilmektedir. CIRP en yalın haliyle (1.4) numaralı eşitlikle ifade edilebilir.

$$\frac{1 + i_t}{1 + i_t^*} = \frac{F_t}{S_t}$$

$$\ln\left(\frac{1 + i_t}{1 + i_t^*} - 1\right) = \ln\left(\frac{F_t}{S_t} - 1\right)$$

$$f - s = \Delta s_{t+1} = i - i^* \quad (1.4)$$

(1.4) numaralı eşitlikte  $f$  logaritmik formda forward kuru,  $s$  logaritmik formda spot kuru,  $i$  ve  $i^*$  sırasıyla yurtiçi ve yurtdışı repo faiz oranlarını,  $\Delta s_{t+1}$  ise spot ve vadeli kur arasındaki yüzdesel değişimi göstermektedir.  $f - s$  değeri,  $i - i^*$  değerinden büyükse, yatırımcıların yurtdışında yatırım yapmaları, tersi durumda ise yurtiçinde yatırım yapmaları daha kazançlı olmaktadır. CIRP yaklaşımına göre bu işlemler bir süre boyunca sınırsız arbitraj yoluyla devam etmekte ve vade sonunda getiriler eşitlenmektedir (Taylor, 1987a; Devereux, 1997; MacDonald, 2007; Salvatore, 2019).

Frenkel & Levich (1975) CIRP’a eleştirel bir katkıda bulunmuştur. Frenkel ve Levich, yatırımcıların işlem maliyetlerinin yok sayılamayacağını ve yatırım kararlarının işlem maliyetlerini göz önüne alınarak yapılmasını savunmaktadırlar. Frenkel ve Levich,  $C = \sum_{i=1}^4 c_i$  olmak üzere, yatırımcıların dört tip işlem maliyeti ile karşı karşıya kalacaklarını ileri sürmektedirler. Bu maliyetler,  $c_1$ : Yurtiçi finansal varlığın satış maliyeti,  $c_2$ : Spot döviz alım maliyeti,  $c_3$ : Yabancı finansal varlığın alım maliyeti,  $c_4$ : Forward kur satış maliyetidir. Frenkel ve Levich’e göre bu dört tip maliyet eğer  $f - s$  farkından büyükse, dış aleme yatırım yapılabilir. Aksi durumda yatırımlar ülke içinde yapılmalıdır.

#### 1.2.2.2. Açık Faiz Oranı Paritesi

Açık döviz kuru paritesi (UIRP), makroekonomi ve uluslararası finans yazınında oldukça ihtilafa neden olan bir yaklaşımdır. Bu yaklaşımda, gelecekteki nominal döviz kurundaki değişim, iki ülke arasındaki nominal faiz farkına eşit olacaktır. Fama’nın etkin piyasa hipotezinin geçerli olduğu, işlem ve bilgiye erişim maliyetlerinin olmadığı, yatırımcıların risk nötr ve rasyonel beklentilere sahip oldukları, sermaye hareketliliğinin mükemmel

olduğu, finansal enstrümanların birbirine tam ikame oldukları varsayımları altında, iki ülke arasındaki faiz farkları, spot kurdaki değişimin yansız tahmin edicisidir. UIRP temel olarak ülkeler arası fon transferinin faiz oranları üzerindeki etkileşimine göre hareket etmektedir. Fonların, faizin düşük olduğu ülkelere yüksek olduğu ülkelere hareketi nedeniyle, fonun çıkışı yaptığı ülkede faiz oranları yükselmekte ve yerel para birimi değer kazanmaktadır. Bu döngüsel hareket sonucunda döviz kurları bir süre sonra denge değerine kavuşmaktadır (Flood & Rose, 2002; Chinn & Meredith, 2004; Bekaert vd., 2007; Lily vd., 2012; Baillie vd., 2023).

Bu açıklamalar ışığında UIRP eşitlik (1.5) ile ifade edilebilir.

$$\Delta s_{t+1} = \beta_0 + \beta_1(i - i^*) + \varepsilon_t \quad (1.5)$$

Eşitlik (1.5)'te  $\Delta s_{t+1}$  spot kurdaki değişimi,  $i$  yurtiçi nominal faiz oranını,  $i^*$  yurtdışı nominal faiz oranını ifade etmektedir. Eşitlikte  $\beta_0=0$  ve  $\beta_1=1$  durumu UIRP koşulunun geçerli olduğunu göstermektedir. Ancak yapılan birçok ampirik çalışmada  $\beta_1 < 0$  durumu ile karşılaşılmaktadır. Bu durum literatürde prim anomalisi olarak tanımlanmaktadır (Baillie & Kiliç, 2006; Kaminsky & Peruga, 1990).  $\beta_1 < 1$  veya  $\beta_1 > 1$  olması döviz piyasasında tam bilginin olmadığı, piyasanın yüksek volatiliteye maruz kalabileceğine işaret etmektedir (Taylor, 1987b).

### 1.2.3. Parasalcı Modeller

Döviz kurunun belirlenmesine yönelik IRP yaklaşımı, döviz kurunu yerli ve yabancı varlıkların göreceli arz ve talebini dengeleyecek şekilde ayarlanan uluslararası varlıkların fiyatı olarak tanımlamaktadır. Bu yaklaşım, mal ve hizmet ticaretinden kaynaklanan döviz işlemlerini, döviz kurunun temel belirleyicisi olarak kabul eden geleneksel görüşe kıyasla varlık piyasalarının ve varlık piyasasında oluşan dengenin döviz kuru üzerindeki rolünü açıklamaktadır. Parasalcı yaklaşımın temel varsayımı ise tam sermaye hareketliliğidir. Yani sermaye akımlarında herhangi bir engel, işlem maliyeti ve sermaye kontrolü yoktur. Ayrıca yerli ve yabancı tahvillerin tam ikame olduğu varsayılır. Portföyler yurtiçi ve yurtdışı faiz oranında anında uyum sağlayacak ve yurtiçi nominal faiz oranı, yabancı faiz oranı artı yerel para biriminin beklenen değer kaybı oranına eşit olacaktır. Portföylerin anında ayarlanmasıyla uluslararası sermaye piyasaları tek bir pazarda birleşmektedir. Bu durum nihayetinde para piyasalarını, döviz kurunun ana belirleyicisi olarak ön plana çıkarmaktadır

### 1.2.3.1. Esnek Fiyatlı Parasal Modeller

Parasalcı modeller, döviz kurunun, iki ülkedeki nispi para talebi ve arzına göre belirlendiği varsayımına dayanır. Parasalcı modellerin öncü isimleri Frenkel (1976) ve Mussa, (1976)'dır. Bu yaklaşıma göre uzun vadeli para piyasası aşağıdaki eşitliklerde belirtildiği gibi dengeye gelmektedir:

$$m_t = p_t + ky_t - hi_t \quad (1.6)$$

$$m_t^* = p_t^* + ky_t^* - hi_t^* \quad (1.7)$$

Eşitlik (1.7), (1.6) numaralı eşitlikten çıkarıldığında,

$$p_t - p_t^* = m_t - m_t^* - k(y_t - y_t^*) + h(i_t - i_t^*) \quad (1.8)$$

elde edilmektedir. UIP koşulundan, yani eşitlik (1.4), (1.8) numaralı eşitlikte yerine yazılırsa,

$$\Delta s_{t+1} = m_t - m_t^* - \beta_2(y_t - y_t^*) + \beta_3(i_t - i_t^*) \quad (1.9)$$

elde edilir. Eşitliklerdeki  $k$  ve  $h$  sırasıyla para talebinin gelir esnekliğini ve para talebinin faiz esnekliklerini gösteren katsayılarıdır. Yurtiçi ve yurtdışında bu katsayıların benzer veya eşit oldukları varsayılarak 1 kabul edilmektedir (Frankel, 1984). (1.9) numaralı eşitlik para piyasalarına ilişkin önemli kanıtlar sunmaktadır. Bu denkleme göre nominal döviz kuru, göreceli para arzı fazlası tarafından sürüklenmektedir. Para talebi sabit tutulduğunda, yurtiçi para arzının yabancı karşılığına göre artması, yerel para biriminde bu oranda değer kaybına neden olmaktadır. Çıktı seviyeleri ve faiz oranındaki değişiklikler, ancak para talebi etkisi yoluyla döviz kurunu etkilemektedir. Yurtiçi gelirin, yurtdışı gelire göre artması, diğer koşullar sabitken yerel para biriminin değer kazanmasına yol açarken, yurtiçi faiz oranının yurtdışı faiz oranına göre artması yerel para biriminin değer kaybetmesine neden olmaktadır (MacDonald, 2007).

### 1.2.3.2. Katı Fiyatlı Parasal Modeller

Esnek fiyatlı parasal model PPP'nin sürekli olarak geçerli olduğu varsayımına dayanmaktadır. Ampirik çalışmalar PPP'nin uzun vadede geçerli olabileceğine, ancak kısa vadede PPP'den büyük sapmalar meydana getireceğine işaret etmektedir, Dornbusch (1976)'a göre kısa vadede fiyatlar katıdır. Bu nedenle para stokundaki herhangi bir artış kısa vadede fiyat artışına yol açmazken, döviz ve finans piyasaları bu duruma hızlı tepki verecektir. Bu durumda ülkenin rekabet gücü artacak, fiili çıktı düzeyi potansiyel çıktı düzeyinin üstüne çıkacak ve müteakiben döviz kuru düşmeye başlayacaktır. Döviz kuru dengelendikçe enflasyon dinamikleri, geçiş etkisi yoluyla yukarı yönlü tetiklenecektir.

(Borgersen & Göcke, 2007; Leventakis, 1987; MacDonald, 1995). Özetle, Dornbusch, Keynesyen teoriyle uyumlu şekilde, fiyatların kısa vadede katı olduğunu varsaymakta ve kısa vadede oluşan şokların, döviz kurunu, uzun vade denge değerinin üzerine sürükleyeceğini ve orta vadede bu sapmanın monoton azalan bir şekilde dengeye geleceğini ileri sürmektedir (Driskill, 1981).

Katı fiyatlı parasal model en basit haliyle eşitlik (1.1) ve paranın miktar teorisinin bileşimiyle elde edilir.  $P_{i,t} = S_t P_{i,t}^*$  olmak üzere yurt içi için paranın miktar denkliği  $M.V = P.T$  ve dış alem için paranın miktar denklemi  $M^*.V^* = P^*.T^*$  olarak yazılırsa,

$$S_t = \frac{M}{M^*} \frac{V}{V^*} \frac{Y^*}{Y} \quad (1.10)$$

elde edilir. Eşitliğin her iki tarafının logaritması alınırsa,

$$\log S = (\log M - \log M^*) - (\log Y - \log Y^*) + (\log V - \log V^*) \quad (1.11)$$

elde edilir. Paranın dolanım hızı Keynesyen teoriye göre iki ana faktöre bağlıdır. Bunlar; faiz oranı ve enflasyon beklentileridir (Higgins, 1978). Faiz oranı ve enflasyon beklentilerinin paranın dolanım hızını etkilediği göz önüne alındığında, denklem yeniden yazılarak katı fiyatlı parasal model denkliğine (1.12) ulaşılır.

$$s_t = \alpha + \beta_4 m_t + \beta_5 y_t + \beta_6 i_t + \beta_7 \pi_t + \varepsilon_t \quad (1.12)$$

Eşitlikte,  $m_t$  para arzını,  $y_t$  gelir düzeyini,  $i_t$  faiz oranını,  $\pi_t$  enflasyon beklentilerini ve  $\varepsilon_t$  hata terimini temsil etmektedir.

#### 1.2.4. Taylor Kuralı Modeli

Taylor (1993) kuralı, politika faizindeki değişimi, enflasyon hedefinden ve çıktı açığındaki sapmalardan yola çıkarak açıklayan mekanik bir modeldir. Başlangıçta sadece ABD ekonomisinin takibi için kullanılan model, daha sonra popülerlik kazanarak, para politikası ve parasal duruşun önemli bir sembolü haline gelmiştir (Hofmann ve Bogdanova, 2012). Taylor kuralı matematiksel olarak (1.13)'teki gibi gösterilmektedir.

$$i_t^* = \pi_t + r^* + \phi(\pi_t - \pi^*) + \gamma y_t \quad (1.13)$$

Eşitlikteki,  $i_t^*$  kısa vadeli nominal faiz oranı hedefini,  $\pi_t$  enflasyon oranını,  $\pi^*$  enflasyon hedefini,  $y_t$  ise çıktı açığını göstermektedir.

Taylor kuralına göre, enflasyonun beklentilerin üzerinde seyretmesi ve çıktının, potansiyelin üzerinde olması durumunda nominal faiz oranının artması gerekir. Başta Clarida ve diğerleri (1998), daha sonra Engel & West (2005), Engel ve diğerleri (2006) ve son olarak Molodtsova

& Papell (2009) çalışmalarında, döviz kurundaki değişimleri açıklamak için Taylor kuralını kullanmışlardır. Taylor kuralında enflasyon ve çıktı açıklarının merkez bankalarının tepki fonksiyonlarında eşit ağırlıklara sahip olduğunu varsayılmaktadır. Denklemde  $\pi^*$  ve  $r^*$  tek sabite dönüştürülerek  $\mu$  elde edilmektedir.

(1.13) numaralı eşitliğe gerekli dönüşüm uygulanırsa (1.14) elde edilir.

$$i_t^T = \mu + \lambda\pi_t + \gamma y_t \quad (1.14)$$

Bu eşitlikte  $i_t^T$ , merkez bankasının kısa vadeli faiz oranı hedefini göstermektedir.  $\lambda = 1 + \phi$ 'dir.  $\lambda > 1$  koşulu, enflasyonun artışıyla birlikte reel faiz oranının da artacağını ve Taylor kuralının sağlanacağını ifade etmektedir. Bu kurala reel döviz kurunun da dahil edilmesiyle model, (1.15) numaralı eşitlikteki halini alır.

$$i_t^T = \mu + \lambda\pi_t + \gamma y_t + \delta q_t \quad (1.15)$$

(1.15) numaralı eşitlikte  $q_t$ , reel döviz kurunu;  $\delta$  ise reel döviz kurunun faiz oranı üzerindeki ağırlık katsayısını ifade etmektedir. Reel döviz kurunun modele dahil edilmesinin temel gerekçesi, döviz kurunun PPP'den saptığında merkez bankasının tepki vereceğine dair beklentidir.

Molodtsova & Papell (2009), Clarida ve diğerleri (1998)'nin modelini genişleterek (1.15)'deki denkleme düzleştirme parametresini de ekleyerek, denge faiz oranına kademeli geçişi sağlayan (1.16) eşitliğini türetmiştir.

$$i_t = (1 - \rho)i_t^T + \rho i_{t-1} + v_t \quad (1.16)$$

Eşitlikte  $i_t$ , gözlemlenebilir faiz oranını,  $\rho$ , faiz oranı düzleştirme parametresini ve  $v$  ise parasal şokları temsil etmektedir. Eşitlik (1.15), eşitlik (1.16)'daki yerine yazılırsa;

$$i_t = (1 - \rho)(\mu + \lambda\pi_t + \gamma y_t + \delta q_t) + \rho i_{t-1} + v_t \quad (1.17)$$

elde edilir.  $\delta=0$  varsayımı altında iki denklemden yola çıkılarak Taylor Kuralı Modeli elde edilebilir. Bunlardan ilki yurtiçi faiz oranını belirten (1.18) numaralı eşitliktir.

$$i_t = (1 - \rho)(\mu + \lambda\pi_t + \gamma y_t) + \rho i_{t-1} + v_t \quad (1.18)$$

Yurtdışı faiz oranı ise (1.19) numaralı eşitlikten yola çıkılarak elde edilir.

$$i_t^* = (1 - \rho^*)(\mu^* + \lambda^*\pi_t^* + \gamma^*y_t^* + \delta^*q_t^*) + \rho^*i_{t-1}^* + v_t^* \quad (1.19)$$

Bu iki denklemin birbirinden çıkarılmasıyla (1.20) eşitliğine ulaşılır.

$$i_t - i_t^* = (1 - \rho)(\mu - \mu^*) + (1 - \rho)\lambda(\pi_t - \pi_t^*) + (1 - \rho)\gamma(y_t - y_t^*) + (1 - \rho)\delta q_t^* + \rho(i_{t-1} - i_{t-1}^*) + (v_t - v_t^*) \quad (1.20)$$

Modeldeki  $(1 - \rho)\lambda$ ,  $(1 - \rho)\gamma$ ,  $(1 - \rho)\delta$ ,  $\rho$ , 1 katsayıları sırasıyla  $\alpha_\lambda$ ,  $\alpha_\gamma$ ,  $\alpha_\rho$ ,  $\alpha_v$  olarak yazılırsa, (1.21) numaralı eşitliğe ulaşılır.

$$i_t - i_t^* = \alpha_\lambda(\pi_t - \pi_t^*) + \alpha_\gamma(y_t - y_t^*) + \alpha_\rho(q_t - q_t^*) + \alpha_v(v_t - v_t^*) \quad (1.21)$$

(1.21) eşitliğindeki  $\alpha$  katsayıları, para otoritesinin ilgili açık karşısındaki tepki katsayılarını göstermektedir. Olağan dışı bir döviz kuru sıçramasında nominal faiz oranları her bir dönem için,  $i_t = i_{t-1} + (1 - \rho)\Delta_{q_t} + (1 - \rho)^2\Delta_{q_t} + \dots$  yoluyla artırılır. Daha basit şekliyle döviz kuru değişimlerine göre faiz oranı ayarlanması (1.22)'de gösterildiği gibidir.

$$i_t = i_t + \delta\Delta q_t \quad (1.22)$$

Molodtsova & Papell (2009), bu modelde rezerv para birimine sahip olan ABD için  $\tilde{\delta}=0$  varsaymıştır. Bu durum ABD için reel döviz kurunun zaman içinde değişmediğini ima etmektedir.  $\delta$  katsayısı, döviz kuru geçişkenliğine, ithalat bağımlılığına, finansal piyasaların gelişmişlik düzeyine ve merkez bankasının döviz rezervlerine göre 0'dan anlamlı derecede farklılaşabilir.

### 1.2.5. Temel Denge Döviz Kuru Modelleri

Sadece parasal değişkenlerin ötesinde, reel döviz kurunun denge değerini belirlemek amacıyla iç denge ile dış dengenin sağlandığı noktaya eşanlı olarak dengeye gelen Temel Denge Döviz Kuru Modelleri (FEER) yaklaşımı ilk olarak IMF araştırmacısı J. R. Artus tarafından ileri sürülmüştür. Artus (1978), denge reel döviz kurunu, cari hesabı net sermaye hesabına eşitleyen oran olarak tanımlamaktadır. Buradaki amaç PPP yaklaşımlarının kavramsal eksikliklerinin önüne geçmektir. Bretton Woods sistemindeki parite değişimi için kriter olan temel dengesizlik (dengeden sapma) kavramını ele alan Williamson (1983, 1994), orta vadeli makroekonomik dengeyi hem sermaye hem de cari hesapta eşanlı sağlayan reel döviz kurunu FEER olarak tanımlamaktadır. İç denge, ekonomide istikrarlı bir fiyat düzeyi ile tam istihdam seviyesindeki çıktı miktarıyla sağlanırken, dış denge ise orta vadede sürdürülebilir bir ödemeler dengesi pozisyonu olarak nitelendirilmektedir.

FEER yaklaşımı, orta vadede devam etmesi beklenen ekonomik temellere daha fazla odaklanmaktadır. Bu temel formda, orta vadeli denge döviz kuru olarak kabul edilmektedir. FEER, denge döviz kurunun normatif bir ölçüsü olarak kabul edilir ve ideal ekonomik

koşullarla tutarlı oranı temsil eder. FEER belirlenirken ilk koşul, düşük enflasyonla ilişkili potansiyel üretim büyümesini belirlemektir (Siregar, 2011). Potansiyel çıktı seviyesini belirlemek gerçek anlamda zor olduğundan, dış denge sağlandığında uyum sürecinin iç dengeyi de sağladığı varsayılmaktadır. Temel denge döviz kuru iki aşamada hesaplanmaktadır. Tam istihdam varsayımı altında;

$$CA = ntb + nfa = f(q^{FEER}, \bar{y}, \bar{y}^*) \quad (1.23)$$

(1.21) numaralı eşitlikte,  $CA$ , cari hesabı;  $ntb$  net dış ticaret dengesini;  $nfa$ , net dış varlıkları;  $\bar{y}$  ve  $\bar{y}^*$ , yurtiçi ve yurtdışında tam istihdam düzeyindeki çıktıyı;  $q^{FEER}$  ise reel efektif döviz kurunu göstermektedir.

Williamson, sermaye hesabı ( $KA$ )'nın dışsal olduğunu ve orta vadede cari hesaba eşitleneceğini ve bu noktada temel denge döviz kurunun belirleneceğini ifade etmektedir.

$$q^{FEER} = f(\bar{KA}; \bar{y}; \bar{y}^*) \quad (1.24)$$

FEER, PPP'den farklı olarak, modele ek faktörler dahil edilerek dengeye izin vermektedir.

### 1.2.6. Davranışsal Denge Döviz Kuru Modelleri (BEER)

Davranışsal denge döviz kuru modeli, PPP'nin başarısızlığını başlangıç noktası olarak kabul etmekte ve reel döviz kurunun gerçek belirleyicine odaklanmaktadır. Modele göre PPP'nin başarısızlığının temel nedeni; orta ve uzun vadede, reel denge değerinden büyük sapmalar göstermesi ve ayarlanma hızının yavaş olmasıdır. BEER en basit haliyle reel döviz kurunu belirleyen makroekonomik değişkenleri uzun vadeli ekonomik temeller ve kısa vadeli reel faiz farklılıkları olarak iki set halinde ayrıştırmaktadır. MacDonald & Clark, (1998) tarafından geliştirilen model, UIRP modelinden türetilmiş olup, herhangi bir normatif unsur içermeyen sağlam istatistiksel testlere dayanmaktadır. BEER modelinde  $Z_{1t}$  ve  $Z_{2t}$  şeklinde iki faktör seti vardır.  $Z_{1t}$ , uzun vadeli reel döviz kuru üzerindeki temel faktörler iken,  $Z_{2t}$  orta vadeli faktörleri temsil etmektedir. Bu bağlamda reel döviz kurunun gerçek değeri (1.25) numaralı eşitlikteki gibidir.

$$q_t = \beta_{1t}^T Z_{1t} + \beta_{2t}^T Z_{2t} + \tau^T T_t + \varepsilon_t \quad (1.25)$$

Eşitlik (1.25)'teki  $T_t$  geçici ve kısa vadeli şokları temsil eden bir set iken,  $\varepsilon_t$  rassal hata terimidir. Eşitlikteki geçici ve kısa vadeli şokları temsil eden  $T_t$  ve rassal hata teriminin sıfır olması denge döviz kurunu ( $\bar{q}_t$ ) verir. Mevcut yanlış dengelenme veya uyumsuzluk  $cm_t$  ile ifade edilirse;

$$cm_t = q_t - \bar{q}_t = q_t - \beta_{1t}^T Z_{1t} - \beta_{2t}^T Z_{2t} = \tau^T T_t + \varepsilon_t \quad (1.26)$$

elde edilir. MacDonald ve Clark, (1998) mevcut dengesizliğin temel ekonomik faktörlerin sürdürülebilir veya arzu edilen seviyelerden sapmasını  $tm$  (toplam uyumsuzluk) ile tanımlamaktadır.

$$tm_t = q_t - \beta_1^T \bar{Z}_{1t} - \beta_2^T \bar{Z}_{2t} \quad (1.27)$$

Eşitlik (1.27)'nin sağ tarafına  $q_t$  eklenip çıkarılırsa toplam uyumsuzluk iki bileşene ayrılır.

$$tm_t = (q_t - \bar{q}_t) + [\beta_1^T (Z_{1t} - \bar{Z}_{1t}) + \beta_2^T (Z_{2t} - \bar{Z}_{2t})] \quad (1.28)$$

Eşitlik (1.28)'da  $(q_t - \bar{q}_t)$  yerine  $\tau^T T_t + \varepsilon_t$  yazılırsa ve denklem yeniden düzenlenirse eşitlik (1.29) elde edilir.

$$tm_t = \tau^T T_t + \varepsilon_t + [\beta_1^T (Z_{1t} - \bar{Z}_{1t}) + \beta_2^T (Z_{2t} - \bar{Z}_{2t})] \quad (1.29)$$

Eşitlik (1.29) herhangi bir zamanda, toplam yanlış dengelenmeyi, geçici faktörlerin etkisini, tesadüfi şokları ve makroekonomik hedeflerden ne kadar uzaklaşıldığını göstermektedir. MacDonald ve Clark'ın yaklaşımı riske göre düzenlenmiş UIRP koşuluna göre yeniden düzenlenirse;

$$\Delta q_{t+k}^e = -(r_t - r_t^*) + \lambda_t \quad (1.30)$$

eşitlik (1.30) elde edilir. Bu eşitlikteki  $\lambda$ , t zamanındaki risk primini ifade etmektedir. Eşitlik, uzun dönemdeki sistematik bileşenlerle yeniden düzenlenirse;

$$q_t = \hat{q}_t - (r_t - r_t^*) + \lambda_t \quad (1.31)$$

eşitlik (1.31) elde edilir. Bu eşitlikteki  $\hat{q}_t$  katsayısı, net yabancı varlıkları, Balassa-Samuelson etkisini ve dış ticaret hadlerinin ( $tot$ ) bir fonksiyonudur. Eşitlik kapalı formda yeniden düzenlenirse, BEER nihai olarak;

$$q_t = f[r_t - r_t^*, nfa, tot, bs, \lambda_t] \quad (1.32)$$

eşitlik (1.32)'deki şekilde tanımlanır (Beza-Bojanowska & MacDonald, 2009).

BEER uygulanabilirliği ve şeffaflığı nedeniyle, reel efektif döviz kurunun denge değerini belirlemede sıkça kullanılmaktadır. Davranışsal denge döviz kuru yorumlanırken, öncelikle eştümleşik vektör sayılarının belirlenmesi daha sonra içsel değişkenlerin işaret ve katsayılarının incelenmesi ve son olarak da makroekonomideki olası normatif etkileri üzerine yoğunlaşmaktadır. Model bu yönüyle diğer reel denge döviz kuru modellerinden ayrılan güçlü bir analitik araç halini almıştır (MacDonald, 2004).

### 1.2.7. Kalıcı Denge Döviz Kuru Modelleri (PEER)

BEER yaklaşımının temel amacı, döviz kurlarının davranışının modellenmesidir. Bu nedenle BEER hesaplamaları değişkenlerin denge seviyesinde olmasını gerektirmez. Bu davranışın farkında olan Clark & MacDonald (2004)  $Z_t - \hat{Z}_t = 0$  durumunda BEER denge değerine geleceğini bu durumda bile döviz kurunun yanlış dengelenmiş olabileceğini, bu nedenle yanlış dengelenmenin tesadüfi şoklara mı yoksa geçici faktörlere mi bağlı olduğunu belirlemek için Kalıcı Denge Döviz Kuru (PEER) Modeli'ni geliştirmişlerdir. PEER, BEER'den türetilen kalıcı denge seviyelerini analiz etmek için kullanılmaktadır. Model, Gonzalo & Granger (1995)'in, eştümleşik modellerde ortak uzun hafıza bileşenlerinin belirlenmesine yönelik geliştirmiş olduğu ekonometrik model ile tahmin edilmektedir. Bu modelde denge makroekonomik dengeden çok ekonometrik dengeyi ifade etmektedir (Driver & Westaway, 2005). PEER, döviz kuru analizlerinden uzun vadeli ekonomik temellerin etkilerini daha iyi anlamak için BEER'den daha detaylı bir analiz perspektifi sunmaktadır.

### 1.2.8. Doğal Denge Döviz Kuru (NATREX)

Doğal Denge Döviz Kuru Modeli (NATREX) ekonominin tam istihdamdayken, spekülasyon ve dönemsel faktörlerin ortadan kalkması durumunda geçerli olan döviz kurunu tahminlemeyi amaçlamaktadır (Allen, 1998; Stein, 1998). NATREX hem makroekonomik hem de mikroekonomik temelleri olan bir modeldir. NATREX'e göre denge reel döviz kuru üç ana bileşenden oluşur. Bunlar; sermaye stoku ( $k$ ), dış borç stoku ( $F$ ), ve tesadüfi şoklardır ( $\varepsilon$ ). Model kapalı formda (1.33)'deki gibi gösterilebilir:

$$q_t(k_t, F_t, \varepsilon_t; Z_t) = [(q_t(k_t, F_t, \varepsilon_t; Z_t) - q(k_t, F_t; Z_t))] + [q(k_t, F_t; Z_t) - q^*(Z_t)] + [q^*(Z_t)] \quad (1.33)$$

Eşitlik (1.31)'deki  $Z$  temel makroekonomik faktörleri temsil etmektedir. Denkleminde sağ taraftaki ilk bileşen  $[(q_t(k_t, F_t, \varepsilon_t; Z_t) - q(k_t, F_t; Z_t))]$ , cari döviz kurunun orta vadedeki sapmasını; ikinci bileşen  $[q(k_t, F_t; Z_t) - q^*(Z_t)]$ , cari döviz kurunun uzun dönem sapmasını ve son olarak  $[q^*(Z_t)]$ , üretkenliği ve zaman tercihi (sosyal tutumluluk düzeyi) belirtmektedir. NATREX, orta vadeli reel döviz kuru olarak kabul görmektedir. NATREX'de  $Z$  vektörü uzun vadede dışsaldır. Bu durum uzun vadede temel makroekonomik değişkenlerin de değişebilir olduğuna işaret eder. Uzun vadedeki bu değişimler NATREX'in genel seyri üzerinde de etkili olabilmektedir (Couharde vd., 2016). NATREX, belirsizlik ortamında ekonomik ajanların zamana dayalı optimizasyon yöntemlerine dayanarak

davranışlarını tanımlamaya olanak tanır. NATREX modeli, orta vadeli reel döviz kuru belirlenirken yatırım, tasarruf ve uzun vadeli temeller gibi faktörlere özel önem vermektedir.

Uzun vadeli reel döviz kuru, sermaye stoku ve dış borç stokunun durağan hale geldiği seviyelere doğru ayarlanır. Sermaye akımları ve reel fiziksel sermaye stoku, servet ve net dış borçlardaki değişiklikler nedeniyle NATREX, hareketli bir denge olarak tanımlanır. Orta vadede, fiyatların ayarlandığı, çıktının potansiyel seviyesine döndüğü ve istenen ulusal yatırımın istenen ulusal tasarrufa eşit olduğu varsayılmaktadır. Bu yaklaşıma göre, NATREX “yapay bir yapı” olup, döviz kurunu ayarlanması gereken bir hedef olarak tanımlamaktadır (IMF, 2007).



## İKİNCİ BÖLÜM

### ZAMAN SERİLERİ VE TAHMİN MODELLERİ

#### 2.1. Zaman Serisi Kavramı

Zaman serisi belirli bir değişkenin, düzenli periyotlarla yapılan ölçümlerinin sıralı bir dizisidir. Matematiksel olarak bir zaman serisi  $Y_t = f_t$  ile gösterilir. Eğer  $f_t$  bilinen bir fonksiyon ise  $Y_t$  deterministiktir. Zaman serisi  $Y_t = X(t)$  olarak ifade ediliyorsa,  $X(t)$  rassal bir değişken olmak üzere  $\{Y_t\}$  stokastik bir süreç olarak nitelendirilir. Zaman serisi analizi ise genel olarak rassal olaylar ve ilgili parametreler arasındaki yapısal bağımlılıkları inceleyen bir istatistik dalıdır.

##### 2.1.1. Zaman Serisi Bileşenleri

Bir zaman serisi temel olarak dört bileşenden oluşmaktadır. Bunlar trend, mevsimsellik, döngüsellik ve düzensiz hareketlerdir. Trend ( $T$ ), serinin genel eğilimini, mevsimsellik ( $M$ ), belirli zaman dönemlerinde tekrarlanan dalgalanmaları, döngüsellik ( $D$ ), uzun vadeli dalgalanmaları, düzensiz hareketler ( $R$ ) ise, seri boyunca trend, mevsimsellik ve döngüsellik ile açıklanamayan rassal dalgalanmaları ifade etmektedir.  $X : T \times \Omega \rightarrow R$  olmak üzere, bir zaman serisi matematiksel formda eşitlik (2.1)'deki gibi gösterilebilir.

$$X(\omega, t) = T(t) + M(t) + D(t) + R(\omega, t), \quad t \in T \quad (2.1)$$

Burada  $X$ ,  $T$  zaman boyutu ve rassal olayları içeren  $\Omega$  kümesinin çarpımından, gerçel sayılara olan bir eşlemeyi ifade etmektedir. Eşitlik (2.1)'de  $T(t)$ ,  $M(t)$  ve  $D(t)$  stokastik bir karaktere sahip olmayan bileşenlerdir.  $R(\omega, t)$  ise  $\mu = 0$  ve  $\sigma^2 < +\infty$  koşulunu sağlayan rassal bir stokastik süreçtir (Valenzuela vd., 2023).

### 2.1.2. Durağanlık ve Birim Kök Testi

Ampirik bir çalışmada, zaman serisi analizi yapılmadan önce, seriyi oluşturan sürecin zaman içindeki eğiliminin araştırılması gerekmektedir. Yapılan analizlerde ekonometrik açıdan anlamlı sonuçlar elde edilebilmek için serinin durağan olması büyük öneme sahiptir. Durağan olmayan zaman serileri ile kurulan modellerden elde edilen sonuçlar, gerçekte var olmayan sahte bir ilişkiyi gösterebilir (Granger & Newbold, 1974).

Bir zaman serisi  $Y_t$ 'nin olasılık dağılımı zamana bağlı olarak değişmiyorsa başka bir deyişle  $(Y_{s+1}, Y_{s+2}, \dots, Y_{s+t})$ 'nin birleşik dağılımı  $s$ 'ye bağlı değilse bu seri durağandır. Aksi halde  $Y_t$  durağan değildir.  $X_t$  ve  $Y_t$  gibi iki zaman serisinin  $(X_{s+1}, Y_{s+1}, X_{s+2}, Y_{s+2}, \dots, X_{s+t}, Y_{s+t})$  birleşik dağılımı  $s$ 'ye bağlı değilse, bunlar seriler için birleşik olarak durağandır. Durağanlık, geleceğin geçmiş gibi olacağını, en azından olasılıksal bir mantıkla açıklamaktadır (Stock & Watson, 2011).

$Y_t$ , bir zaman serisi olmak üzere, serinin durağan olabilmesi için (2.2), (2.3), (2.4) eşitliklerinin sağlanması gerekmektedir.

$$E(Y_t) = \mu \quad (2.2)$$

$$Var(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (2.3)$$

$$\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)] \quad (2.4)$$

Eşitlik (2.4)'te  $\gamma_k$ ,  $Y_t$  ile  $Y_{t+k}$  arasındaki  $k$  gecikmeli ortak varyansı (veya ardışık ortak varyansı) ifade eder.  $k$  iki  $Y$  arasındaki dönem farkını gösterir.  $k = 0$  olduğunda,  $\gamma_0$  bulunur, bu da basitçe  $Y$ 'nin varyansıdır. Başka bir deyişle, eğer bir zaman serisi durağansa, ne zaman ölçüldüğünden bağımsız olarak aynı ortalamaya, varyansa ve ortak varyansa (çeşitli gecikmelerde) sahiptir (Gujarati & Porter, 2008).

Augmented Dickey-Fuller (ADF) birim kök testi, durağanlık için yaygın olarak kullanılan testlerden biridir. ADF birim kök testi eşitlik (2.5), eşitlik (2.6) ve eşitlik (2.7)'de, sırasıyla, sabit ve trend, yalnızca sabit veya ne sabit ne de trend içeren modeller üzerinden durağanlığı araştırmaktadır.

$$\Delta Y_t = \alpha_0 + \delta y_{t-1} + \alpha_1 t + \delta_1 \Delta y_{t-1} + \dots + \delta_{p-1} \Delta y_{t-p+1} + \varepsilon_t \quad (2.5)$$

$$\Delta Y_t = \alpha_0 + \delta y_{t-1} + \delta_1 \Delta y_{t-1} + \dots + \delta_{p-1} \Delta y_{t-p+1} + \varepsilon_t \quad (2.6)$$

$$\Delta Y_t = \delta y_{t-1} + \delta_1 \Delta y_{t-1} + \dots + \delta_{p-1} \Delta y_{t-p+1} + \varepsilon_t \quad (2.7)$$

ADF testinin sıfır hipotezleri sırasıyla şunlardır:  $H_0: (\alpha_0, \delta, \alpha_1) = (0, 0, 0)$ ,  $H_0: (\alpha_0, \delta) = (0, 0)$ ,  $H_0: (\delta) = (0)$ . Bu eşitliklerde hesaplanan  $(\tau = \frac{\hat{\delta}}{S.E(\hat{\delta})})$  istatistikleri sırasıyla  $\tau$ ,  $\tau_\mu$  ve  $\tau_\tau$

eşik değerleri ile karşılaştırılmaktadır (Dickey & Fuller, 1981). Eğer  $|\tau|$  istatistiği, belirlenen model için  $\tau$  eşik değerinden büyükse  $H_0$  hipotezi reddedilir.  $H_0$  hipotezinin reddedilmesi,  $Y$  zaman serisinin durağan olduğu anlamına gelmektedir (Brooks, 2019).

Düzeyde durağan olmayan seriler, yeterli sayıda farkı alınarak durağan hale getirilebilir. ADF testi, hata teriminin temiz dizi (white noise,  $(\varepsilon_t \sim IID(0, \sigma_\varepsilon^2))$ ) olması için gereken gecikme sayısı  $p$ 'ye karşı oldukça hassastır. Bu nedenle,  $p$  gecikme sayısının uzunluğu ile ilgili herhangi bir uzlaşma olmasa da, bu uzunluk hata teriminde otokorelasyona neden olmayacak bir serbestlik derecesi ile sınırlandırılmalıdır (Yurdakul, 1999).

## 2.2. Geleneksel Tahmin Yöntemleri

Geleneksel tahmin yöntemleri, zaman serisi analizlerinde sıkça kullanılan ve istatistiksel temellere dayanan yöntemlerdir. Bu yöntemler arasında Naive, Theta, Üstel Düzleştirme, ARIMA, Doğrusal Regresyon, VAR (Vektör Otoregresyon) gibi yöntemler bulunmaktadır. Bu yöntemler geçmiş verilerden hareketle gelecekteki değerleri tahmin etmek için yaygın olarak kullanılmaktadır. Bu yöntemler makine öğrenmesi modellerine kıyasla daha anlaşılır ve çözümlenmesi daha kolaydır.

### 2.2.1. Naïve Drift Yöntemi

Naïve yöntemi, tüm tahminlerin gözlem setindeki son değere eşit olacağını varsayan basit bir tahmin yaklaşımıdır. Ancak, Naïve Drift yaklaşımı, tahminlerin zaman içinde değişmesine izin verir ve geçmiş verilerden ortalama sapmaları dikkate alır. Bu yönteme ilişkin model eşitlik (2.8)'de gösterilmiştir.

$$\hat{y}_{t+h|t} = y_t + \frac{h}{t-1} \sum_{t=2}^T (y_t - y_{t-1}) = y_T + h \left( \frac{y_T - y_1}{t-1} \right) \quad (2.8)$$

Eşitlik (2.8) bir zaman serisindeki ilk ve son gözlemler arasındaki ortalama sapmaları içeren bir regresyon denklemidir. Burada  $y_t$  t anındaki gözlem değerini,  $h$  tahmin ufkunu temsil etmektedir. Veri setindeki sapmaları dikkate alan bu yöntem klasik Naïve yöntemine göre daha başarılı tahminler üretmektedir (Hyndman & Athanasopoulos, 2018).

### 2.2.2. Theta Yöntemi

Assimakopoulos & Nikolopoulos (2000), tarafından geliştirilen Theta yöntemi, M3 tahmin yarışmasındaki performansı nedeniyle, bu alandaki araştırmacıların dikkatini çekmiştir. Bu

yöntem basit üstel düzleştirme ve basit lineer regresyonun bileşiminden oluşmaktadır. Theta yöntemi matematiksel olarak eşitlik (2.9)'daki gibi gösterilmektedir.

$$Y''_{(t,\theta)} = \theta X''_t \quad (2.9)$$

Eşitlikte  $\{x_1, x_2, x_3, \dots, x_n\}$ , tek değişkenli bir zaman serisindeki gözlemleri gösterirken,  $t = 3, 4, \dots, n$  zaman boyutunu ifade etmektedir. Burada  $x''_t = x_t - 2x_{t-1} + x_{t+2}$  ve  $y''_t = y_t - 2y_{t-1} + y_{t+2}$  ikinci derece farkları göstermektedir. Model, ikinci dereceden diferansiyel denklemler yardımıyla çözümlenmekte ve parametreler, ortalama karesel hatayı minimum yapacak şekilde belirlenmektedir. Theta yöntemine ait model eşitlik (2.10)'daki gibi gösterilmektedir.

$$y_{t,0} = a + b(t - 1) + \theta x_t \quad (2.10)$$

Eşitlikten de görüleceği üzere  $y_{t,0}$  lineer bir trendin ve  $x$ 'in doğrusal bir fonksiyonunun bileşimine eşitlenmektedir. Eşitlik (2.10)'daki  $a$  ve  $b$  model içindeki sabitlerdir. Katsayılar ve zaman serisinin ortalama değeri sırasıyla eşitlik (2.11), eşitlik (2.12) ve eşitlik (2.13) yardımıyla belirlenmektedir.

$$b_\theta = \frac{6(1 - \theta)}{n(n^2 - 1)} \left( \sum_{i=1}^n X_i - (n + 1)X_1 \right) \quad (2.11)$$

$$a_\theta = \frac{1}{n} \sum_{i=1}^n X_i - b_0 \frac{(n - 1)}{2} \quad (2.12)$$

$$T_0 = a_\theta + \frac{b_\theta(t - 1)}{2} + \theta X_t = X_t \quad (2.13)$$

Eşitliklerden de anlaşılabacağı üzere  $\theta = 0$  durumunda, model sadece  $t$ 'ye bağlı lineer bir trend içerirken,  $\theta \neq 0$  durumunda model  $x_t$ 'ye ve  $t$ 'ye bağımlı hale gelmektedir (Dudek, 2019; Spiliotis vd., 2019; Hossain vd., 2021).

### 2.2.3. Üstel Düzleştirme Yöntemi (ETS)

Holt-Winters üstel düzleştirme yöntemi, iki parametrelili üstel düzleştirme yöntemine, mevsimsel etki değişkeninin dahil edilmiş versiyonudur. Bu modelde, yüksek frekanslı sinyaller, zaman serisinden çıkarılarak model düzleştirilir. Durağanlık, diğer üstel düzleştirme yöntemlerinde olduğu gibi, Holt Winters üstel düzleştirme yönteminde de gerekli değildir. Model sırasıyla, düzey, trend, mevsimsellik ve tahmin olmak üzere dört denklemden oluşmaktadır.

$$L_t = \alpha \frac{y_t}{s_t - 12} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2.14)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (2.15)$$

$$S_t = \gamma \frac{y_t}{L_t} + (1 - \gamma)S_{t-1} \quad (2.16)$$

$$F_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (2.17)$$

Eşitlik (2.14), eşitlik (2.15), eşitlik (2.16) ve eşitlik (2.17)'deki  $L_t$ , zaman serisinin  $t$  anındaki düzey değerini,  $b_t$  serinin  $t$  anındaki eğilimini,  $S_t$   $t$  anındaki mevsimsel bileşeni,  $s_t$  mevsimsel periyodu, ve  $F_{t+m}$   $t$  anından sonraki  $m$  dönem için tahmin edilen değeri ifade etmektedir. Düzleştirme katsayıları olan  $\alpha$ ,  $\beta$  ve  $\gamma$  katsayıları  $[0,1]$  aralığında olup, parametreler eşitlik (2.18)'da gösterilen en düşük ortalama mutlak yüzdesel hata (MAPE) kriterine göre hesaplanmaktadır.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| * 100 \quad (2.18)$$

Eşitlikteki,  $y_t$   $t$  anındaki gerçek değeri,  $\hat{y}_t$   $t$  anındaki tahmin edilen değeri ve  $n$  toplam gözlem sayısını ifade etmektedir. Holt Winters üstel düzleştirme yöntemine dayalı iyi bir tahmin yapmak için aşağıdaki iki şartın sağlanması tercih edilmektedir (Soni & Srikanth, 2017; Nurhamidah vd., 2020).

$$1- \varepsilon_t \sim N(0, \sigma^2),$$

$$2- Cov(\varepsilon_t, \varepsilon_{t+k}) = 0 \quad \forall t \neq k$$

Bu şartlar, hata terimlerinin ortalamasının sıfır, varyansının sabit ve hatalar arası otokorelasyonun olmadığını göstermektedir.

#### 2.2.4. Otoregresif Bütünleşik Hareketli Ortalama Modeli (ARIMA)

ARIMA süreci, eşitlik (2.19)'daki otoregresif süreç ile eşitlik (2.20)'deki hareketli ortalama (MA) sürecinin birleştirilmesiyle elde edilir. ARIMA süreci, ilgili değişkeni durağan hale getiren fark alma denkleminin modele eklenmesiyle oluşturulur. Parametreleri  $(p, d, q)$  olan bir ARIMA süreci, eşitlik (2.21)'de gösterilmektedir:

$$Y_t = c + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t \quad (2.19)$$

$$Y_t = c + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2.20)$$

$$(1 - \varphi_1 B - \dots - \varphi_p B^p)(1 - B)^d Y_t = c + (1 + \theta_1 B + \dots + \theta_q B^q) \varepsilon_t \quad (2.21)$$

Eşitlikteki  $\varepsilon_t$ , hata terimini göstermekte olup ( $\varepsilon_t \sim IID(0, \sigma_\varepsilon^2)$ ) özelliktedir.  $B$  gecikme operatörünü,  $p$  ve  $q$ , sırasıyla AR ve MA süreçlerindeki gecikme uzunluklarını,  $d$  ise seriyi durağan hale getirmek için yapılan fark alma sayısını,  $\varphi$  ve  $\theta$  ise sırasıyla  $AR(p)$  ve  $MA(q)$  süreçlerine ait katsayıları göstermektedir. ARIMA sürecinde tahminler, gözlemlerin doğrusal fonksiyonlarına dayanır. ARIMA sürecinde amaç, gözlemlenen verinin yeterli bir tanımını sağlayan en basit modeli elde etmektir. Eğer  $d = 0$  ise gözlem seti doğrudan modellenir,  $d = 1$  ise ardışık gözlemler arası farklar modellenir. Eğer  $d = 2$  ise, ardışık farkların farkları modellenir. Uygulamada  $d > 2$  durumu ise nadiren görülmektedir (Kirchgässner vd., 2007; Wang vd., 2014; Jirsik vd., 2019).

ARIMA sürecine dayalı tahmin yapmak için bazı şartlar vardır. Bunların ilki, zaman serisinin durağanlık şartını sağlamasıdır. Durağanlık şartı sağlandıktan sonra, ikinci şartı ise Akaike (AIC), Schwarz (SIC) veya Bayesyen (BIC) bilgi kriterleriyle en iyi modelin belirlenmesidir. Model belirlendikten sonra hatalar, normallik testine ve otokorelasyon testine tabi tutulur. Bu testlerden geçen model parametreleriyle tahminler yapılır (Peixeiro, 2022).

### 2.2.5. Çok Değişkenli Doğrusal Ridge Regresyon

Ridge regresyonu açıklamadan önce çoklu doğrusal regresyon modelini incelemek gerekmektedir.

$$y_{t+h} = \beta_0 + \beta_1 x_{t,1} + \dots + \beta_q x_{t,q} + \varepsilon_{t+h}, \quad t = 1, \dots, T. \quad (2.22)$$

Eşitlik (2.22)'de  $Y = (y_1, \dots, y_n)^T$  bağımlı rassal değişken vektörü,  $X = (x_1, \dots, x_n)^T$  bağımsız değişkenler vektörü,  $\beta = (\beta_1, \dots, \beta_q)^T$  katsayılar vektörü,  $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)^T$  ( $\varepsilon_t \sim IID(0, \sigma_\varepsilon^2)$ ) özellikte olan hata terimleri vektörüdür. Bu model,  $q < n$ , şartıyla bir tahmin modeline dönüştürülürse, eşitlik (2.23)'e ulaşılır.

$$\hat{y}_{t+h} = \hat{\beta}_0 + \hat{\beta}_1 x_{t,1} + \dots + \hat{\beta}_q x_{t,q}, \quad t = 1, \dots, T. \quad (2.23)$$

Doğrusal modelde, tahmin edilen katsayılar, hata kareleri toplamı (RSS) en az indirgenecek şekilde elde edilir. Bu optimizasyon problemi eşitlik (2.24)'teki gibi tanımlanmaktadır.

$$\hat{\beta}(\theta) = \min_{b_0, \dots, b_q} \left[ \sum_{t=1}^{T-h} \underbrace{\left( y_{t+h} - b_0 - \sum_{j=1}^q x_{t,j} \right)^2}_{RSS(b_0, \dots, b_q)} + p(b_1, \dots, b_q; \theta) \right] \quad (2.24)$$

Eşitlik (2.24)'te  $\Theta$ ,  $\hat{\beta}$  katsayılar vektörünün ayarlama (tuning) vektörünü,  $\theta$  ise her bir  $\hat{\beta}$  için ayarlama vektörünü,  $p(\cdot)$  ise ceza fonksiyonunu göstermektedir. Hoerl & Kennard (1970), tarafından geliştirilen Ridge regresyonda ise  $\hat{\beta}$  katsayıları sıfıra yakınsatılarak, yanlılık artışı sağlanmakta ve bu yanlılık, modelin varyansında küçülmeye neden olmaktadır. Model varyansındaki bu azalma, tahmin doğruluğunu artırmaktadır (James vd., 2023).

Hoerl & Kennard (1970) (2.24) eşitliğindeki  $p(\cdot)$  ceza fonksiyonunu  $\lambda \sum_{j=1}^q b_j^2$  tipine dönüştürerek, eşitlik (2.25) teki optimizasyon problemine odaklanmaktadır.

$$\hat{\beta}^{Ridge} = \min_{b_0, \dots, b_q} \left[ RSS(b_0, \dots, b_q) + \lambda \sum_{j=1}^q b_j^2 \right] \quad (2.25)$$

Eşitlik (2.25)'teki  $\lambda$  katsayısı, küçülme miktarını kontrol eden bir parametredir. Parametrelerin kareler toplamını minimize etme anlayışı, yapay sinir ağlarında da kullanılmaktadır. Bu durum ağırlık azalması (weight decay) olarak bilinmektedir. Ridge regresyonu eşitlik (2.26)'daki gibi de formülleştirilebilir. Bu eşitliklerdeki  $\lambda$  ve  $s$  parametreleri arasında birebir ilişki vardır.

$$\hat{\beta}^{Ridge} = \min_{\beta} \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 \text{ koşuluyla } \sum_{j=1}^q b_j^2 \leq s \quad (2.26)$$

$$s_0 = \sum_{j=1}^q (\hat{\beta}_j^{LS})^2 \quad (2.27)$$

Eğer  $s \geq s_0$  veya  $\lambda = 0$  ise Ridge tahminleri, En Küçük Kareler (LS) tahminleri ile aynı olacaktır. Bu nedenle Ridge tahmincilerine ulaşmak için  $\lambda > 0$  koşulu sağlanmalıdır. Ridge regresyonun matris boyutunda çözümü eşitlik (2.28) ve eşitlik (2.29)'daki gibidir.

$$RSS(\lambda) = (y - X\beta)^T (y - X\beta) + \lambda \beta^T \beta \quad (2.28)$$

$$\hat{\beta}^{Ridge} = (X^T X + \lambda I)^{-1} X^T y_h \quad (2.29)$$

Eşitlikte  $I$ ,  $p \times p$  boyutunda birim matrisi göstermektedir.  $\beta$  vektörünün her bir elemanının karesi olan kuadratik ceza bileşeni  $\beta^T \beta$ ,  $y$ 'nin doğrusal bir fonksiyonu olmadığı görülmektedir. Bu durum, katsayıları küçültürken modelin daha basit ve genelleştirilebilir olmasını sağlamaktadır. Eşitliklerde parametreler üzerindeki büyüklük kısıtlaması açıktır. Bir doğrusal modelde birçok ilişkili değişken olduğunda katsayılar kötü şekilde belirlenebilmekte ve model büyük bir varyansa sahip olabilmektedir. Bir değişken üzerindeki büyük pozitif katsayı, bu değişkenle ilişkili bir diğer değişkendeki negatif bir

katsayı ile gizlenebilmektedir (Ehsanes Saleh vd., 2019; Zhao vd., 2021). Çok değişkenli doğrusal regresyon modelindeki, çoklu doğrusal bağlantı ve veri setindeki gözlemleri aşırı öğrenme/uyum (overfitting) problemleri Ridge regresyon ile giderilebilmektedir (Golden, 2020).

### 2.3. Makine Öğrenimine Dayalı Tahmin Yöntemleri

Makine öğrenmesi (ML) yöntemlerinin kullanımının yaygınlaşması ve yüksek frekanslı verilere erişimin artmasıyla birlikte, doğrusal tahmin yöntemlerinin güvenilirliği sorgulanmaya başlanmıştır. ML yöntemlerinin, ekonometrik yöntemlere göre derin prosedürler içermemesi ve algoritmik tasarıma açık olması tahmin güvenilirliğini artırmaktadır (Abraham vd., 2022; Chen vd., 2019; Xu vd., 2022; Pustokhina & Pustokhin, 2023). Ancak bu ekonomik tahminlerin iktisadi teoriye nasıl katkıda bulunabileceği konusunda net bir yaklaşım bulunmazken; teorisyenler arasında tek bir algoritmik yaklaşımı taçlandırmaktan ziyade keşfedilmesi gereken birçok algoritmanın olduğunun benimsenmesi gerektiği konusunda bir görüş birliği vardır (Goulet Coulombe vd., 2022).


Athey (2018), “*Makine Öğreniminin Ekonomi Üzerindeki Etkileri*” başlıklı çalışmada veri odaklı ekonomik çalışmalar için ML yöntemlerinin çok güçlü olduğunu vurgularken; istatistik ve ekonometrideki model spesifikasyonu ve bilimsel araştırmalarda sıkça kullanılan *p* hacking (saha çalışmalarında sadece aynı sonucu elde eden çalışmaları referans almak) sorunlarına da çözüm getirmektedir. Athey (2018) ML yöntemlerinin yüksek frekanslı, karmaşık, gürültülü veri setleri üzerinden çıkarımlar yapabileceğine; hızla değişen veri setlerini öğrenebileceğine ve iç içe geçmiş nedensel yapıları ortaya çıkarabileceğine vurgu yapmaktadır. Athey, bu yöntemlerin ekonomistlerin piyasa yapısını ve makroekonomik dengeyi çok daha düşük maliyetle okuyabilmelerine olanak sağlayacağını iddia etmektedir.

ML yöntemleri denetimli (supervised) ve denetimsiz (unsupervised) modeller olarak ikiye ayrılmaktadır. Denetimli yapılar, etiketli (tanımlanmış) veriler yardımıyla tahminler yapmaktadır. Denetimsiz yapılar ise etiketlenmemiş veriler ile çıktı değişkenini tahmin etme veya sınıflandırma işlemi yapmaktadır. Denetimli yapıların eğitim maliyeti, denetimsiz yapılara göre çok daha düşüktür. Buradaki maliyet kavramı, zaman kavramıyla ilişkilidir. Reel hesaplama yöntemleri için en uygun yöntemler denetimli yapılardır. Bu nedenle bu kısımda, tekrarlayan sinir ağları (RNN-Recurrent Neural Network), uzun-kısa dönem hafıza (LSTM- Long Short Term Memory), tekrarlayan geçitli birim (GRU-Gated Recurrent Unit),

evrimsel sinir ağıları (CNN- Convolutional Neural Network) ve aşırı gradyan artırma modeli (XGBoost) mimarileri açıklanacaktır.

### 2.3.1. Tekrarlayan Sinir Ağları (RNN)

Elman (1990), tarafından geliştirilen ve zaman serilerini tahmin etmek için kullanılan tekrarlayan sinir ağıları (RNN), tek yönlü sinir ağlarının aksine, dinamik yapıda olan bir mimariye sahiptir. Bir veya daha fazla gizli katmana sahip olan RNN’de, her katman bir önceki katmandan gelen ağırlık ile hareket etmektedir. RNN’deki çıktı bilgisi, önceki hesaplamalardan türetilmektedir. RNN’de aktivasyon fonksiyonu tipik olarak sigmoid türündendir (Bianchi vd., 2017). RNN’in mimari yapısı Şekil 2.1’de gösterilmektedir.



Şekil 2.1. RNN Mimarisi

Şekil 2.1’deki  $X$  bir zaman serisi vektörünü,  $W_i^h$  giriş katmanındaki ağırlık matrisini,  $W_h^h$  gizli katmandaki ağırlık matrisini,  $W_o^h$  çıkış katmanındaki ağırlık matrisini,  $\sigma$  aktivasyon fonksiyonunu,  $h$  gizli katmanı,  $z^{-1}$  gecikme operatörünü,  $y$  ise çıktı matrisini (tahminler) temsil etmektedir. Bir RNN’de ham veriler, zaman boyutu  $T = t_1, t_2, \dots, t_n$  olan bir  $X$  setinde aşağıdaki gibi tahmine dönüştürülmektedir.

$$h_{t+1} = \sigma(W_i^h x_t + z^{-1} W_h^h) \quad (2.30)$$


Eşitlik (2.30)’da ham verinin gizli katmana kadar hesaplama adımı gösterilmektedir. Bu aşamada  $h_{t+1}$ ’deki hesaplanan değer yeniden işlenmek üzere geri beslenir ve çıktı kapısına gönderilir. Bu aşamada tahmin edilen değer eşitlik (2.31)’deki gibi hesaplanmaktadır.

$$y_{t+1} = \sigma(W_h^o(h_{t+1})) \quad (2.31)$$

Eşitlik (2.31)’den, RNN’deki dinamik sistemin  $z^{-1}$  parametresi ile hareket ettiği gözlemlenebilir (Salman vd., 2018; Salem, 2022).

### 2.3.2. Uzun- Kısa Dönem Hafıza Modeli (LSTM)

RNN ailesine ait olan LSTM modeli, verilerin ağda dolaşımını ve önceki katmanlarda yeniden işlenmesini sağlayarak tahminler üreten bir modeldir. Bu mimari, LSTM'yi basit RNN'den ayıran özelliktir. LSTM mimarisi Hochreiter & Schmidhuber (1997) tarafından geliştirilen LSTM modeli temelde dört katman ve çeşitli operasyonel süreçlerden oluşmaktadır. LSTM mimarisi Şekil 2.2'de gösterilmektedir.



Şekil 2.2. LSTM Mimarisi (Yan, 2017)

Şekil 2.2'deki,  $h_{t-1}$  LSTM hücresinde işlenen son çıktı vektörünü,  $C_{t-1}$  LSTM hücresindeki son hafıza vektörünü,  $C_t$  güncellenen son hafıza vektörünü,  $h_t$  güncellenen son çıktı vektörünü,  $\oplus$  hafızaya alınan veya birleştirilen bilgiyi,  $\otimes$  bir dizi operatif süreçten geçmiş bilgiyi,  $\tanh$  ve  $\sigma$  ise bilgiyi doğrusallıktan ayıran tanjant ve sigmoid tipindeki aktivasyon fonksiyonlarını temsil etmektedir.

Bir LSTM ağında  $X = (x_1, x_2, \dots, x_t)$  seti LSTM ağına giriş vektörü iken  $y = (y_1, y_2, \dots, y_t)$  LSTM ağından çıkış vektörüdür. LSTM hücresine hangi yeni bilgilerin ekleneceğine giriş kapısında (input gate) karar verilir. Bu kapıdaki hesaplama eşitlik (2.32)'de gösterilmektedir.

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2.32)$$

Eşitlikteki  $x_t$  mevcut girdi setini,  $h_{t-1}$  bir önceki periyottaki bilgi yükünü,  $W_i$  girdi verisine uygulanan ağırlık matrisini,  $U_i$  bir önceki periyottaki bilgi yüküne uygulanan ağırlık matrisi,  $b_i$  yanlılık(bias) vektörü ve  $\sigma$  hesaplanan değeri (0-1) arasında döndüren sigmoid tipi aktivasyon fonksiyonudur.

Bu aşamada hesaplanan değer geçici hücreye ( $\tilde{C}_t$ ) aktarılır. Geçici hücrede eşitlik (2.33)'deki gibi hesaplama yapılmaktadır.

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (2.33)$$

Eşitlikteki  $W_c$  girdi verisine uygulanan ağırlık matrisini,  $U_c$  bir önceki periyottaki bilgi yüküne uygulanan ağırlık matrisini,  $b_c$  yanlılık vektörünü,  $\tanh$  ise elde edilen sonucu hiperbolik tanjant fonksiyonu yardımıyla (-1,1) aralığına döndüren aktivasyon fonksiyonunu temsil etmektedir.  $\tilde{C}_t$  hesaplandıktan sonra, elde edilen bilgi unutma kapısı  $f_t$ 'ye gönderilmektedir. Bu kapıda bilgiler bir dizi operasyonel süreçten daha geçmektedir. Unutma kapısında hesaplanan değer, bir dizi gürültüden arındırma işleminden sonra değer,  $C_t$  hücre durumuna dönüşmektedir.

Bu süreçlere dair hesaplamalar eşitlik (2.34) ve eşitlik (2.35)'te gösterilmektedir.

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2.34)$$

$$C_t = i_t + \tilde{C}_t + f_t + c_{t-1} \quad (2.35)$$

Hücre durumundaki bilgi bu aşamadan sonra çıkış kapısına ( $o_t$ ) gönderilir. Bu aşamada ise bilgi hiperbolik tanjant fonksiyonu ve hücre durumu ( $C_t$ ) vasıtasıyla çoğaltılır ve çıktı vektörüne dönüştürülür. Bu işlemlere ait hesaplamalar eşitlik (2.36) ve eşitlik (2.37)'de gösterilmektedir

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + V_o C_t + b_o) \quad (2.36)$$


$$h_t = o_t \tanh(C_t) \quad (2.37)$$

Eşitlik (2.36)'daki  $W_o$  girdi verisine çıkış kapısı içinde uygulanan ağırlık matrisini,  $V_o$  hücre durumundaki bilgi vektörüne uygulanan ağırlık matrisini,  $U_o$   $h_{t-1}$ 'e uygulanan ağırlık matrisini ve  $b_o$  çıkış kapısındaki yanlılık vektörünü göstermektedir. LSTM mimarisi, zaman serilerinde uzun vadeli bağımlılıkları öğrenme ve unutma kapısının gereksiz bilgileri işlememe yeteneği sayesinde, RNN modelindeki kaybolan gradyanlar sorununa (vanishing gradient problem) çözüm getirmektedir (Masum vd., 2018).

### 2.3.3. Tekrarlayan Geçitli Birim Modeli (GRU)

Geleneksel RNN modelindeki temel problem, kaybolan gradyanlara sahip olmalarıdır. Bu durum gözlemler arasındaki uzun vadeli bağımlılıkları ortaya çıkarmayı zorlaştırmaktadır. “Bu durumun çözümü için alternatif optimizasyon teknikleri ve mimarileri kullanılmalıdır”, motivasyonu hareket eden Bengio ve diğerleri (1993), Cho ve diğerleri (2014) ve Chung ve diğerleri (2014) yaptıkları çalışmalarla, azalan gradyanlar problemine çözüm getiren ve LSTM'den daha sade yapıda olan GRU mimarisini geliştirdiler. GRU, aynı uzunluktaki girdi

serilerini, tüm ağ boyunca tekrarlayan ve girdi dizisine tekrarlayarak uygulayan evrişimli bir sinir ağıdır. Bu mimari, Şekil 2.3'te gösterilmektedir.



**Şekil 2.3.** GRU Mimarisi

Şekil 2.3'ten görüleceği üzere, LSTM mimarisinden farklı olarak operatif süreçler sıfırlama (reset gate) ve güncelleme (update gate) kapılarında gerçekleştirilmektedir. Bir GRU ağına,  $X = (x_1, x_2, \dots, x_t)$  seti, GRU ağına giriş vektörünü,  $y = (y_1, y_2, \dots, y_t)$  ise GRU ağından çıkış vektörüdür. GRU hücresindeki operasyonel süreç, eşitlik (2.38), (2.39), (2.40), (2.41)'de gösterilmektedir.

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2.38)$$

$$\tilde{h}_t = \tanh(W_h x_t + r_t \otimes (U_h h_{t-1}) + b_h) \quad (2.39)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (2.40)$$

$$h_t = z_t \otimes \tilde{h}_t \oplus (1 - z_t) \otimes h_{t-1} \quad (2.41)$$

Eşitliklerdeki,  $x_t$  girdi verisi olmak üzere,  $h_{t-1}$  gizli durumu,  $r_t$  sıfırlama kapısını,  $\tilde{h}_t$  bir dizi operatif süreçten geçmiş gizli durumu,  $z_t$  güncellemeye geçecek bilgidaki sınırlamayı,  $h_t$  ise çıkışa gönderilecek bilgiyi,  $\otimes$  bir dizi işlemde geçmiş bilgiyi,  $\oplus$  birleştirilen bilgiyi göstermektedir (Lawi vd., 2022).

#### 2.3.4. Evrişimsel Sinir Ağları (CNN)

Genellikle görüntü işleme teknolojilerinde kullanılan bir yapay sinir ağı türü olan evrişimsel sinir ağları (CNN) zaman serilerindeki doğrusal olmayan yapıları tanımlamak için de kullanılmaktadır (Hatami vd., 2017). CNN mimarisi, temel olarak üç katmandan oluşmaktadır. Bunlar; evrişimsel, havuzlama ve tam bağlantı katmanlarıdır. Evrişimsel katman, giriş verilerinden özellikleri çıkarmaktan sorumludur. Havuzlama katmanında,

evrişimsel katmandan çıkarılan özellikler bir çekirdek fonksiyon (kernel) ile filtrelenerek kümeleme yapılır. Elde edilen kümeler etiketleme ve girdilerin uzunluğuna göre, bilgi üretim katmanı olan tam bağlantı katmanına gönderilir. Bu süreçlere dair denklemler eşitlik (2.42), eşitlik (2.43) ve eşitlik (2.44)'te gösterilmektedir (Lawal vd., 2021; Liu vd., 2021; Tran, 2021).

$$C_r(t) = f \left( \sum_{i=1}^l \sum_{j=1}^k x(i + s(t-1), j) W_r(i, j) + b(r) \right) \quad (2.42)$$


Eşitlik (2.42), evrişimsel katmanda ( $C_r$ ) özelliğin hesaplanma aşamalarını göstermektedir. Eşitlikteki  $f$  veriyi doğrusallıktan ayıran aktivasyon (genellikle ReLU veya sigmoid) fonksiyonunu,  $l$ ,  $k$  ve  $N$  sırasıyla çekirdek filtre yüksekliği, genişliği ve zaman serisinin uzunluğunu,  $s$  evrişimsel adım sayısını (stride),  $(t-1)$  zaman kaymasını,  $W_r$  filtre ağırlığını,  $b(r)$  ise yanlılık terimini ifade etmektedir.

$$P_r(t) = g \left( C_r((t-1)l + 1), C_r((t-1)l + 2), \dots, C_r(tl) \right) \quad (2.43)$$

Eşitlik (2.43) havuzlama katmanında özellik kümeleme işlemini göstermektedir. Eşitlikteki  $g$  havuzlama stratejisini göstermektedir. Yaygın olarak kullanılan stratejiler ortalama veya maksimum havuzlama stratejileridir.

$$O(j) = f(\sum_{i=1}^N z(i) W_f(i, j) + b_f(j)), j = 1, 2, \dots, n \quad (2.44)$$

Eşitlik (2.44) tam bağlantı katmanındaki operasyonel süreçleri ifade etmektedir. Eşitlikteki  $z$  tam bağlantı katmanındaki son özellik haritasını,  $W_f$  bu katmanla çıkış katmanı arasındaki ağırlık katsayılarını,  $b_f$  ise yanlılık katsayısını göstermektedir. CNN mimarisi Şekil 2.4'te gösterilmektedir (Lewinson, 2020).



Şekil 2.4. CNN Mimarisi

CNN mimarisi, tekrarlayan sinir ağırları ve bunun türevlerinden yapısal olarak ayrılmaktadır. CNN'in eğitimi zaman almaktadır, çünkü bu mimaride uygun parametreler deneysel olarak belirlenmektedir, bu deneysel süreçte, zaman serisinin eğitim ve test uzunlukları sabit tutulmalıdır (Zhao vd., 2017).

### 2.3.5. Aşırı Gradyan Artırma Modeli (XGBoost)

Chen & Guestrin (2016), tarafından geliştirilen XGBoost, sıradan gradyan artırma modeline (GBM) ek olarak, Ridge regresyonda da gösterilmiş olan  $\lambda$  ceza parametresini ve budama gibi özellikleri modele ekleyen, denetimli bir makine öğrenmesi algoritmasıdır. XGBoost, birçok veri analitiği çözümlemesindeki hızı ve başarısıyla makine öğrenmesi alanında oldukça ses getirmiştir. XGBoost modeli, temel olarak karar ağaçlarının paralel çalışmasını sağlayan, ağacın derinliğine göre budama fonksiyonu oluşturup, veri üzerindeki hata ve zayıflıklarını belirleyen, bu hata ve zayıflıkları güçlü birer fonksiyon haline getiren bir algoritmaya sahiptir. Algoritma her bir ağaçtan elde edilen bilgiyi bir sonraki ağacın hata payını azaltacak şekilde, ardışık olarak bir dizi küçük ormanlar oluşturmaktadır. Bu küçük ormanlar yüksek yanlılık (bias) parametresi ve düşük varyans ile oluşturulmaktadır.  $D = \{(x_i, y_i)\}$ ,  $n$  örnek ve  $m$  özelliğe sahip bir veri setini göstermek üzere, XGBoost algoritması, çıktıları tahmin etmek için  $K$  adet karar ağacı ormanı kullanır.

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in \mathcal{F} \quad (2.45)$$

(2.45) eşitliğindeki  $\hat{y}_i$ , tahmin edilen değeri,  $\mathcal{F}$  regresyon ağaçları uzayını temsil etmektedir. Eşitlikteki  $f_k$  fonksiyonu,  $q$  ve  $w$  olmak üzere iki parametre ile belirlenmektedir.  $q$  ve  $w$  parametreleri, sırasıyla ağaç yapısını ve yaprak ağırlıklarını göstermektedir. Yaprak sayısı  $T$  ve  $K$  adet ağacın,  $m$  adet özelliği ve  $n$  adet örneğiyle hedef kayıp fonksiyonu (2.46) ve (2.47) eşitlikleriyle tanımlanmaktadır.

$$\mathcal{L}(\phi) = \sum_{k=1}^K \ell(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2.46)$$

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (2.47)$$

Eşitliklerdeki  $\ell(y_i, \hat{y}_i)$ , bir kayıp fonksiyonunu,  $\Omega(f_k)$  ise düzenleme terimini göstermektedir.  $\gamma$ , her bir ağacın karmaşıklığını kontrol eden bir parametre iken,  $\lambda$  ağaç karmaşıklığı için ek bir ceza parametresidir. Kayıp fonksiyonu  $\ell(y_i, \hat{y}_i)$ , modelin

uygunluğunu ölçen ve gerçek değerler ile modelin tahmin ettiği değerler arasında oluşan hatayı temsil eden sürekli ve türevlenebilir yapıda bir fonksiyondur.  $\Omega(f_k)$  parametresinin asli görevi aşırı öğrenmeyi önlemeye yardımcı olmaktır.  $\ell(y_i, \hat{y}_i)$ , kayıp fonksiyonu iki terimle optimize edilmektedir. Bu terimler, kayıp fonksiyonunun birinci ve ikinci derece türevi olan,  $g_i$  ve  $h_i$  parametreleridir. Bu parametreler matematiksel olarak (2.48) ve (2.49) eşitlikleriyle ifade edilmektedir.

$$g_i = \frac{\partial \mathcal{L}(y_i, \hat{y}_i^{t-1})}{\partial (\hat{y}_i^{t-1})} \quad (2.48)$$

$$h_i = \frac{\partial^2 \mathcal{L}(y_i, \hat{y}_i^{t-1})}{\partial (\hat{y}_i^{t-1})^2}$$

Bu optimizasyon, modelin uyarlamalı bir şekilde eğitildiği anlamına gelmektedir. Her yeni iterasyonda yeni bir  $f_t$  eklenerek yeni kayıp fonksiyonu eşitlik (2.48)'deki hali almaktadır.

$$\mathcal{L}^t = \sum_{i=1}^n \ell(y_i, \hat{y}_i^{t-1} + f_t(x_i)) + \Omega(f_t) \quad (2.49)$$

Eşitlikteki,  $\hat{y}_i^{t-1}$  bir önceki iterasyonun tahmini olmak üzere, ikinci dereceden Taylor açılımı ve bazı operatif süreçlerden sonra, sabit bir yaprak için optimize edilmiş ağırlık  $w_j^*$ , eşitlik (2.50)'deki gibi hesaplanmaktadır.

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (2.50)$$

Eşitlikteki  $g_i$  ve  $h_i$ , kayıp fonksiyonundaki birinci ve ikinci dereceden gradyan istatistikleridir.  $I_j$ ,  $j$ . yapraktaki eğitim örneklerinin bulunduğu kümeyi göstermektedir. Ağırlıklandırma,  $t$  anındaki  $q$  parametrelili kayıp fonksiyonunu optimize etmek için oldukça önemlidir. Bu andaki kayıp fonksiyonu, her bir ağaç için hesaplamaktansa, XGBoost yapısı gereği yaprak ve dallardan elde edilen bilgiyi, ağaçlı bir algoritmayla hedef fonksiyona bilgi olarak aktarmaktadır. Bu bilgiler ışığında  $G_j = \sum_{i \in I_j} g_i$  ve  $H_j = \sum_{i \in I_j} h_i$  olmak üzere amaç fonksiyonu eşitlik (2.51)'deki gibidir.

$$\hat{\mathcal{L}}^t = \sum_{j=1}^T \left[ G_j w_j + \frac{1}{2} H_j w_j^2 + \frac{1}{2} \lambda w_j^2 \right] + \gamma T \quad (2.51)$$

Eşitlik (2.50)'deki amaç fonksiyonu ile yaprakların optimal ağırlıkları ve bu optimal ağırlıklara karşılık gelen en iyi ağaç yapısı eşitlik (2.52) ve (2.53)'deki gibi elde edilir.

$$w_j^* = -\frac{G_j}{H_j + \lambda} \quad (2.52)$$

$$\hat{\mathcal{L}}^t_* = -\frac{1}{2} \sum_{j=1}^T T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (2.53)$$

XGBoost modelinde genellikle, her bir ağacın maksimum derinliği, öğrenme oranı, kullanılacak ağaç sayısı, gamma katsayısı, her ağacın öğrenimi için kullanılacak minimum örnek sayısı belirli bir aralıkta optimize edilmektedir (Mitchell ve Frank, 2017).

## 2.4. Bayesyen Optimizasyon

Optimizasyon, Türk Dil Kurumu veri tabanında “en uygun duruma getirme” olarak tanımlanmaktadır. Optimizasyon doğuştan gelen bir insan davranışıdır. Bireysel açıdan bakıldığında, her birey sürekli olarak kendini ve çevresini optimize etmeye çalışır. Toplumsal olarak ise optimizasyon, refah düzeyi, güvenlik, eğitim ve sağlık konularında sürekli olarak devam eden bir sosyolojik ögedir. Optimal bir çözüm arayışı içinde olan birey ve toplumlar, ilk etapta alt-optimal çözümlerden yola çıkarak makro optimali yakalamaya çalışmaktadırlar.

1960’lardan günümüze, özellikle istatistik alanında birçok optimizasyon tekniği geliştirilmiştir. Bayesyen optimizasyon tekniği, herhangi bir problemin veya algoritmanın en verimli kararı almasına rehberlik eden, hedef fonksiyonun istatistiksel bir modelidir. Optimizasyon içindeki her bir denemeye iterasyon denilmektedir. İterasyon sürecindeki her bir adım ayrı bir maliyet gerektirmektedir. Bu maliyetin ödülü ise modelin üstün tahminler üretmesidir. Örneğin bir makine öğrenmesi modelinin eğitimi hem zaman hem de enerji açısından oldukça maliyetli olabilir. Bu sorun karşısında, bayesyen optimizasyon etkileyici bir performans sergileyebilir. Öyle ki, bayesyen optimizasyon tekniği son 50 yılın en adaptif karar analizi olarak görülmektedir (Gelman ve Vehtari, 2020; Garnett, 2023).

Makine öğrenmesi modellemelerinde, uygun hiperparametrelerin belirlenmesi için sıklıkla bayesyen optimizasyon tekniklerine başvurulmaktadır. Bu teknik, ilk hiperparametreler ile rassal bir model kullanarak bir çıktı üretir. İlk kullanılan parametreler ikinci iterasyon başlangıcında hatayı minimize etmek için ikinci hiperparametrelerin belirlenmesinde kullanılarak, seçimleri stokastik bir sürece dayandırır. Bu olasılıksal süreç iterasyon sayısı kadar devam eder ve amaç fonksiyonuna uygun hiperparametreler elde edilir. Bayesyen

hiperparametrelerin belirlenmesine yönelik matematiksel denklemler aşağıda gösterilmektedir.

$$a_{L(\lambda, V_L)} = \int_{-\infty}^{\infty} \max(L - L^*, 0) pV_L(L|\lambda) d_L \quad (2.54)$$

$\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]$  olmak üzere hiperparametreler matrisini,  $L = [L_1, L_2, \dots, L_n]$  doğrulama skoru matrisini,  $V_L$ , kazanç fonksiyonunu optimize eden olasılıksal bir regresyon denklemini göstermek üzere, en iyi doğruluk skoru  $L^*$ , (2.54) numaralı eşitlik yardımıyla bulunmaktadır.

Bu denklemde  $pV_L(L|\lambda)$  yardımıyla  $\lambda$  değeri, iterasyon boyunca optimize edilmektedir. Ve nihayetinde optimal  $\lambda$  değerleri elde edilmektedir (Snoek vd., 2012; Wang vd., 2020; Masum vd., 2021).

## 2.5. Performans Ölçütleri

Tahmine dayalı her bir modelin, diğer bir model ile karşılaştırılması veya optimizasyon esnasında hangi parametrelerin önemli olduğunu belirlemek için gerçek değerler ile tahmin edilen değerler arasındaki farktan elde edilen bilgiler yardımıyla performans değerlendirmeleri yapılmaktadır. Sürekli verilerde noktasal tahminler için en yaygın kullanılan ölçütler, MAPE, kök ortalama karesel hata (RMSE: Root Mean Square Error) ve çoklu belirtme katsayısı ( $R^2$ ) iken, yönsel tahminlerin doğruluğunu belirlemek için, ortalama yüzdesel doğruluk (MDA: Mean Directional Accuracy) kullanılmaktadır. Bu ölçütler, matematiksel formda eşitlik (2.46), (2.47), (2.48) ve (2.49)'da gösterilmektedir.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| * 100 \quad (2.55)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (2.56)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \mu)^2} \quad (2.57)$$

$$MDA = \frac{1}{N} \sum_{t=1}^n 1_{i\text{şaret}}(Y_t - Y_{t-1}) == i\text{şaret}(\hat{Y}_t - Y_{t-1}) \quad (2.58)$$

RMSE değeri, hata verilerini orijinal birimlerde vermesi, büyük hatalara karşı aşırı duyarlılığı ve tahmin hatalarının varyansının anlaşılabilmesi için avantajlı bir ölçüttür. Ancak matematiksel olarak, hataların karesini aldığı için, pozitif ve negatif hataların yönü

göz ardı edilir ve bu nedenle modelin sistematik bir hata içerip içermediğinin anlaşılması zorlaşır.

MAPE, hataların yüzdesel sapmasını ifade etmesi ve kullanılan ölçekten bağımsız olması nedeniyle parametre belirlemede ve model seçiminde oldukça avantajlıdır. Ancak MAPE ölçütünün de dezavantajları da bulunmaktadır. Tahmin edilen değer ile gerçek değer arasındaki farkın sifıra yakınsaması durumunda, büyük MAPE değerlerine ulaşabilmektedir. MAPE, pozitif ve negatif hataları eşit şekilde değerlendirmede için model seçiminde tek başına kullanılmaması gerekmektedir.

$R^2$ , bağımsız değişken veya değişkenlerin, bağımlı değişkeni ne kadar iyi açıkladığını gösteren bir ölçüttür. Bu ölçüt, varyans üzerinden hareket etmektedir.  $R^2$ , 0-1 arasında değerler almaktadır.  $R^2$ 'nin 1'e çok yakın olması modelin aşırı uyum (overfitting) gösterdiğini ima etmektedir.  $R^2$ , sadece doğrusal ilişkileri ölçmektedir. Eğer bağımlı değişken ile bağımsız değişken arasında doğrusal olmayan bir ilişki mevcut ise  $R^2$  metriği yanıltıcı olabilir.  $R^2$ , tahminin gücünü değil, modelin veriyi ne kadar iyi açıkladığını gösterir, örneklem dışı tahminlerinin gücünü doğrudan yansıtmak için tek başına yeterli değildir.

MDA, tahmin edilen değer ile gerçek değerlerin yönsel hareketlerinin aynı olup olmadığıyla ilgilenir. Bu metrik, gözlem setinin ölçeğinden bağımsız olarak kurulan modellerin, trende ne kadar uyum gösterdiğinin anlaşılması açısından çok önemlidir.

Bu çalışmada kullanılan performans ölçütlerinin her biri, diğerlerinin dezavantajlarını kapatması için özenle seçilmiştir.

## ÜÇÜNCÜ BÖLÜM

### KIRILGAN BEŞLİ DÖVİZ KURLARI ÜZERİNE UYGULAMALAR

#### 3.1. Giriş

Çalışmanın bu kısmında, araştırma konusu, örneklem seçimi, çalışmanın motivasyonu ve amacı anlatılacaktır. Daha sonra alan yazını incelenecektir. Analiz kısmında ilk etapta her bir ülke döviz kuru için geleneksel ve ML modellemeleri, tek değişkenli olarak yapılacaktır. Tek değişkenli analizlerden sonra, her bir ülke için analizler çok değişkenli boyutta yapılacak ve analiz sonuçları toplulaştırılarak sunulacaktır.

Makroekonomik değişkenlere ilişkin tahminler, o ülkenin genel ekonomik seyri hakkında, ekonomik aktörlere ve finansal yatırımcılara büyük bilgiler sunmaktadır. Cari ve geçmiş dönem bilgileri ile geleceğe dönük tahminler yapmak, ekonomik şoklara karşı bu aktörlere ve finansal yatırımcılara bir direnç alanı oluşturmaktadır. Geleneksel tahmin yöntemleri, geçmiş dönem verileriyle belirli bir prosedüre bağlı kalınarak gelecek dönemi tahmin etme metodolojilerine dayanır. Makine öğrenmesi tahmin yöntemleri ise, herhangi bir istatistik veya ekonometrik prosedüre bağlı kalınmaksızın yüzlerce algoritma içinden, mevcut veri setini en iyi tanımlayan bir fonksiyonla, geleceği tahmin etme yeteneğine sahip bir yaklaşımdır.

Haffner (2016), makine öğreniminin yeni bir kavram olmadığını, 60 yıllık bir geçmişe sahip olduğunu belirtmekte, Marr (2016) ise makine öğreniminin 1950’de Alan Turing’in, “Turing Testi” fikrini ortaya atmasıyla başladığını ifade etmektedirler. 1967 yılında ise KNN (K-Nearest-Neighbor) algoritmasının tasarımı ile makine öğrenmesi metodolojik bir alan haline gelmiştir (Sodhi vd., 2019).

Makine öğrenmesi, yeni bir yaklaşım olmasa da teknolojik ilerlemeler ve ekonomi alanına uygulanabilirliğinin artmasıyla birlikte ekonomistler için yeni bir araç haline gelmiştir (Varian, 2014). Makine öğrenmesine dayalı modeller, ekonometrik yöntemlerle analizi mümkün olmayan modeller kurarak, ekonomik aktörlere ve finansal yatırımcılara ekonomik teoriyi test etme ve doğrulama konusunda büyük kolaylıklar sağlamaktadır (Basuchoudhary vd., 2018).

Makine öğreniminin ekonometri ile kesişimi, ekonomik araştırmalarda oldukça önem kazanmıştır, ancak makro ekonometri alanındaki çalışmalar salt performans karşılaştırmalarına dayanmakta ve makine öğrenmesi yöntemlerinin teorik alt yapısından bahsedilmemektedir (Athey, 2018). Geleneksel yöntemler  $y = \alpha + \beta x$  denkleminde,  $\beta$ 'nın tutarlılığı ve etkinliği üzerinden analiz yaparken; makine öğrenmesi yöntemleri,  $y - \hat{y}$  minimizasyonu ile ilgilenmektedir (Mullainathan ve Spiess, 2017). Bu minimizasyon, makine öğrenmesi yöntemlerinin kendi içerisinde belirli özelliklerin optimizasyonu ile sağlanmaktadır. Bunlar; doğrusal olmama, hiperparametrelerin seçimi, kayıp fonksiyonlar ve düzenleştirme aşamalarıdır (Goulet Coulombe vd., 2022).

Türkiye'deki makroekonometrik yazın incelendiğinde, makine öğrenmesi yöntemlerinin bir analiz aracı olarak kullanıldığı, ancak geleneksel yöntemlerin halen yüksek oranda tercih edildiği görülmektedir (Akay vd., 2020).

2013 yılında, Amerikan Merkez Bankası'nın (Fed) genişleyici para politikasını sonlandıracağını duyurmasıyla birlikte, özellikle gelişmekte olan ülkelerden büyük ölçekli sermaye çıkışları yaşanmıştır (Nechio, 2014). Morgan Stanley tarafından yayımlanan bir araştırma raporunda yüksek enflasyon ve cari açık problemleri nedeniyle Fed'in politika değişiminden en çok etkilenecek beş ülke (Brezilya, Endonezya, Güney Afrika, Hindistan ve Türkiye) "Kırılgan Beşli" olarak adlandırılmıştır Aynı raporda, kırılgan beşli ülke para birimlerine karşı Usd pozisyonuna geçmeleri tavsiye edilmiştir (Lord ve Rahman, 2013). Fed'in politika değişimi ve Morgan Stanley'in raporu birlikte ele alındığında, bu ülkeler için döviz kuruna yönelik güvenilir tahminler yapmak, para otoritesi ve finansal yatırımcılar için büyük önem arz etmektedir.

Döviz kurunun mal ve hizmet piyasası ile sermaye hareketlerini etkileyen bir gösterge olarak alacağı değeri doğru tahmin etmek ekonominin tüm tarafları için çok değerlidir. Döviz kurunun doğru tahmin edilmesi ekonomik istikrarsızlığın ve kırılganlığın yüksek olduğu küçük ekonomiler için daha da önemlidir. Bu nedenle tezin uygulama sahası olarak Kırılgan Beşli ekonomileri seçilmiştir

Kırılgan beşli ülkelerin, doğrudan sermaye akımlarına olan yüksek derecedeki bağımlılığı, para birimlerinin oynak yapıda olmasının önemli nedenlerinden biridir. Bu oynaklık, finansal yatırımcılar için bir işlem alanı oluşturmaktadır. Para otoritesinin, artan Fx, vadeli opsiyon ve swap işlemlerine karşılık para arzını arttırmak zorunda kalması da diğer makroekonomik değişkenler üzerinde etkili olabilmektedir. Ayrıca, ulusal para birimindeki dalgalanmalar, döviz kuru geçişkenliği yoluyla, ithal edilen ara ve nihai mal fiyatlarının üzerinde etkili olarak hedef enflasyon üzerinde sapmalara neden olabilmektedir (Takhtamanova, 2008; Fendoğlu vd., 2020). Bu

sapmalar para otoritesinin güvenilirliğini zedeleyerek, diğer aktörlerin davranışlarında değişikliğe yol açabilmektedir.

### 3.2. Alan Yazını

Döviz kurunu tahmin etmeye yönelik yazında, bilişim teknolojilerindeki yeniliklere ve veri yığınlarındaki artışa rağmen, makine öğrenmesi ile geleneksel yöntemlerin karşılaştırıldığı çalışmaların sayıca az olduğu görülmektedir. Bu çalışmalarda da optimizasyon tekniklerinin kullanılmadığı ve modellemelerin iktisadi teorilerden uzak olduğu dikkat çekmektedir. Kırılgan beşli ülkeler üzerine yapılan ekonomik çalışmalar genellikle döviz kurlarının ülkeler arası etkileşime sahip olup olmadıkları, döviz kurlarının yerel düzeyde diğer makroekonomik değişkenlerle ilişkileri ve Fed'in genişlemeci politikalarının yansımalarına odaklanmaktadır (Akel vd., 2015; Bhattacharai vd., 2021; Hersi ve Koy, 2020). Yazarı olduğumuz çalışma haricinde Kırılgan Beşli ülkeler için makine öğrenmesi ile geleneksel yöntemlerin karşılaştırıldığı herhangi bir çalışmaya rastlanmamıştır.

Galeshchuk ve Mukherjee (2017) yaptıkları çalışmada, EURUSD, GBPUSD ve JPYUSD pariteleri için geleneksel tahmin yöntemleri ile derin öğrenme yöntemlerini karşılaştırmışlardır. Geleneksel yöntem olarak, sınıflandırmaya dayalı Naïve, Üstel Düzleştirme (EST) ve ARIMA modelleri kullanılırken, derin öğrenme yöntemleri olarak, yapay sinir ağları (ANN), destek vektör makineleri (SVM) ve evrişimsel sinir ağları (CNN) kullanılmıştır. Çalışma sonucunda, ARIMA ve EST düşük hata oranlarına sahip olmalarına rağmen, yönsel doğruluğu belirlemede yetersiz kalmıştır. ANN ve SVM modelleri, doğruluğu belirlemede iyi performans göstermiştir. Ancak CNN ağı, diğer tüm modellere göre yüksek performans sergileyerek, %75'in üstünde doğruluk oranına sahip olmuştur. Yazarlar, derin mimarili CNN ağlarının, özellik belirlemede ve verilerdeki soyut bilgileri sınıflandırmada çok daha başarılı olabileceğini vurgulamaktadırlar.

García ve diğerleri (2023), tarafından yapılan çalışmada, EURUSD, GBPUSD, JPYUSD, AUDUSD, NZDUSD, ve Bitcoin vadeli paritelerine ait günlük kapanış verileri kullanılarak ARIMA, LSTM ve ARIMA-LSTM hibrit modellerine ait tahmin performansları karşılaştırılmıştır. LSTM modelinin belirgin bir şekilde ARIMA yönteminden olumlu yönde ayrıştığı çalışmada, ARIMA tahminlerinin ek girdi değişkeni olarak LSTM modeline dahil edildiği hibrit model, pür LSTM modeline göre küçük bir iyileşme göstermiştir. Yazarlar LSTM mimarisinin kısa vadeli tahminler için oldukça başarılı olduğunu iddia etmektedirler.

Shen ve diğerkleri (2021), aylık verilerle USDAUD, USDGBP, CADUSD, RMBUSD, USDEUR, JPYUSD ve NTDUSD pariteleriyle tahmin modelleri oluřturmuřlardır. Geleneksel modeller olarak Rasssal Yürüyüş (Random Walk), ETS, ARIMA ve mevsimsel ARIMA (SARIMA) yöntemlerinin kullanıldığı çalışmada, makine öğrenmesi teknikleri olarak, ANN ve farklı varyasyonlara sahip SVR algoritmaları kullanılmıştır. Elde edilen sonuçlar, SVR mimarisinden türetilen algoritmaların tüm tahmin modellerinden daha başarılı olduğunu, yüksek frekanslı veriler ile, döviz kuru teorilerine dayalı yaklaşımların birleştirilmesiyle daha başarılı sonuçlar elde edilmiştir. Çalışmada açık faiz paritesi koşulunun tahmin modellerine dahil edilmesi iktisat yazınına katkı sunmaktadır.

Qureshi ve diğerkleri (2023), Pakistan reel döviz kurunu (USDPKR) tahmin etmeye çalışmıştır. Çalışma herhangi bir döviz kuru modeline dayanmamaktadır. İstatistiksel model olarak EST ve ARIMA kullanılırken, ML modelleri olarak, çok katmanlı algılayıcı (MLP: Multi Layer Perceptron) ve aşırı öğrenme makineleri (ELM: Extreme Learning Machines) mimarileri kullanılmıştır. Eğitim ve test setinin sırasıyla 4:1 ve 3:2 oranlarında bölüldüğü veri setinde iki ayrı tahmin ufku için tahminler yapılmıştır. Elde edilen sonuçlar makine öğrenmesi yöntemlerinin küçük de olsa istatistiksel modellerden daha iyi performans sergilediğini göstermiştir.

Erem (2023), günlük, haftalık ve aylık verilerle CHF EUR, GB EUR, US EUR paritelerini tahmin etmek için örneklem içi ve örneklem dışı modeller kurmuştur. Tahminler bir veya birkaç gizli katmandan oluşan ANN modeli ile yapılmıştır. Çalışma farklı periyotlardaki tahmin doğruluklarını ölçmeye çalıştığından dolayı, alan yazını için önemlidir. CHF EUR ve GB EUR gibi çapraz pariteler günlük ve aylık bazda başarılı sonuçlar verirken, işlem hacmi çok yüksek olan US EUR tahminleri gerçek değerlerden büyük sapmalar içermektedir.

Liao ve diğerkleri (2020), ARIMA, RNN ve SVR yöntemleriyle USDRMB paritesini tahmin etmeye çalışmıştır. Çalışmada, döviz kurunun gecikmeli değerleri kullanılarak tahminler tek değişkenli temelde yapılmış, hem de makroekonomik faktörler girdi değişkeni olarak RNN ve SVR modellerine eklenmiştir. Kullanılan makroekonomik değişkenler, M2, net ticaret hadleri, ihracat fiyat endeksi, ithalat fiyat endeksi, Çin ve ABD enflasyon farklılıkları, doğrudan yabancı yatırımlar, Çin ve ABD faiz farklılıkları, petrol fiyatları, Çin ve ABD borsa endeksleri ve ABD volatilité endeksi (VIX), ve Twitter platformu üzerinden metin kazıma yöntemi olarak oluşturulan bir endeks kullanılmıştır. Herhangi bir optimizasyon sürecinin yer almadığı çalışmada, gizli katman sayıları değiştirilerek ayrı ayrı modeller oluşturulmuştur. Elde edilen sonuçlar gizli katman sayılarının artırıldığı mimarilerin kesin üstünlüğünü göstermektedir.

Çalışma iktisat yazını ve döviz kuru teorilerinin değerlendirilmesi açısından oldukça önemlidir. Araştırma, döviz kurunun salt faiz farklılıkları veya enflasyon farklılıkları üzerinden açıklanamayacak kadar karmaşık bir yapıda olduğunu göstermektedir.

Reddy ve Babu (2015), 2010-2015 yılları arasındaki günlük verileri kullanarak, USDINR, GBPINR, EURINR ve JPYINR paritelerini tahmin etmeye çalışmıştır. Yazarlar yöntem olarak ARIMA, ANN ve fuzzy işlemcili ANN mimarileriyle tahminler yapmışlardır. Herhangi bir optimizasyonun yapılmadığı çalışmanın sonuçları mevcut literatürün aksini iddia etmektedir. Çalışma sonucunda doğrusal olmayan mimariler, doğrusal yapıdaki ARIMA yöntemine göre kötü performans sergilemişlerdir. Bu çalışma gerek iktisat yazını gerek tahmin modelleri açısından optimizasyonun ve model parametrelerinin belirlenme sürecinin önemini vurgulamaktadır.

Escudero ve diğerleri (2021), günlük verilerle EURUSD paritesini tahmin etmeye çalışmışlardır. Yazarlar, 5-11-22-35-44 ve 55 günlük zaman ufukları için ayrı ayrı modellemeler yapmışlardır. ARIMA yöntemine karşılık RNN ve LSTM mimarilerinin, ML yöntemi olarak kullanıldığı çalışmada ARIMA süreci, Rassal Yürüyüş davranışı sergilemiştir. Tahmin sonuçları LSTM mimarisinin kısa vadede, RNN mimarisinin uzun vadede iyi çıkarımlar yaptığını göstermektedir. Bu durumun Elman tipi RNN mimarisindeki  $z^{-1}$  operatörünün uzun vadeli özellikleri çıkarma yeteneğinden kaynaklandığı düşünülmektedir.

Bakır ve diğerleri (2023), yaptıkları çalışmada, kırılğan beşli ülkeler için döviz kurunu hem istatistiksel modellerle hem de ML mimarileriyle tahmin etmeye çalışmışlardır. Yazarlar, 2013-2022 arası günlük verilerle, Naïve, Theta, EST ve ARIMA istatistik yöntemlerine karşılık herhangi bir optimizasyon sürecinin yer almadığı RNN, LSTM, GRU ve CNN mimarilerini kullanmışlardır. Çalışma sonucunda hem nokta hem de yönsel tahminler için RNN mimarisinin üst düzey performans sergilediği, yönsel tahminlerde istatistiksel yöntem olan Naïve yönteminin diğer istatistiksel tahmin yöntemlerinden daha başarılı olduğu tespit edilmiştir.

### 3.3. Kırılğan Beşli Ülkeler

Çalışmamızda, “Kırılğan Beşli” tanımının ilk kez yapıldığı ülke grubu örneklem olarak alınmıştır. Bu ülkeler Brezilya, Endonezya, Güney Afrika, Hindistan ve Türkiye’dir. Daha sonra kırılğan beşli ülke gruplarında değişiklikler olsa da ilk tanımdaki ülkeler günümüzde de ekonomik göstergeleriyle benzer davranışlar sergilemektedir. Bu ülkelere dair, her ülkenin Merkez Bankası, Resmi İstatistik Kurumu ve Federal Rezerv Bankası Ekonomik

Veritabanı'ndan (FRED) elde edilen makroekonomik bilgiler (06/06/2024 itibariyle) aşağıda özetlenmektedir.

### 3.3.1. Brezilya

Kur rejimi dalgalı yapıda olan ve bir G20 ülkesi olan Brezilya, 2023 yılında %2,91 oranında büyüme performansı sergilemiştir. Brezilya'da Borç/Gsyih rasyosu %74,44; kişi başı gelir 9033,77\$; cari politika faiz oranı %10,5; 5 yıllık CDS risk primi 143,35; dış ticaret hacmi 499 milyar\$'dır. Brezilya'nın, çalışma konumuz açısından önem arz eden ve ABD ile farklılıkların ifade edildiği makroekonomik değişkenlerine ilişkin göstergeler Şekil 3.1'de sunulmuştur.



Şekil 3.1. Brezilya Makroekonomik Görünüm


Brezilya'nın makroekonomik görünümüne dair grafik incelendiğinde, özellikle Fed'in parasal genişlemeyi sonlandıracağını duyurmasının ardından, döviz kurunun kontrolden çıktığı, bu kontrolsüzlüğün, ilk etapta faiz artırımla durdurulmaya çalışıldığı, ancak faiz artışına rağmen piyasanın bol likidite ile fonlandığı, bu sırada döviz kurunun hızla

yükselmeye devam ettiği ve para otoritesinin, döviz kurunu istikrara kavuşturmak adına faiz indirdiği, ancak bu faiz indiriminin piyasadaki parasal bolluğu daha da artırdığı gözlemlenmiştir. Bu durum neticesinde döviz kurunun 2017 sonlarında sıçrama yaptığı, Covid 19 süreciyle birlikte reel gelirde büyük düşüş yaşandığı ve 2021 itibariyle para otoritesinin büyük bir faiz artışıyla bu duruma yanıt verdiği görülmektedir. Bu büyük faiz artışıyla birlikte döviz kurunun, önceki dönemlere göre nispeten istikrara kavuştuğu anlaşılmaktadır.

### **3.3.2. Endonezya**

Endonezya, 2023 yılında büyüme oranı %5,05; kişi başı gelir düzeyi 4246,3\$; Borçlar/Gsyih rasyosu %41,95; 1 haftalık repo faiz oranı %6,25; 5 yıllık CDS risk primi 72,72; dış ticaret hacmi 381 milyar\$, kur rejimi dalgalı ve gelişmekte olan bir G20 ülkesidir. Güneydoğu Asya'nın en büyük ekonomisi olan Endonezya, dünyanın en kalabalık dördüncü ülkesidir. Dünyanın en büyük altın madenlerinden birinin yer aldığı Endonezya, son yıllarda güçlü bir dış ticaret performansı sergilemektedir. 2024'ün başından itibaren dış ticaret fazlası veren Endonezya 2023 yılından itibaren uyguladığı düşük faiz, düşük parasal büyüme politikası ile, 2022 yılında %6'lara ulaşan enflasyonu, %3 seviyelerine kadar düşürmeyi başarmıştır. Dornbusch'un Hedefi Aşan Döviz Kuru Modeli temelinde, önem arz eden makroekonomik değişkenler, Şekil 3.2'de gösterilmektedir.

Fed'in kararı ve Morgan Stanley'in raporu sonrasındaki üç yıl boyunca, Endonezya Rupisi yaklaşık olarak %50 değer kaybetmiştir. Endonezya para otoritesi, kurdaki dalgalanmaya 2016'nın başlarında faiz indirimi ile yanlış bir yanıt vererek, USDIDR kurunda bir yukarı sıçrama daha yaratmıştır. Piyasanın sürekli olarak fonlanması, faiz politikasıyla parasal büyümenin asimetrik oluşu, enflasyonu da M2 ile hareket etmeye zorlamıştır. Covid 19 sürecinde kur bir sıçrama daha yaparak tüm zamanların en yüksek seviyesini görmüştür. Endonezya para otoritesi 2020 başlarında, Fed'in faiz indirimlerine karşın, politika değişikliğine gitmeyerek, deflasyonist bir süreç izlemeye çalışmıştır. Ancak 2020 ortalarından itibaren bu tutumunu, faiz indirimleri yönünde değiştirmiştir. Endonezya Merkez Bankası 2022 ortalarından itibaren asimetrik bir yol izleyerek, düşük faiz düşük parasal büyüme politikası ile döviz kuru üzerinde nispeten istikrar sağlamıştır. Endonezya'nın son iki yıl içinde uygulamış olduğu para politikaları hem reel ekonomi hem de enflasyon üzerinde daha istikrarlı bir zemin oluşturmuştur.




Şekil 3.2. Endonezya Makroekonomik Görünüm

### 3.3.3. Hindistan

Hindistan gelişmekte olan ülkeler sınıfında, dalgalı kur rejiminde, nominal olarak dünyanın 5. büyük ekonomisidir. 2023 büyüme oranı %7,69; kişi başı gelir düzeyi 2231,52\$; Borç/Gsyih rasyosu %82,81; 5 Yıllık CDS risk primi 84,09 olan Hindistan'da cari politika faiz oranı %6.50'dir. Hindistan'a ait makroekonomik görünüm Şekil 3.3'te sunulmuştur. Fed'in 2013 yılındaki politika değişikliğinden önce de genel eğilimi yukarı yönlü olan USD/INR paritesi, politika değişikliğinin ardından da yukarı yönlü seyrini sürdürmüştür. Hindistan Merkez Bankası'nın politika faiz oranı üzerindeki müdahalelerinin, kur üzerinde kısa vadeli şoklar yarattığı gözlemlenmektedir. Para arzındaki daraltıcı tutumun, kur üzerinde faiz politikasından daha etkili olduğu dikkat çekmektedir. COVID-19 sürecindeki


genişleyici politikaların, kurdaki genel eğilimi bozmadığı ve reel çıktı üzerinde sadece kısa süreli negatif bir şok yarattığı anlaşılmaktadır. Hindistan'ın kur, enflasyon ve reel çıktı değişkenlerine ait yapısının diğer ülkelere kıyasla daha kararlı halde olduğu görülmektedir.



**Şekil 3.3. Hindistan Makroekonomik Görünüm**

### 3.3.4. Güney Afrika

Güney Afrika, dalgalı kur rejiminde, ihracatı genellikle kıymetli madenlere dayanan ve 208 milyar dolarlık dış ticaret hacmi bulunan, BRICS ve G20 ülke grubuna dahil bir ülkedir. Güney Afrika, 2023 yılında %0,6 büyüme oranına sahip olup, Borç/Gsyih oranı %73,93'tür. Ülkenin politika faiz oranı %8,25; 5 yıllık CDS risk primi 240,8 ve kişi başı gelir düzeyi 6006,74 dolardır. Güney Afrika'nın makroekonomik görünümü Şekil 3.4'te sunulmuştur.




**Şekil 3.4. Güney Afrika Makroekonomik Görünüm**

USD/ZAR paritesi, 2013'ün sonlarına doğru yukarı yönlü bir hareket başlatmıştır. Güney Afrika Merkez Bankası'nın faiz oranı tepkisi, parasal genişlemenin etkisi altında kalarak kurdaki yukarı yönlü ivmenin azalmasında etkili bir araç olamamıştır. 2015'in başlarındaki faiz artırımını etkili olmasına rağmen, 2017'nin başlarından itibaren gerçekleştirilen faiz indirimleri, kurun yeniden yukarı yönlü bir sıçrama yapmasına neden olmuştur. COVID-19 süreciyle birlikte reel çıktıda yaşanan düşüşe paralel olarak Güney Afrika Merkez Bankası'nın genişleyici para politikası, kurla ve enflasyonda yeni yukarı yönlü hareketlerin devamını getirmiştir. COVID-19 sürecinde merkez bankalarının uyguladığı genişleyici politikaların, reel çıktı üzerinde olumlu etkiler yarattığı, diğer makroekonomik göstergeler üzerinde ise yıllar süren olumsuz etkiler yarattığı gözlemlenmektedir.

### 3.3.5. Türkiye

Türkiye, G20 ülkeleri arasında yer alan ve dalgalı kur rejimine sahip, nominal bazda dünyanın en büyük 17. ekonomisidir. 2023 yılında Türkiye ekonomisi %4,52 oranında büyüme kaydetmiştir. Türkiye’de kişi başına düşen gelir 12849 dolar olup, dış ticaret hacmi 617 milyar dolar seviyesindedir. Borç/Gsyih oranı %35,25; 5 yıllık CDS risk primi 262,16 ve cari politika faiz oranı %50 olarak belirlenmiştir. Fed’in 2013 yılındaki genişlemeci politikasını sonlandırmasıyla birlikte, Türkiye’nin makroekonomik görünümü Şekil 3.5’te gösterilmiştir.



Şekil 3.5. Türkiye Makroekonomik Görünüm

2013 yılında Fed'in parasal genişlemeyi sonlandıracağını duyurması ve Morgan Stanley'in Türkiye'yi kırılğan ekonomiler arasında tanımlaması, Türk Lirası üzerinde başlangıçta küçük bir baskı oluşturmuştur. 2014 yılının başında Türkiye Cumhuriyet Merkez Bankası (TCMB) bu duruma hızlı bir yanıt vererek faiz oranlarını yükseltmiş ve bu baskıyı büyük ölçüde hafifletmiştir. Ancak, 2015 sonrası dönemde para arzındaki hızlı artış ve buna bağlı olarak enflasyonun yükselmesi, döviz kuru üzerinde sürekli yukarı yönlü bir baskı yaratmıştır. Özellikle 2019 ortasındaki faiz indirimleri, kurun kontrolsüz bir şekilde yükselmesine neden olmuş, COVID-19 sürecinde artan enflasyonist baskılar reel çıktı üzerinde de olumsuz etkiler yaratmıştır. TCMB, 2023 Mayıs ayı itibariyle düşük faiz politikasından vazgeçmiş ve faiz oranlarını %50'ye kadar yükseltmiştir. Ancak, faiz politikasının döviz kuru üzerinde etkin bir politika aracı olmadığı gözlemlenmektedir.

### **3.4. Analiz ve Bulgular**

Bu kısımda, kırılğan beşli ülke döviz kurlarına ait hem tek değişkenli hem çok değişkenli analizler yapılmıştır. Çalışmada kullanılan döviz kuru değişkenler ICE (Inter Continental Exchange) veri tabanından elde edilmiştir. Gözlemler 01/06/2013-01/06/2024 tarih aralığında olup, frekansı iş günüdür (business day). Tahminlere yönelik analizlere başlamadan önce, tanımlayıcı istatistikler ve veri ön işleme sürecine dair bilgiler verilmiştir.

#### **3.4.1. Tanımlayıcı İstatistikler**

Kırılğan beşli döviz kurlarına ait Tablo 3.1 incelendiğinde, en homojen dalgalanan döviz kurlarının USDIDR ve USDINR olduğu görülmektedir. Değişim katsayısı, ortalama başına standart sapma olduğundan, özellikle USDTRY paritesinin, diğer kırılğan beşli ülkelerden ayrıştığı net olarak ifade edilebilir. USDTRY'deki bu yüksek volatilité, yatırımcıların TL'ye duydukları güvenin düşük olduğunu, ekonomik belirsizliklerin had safhada olduğunu göstermektedir. Bu istatistikler ışığında, Kırılğan Beşli ülkeler içinde en riskli para biriminin TL olduğu söylenebilir. USDTRY dışında en yüksek volatilitéye sahip para birimi USDBRL'dir. Fed'in 2015 yılında faiz artırmaya başlamasıyla, Brezilya'dan ciddi sermaye çıkışları yaşanmış ve ekonomi durgunluğa girmiştir. Ekonomi yönetiminin, 2016 yılı başlarından itibaren uygulamış olduğu düşük faiz politikası bu volatilitenin ana nedenlerinden biridir.

**Tablo 3.1.** Tanımlayıcı İstatistikler

|        | Gözlem Sayısı | Genişlik | En Düşük | En Yüksek | Ortalama    | Standart Sapma | Değişim Katsayısı |
|--------|---------------|----------|----------|-----------|-------------|----------------|-------------------|
| USDBRL | 2869          | 3,761    | 2,125    | 5,886     | 4,00829     | 1,075922       | 26.84             |
| USDIDR | 2869          | 6951,000 | 9787,000 | 16738,000 | 13841,90881 | 1238,276856    | 8.95              |
| USDZAR | 2869          | 10,250   | 9,566    | 19,816    | 14,45636    | 2,499807       | 17.29             |
| USDINR | 2869          | 27,160   | 56,488   | 83,648    | 70,53371    | 7,100795       | 10.07             |
| USDTRY | 2869          | 30,691   | 1,857    | 32,548    | 8,42508     | 8,096677       | 96,10             |

### 3.4.2. Veri Ön İşleme Süreci

Ham veriler için ilk etapta, eksik gözlem olup olmadığı incelenmiştir. Bazı ülkelerdeki tatil günlerindeki farklılıklar nedeniyle “*pandas*” kütüphanesindeki “*interpolate*” fonksiyonu yardımıyla, eksik gözlemler, önceki ve sonraki iş gününün ortalama fiyatı ile doldurulmuştur.

Hem tek değişkenli hem de çok değişkenli analizlerde veriler, standart normalizasyon süreci kullanılarak  $[-1, 1]$  arasına indirgenmiştir. Buradaki amaç, negatif şokların negatif çıktılarına, pozitif şokların ise pozitif çıktılarına dönüşmesini sağlamaktır. Verilerin bu aralığa indirgenmesi nedeniyle, ML modelleri bu aralıkta çalışan aktivasyon fonksiyonlarıyla optimize edilmeye çalışılmıştır. Bu aktivasyon fonksiyonları [*‘SeLu’*, *‘Elu’*, *‘tanh’*] tipindedir.

Analizlerde, gözlem setinin %70’i eğitim seti, %15’i doğrulama seti ve %15’i test seti olarak kullanılmıştır. Doğrulama seti geleneksel yöntemlerin doğası gereği kullanılamadığı için, modeller %70’lik set ile parametre belirlemede, son %15’lik kısım ise örneklem dışı tahminleme mantığıyla kurulmuştur. Geleneksel yöntemlerdeki modellerden ETS ve Theta yöntemlerindeki mevsimsel uzunluk frekansı, 100-270 arası gün belirlenerek en düşük RMSE değerine göre optimize edilmiştir. ARIMA yöntemi için  $(p, d, q)$  katsayıları tahmin edilmeden önce veri Box-Cox dönüşümüne tabi tutulmuş ve parametreler RMSE değerine göre optimize edilmiştir. Makine öğrenmesi modelleri için verilerin %70’i eğitim sürecinde, %15’i doğrulama sürecinde ve %15’i test sürecinde kullanılmıştır. Makine öğrenmesi yöntemlerinde, veriyi ezberlemenin önüne geçmek için iki kez seyreltme işlemi (dropout) uygulanmıştır. Aktivasyon fonksiyonları, nöron sayıları, katman sayıları, öğrenme oranları bayesyen teoriyle uyumlu bir şekilde optimize edilmiştir.

Ridge regresyon için  $\lambda$  katsayısı için optimizasyon yapılırken, XGBoost için derinlik, her bir ağaç için kullanılacak örnek sayısı, gamma katsayısı ve öğrenme oranı optimize edilmiştir.


Çalışmadaki tüm tahminler, eğitim sürecinden elde edilen bilgiler neticesinde, örneklem dışı (out-of-sample) mantıkla yapılmıştır.

### 3.4.3. Naive Drift Tahminleri

Naive drift tahminleri, eğitim setindeki ilk nokta ile son noktayı birleştiren ve bu noktalar arasındaki sapmaların ortalamasına göre eğilim belirleyen bir yöntemdir. Model, mevsimsel veya döngüsel bileşenleri göz ardı ettiği için, zaman serisindeki dalgalanmalara karşı hassas değildir. Naive drift yöntemine ilişkin performans metrikleri ve tahminler sırasıyla Tablo 3.2 ve Şekil 3.6’da gösterilmektedir.

**Tablo 3.2.** Naive Drift Modeli Tahmin Metrikleri

| Döviz Kuru | RMSE     | MAPE   | $R^2$ | MDA   |
|------------|----------|--------|-------|-------|
| USDBRL     | 0,740    | 13,541 | 0,216 | 0,379 |
| USDIDR     | 1017,472 | 6,217  | 0,268 | 0,388 |
| USDINR     | 8,220    | 9,913  | 0,539 | 0,402 |
| USDZAR     | 3,303    | 17,660 | 0,393 | 0,395 |
| USDTRY     | 18,127   | 68,518 | 0,934 | 0,535 |



**Şekil 3.6.** Naive Drift Modeli Tahminleri

Tablo 3.2 ve Şekil 3.6 incelendiğinde trend eğilimi, tüm kırılkan beşli ülkeler için yukarı yönlüdür. Döviz kurunun gerçek değerlerinin, Naive tahminleriyle yakın sapmalı hareket etmesi, o piyasadaki fiyat dengesinin beklentilerle uyumlu olduğunu göstermektedir. USDTRY için  $R^2$  ve MDA değerinin diğer ülkelere göre çok yüksek olduğu görülmektedir. Bu metriklerin gerçekte tutarlı olmadığı MAPE ve RMSE değerlerinden net bir şekilde anlaşılmaktadır. Hem

Naive tahmincisi hem de USDTRY kurunun trend eğiliminin dalgalanma olmadan sürekli olarak yukarı olması bu tutarsız sonucu doğurmaktadır.


#### 3.4.4. Theta Tahminleri

Theta yöntemi basit üstel düzeltirme ve lineer regresyon modelinin bileşimidir. Model genel anlamda serinin düzeyi ve eğilim bileşenlerini analiz ederek çıkarım yapmaktadır. Çalışmada kurulan Theta modellerinde “ $\theta = 2 - np.linspace(-10, 10, 50)$ ” yaklaşımıyla, theta için -10, +10 arasındaki reel sayılar için 50 adet değer belirlenerek, bu değerler arasında MAPE değerinin en düşük olduğu theta değeri en iyi theta olarak belirlenmiştir. En iyi theta değeri belirlendikten sonra, serinin mevsimsel yapısı da göz önüne alınarak 30 ila 270 gün arasındaki her gün için ayrı ayrı model denemeleri yapılmış ve en iyi mevsimsel yapı, en düşük MAPE değerine göre elde edilmiştir. Bu iki aşamalı optimizasyon süreci sonrasında elde edilen tahminlere ait metrikler Tablo 3.3’te sunulmuştur.

**Tablo 3.3.** Theta Modeli Tahmin Metrikleri

| Döviz Kuru | Mevsimsel Periyot | Optimal Theta | RMSE     | MAPE   | $R^2$ | MDA   |
|------------|-------------------|---------------|----------|--------|-------|-------|
| USDBRL     | 187               | 0,571         | 0,218    | 3,741  | 0,229 | 0,421 |
| USDIDR     | 151               | -8            | 1022,239 | 6,238  | 0,244 | 0,358 |
| USDINR     | 114               | -1,061        | 7,356    | 8,768  | 0,554 | 0,419 |
| USDZAR     | 206               | 2,204         | 3,488    | 18,588 | 0,156 | 0,386 |
| USDTRY     | 178               | -0,245        | 15,102   | 58,295 | 0,933 | 0,493 |

Model metrikleri incelendiğinde, USDTRY’nin diğer ülke döviz kurlarından net bir şekilde ayrıştığı görülmektedir. Yüksek  $R^2$  ve MDA değerleri, USDTRY’nin sürekli yükseliş hareketinden kaynaklanmaktadır. USDZAR paritesi için mevsimsel periyodun en yüksek değere sahip olması, bu paritenin mevsimsel etkilerden güçlü bir şekilde etkilendiğini, düşük  $R^2$  ve MDA değeri ise kurulan modelin bu etkileri tahmin etmede zorlandığını göstermektedir. USDBRL için RMSE ve MAPE değerinin düşük, MDA değerinin yüksek olması ise, Theta modelinin, bu döviz kuru için iyi bir tahminci olduğunu ima etmektedir. Theta modelindeki optimal theta değerlerinin birbirlerinden ciddi şekilde ayrışması, optimizasyon sürecinin önemini ortaya koymaktadır. Theta tahminlerine ait zaman yolu grafiklerinin sunulduğu Şekil 3.6 incelendiğinde, USDBRL’nin tahmin başarısı net bir şekilde görülmektedir. Türkiye için trendin doğru ancak tahminlerin gerçek fiyattan büyük sapmalar göstermesi  $R^2$  metriğinin yanıtlar sonuçlar içerdiğine işaret etmektedir.



Şekil 3.7. Theta Modeli Tahminleri


### 3.4.5. Holt's Winters Üstel Düzleştirme (ETS) Tahminleri

ETS modeli, bir serinin mevsimsel ve trend bileşenlerini ayrı ayrı modelleyerek tahminler yapmaktadır. Model, periyodik dalgalanmaları ve uzun vadeli eğilimleri ortaya çıkarmak için özellikle satış, stok yönetimi, enerji tüketimi ve turizm ziyaretçi sayıları gibi trend ve mevsimsel bileşenlerin baskın olduğu zaman serilerini tahmin etmede sıkça kullanılmaktadır. ETS yöntemiyle tahminler yapılmadan önce, serinin mevsimsel yapısını belirlemek için 100-270 gün arası dönem mevsimsel aralık olarak seçilmiştir. Mevsimsellik bileşeni çarpımsal ve toplamsal model için ayrı ayrı optimize edilmiştir. Bu aralıkta ayrı ayrı 171 model kurularak, en düşük RMSE değerine göre optimal mevsimsel periyotlar belirlenmiştir. Bu yaklaşım sonucunda kurulan modellere ilişkin, performans metrikleri Tablo 3.4'te sunulmuştur.

Tablo 3.4. ETS Modeli Tahmin Metrikleri

| Döviz Kuru | Mevsimsel Periyot | RMSE    | MAPE   | $R^2$ | MDA   |
|------------|-------------------|---------|--------|-------|-------|
| USDBRL     | 200               | 0,514   | 8,856  | 0,186 | 0,406 |
| USDIDR     | 143               | 985,625 | 5,965  | 0,209 | 0,365 |
| USDINR     | 255               | 7,151   | 8,538  | 0,323 | 0,423 |
| USDZAR     | 151               | 3,036   | 16,113 | 0,205 | 0,381 |
| USDTRY     | 241               | 17,560  | 66,094 | 0,528 | 0,430 |

ETS tahmin sonuçlarına ait metrikler incelendiğinde, USDTRY'deki  $R^2$  ve MDA metriklerindeki doğruluğu, RMSE ve MAPE metrikleri teyit edememektedir. Örneklem dışı tahminlerin yer aldığı ETS modeli için en tutarlı tahminler USDINR için yapılmıştır.



Şekil 3.8. ETS Modeli Tahminleri


Şekil 3.8 de örneklem dışı tahminler, USDINR metriklerini teyit etmektedir. ETS modelinde de noktasal tahminlerin en başarısız olduğu parite USDTRY'dir. Diğer pariteler için mevsimsel periyodun belirlenmesindeki optimizasyon sürecinin işlevsel olduğu göze çarpmaktadır.

### 3.4.6. ARIMA Tahminleri

ARIMA sürecinde, her bir ülke döviz kurunun tahminine geçilmeden önce veriler üzerinde durağanlık analizi yapılmıştır. İlgili değişkenin birim kök içerip içermediği, sabit ve trend içeren modeller yardımıyla belirlenmiştir. ARIMA süreci için  $(p, d, q)$  parametreleri optimize edilmiştir. Bayesyen Bilgi Kriteri (BIC)'nin en düşük değere ulaştığı parametre kümesi en iyi model olarak tercih edilmiştir. Kurulan modellere ilişkin performans metrikleri ve tahminlere ilişkin zaman yolu grafikleri Tablo 3.5 ve Şekil 3.9'da gösterilmiştir.

**Tablo 3.5. ARIMA Modeli Tahmin Metrikleri**

| Döviz Kuru | Parametreler<br>( $p, d, q$ ) | MAPE     | RMSE   | R2    | MDA   |
|------------|-------------------------------|----------|--------|-------|-------|
| USDBRL     | (2, 1, 1)                     | 0,786    | 14,322 | 0,200 | 0,379 |
| USDIDR     | (3, 1, 0)                     | 1248,843 | 7,780  | 0,284 | 0,388 |
| USDINR     | (5, 1, 0)                     | 7,966    | 9,587  | 0,540 | 0,406 |
| USDZAR     | (2, 1, 0)                     | 3,406    | 18,205 | 0,382 | 0,395 |
| USDTRY     | (0, 1, 5)                     | 17,654   | 66,992 | 0,934 | 0,534 |

**Şekil 3.9. ARIMA Modeli Tahminleri**

Tablo 3.5 incelendiğinde USDTRY haricindeki paritelerin yoğun olarak AR(p) süreci ile hareket ettiği buna karşın USDTRY'nin sadece MA(q) süreci ile hareket ettiği gözlemlenmiştir. USDTRY'nin bu yapısı, fiyat oluşumunun geçmiş fiyat hareketlerinden daha çok, fiyattaki sapmalara göre hareket ettiğini göstermektedir. Bu sonuç, USDTRY'nin volatil bir yapıya sahip olduğunu ve ani fiyat değişikliklerine duyarlı olduğuna işaret etmektedir. USDTRY'deki yüksek  $R^2$  ve MDA değeri, RMSE ve MAPE metrikleriyle tutarlılık göstermemektedir. Yüksek  $R^2$  ve MDA, düşük MAPE ve RMSE değerlerinden hareketle, ARIMA yöntemiyle en başarılı tahmin edilen kur USDINR'dir. Örneklem dışı tahminlere ilişkin zaman yolu grafiğinin yer aldığı Şekil 3.9 incelendiğinde en başarılı tahminin USDIDR için yapıldığı görülmektedir. Performans metrikleri ile görsel arasındaki bu fark, USDIDR'nin döviz kuru değerinin yüksek olmasından kaynaklanmaktadır. ARIMA tahmin sonuçları, Kırılgan Beşli ülkeler için her ne kadar trend hakkında genel bilgi verse

de, ani fiyat ve politika değişimlerinin yaşandığı günümüz finans piyasaları için, yeterli düzeyde tahmin başarısı gösterememiştir.

Şekil 3.9 ve Tablo 3.5 birlikte değerlendirildiğinde ARIMA sürecinde için en isabetli örneklem dışı tahminlerin USDIDR için yapıldığı görülmektedir.


### 3.4.7. RNN Tahminleri

RNN modelleri, özellikle zaman serisi verileri gibi ardışık veriler üzerinde etkili tahminler yapabilen güçlü makine öğrenimi teknikleridir. Bu modeller, önceki adımlardan gelen bilgiyi kullanarak gelecekteki adımları tahmin edebilme yeteneğiyle öne çıkmaktadır. RNN mimarisi kendi içinde, ağırlıkları optimize eden fonksiyonel bir yapıya sahiptir. Ağırlıkların optimizasyonu sırasında elde edilen hatalar, geri yayılım algoritmasıyla (backpropagation through time) geriye doğru işlenmektedir. Hataların minimizasyonu ile ağırlık parametreleri nihai halini almaktadır.

RNN kendi iç mimarisi haricinde; nöron sayısı, aktivasyon fonksiyonu, öğrenme oranı ve gizli katman gibi parametrelerin optimizasyonu ile daha hassas ve isabetli tahminler yapılabilir. Bayesyen optimizasyon teknikleri, bu parametrelerin en uygun şekilde belirlenmesine yardımcı olmaktadır. Optimizasyon sürecinde aşırı öğrenme (overfitting) sorununu önlemek için seyreltme (dropout) ve erken durdurma (early stopping) teknikleri kullanılmıştır. Kırılgan Beşli döviz kurları için RNN tahminleri yapılırken, giriş katmanındaki nöron sayısı, aktivasyon fonksiyonu, öğrenme oranı ve gizli katmandaki nöron sayıları Bayesyen tekniklerle optimize edilmiştir. Optimizasyon parametrelerinin belirlenmesi için, nöron sayıları 32-128 aralığında ve adım sayısı (stepwise) 32 olarak, seyreltme oranı 0.3, 0.5 aralığında ve adım sayısı 0.05 olarak, öğrenme oranları ise 0.001 ve 0.00001 aralığında seçilmiştir. Bu optimizasyon sürecinde, verilerdeki aşırı öğrenme (overfitting) sorununun önüne geçmek için iki kez seyreltme işlemi uygulanmıştır. Tahminler için epok sayısı 50 olarak kullanılmıştır. Tüm bu düzenleme (regularization) işlemlerine ek olarak, aşırı öğrenmenin önüne geçmek için algoritmaya “erken durdurma” (early stopping) fonksiyonu entegre edilmiştir. Seyreltme işlemine ait parametrelerin de optimizasyon mantığıyla elde edildiği RNN modeline ait performans metrikleri Tablo 3.6’da sunulmuştur (Ek-5). Bu optimizasyon teknikleri, modelin genel performansını artırmak ve tahmin doğruluğunu maksimize etmek için kritik öneme sahiptir.

Tablo 3.6. RNN Modeli Tahmin Metrikleri

| Döviz Kuru | RMSE    | MAPE   | MDA    | $R^2$  |
|------------|---------|--------|--------|--------|
| USDBRL     | 0,0466  | 0,7550 | 0,5691 | 0,9398 |
| USDIDR     | 53,7926 | 0,2476 | 0,5504 | 0,9810 |
| USDINR     | 0,4177  | 0,4726 | 0,5386 | 0,9244 |
| USDZAR     | 0,1600  | 0,6783 | 0,5738 | 0,9500 |
| USDTRY     | 0,9646  | 2,4626 | 0,6112 | 0,9972 |



Şekil 3.10. RNN Modeli Tahminleri

Tablo 3.6 incelendiğinde RNN modeli tahmin sonuçlarının, tek değişkenli geleneksel istatistiksel yöntemlerden daha iyi performans sergilediği görülmektedir. Ancak USDTRY paritesindeki yüksek  $R^2$  ve MDA değeri, geleneksel istatistiksel yöntemlerde olduğu gibi RMSE ve MAPE metrikleri tarafından teyit edilememektedir. Modellere ait zaman yolu grafiğinin sunulduğu Şekil 3.10, performans metriklerini doğrular niteliktedir. Özellikle USDINR ve USDTRY'deki sapmalar RMSE metriğinin işlevselliğini göstermektedir. Metrikler arası uyumun en yüksek olduğu parite USDBRL ve USDZAR pariteleridir. RNN modeli yardımıyla en yüksek yönsel doğruluk USDZAR paritesi için elde edilmiştir. Çalışmamızda belirli parametre aralıkları için optimizasyon işlemi yapılmıştır. USDINR ve USDTRY paritesindeki dalgalanmalar RNN mimarisi kullanılarak yapılan tahminlere göre sapmalar içermektedir. Bu sapmalar, modelin daha fazla optimize edilmesi gerektiğini ima etmektedir. RNN mimari yapısı gereği uzun vadeli bağımlılıkları öğrenmekte zorlanabilmektedir. Bu sorunu çözmek için LSTM ve GRU mimarileri geliştirilmiştir.

### 3.4.8. LSTM Tahminleri

LSTM, RNN ailesinden bir mimariye sahiptir. LSTM, uzun vadeli bağımlılıkları tespit etmek için, unutmama-giriş-çıkış kapılarındaki bilgileri geçici olarak unutan veya hatırlayan bir yapay sinir ağı türüdür. LSTM son yıllarda özellikle finans piyasalarının karmaşık yapısını çözümlemede ve volatilité modellemelerinde sıkça kullanılmaktadır. LSTM'in mimari şeffaflığı ve artan gradyan sorununu çözme yeteneği, eğitim sürecinin daha istikrarlı olmasını sağlamaktadır.


Çalışmamızdaki LSTM modellemeleri için, her bir katmandaki nöron sayısı 32-128 aralığında ve adım sayısı 32; her iki seyreltme katmanı için oranlar 0,3-0,5 aralığında ve adım sayısı 0,05; gizli katman nöron sayısı 32-128 aralığında ve adım sayısı 32; öğrenme oranı 0,001 ve 0,00001 aralığında olmak üzere optimizasyon işlemi yapılmıştır. Optimizasyon sürecindeki bu değerlerin küçük tutulma nedeni, veri üzerinde aşırı öğrenmeyi engellemektir.

Verilerdeki aşırı uyum sorununun giderilmesi için de iki ayrı katmanda seyreltme işlemine ek olarak ayrıca erken durdurma fonksiyonu kullanılmıştır (Ek-6). Bu mimari yapıya göre kurulan LSTM modellerine ait performans metrikleri Tablo 3.7'de sunulmuştur.

**Tablo 3.7.** LSTM Modeli Tahmin Metrikleri

| Döviz Kuru | RMSE   | MAPE  | MDA   | $R^2$ |
|------------|--------|-------|-------|-------|
| USDBRL     | 0.050  | 0.762 | 0.496 | 0.913 |
| USDIDR     | 62.533 | 0.313 | 0.518 | 0.978 |
| USDINR     | 0.395  | 0.427 | 0.429 | 0.862 |
| USDZAR     | 0.152  | 0.655 | 0.555 | 0.946 |
| USDTRY     | 1.641  | 4.806 | 0.623 | 0.998 |

LSTM modeli tahmin metrikleri, bu mimariye ait tahminlerin RNN modelinden daha iyi olmadığını göstermektedir. Bu sonuç, RNN'deki kaybolan gradyanlar sorununun, LSTM mimarisi ile çözümlenemediğini ima etmektedir. LSTM sonuçları da, diğer modellerde olduğu gibi USDTRY metriklerindeki tutarsızlıkları teyit etmektedir. LSTM modeline en iyi uyumu gösteren parite USDZAR paritesidir. Modellere ait zaman yolu grafiği de bu sonucu doğrular niteliktedir (Şekil 3.10).



Şekil 3.11. LSTM Modeli Tahminleri

### 3.4.9. GRU Tahminleri


LSTM hücrelerine alternatif olarak geliştirilen, uzun vade bağımlılıklarını daha etkili bir şekilde öğrenebilen bir algoritmaya sahiptir. GRU algoritması kendi içinde LSTM'den daha az parametreye sahip, hesaplama açısından daha verimli bir modeldir. Bu mimaride sadece güncelleme ve sıfırlama kapıları bulunduğundan, veri üzerindeki karmaşıklık daha kolay çözümlenebilmektedir. Güncelleme kapısı, uzun vadeli bağımlılıkların ortaya çıkarılmasında rol oynamaktadır. Ayrıca unutma kapısı gradyan kaybı sorununun da çözüldüğü kapıdır. GRU mimarileri gerçek zamanlı finans uygulamalarında, sıkça kullanılmaktadır. Çalışmamızda modellenen GRU mimarisine ait hiperparametreler ve aralıkları değiştirilmeden, Bayesyen tekniklerle optimize edilmiştir.

Kırılgan beşli ülkelere ait örneklem dışı tahmin metrikleri Tablo 3.8'de gösterilmiştir.

Tablo 3.8. GRU Modeli Tahmin Metrikleri

| Döviz Kuru | RMSE   | MAPE  | MDA   | $R^2$ |
|------------|--------|-------|-------|-------|
| USDBRL     | 0.042  | 0.623 | 0.543 | 0.931 |
| USDIDR     | 48.152 | 0.211 | 0.571 | 0.984 |
| USDINR     | 0.183  | 0.147 | 0.506 | 0.915 |
| USDZAR     | 0.152  | 0.640 | 0.595 | 0.951 |
| USDTRY     | 0.410  | 1.415 | 0.607 | 0.999 |

GRU modeline ait metrikler incelendiğinde, model performansının LSTM'den daha iyi olduğu göze çarpmaktadır. USDTRY için metriklerdeki uyumsuzluk devam etmektedir. Örneklem dışı GRU tahminleri içinde en iyi performans USDZAR paritesinde görülmektedir. Modellerin zaman yolu grafikleri de GRU mimarisine ait performansın LSTM ve RNN'den daha iyi olduğuna işaret etmektedir (Şekil 3.12). RNN ve LSTM modelindeki gerçek değer ve tahmin edilen değer arasındaki büyük sapmalar, GRU mimarisi yardımıyla oldukça azalmıştır. Bu sonuç, USDINR ve USDTRY paritelerindeki fiyat hareketlerinin uzun dönem bilgiye dayalı olduğunu göstermektedir.



Şekil 3.12. GRU Modeli Tahminleri


#### 3.4.10. CNN Tahminleri

CNN mimarisi, önceki makine öğrenmesi mimarilerinden ayrışmaktadır. CNN mimarisi, havuzlama ve filtreleme aşamalarında, katmanlar arasında ağırlıkları paylaştırarak, hesaplama yükünü azaltmakta ve karmaşık verileri daha iyi çözümleyebilmektedir. Analizin bu aşamasında kernel büyüklüğü, filtre sayıları, aktivasyon fonksiyonları, öğrenme oranları ve iki ayrı katmanda uygulanan seyreltme işlemleri Bayesyen teoriyle uyumlu bir şekilde optimize edilmiştir. Bu mimariye ilişkin tahmin metrikleri Tablo 3.9'da sunulmuştur.

**Tablo 3.9.** CNN Modeli Tahmin Metrikleri

| Döviz Kuru | RMSE   | MAPE  | MDA   | $R^2$ |
|------------|--------|-------|-------|-------|
| USDBRL     | 0.038  | 0.555 | 0.539 | 0.944 |
| USDIDR     | 54.955 | 0.260 | 0.548 | 0.982 |
| USDINR     | 0.251  | 0.262 | 0.553 | 0.931 |
| USDZAR     | 0.148  | 0.633 | 0.584 | 0.949 |
| USDTRY     | 0.462  | 1.133 | 0.574 | 0.999 |

Performans metrikleri incelendiğinde, CNN mimarisinin USDTRY paritesi haricinde neredeyse GRU mimarisi ile aynı performansa sahip olduğunu göstermektedir. CNN mimarisinde en iyi performansın gözlemlendiği pariteler USDIDR, USDBRL ve USDZAR’dır. Modelden elde edilen metrik bilgileri, zaman yolu grafiğinde de göze çarpmaktadır (Şekil 3.13).

**Şekil 3.13.** CNN Modeli Tahminleri

### 3.4.11. Ridge Regresyon Tahminleri

Ridge regresyonu kullanılarak yapılan tahminlerde, Dornbusch’un katı fiyatlı parasal modelinden yararlanılmış ve her ülke için ayrı ayrı gecikme uzunluğu ve  $\lambda$  optimizasyonu gerçekleştirilmiştir. Dornbusch’un orijinal çalışmasında, geçmiş fiyat hareketleri teorik olarak modele dahil edilmemiştir. Biz de bu yöntemi esas alarak, her ülkenin M2 parasal büyüme oranı ile ABD M2 parasal büyüme oranı arasındaki farkı, faiz oranları farklılıklarını, enflasyon oranları farklılıklarını ve reel çıktı farklılıklarını bağımsız değişkenler olarak

kullanarak, nominal döviz kurunu bağımlı değişken olarak modellemeyi amaçladık. Bağımsız değişkenlerin gecikme uzunlukları belirlenirken, minimum 1, maksimum 5 gecikme esas alınarak, 4 bağımsız değişkenin 625 adet kombinasyonu ve 20 farklı  $\lambda$  denemesi yapılmıştır. Optimum gecikme uzunluğu ve  $\lambda$  değeri için ayrıca K-Fold çapraz doğrulama tekniği kullanılmıştır. Yapılan algoritmik işlem Ek-9'da yer almaktadır. Ridge regresyon uygulamasındaki asıl amaç birbirleriyle etkileşimli değişkenler arasındaki çoklu doğrusal bağlantıyı ortadan kaldırıp, para politikasının makroekonomik değişkenler üzerindeki etkisini ortaya çıkarmaktır. Ridge Regresyon modelleri için yapılan analizlerde her ülke için ayırı ayırı değerlendirmelerde bulunulmuştur.

#### 3.4.11.1. Brezilya için Ridge Regresyon Tahminleri

Brezilya için kurulan Ridge Regresyon modelinde, eğitim ve test seti olarak ikiye ayrılmıştır. Eğitim setinden elde edilen bilgiler ışığında en iyi gecikme uzunluğu ve  $\lambda$  değeri belirlenmiş ve bu paramtereler örneklem dışı test setine uygulanmıştır. Bu uygulama sonrasında elde edilen modele ait istatistikler Tablo 3.10'da gösterilmiştir

**Tablo 3.10.** Brezilya için Ridge Regresyon İstatistikleri

| Değişken                               | Katsayı      | p-değeri |
|----------------------------------------|--------------|----------|
| Parasal Büyüme Farklılığı (BR-US) lag1 | -0.009       | 0.415    |
| Enflasyon Farklılığı (BR-US) lag1      | -0.099       | 0.455    |
| Reel Çıktı Farklılığı (BR-US) lag1     | 0.108        | 0.179    |
| Reel Çıktı Farklılığı (BR-US) lag2     | 0.076        | 0.236    |
| Reel Çıktı Farklılığı (BR-US) lag3     | 0.048        | 0.430    |
| Reel Çıktı Farklılığı (BR-US) lag4     | 0.028        | 0.789    |
| Reel Çıktı Farklılığı (BR-US) lag5     | -0.005       | 0.821    |
| Faiz Farklılığı (BR-US) lag1           | -0.743       | 0.000    |
| Sabit Terim                            | 3.889316     | 0.000    |
| F Katsayısı                            | 6.349        |          |
| F Katsayısı p olasılığı                |              | 0.000    |
| En iyi gecikme kombinasyonu            | (1, 1, 5, 1) |          |
| En iyi $\lambda$ değeri                | 10           |          |
| En düşük RMSE                          | 0.819        |          |

Ridge regresyon istatistiklerinin gösterildiği tablo incelendiğinde, en iyi gecikme uzunluğunun (1, 1, 5, 1) olduğu görülmektedir. Model katsayılarından sadece faiz farklılıklarına ait katsayı istatistiksel olarak anlamlıdır. Modelin genel uyumu ve açıklayıcılığı istatistiksel olarak anlamlıdır. Bu analiz sonuçları, Brezilya para otoritesinin, kurdaki olası riskleri minimize etmesi için, politika faiz oranını, Fed'in politika faiz oranından daha yüksek tutması gerektiğini ifade etmektedir. Modeldeki diğer bağımsız değişkenlerin istatistiksel olarak anlamlı bulunmaması, bu değişkenlerin önemsiz olduğu

manasına gelmemektedir. Çalışmamızdaki asıl amaç katı fiyatlı parasal modelin hangi gecikmelerde döviz kurunu etkileyebileceğini ortaya koymaktır. Zira, Tablo 3.11’de kurulan Ridge regresyona ait performans metrikleri, Dornbusch’un katı fiyatlı parasal modelinin döviz kurunu yönsel olarak, tek değişkenli geleneksel modellerden daha iyi tahmin ettiğini göstermektedir.

**Tablo 3.11.** Brezilya için Ridge Regresyon Performans Metrikleri

| Döviz Kuru | RMSE  | MAPE   | MDA   | $R^2$  |
|------------|-------|--------|-------|--------|
| USDBRL     | 1.551 | 29.744 | 0.545 | 0.0217 |

### 3.4.11.2. Endonezya için Ridge Regresyon Tahminleri

Ridge regresyon analizi, regresyon modellerinde aşırı uyumu (overfitting) önlemek için kullanılan bir yöntemdir. Endonezya için kurulan model sonucunda, makroekonomik değişkenlerin gecikme yapısı (4, 5, 3, 1) olarak belirlenmiştir. Optimizasyon sonucunda elde edilen modele ait istatistikler Tablo 3.12’de gösterilmiştir.

**Tablo 3.12.** Endonezya için Ridge Regresyon İstatistikleri

| Değişken                               | Katsayı      | p-değeri |
|----------------------------------------|--------------|----------|
| Parasal Büyüme Farklılığı (ID-US) lag1 | -115.936655  | 0.251    |
| Parasal Büyüme Farklılığı (ID-US) lag2 | -123.387139  | 0.052    |
| Parasal Büyüme Farklılığı (ID-US) lag2 | -133.764444  | 0.079    |
| Parasal Büyüme Farklılığı (ID-US) lag4 | -107.463098  | 0.293    |
| Enflasyon Farklılığı (ID-US) lag1      | -59.532557   | 0.466    |
| Enflasyon Farklılığı (ID-US) lag2      | -41.181831   | 0.745    |
| Enflasyon Farklılığı (ID-US) lag3      | -91.986848   | 0.737    |
| Enflasyon Farklılığı (ID-US) lag4      | -82.997928   | 0.705    |
| Enflasyon Farklılığı (ID-US) lag5      | -150.221016  | 0.398    |
| Reel Çıktı Farklılığı (ID-US) lag1     | -48.823652   | 0.985    |
| Reel Çıktı Farklılığı (ID-US) lag2     | -56.737133   | 0.635    |
| Reel Çıktı Farklılığı (ID-US) lag3     | -106.866043  | 0.228    |
| Faiz Farklılığı (ID-US) lag1           | -873.76864   | 0.000    |
| Sabit Terim                            | 14568.96937  | 0.000    |
| F Değeri                               | 5.683        |          |
| F Değeri p olasılığı                   |              | 0.000    |
| En iyi gecikme kombinasyonu            | (4, 5, 3, 1) |          |
| En iyi $\lambda$ değeri                | 10           |          |
| En düşük RMSE                          | 945.974      |          |

Ridge regresyon modeline ait analiz sonuçları faiz farklılığının birinci gecikmede döviz kurunu etkilediğini göstermektedir. Parasal büyüme farklılıkları ise ikinci ve üçüncü gecikmede, döviz kuru üzerinde etkilidir. Bu gecikme yapıları, faiz oranının, parasal büyüme üzerinde gecikmeli etkisini de ifade etmektedir. Enflasyon ve reel çıktı farklılığına ait katsayıların istatistiksel olarak anlamlı değildir. Bu sonuç, enflasyon ve reel çıktı farklılıklarının ekonomik aktivite üzerinde doğrudan etkili olmadığına işaret etmektedir.

Endonezya para otoritesi, parasal büyüme oranlarını ve faiz oranlarını ABD’den yüksek tutarak, negatif kur şoklarına karşı korunabilir. Bu yerel para biriminin değer kaybını önlemeye ve ekonomik istikrarı sağlamaya yardımcı olabilir. Endonezya için kurulan modellerin performans metrikleri, fiyatın gecikmeli değerleri ile modellenen tek değişkenli birçok modelden yönsel olarak daha tutarlı olduğu sonuçlar vermiştir (Tablo 3.13).

**Tablo 3.13.** Endonezya için Ridge Regresyon Performans Metrikleri

| Döviz Kuru | RMSE    | MAPE  | MDA   | $R^2$ |
|------------|---------|-------|-------|-------|
| USDIDR     | 896.235 | 5.248 | 0.575 | 0.436 |

### 3.4.11.3. Hindistan için Ridge Regresyon Tahminleri

Hindistan için yapılan Ridge regresyon analizinde, makroekonomik değişkenlerin gecikme yapısı (1, 1, 2, 1) olarak belirlenmiştir. Optimizasyon sonucu elde edilen modele ait istatistikler Tablo 3.14’te sunulmuştur.

**Tablo 3.14.** Hindistan için Ridge Regresyon İstatistikleri

| Değişken                               | Katsayı      | p-değeri |
|----------------------------------------|--------------|----------|
| Parasal Büyüme Farklılığı (IN-US) lag1 | -3.973       | 0.090    |
| Enflasyon Farklılığı (IN-US) lag1      | 1.862        | 0.210    |
| Reel Çıktı Farklılığı (IN-US) lag1     | 0.793        | 0.771    |
| Reel Çıktı Farklılığı (IN-US) lag2     | 1.015        | 0.691    |
| Faiz Farklılığı (IN-US) lag1           | -10.503      | 0.000    |
| Sabit Terim                            | 73.661       | 0.000    |
| F Katsayısı                            | 40.163       |          |
| F Katsayısı p olasılığı                |              | 0.000    |
| En iyi gecikme kombinasyonu            | (1, 1, 2, 1) |          |
| En iyi $\lambda$ değeri                | 0.061        |          |
| En düşük RMSE                          | 2.799        |          |

Hindistan için kurulan Ridge Regresyon modeline %5 anlamlılık düzeyinde, döviz kurunun en iyi belirleyicisi faiz farklılığıdır. %10 önem düzeyinde ise birinci gecikmedeki parasal büyüme farklılığı istatistiksel olarak anlamlıdır. Bu sonuç Hindistan ve ABD arasındaki faiz oranı farklılıklarının döviz kuru üzerinde güçlü bir etkisi olduğunu göstermektedir. Kurulan modelde, faiz oranı ve parasal büyüme farklılığı gecikmesi bir olarak belirlenmiştir. Bu sonuç Hindistan ekonomisindeki ekonomik aktörlerin, diğer Kırılgan Beşli ülkelere göre daha hızlı kararlar aldığını ve “Rasyonel Beklentiler” teorisi ile uyumlu hareket ettiklerine işaret etmektedir. Ridge modeline ait performans metrikleri hem yönsel hem de noktasal olarak tüm geleneksel yöntemlerden daha tutarlı sonuçlar vermiştir.

**Tablo 3.15.** Hindistan için Ridge Regresyon Performans Metrikleri

| Döviz Kuru | RMSE  | MAPE  | MDA    | $R^2$ |
|------------|-------|-------|--------|-------|
| USDINR     | 5.934 | 7.043 | 0.5278 | 0.797 |

#### 3.4.11.4. Güney Afrika için Ridge Regresyon Tahminleri

Güney Afrika için kurulan Ridge regresyon analizi sonuçlarına göre, makroekonomik değişkenlerin gecikme yapısı (5, 1, 4, 1) olarak belirlenmiştir. Analiz sonuçları Tablo 3.16’da gösterilmiştir.

**Tablo 3.16.** Güney Afrika için Ridge Regresyon İstatistikleri

| Değişken                               | Katsayı      | p-değeri |
|----------------------------------------|--------------|----------|
| Parasal Büyüme Farklılığı (ZA-US) lag1 | -0.363       | 0.151    |
| Parasal Büyüme Farklılığı (ZA-US) lag2 | -0.412       | 0.051    |
| Parasal Büyüme Farklılığı (ZA-US) lag2 | -0.497       | 0.054    |
| Parasal Büyüme Farklılığı (ZA-US) lag4 | -0.409       | 0.064    |
| Parasal Büyüme Farklılığı (ZA-US) lag5 | -0.276       | 0.256    |
| Enflasyon Farklılığı (ZA-US) lag1      | -0.198       | 0.808    |
| Reel Çıktı Farklılığı (ZA-US) lag1     | 0.058        | 0.528    |
| Reel Çıktı Farklılığı (ZA-US) lag2     | 0.096        | 0.767    |
| Reel Çıktı Farklılığı (ZA-US) lag3     | 0.039        | 0.661    |
| Reel Çıktı Farklılığı (ZA-US) lag4     | 0.031        | 0.824    |
| Faiz Farklılığı (ZA-US) lag1           | -0.762       | 0.077    |
| Sabit Terim                            | 15.270       | 0.000    |
| F Değeri                               | 2.108        |          |
| F Değeri p olasılığı                   |              | 0.000    |
| En iyi gecikme kombinasyonu            | (5, 1, 4, 1) |          |
| En iyi $\lambda$ değeri                | 7.742        |          |
| En düşük RMSE                          | 1.937        |          |

Güney Afrika için Ridge Regresyon katsayı istatistikleri %5 anlamlılık düzeyinde anlamlı sonuçlar vermemiştir. Ancak %10 anlamlılık düzeyinde, ikinci gecikmeden dördüncü gecikmeye kadar parasal büyüme farklılıkları ve ilk gecikmedeki faiz farklılıkları anlamlıdır. Faiz farklılıklarının ilk gecikmede, parasal büyüme farklılıklarının ise ikinci ve üçüncü gecikmede anlamlı olması, ekonomik aktörlerin, beklentilerini cari ekonomik kararlara göre hızlı bir şekilde uyarlayamadığını göstermektedir. Kurulan model, istatistiksel olarak anlamlıdır. Fiyatın hiçbir şekilde bağımsız değişken olarak yer almadığı optimize edilmiş Ridge regresyon modeli bu durumda dahi, geleneksel istatistiksel tahmin yöntemlerine karşı üstün performans sergilemiştir (Tablo 3.17).

Güney Afrika para otoritesi, parasal büyüme ve faiz farklılıklarını kontrol altında tutarak, kur üzerindeki negatif şokların etkilerini minimize edebilir. Parasal büyüme farklılığındaki uzun gecikme sayısı ve Şekil 3.4 birlikte incelendiğinde, Güney Afrika’da parasal büyümenin döviz kurunu kısa dönemde stabilize ettiğini ancak, enflasyon üzerinde de etki yarattığını, enflasyon üzerindeki etkinin, döviz kurundaki orta-uzun vadeli istikrarı yok ettiği gözlemlenmiştir.

**Tablo 3.17.** Güney Afrika için Ridge Regresyon Performans Metrikleri

| Döviz Kuru | RMSE  | MAPE   | MDA   | $R^2$ |
|------------|-------|--------|-------|-------|
| USDZAR     | 3.409 | 16.521 | 0.485 | 0.399 |

**3.4.11.5. Türkiye için Ridge Regresyon Tahminleri**

Türkiye için kurulan Ridge regresyon analizi sonuçlarına göre makroekonomik değişkenlerin gecikme yapıları (4, 1, 2, 1) olarak belirlenmiştir. Kurulan modele ait istatistikler Tablo 3.18’de sunulmuştur. Analiz sonuçları Türkiye için döviz kuru dinamiklerini anlamada ve modellemede önemli bilgiler içermektedir

**Tablo 3.18.** Türkiye için Ridge Regresyon İstatistikleri

| Değişken                               | Katsayı      | p-değeri |
|----------------------------------------|--------------|----------|
| Parasal Büyüme Farklılığı (TR-US) lag1 | 0.649        | 0.337    |
| Parasal Büyüme Farklılığı (TR-US) lag2 | 0.562        | 0.279    |
| Parasal Büyüme Farklılığı (TR-US) lag2 | 0.527        | 0.266    |
| Parasal Büyüme Farklılığı (TR-US) lag4 | 0.235        | 0.518    |
| Enflasyon Farklılığı (TR-US) lag1      | 0.396        | 0.701    |
| Reel Çıktı Farklılığı (TR-US) lag1     | 1.291        | 0.022    |
| Reel Çıktı Farklılığı (TR-US) lag2     | 1.252        | 0.034    |
| Faiz Farklılığı (TR-US) lag1           | 2.584        | 0.000    |
| Sabit Terim                            | 0.913        | 0.000    |
| F İstatistiği                          | 5.254        |          |
| F İstatistiği p-olasılığı              |              | 0.000    |
| En iyi gecikme kombinasyonu            | (4, 1, 2, 1) |          |
| En iyi $\lambda$ değeri                | 1.129        |          |
| En düşük RMSE                          | 1.430        |          |

Türkiye için Ridge regresyon modelinden elde edilen bilgiler, Türkiye’nin diğer kırılğan beşli ülkelerinden ayrıştığını göstermektedir. %5 önem düzeyinde birinci gecikmedeki faiz ve ikinci gecikmeye kadar reel çıktı farklılığı istatistiksel olarak anlamlıdır. Katsayı işaretleri her iki değişken seti için de pozitifdir. Bu sonuçlar, faiz artışlarının ekonomik ve finansal aktörler için risk olarak algılandığını ifade etmektedir. Reel çıktı ile döviz kuru arasındaki pozitif ilişki ise, reel çıktının ithalata bağlı olduğunu, ithalatın ise döviz talebini artırdığını ima etmektedir. Bu sonuçlar, ekonomik ve finansal aktörlerin enflasyon beklentilerini faiz kararlarına göre şekillendirdiklerini göstermektedir. Sonuçlar bir bütün olarak değerlendirildiğinde, merkez bankası para politikası araçlarının etkin olmadığı söylenebilir.

Tablo 3.19’da sunulan Ridge regresyona ait performans metrikleri de, katı fiyatlı parasal modelin, geleneksel istatistiksel yöntemlere göre başarısını ortaya koymaktadır.


**Tablo 3.19.** Türkiye için Ridge Regresyon Performans Metrikleri

| Döviz Kuru | RMSE   | MAPE   | MDA   | $R^2$ |
|------------|--------|--------|-------|-------|
| USDTRY     | 14.610 | 66.072 | 0.529 | 0.101 |

### 3.4.12. XGBoost Tahminleri

Ridge Regresyondaki ceza terimi  $\lambda$ 'nın kullanıldığı, hız ve performans açısından, birçok makine öğrenmesi modeline göre üstünlük sağlayan, bağımsız değişkenlerin özelliklerini ve önem düzeylerini ortaya çıkarmada ve aşırı öğrenme/uyum (overfitting) sorunu azaltma algoritmasıyla ön plana çıkan XGBoost için, kırılğan beşli döviz kurları “katı fiyatlı parasal model” denkliği ile tahmin edilmiştir. Bu modelde de asıl amaç nokta tahmini değil, politikaların etkinliği ve teorideki makroekonomik değişkenlerinin döviz kuru için önem düzeyinin sorgulanmasıdır. XGBoost modelinde de her ülke döviz kuru kendi özelinde optimize edilerek modellenmiştir (Ek 16-20). Önem düzeyleri, maksimum gecikme 5 kabul edilerek tespit edilmiştir. Özellik önemleri sıralanırken M2, parasal büyüme farklılıklarını; CPI, enflasyonu farklılıklarını; IPI, reel çıktı farklılıklarını; INT, faiz farklılıklarını temsil etmektedir.

#### 3.4.12.1. Brezilya için XGBoost Tahminleri



Şekil 3.14. USDBRL için Makroekonomik Değişkenlerin Önem Düzeyleri

Şekil 3.14, XGBoost modeli, katı fiyatlı parasal modeldeki makroekonomik yapıyı beş gecikmeye kadar inceleyerek, USDBRL üzerindeki gecikmeli etkilerini ortaya koymaktadır. Model incelendiğinde USDBRL için en önemli faktörlerin, faiz oranı ve reel çıktı farklılıkları olduğu görülmektedir. Faiz oranı kararları; USDBRL için özellikle üçüncü, dördüncü ve beşinci gecikmede etkili olmaktadır. Dornbusch'un modeline göre, faiz oranlarındaki değişiklikler kısa vadede döviz kurunda aşırı tepkiye neden olmaktadır. Analiz

sonuçlarından elde edilen faiz farklılıklarına ait gecikme yapısı, bu etkinin zamana yayıldığını ve dengenin birkaç dönem alabileceğini göstermektedir.

Reel çıktı farklılığının özellikle ilk gecikmede döviz kurunu etkilemesi, ekonomik aktivitenin döviz kuru dinamiklerinde etkin rol oynadığını göstermektedir. Parasal büyüme ve enflasyon farklılıklarının nispeten daha düşük öneme sahip olması bu değişkenlerin dolaylı etkilerinin olduğuna işaret etmektedir.


Bu sonuçlar döviz kuru istikrarının sağlanabilmesi için para otoritesinin özellikle bu iki değişkeni monitörize ederek döviz kurunu istikrara kavuşturabileceğini ima etmektedir. Tablo 3.20'deki performans metrikleri, Dornbusch modelinin, yönsel olarak para politikası için uygulanabilirliğini gözler önüne sermektedir.

**Tablo 3.20.** USDBRL için XGBoost Performans Metrikleri

| Döviz Kuru | RMSE  | MAPE   | MDA   | $R^2$ |
|------------|-------|--------|-------|-------|
| USDBRL     | 1.736 | 32.829 | 0.606 | 0.192 |

#### 3.4.12.2. Endonezya için XGBoost Tahminleri

USDIDR için faiz oranı, reel çıktı ve parasal büyüme farklılıkları en çok önem arz eden değişkenlerdir. USDIDR için faiz oranı farklılıkları, sırasıyla dördüncü, birinci ve beşinci gecikmede en yüksek öneme sahiptir. Bu gecikme yapısı faiz oranında yapılacak değişikliklerin makroekonomik etkilerinin zamana yayıldığını göstermektedir. Faiz farklılıklarının gecikme yapısı, yatırımcı beklentilerini ve sermaye akışlarını kısa ve orta dönem için ayrıştırdığına işaret etmektedir. İkinci gecikmedeki reel çıktı farklılıkları, döviz kuru üzerinde önemli bir etkiye sahiptir. Bu sonuç, Dornbusch'un reel ve finansal sektörler arasındaki etkileşimi vurgulayan yönüyle uyumludur. Piyasadaki yeni bilgiler ilk başta varlık piyasalarında değerlendirilmekte, daha sonra bu bilgiler mal piyasalarına etki etmektedir. Parasal büyüme farklılığının beşinci gecikmede öneme sahip olması, para arzındaki değişikliklerin daha uzun vadede döviz kuru üzerinde etkili olduğuna işaret etmektedir. Enflasyon farklılığının daha düşük öneme sahip olması, enflasyon farklılıklarının doğrudan etkisinin sınırlı olduğunu ima etmektedir. Bu sonuçlara göre Endonezya para otoritesi, faiz oranındaki değişikliklerin orta vadeli etkilerini gözeterek ani ve büyük değişikliklerden kaçınmalı, kademeli ve öngörülebilir bir politika izlemelidir.



**Şekil 3.15.** USDIDR için Makroekonomik Değişkenlerin Önem Düzeyleri

Tablo 3.21'deki performans metrikleri incelendiğinde, XGBoost tahminlerinin, yönsel olarak tek değişkenli istatistiksel modellerden daha başarılı olduğu görülmektedir.


**Tablo 3.21.** USDIDR için XGBoost Performans Metrikleri

| Döviz Kuru | RMSE     | MAPE   | MDA    | $R^2$  |
|------------|----------|--------|--------|--------|
| USDIDR     | 593.8861 | 3.4086 | 0.4242 | 0.0494 |

### 3.4.12.3. Hindistan için XGBoost Tahminleri

USDINR için kurulan XGBoost modelinden elde edilen sonuçlara göre faiz oranı sırasıyla beşinci, dördüncü, birinci ve ikinci gecikmede döviz kurunu en yüksek düzeyde etkilemektedir. Bu sonuçlar, Dornbusch'un modeliyle uyumlu olarak, faiz oranı farklılıklarının döviz kuru dinamiklerinde baskın bir rol oynadığını göstermektedir. Faiz oranındaki gecikme yapısı, politika faiz oranındaki değişikliklerin, yatırımcı beklentilerini ve sermaye akışlarının hem kısa hem orta vadede etkilediğini, bu nedenle döviz kurunun dengeye ulaşabilmesinin daha uzun vadeye yayılabileceğini ima etmektedir. Parasal büyüme farklılıklarının ikinci ve üçüncü gecikmede, diğer değişkenlere göre daha yüksek öneme sahip olması, para arzının faiz kararlarından etkilendiğini göstermektedir.

Reel çıktı farklılığının döviz kuru üzerinde ikinci gecikmede öneme sahip olması, reel sektörün para politikasındaki değişikliklere parasal aktarım mekanizması ve beklentilerin uyarlanmasıyla yanıt verdiğine işaret etmektedir.



**Şekil 3.16.** USDINR için Makroekonomik Değişkenlerin Önem Düzeyleri

Hindistan için oluşturan XGBoost modeli, bu ülkede katı fiyatlı parasal modelin daha uygulanabilir olduğunu gözler önüne sermektedir. Özellik önem sıralaması dikkate alındığında ilk 10 özellik içinde, Dornbusch'un modelindeki tüm değişkenler yer almaktadır (Şekil 3.16). USDINR için en önemli iki özelliğin beşinci ve dördüncü gecikmedeki faiz oranı olduğu dikkate alındığında, politika faizindeki yanlış kararların, makroekonomik istikrar üzerinde kalıcı olumsuz etkiler yaratabileceği söylenebilir.

**Tablo 3.22.** USDIDR için XGBoost Performans Metrikleri


| Döviz Kuru | RMSE  | MAPE  | MDA    | $R^2$  |
|------------|-------|-------|--------|--------|
| USDINR     | 7.885 | 9.023 | 0.4545 | 0.4074 |

USDIDR için, XGBoost modeli performans metrikleri, modelin ekonomik aktörler için, tek değişkenli modellere kıyasla daha iyi yönsel tahminler sunduğunu göstermektedir.

#### 3.4.12.4. Güney Afrika için XGBoost Tahminleri

USDZAR paritesi için optimize edilen XGBoost modeli sonuçları, döviz kuru dinamiklerinde faiz oranı ve enflasyonun en büyük etkiye sahip olduğunu göstermektedir (Şekil 3.17). Bu bulgular, Güney Afrika'yı Brezilya, Endonezya ve Hindistan'dan ayırmaktadır. Faiz oranı farklılıklarının sırasıyla üçüncü, ikinci ve birinci gecikmelerde döviz kurunu etkilemesi, Güney Afrika para otoritesi için kritik içgörüler sunmaktadır. Bu gecikmeli yapı, Güney Afrika'daki finansal aktörlerinin faiz oranı değişikliklerine kısa ve orta vadede farklı tepkiler verdiğini göstermektedir. Enflasyon farklılıklarının döviz kuru

üzerindeki etkisi, önem sırasında ikinci sırada yer almaktadır. Enflasyonun üçüncü ve beşinci gecikmelerde döviz kurunu etkilemesi, enflasyon dinamiklerinin faiz oranı değişikliklerinden de etkilendiğine işaret etmektedir. Bu sonuçlar ışığında, Güney Afrika para otoritesinin, döviz kuru istikrarını sağlamak için faiz oranı kararlarını alırken, bu kararların orta vadeli enflasyon etkilerini de göz önünde bulundurması gerekmektedir. Bu yaklaşımın, para politikasının etkinliğini artırırken, döviz kuru volatilitesi azaltmaya yardımcı olabileceği düşünülmektedir. Ayrıca, bu bulgular Güney Afrika ekonomisinin kendine özgü yapısını ve dış şoklara karşı duyarlılığını da yansıtmaktadır. Sonuç olarak, Güney Afrika'nın döviz kuru üzerinde istikrarı sağlayabilmesi için, faiz oranı ve enflasyon dinamiklerini dikkatle izlemesi ve bu değişkenler arasındaki etkileşimi göz önünde bulundurarak proaktif bir para politikası uygulaması gerekmektedir.



**Şekil 3.17.** USDZAR için Makroekonomik Değişkenlerin Önem Düzeyleri

**Tablo 3.23.** USDZAR için XGBoost Performans Metrikleri

| Döviz Kuru | RMSE  | MAPE   | MDA   | $R^2$ |
|------------|-------|--------|-------|-------|
| USDZAR     | 2.080 | 10.459 | 0.424 | 0.466 |

USDZAR paritesi için XGBoost performans metrikleri, tek değişkenli istatistiksel modellerden daha iyi sonuçlar elde edildiğini göstermektedir.

#### 3.4.12.5. Türkiye için XGBoost Tahminleri


Grafikte görülen XGBoost modeline ait önem düzeyleri (Şekil 3.18) analiz edildiğinde, USDTRY paritesinin diğer ülke kurlarından farklı bir dinamik sergilediği belirlenmiştir.

Döviz kuru üzerindeki en önemli değişken, diğer Kırılgan Beşli ülkelerden farklı olarak, reel çıktı olarak öne çıkmaktadır. Reel çıktı farklılığının döviz kuru üzerinde bu kadar etkili olması, dış ticaretin döviz kurunu belirleyen en önemli unsur olduğunu göstermektedir. Bu durum, Türkiye ekonomisinin dış ticarete olan yüksek bağımlılığını ve reel ekonomik faktörlerin kur üzerindeki önemini vurgulamaktadır.

Faiz oranının ilk gecikmede yüksek öneme sahip olması, varlık ve mal piyasalarında para politikasına ait bilgilerin hızlı bir şekilde fiyatlara yansıdığını göstermektedir. Parasal büyüme farklılığının ikinci gecikmede döviz kuru üzerinde etkili olması ise, para arzındaki değişimlerin kur üzerinde ani ve belirgin sıçramalar yarattığını ortaya koymaktadır. Bu durum, Türkiye'de döviz kurunun hem reel ekonomik faktörlerden hem de finansal faktörlerden etkilendiği sonucunu desteklemektedir.

Reel ekonomik faktörlerin gecikmeli etkisi, Dornbusch'un modelinde öngörüldüğü gibi, para politikalarındaki değişimlerin döviz kuru üzerindeki etkisini yansıtmaktadır. Türkiye için faiz farklılıklarının ikinci en yüksek öneme sahip olması, para politikalarının etkinliği konusunda bazı şüpheler uyandırmaktadır. Bu analiz, Türkiye'nin döviz kuru dinamiklerinin hem gelişmekte olan finansal piyasalar hem de dış ticarete bağımlı reel ekonomisinin etkisi altında şekillendiğini göstermektedir.

Bu bulgular, Türkiye'nin döviz kuru politikalarının hem iç ekonomik faaliyetler hem de küresel piyasa dinamikleri tarafından belirlendiğini göstermektedir. Özellikle para politikalarının etkinliğinin artırılması, döviz kuru dalgalanmalarını minimize etmek için kritik öneme sahiptir. Ayrıca, dış ticaretin döviz kuru üzerindeki belirleyici rolü, Türkiye'nin ekonomik büyüme stratejilerinde ihracatın artırılmasının ve ithalat bağımlılığının azaltılmasının gerekliliğini ortaya koymaktadır. Politika yapıcılar, bu içgörülerini göz önünde bulundurarak, döviz kuru istikrarını sağlamayı hedefleyen daha etkin ve kapsamlı politikalar geliştirebilirler.



**Şekil 3.18.** USDTRY için Makroekonomik Değişkenlerin Önem Düzeyleri

XGBoost performans metrikleri (Tablo 3.23), USDTRY için yapılan tahminlerin, Theta modeli haricinde, tek değişkenli geleneksel modellere göre daha iyi nokta tahmini yaptığını göstermektedir.

**Tablo 3.24.** USDTRY için XGBoost Performans Metrikleri

| Döviz Kuru | RMSE   | MAPE   | MDA   | $R^2$ |
|------------|--------|--------|-------|-------|
| USDTRY     | 14.901 | 64.510 | 0.456 | 0.214 |

### 3.4.13. Karşılaştırmalı Doğruluk Ölçütleri

Çalışmamızda, Naive modeli hariç tek değişkenli ve çok değişkenli tüm modellerdeki parametreler optimizasyon sonucunda elde edilmiştir. Bu parametreler yardımıyla örneklem dışı tahminler yapılmıştır. Tahmin performansları RMSE, MAPE  $R^2$  ve MDA metrikleri yardımıyla hesaplanmıştır. Kurulan tüm modellere ait performans metrikleri Şekil 3.19'daki görseller ile özetlenmiştir.

USDBRL paritesi için en düşük RMSE ve MAPE değerleri, CNN mimarisi kullanılarak elde edilmiştir. CNN modelini sırasıyla GRU, RNN ve LSTM modelleri takip etmektedir. Geleneksel istatistiksel yöntemler arasında en başarılı tahminler Theta modeli ile gerçekleştirilmiştir. USDBRL paritesi için  $R^2$  metriği göz önüne alındığında, en yüksek açıklayıcılığa sahip tahminler sırasıyla CNN, RNN, GRU ve LSTM modelleri ile yapılmıştır. Bu sonuçlar, bu derin öğrenme modellerinin döviz kuru tahminlerinde yüksek bir açıklama gücüne sahip olduğunu göstermektedir. USDBRL paritesi için MDA metriği incelendiğinde,

en iyi tahminler, fiyatın bağımsız değişken olarak modelde yer almadığı XGBoost modeli ile elde edilmiştir. XGBoost modeli, yönsel doğruluk açısından diğer modellere kıyasla üstün performans sergilemiştir.



Şekil 3.19. Tüm Modeller İçin Çoklu Performans Karşılaştırmaları

USDIDR için RMSE metriğine göre en başarılı tahminler GRU modelinden elde edilmiştir. Bu başarıyı sırasıyla RNN, CNN ve LSTM modelleri takip etmektedir. Nokta tahmini açısından, fiyatın gecikmeli değerlerinin, model içerisine dahil edilmediği XGBoost modeli, geleneksel istatistiksel yöntemlere göre daha başarılı sonuçlar vermiştir. Geleneksel istatistiksel yöntemler kendi aralarında kıyaslandığında, en başarılı tahminlerin ETS modelinden elde edildiği görülmektedir. USDIDR için MAPE metriği göz önüne alındığında en başarılı tahminlerin RMSE’de olduğu gibi GRU mimarisinden elde edildiği anlaşılmaktadır. Bu başarıyı sırasıyla RNN, CNN ve LSTM mimarileri takip etmektedir. XGBoost modeli, Dornbusch’un Hedefi Aşan Döviz Kuru modelindeki makroekonomik değişkenlerle, geleneksel istatistiksel yöntemlere göre daha iyi nokta tahmini başarısı

göstermiştir. USDIDR modelleri için  $R^2$  metriğine ait başarı düzeyleri incelendiğinde en yüksek tahmin başarısını GRU modeli göstermiştir. MDA metriğine göre ise en iyi tahminleri Ridge regresyon modeli üretmiştir.



Şekil 3.20. Tüm Modeller İçin Çoklu Performans Karşılaştırmaları (Devamı)

USDINR paritesi için RMSE metriğine göre yapılan incelemelerde, en iyi nokta tahminlerinin GRU modeliyle yapıldığı görülmektedir. Bu modeli sırasıyla CNN, LSTM ve RNN modelleri izlemektedir. Ayrıca, Ridge regresyon modeli de nokta tahminlerinde başarılı bir performans göstermiştir. Ridge regresyon modeli, fiyatın gecikmeli değerlerinin model içine dahil edilmediği durumda bile, geleneksel istatistiksel modellere göre daha başarılı tahminler üretmiştir. USDINR paritesi için MAPE metriğine göre yapılan analizlerde de en yüksek başarı GRU modeliyle elde edilmiştir. GRU modelini sırasıyla CNN, LSTM ve RNN modelleri takip etmektedir. Ayrıca, MAPE metriğine göre de Ridge regresyon modeli, diğer geleneksel istatistiksel yöntemlere kıyasla daha başarılı nokta tahminler yapmıştır.  $R^2$  metriğine göre en başarılı tahminler CNN modelinden elde

edilmiştir. Bu başarıyı sırasıyla RNN ve GRU takip etmektedir. USDINR için yönsel tahmin doğruluklarını ölçen MDA metriği ise en başarılı tahminlerin CNN, RNN ve Ridge regresyon modellerinden elde edildiğini göstermektedir.

USDZAR paritesi için RMSE ve MAPE metriğine göre en başarılı tahminler CNN modeli ile yapılmıştır. Bu başarıyı sırasıyla GRU, LSTM ve RNN modelleri takip etmektedir. Nokta tahmininde XGBoost modeli, geleneksel istatistiksel yöntemlerden daha başarılı sonuçlar vermiştir. USDZAR için, geleneksel istatistiksel yöntemler içindeki en başarılı tahminler ETS modelinden elde edilmiştir.  $R^2$  ve MDA metriğine göre performansı en yüksek model GRU modelidir. Fiyatın model içine dahil edilmediği XGBoost ve Ridge regresyon modelleri yön tahmininde geleneksel tahmin yöntemlerinden daha iyi performans sergilemiştir.

USDTRY paritesi için RMSE metriğine göre en başarılı tahminler GRU modeliyle, MAPE metriği için ise CNN modeliyle elde edilmiştir. Bu modelleri yine tek değişkenli diğer makine öğrenmesi modelleri takip etmektedir. USDTRY için Ridge ve XGBoost modelleri, geleneksel istatistiksel yöntemlerden daha iyi nokta tahmininde bulunmuştur.  $R^2$  metriğine göre USDTRY paritesinde en iyi performansı sergileyen model GRU'dur. Örneklem dışı tahminler  $R^2$  değerinin 1'e çok yakın olması, bu metriğin fonksiyonel yetersizliğini ön plana çıkarmaktadır.  $R^2$  değerine göre, tahmin modellerinin göstermiş olduğu bu başarı MDA metriği tarafından teyit edilememektedir. USDTRY için MDA metriğine göre en başarılı model LSTM modelidir. Nokta ve yön tahminindeki bu farklılaşma, USDTRY paritesini uzun vadeli bağımlılıklardan daha çok kısa vadeli şokların etkilediğini göstermektedir.

Tüm karşılaştırmalar birlikte ele alındığında, makine öğrenimi modelleri genel olarak daha üstün performans sergilemiştir. Özellikle, GRU ve CNN gibi mimariler, hem RMSE hem de MAPE metriklerinde en düşük hata oranlarını ve en yüksek doğruluk oranlarını sunmuştur. XGBoost modeli, fiyatın gecikmeli değerlerinin modelde yer almadığı durumlarda bile, geleneksel yöntemlere kıyasla daha başarılı nokta tahminleri yapmıştır. Ridge regresyon modeli de benzer şekilde, geleneksel istatistiksel yöntemlere göre daha yüksek doğruluk oranları elde etmiştir. Bu bulgular, makine öğrenimi ve derin öğrenme modellerinin, döviz kuru tahminlerinde geleneksel yöntemlere göre daha isabetli sonuçlar verdiğini ve bu modellerin ekonomik analizlerde önemli bir araç olduğunu göstermektedir.

## SONUÇ

Bu çalışma, Kırılğan Beşli (Brezilya, Endonezya, Güney Afrika, Hindistan ve Türkiye) olarak adlandırılan ülkelerin döviz kuru dinamiklerini tahmin etmede geleneksel istatistiksel yöntemler ile ileri düzey makine öğrenimi (ML) modellerinin karşılaştırmalı bir analizini sunmaktadır. Araştırmamızın bulguları, ML modellerinin (RNN, LSTM, GRU, CNN, XGBoost) döviz kurlarının karmaşık ve dalgalı yapısını modellemede geleneksel yöntemlere kıyasla belirgin bir üstünlüğe sahip olduğunu göstermektedir. İlgi çekici bir sonuç da ML modellerinin uygulanan sıkı düzenleme tekniklerine rağmen döviz kuru tahminlerindeki üstün performanslarını korumuş olmalarıdır.

Araştırmanın karşılaştırmalı analiz bulguları, geleneksel istatistiksel yöntemlerin sınırlılıklarını da net bir şekilde ortaya koymaktadır. Bu modeller (Naive Drift, Theta, ETS, ARIMA) genel eğilimleri belirlemede, belirli bir yeterliliğe sahip olsa da döviz kurlarındaki yüksek frekanslı dalgalanmaları modellemede yetersiz kalmıştır. Geleneksel modeller arasında, optimize edilmiş Theta ve ETS en etkili modeller olarak belirlenmiştir. Tek değişkenli tahmin modellerindeki bu sonuç, finansal piyasaların modellenmesinde, daha gelişmiş yaklaşımlara olan ihtiyacı da vurgulamaktadır.

Bu çalışmada, çok değişkenli analizler Ridge Regresyon ve XGBoost ile yapılmıştır. Analizlerde iktisadi model olarak ise Dornbusch'un Hedefi Aşan Döviz Kuru modeli referans alınmıştır. Ridge Regresyon analiz sonuçları, her bir ülkenin döviz kuru dinamiklerinin farklı olduğunu göstermektedir. Brezilya, Endonezya, Güney Afrika ve Hindistan için faiz farklılıklarının döviz kurları üzerindeki etkisi negatif iken, Türkiye için bu farklılık döviz kuru üzerinde pozitif etki yaratmaktadır. Döviz kuru dinamiklerindeki bu farklılıklar, döviz kurundaki istikrarın sağlanmasına yönelik olarak uygulanacak politikaların ülkeden ülkeye farklılaşacağına işaret etmektedir. Makroekonomik değişkenlerin döviz kuru üzerindeki önem düzeylerinin belirlendiği XGBoost modellemeleri de döviz kuru üzerinde etkili makroekonomik değişkenlerinin farklı dinamiklere sahip olduğunu göstermektedir. Türkiye haricindeki Kırılğan Beşli ülkelerde döviz kuru üzerindeki en etkin değişken faiz oranı iken, Türkiye'de döviz kurunu etkileyen en önemli

değişken reel çıktı farklılıklarıdır. Ridge Regresyon ve XGBoost analizlerinden elde edilen bu sonuçlar, Türkiye’de yaşanan enflasyonist sürece dair kanıtlar sunmaktadır. Türkiye’de son yıllarda yükselen döviz kurunun dış ticarete bağlı olarak artan döviz talebi ve para politikası araçlarının etkisizleşmesine bağlı olarak arttığı düşünülmektedir.

Araştırmada, Ridge Regresyon modelini uygularken, Dornbusch'un Hedefi Aşan Döviz Kuru Model’indeki bağımsız değişkenlerin gecikme uzunlukları, tarafımızca geliştirilen yenilikçi bir yaklaşımla belirlenmiştir. Geleneksel ARDL modelinde, bağımlı değişkenin gecikmeli değerleri modele dahil edilerek uzun dönem ve kısa dönem ilişkiler analiz edilmektedir. Ancak bu yeni yaklaşımda optimal gecikme haritası, bağımlı değişken sistem içerisine dahil edilmeden, farklı kombinasyonlar denenerek çıkarılmaktadır. Bu süreç, model karmaşıklığını azaltmakta ve esnek bir modelleme imkânı sunmaktadır.

Metodolojik açıdan çalışmamız, tahmin modellerinin değerlendirilmesinde çok boyutlu bir yaklaşımın önemini vurgulamaktadır. Sadece nokta tahminlerine odaklanmak yerine, yönsel doğruluğu da içeren kapsamlı performans metriklerinin kullanılmasının gerekliliği ortaya çıkmıştır. Bilimsel çalışmalarda determinasyon katsayısı gibi geleneksel metriklerin model başarısını tanımlamada yetersiz kaldığı, büyük hataların daha yüksek oranda cezalandırıldığı metriklerin model başarısını daha iyi tanımladığı belirlenmiştir. Bu yaklaşım, modellerin gerçek dünyada karşılaşılabileceği durumları daha iyi simüle etmesine olanak tanıyacaktır.

Bu çalışmanın mevcut literatüre katkılarından biri de optimizasyon tekniklerinin tahmin modelleri için gerekliliğini vurgulamasıdır. Hem istatistiksel hem de ML modellerinde gelişmiş optimizasyon stratejilerinin uygulanması, modellerin performansını ve güvenilirliğini önemli ölçüde artırmıştır. Bu sonuç, ekonometrik modelleme çalışmalarında titiz bir optimizasyon sürecinin vazgeçilmezliğini vurgulamaktadır. Özellikle ML modellerinde, aşırı uyumu azaltmak için seyreltme işleminin en az bir kez uygulanması, daha gerçekçi sonuçlara ulaşılmasını sağlamaktadır.

Çalışmamız, ampirik tahmin modellerine eleştirel bir perspektif sunmaktadır. Özellikle, istatistiksel tahmin modellerinde örneklem içi analizlerle elde edilen sonuçların, örneklem dışı tahmin performansını tam olarak yansıtmayabileceğini vurgulamaktadır. Bu bağlamda, tüm veri setinin kullanılmasıyla oluşturulan modellerin tahmin performansının gerçek dünya koşullarında doğrudan uygulanabilirliği konusunda ihtiyatlı bir yaklaşım benimsenmesi gerekmektedir. Bu kritik bakış açısı, tahmin sonuçlarının genellenmeden önce titizlikle

değerlendirilmesi gerektiğini ve model performans değerlendirmelerinde daha sıkı metodolojik standartların uygulanmasının önemini vurgulamaktadır.

Bu tez, iktisat teorisi, istatistiksel yöntemler ve yapay zekâ modellerini entegre eden yenilikçi bir yaklaşım sunmaktadır. Bu üçlü entegrasyonun en önemli çıkarımı, teorik temelden yoksun makroekonomik tahminlerin ekonomik karar vericiler için sınırlı fayda sağladığıdır. Buna karşılık, iktisadi teorilerle harmanlanmış tahmin modelleri, ekonomik aktörler için anlaşılır ve uygulanabilir öngörüler sunmaktadır. Bu bulgu, ekonomik analizlerde teori ve ampirik yöntemlerin bütünleşik kullanımının önemini vurgulamakta ve daha etkili politika kararları alınmasına olanak tanımaktadır.

Bu çalışma, döviz kuru tahmininde makine öğrenimi (ML) tekniklerinin devrim niteliğindeki potansiyelini gözler önüne sermektedir. Elde edilen bulgular, ML tabanlı modellerin ekonomik teoriler ile entegrasyonunun, politika yapıcılar ve finansal analistler için daha keskin öngörüler ve yenilikçi politika kararları alınmasına olanak tanıyan bir araç olarak kullanılabileceğini göstermektedir. ML modellerinin karmaşık ekonomik örüntüleri çözme yeteneği ve aşırı öğrenmeye karşı geliştirilmiş savunma mekanizmaları, bu modelleri güvenilir ekonomik tahminler için vazgeçilmez araçlar haline getirmektedir.

Gelecek araştırmalar, bu güçlü modellerin daha da geliştirilmesi ve ekonomik teorilerle kusursuz bir uyum içinde çalışması üzerine odaklanmalıdır. Özellikle, makroekonomik değişkenlerin döviz kurları üzerindeki etkilerinin ülkeler arasındaki nüanslarını deşifre etmek, politika yapıcılara paha biçilmez içgörüler sunacaktır. Ayrıca, ML modellerinin şeffaflığını artırmak ve ekonomik sezgilerle daha uyumlu hale getirmek için yenilikçi yöntemler geliştirmek, gelecekteki araştırmaların öncelikli hedefleri arasında olmalıdır. Bu gelişme hem akademik hem de uygulamalı alanlarda daha etkili ve güvenilir ekonomik modellerin oluşturulmasına katkıda bulunacaktır.

Kırılgan Beşli ülkelerinin her biri için elde edilen sonuçlar, bu ülkelerin para otoriteleri ve politika yapıcıları için adeta bir yol haritası niteliğindedir. Özellikle, faiz oranları, enflasyon ve reel çıktı gibi makroekonomik değişkenlerin döviz kurları üzerindeki etkilerinin ülkeler arasında gösterdiği çarpıcı farklılıklar, her ülkeye özgü politika önerilerinin geliştirilmesi gerekliliğini ortaya koymaktadır. Bu durum, her ülkenin kendi ekonomik koşullarına ve dinamiklerine uygun stratejiler oluşturulmasının önemini vurgulamaktadır.

Sonuç olarak bu çalışma, döviz kuru tahmininde geleneksel yöntemlerden ML tekniklerine geçişin kaçınılmazlığını vurgulamaktadır. Ayrıca, ekonomik teori ile ampirik modellemenin

bütünleşik bir ilişki içinde ele alınmasının gerekliliğini ortaya koymaktadır. Bu bütünleşik yaklaşım, daha isabetli tahminler ve daha etkili ekonomi politikaları oluşturulması için sağlam bir temel atarak, geleceğin ekonomik zorluklarına karşı daha donanımlı olmamızı sağlayacaktır.



## KAYNAKÇA

- Abraham, K. G., Jarmin, R. S., Moyer, B., & Shapiro, M. D. (2022). *Big data for twenty-first-century economic statistics*. University of Chicago Press.  
<https://doi.10.7208/chicago/9780226801391.001.0001>
- Akan, H. D. M. (2010). Uluslararası döviz kuru sistemlerinin geleceği: Bretton Woods'a geri dönülebilir mi?. *Sosyal Bilimler Dergisi*, (2), 108-115.  
<https://dergipark.org.tr/tr/download/article-file/100731>
- Akay, E. C., Soydan, N. T. Y., & Gacar, B. K. (2020). Machine learning and economics: Bibliometric analysis. *Pressacademia*, 12(1), 104-105.  
<https://doi.10.17261/pressacademia.2020.1367>
- Akel, V., Kandır, S., Yavuz, Ö. S. (2015). Dynamic relationship between stock prices and exchange rates in emerging markets: Evidence from Fragile Five economies. Ö. Olgu, H. Dinçer, & Ü. Hacıoğlu (Eds.), *Handbook of research on strategic developments and regulatory practice in global finance* içinde (s. 166-181). IGI Global.  
<https://doi.10.4018/978-1-4666-7288-8.ch011>
- Allen, P. R. (1998). The economic and policy implications of the NATREX approach. J. L. Stein, & P. R. Allen (Eds.), *Fundamental determinants of exchange rates* içinde (s. 1-37). Oxford University Press. <https://doi.10.1093/0198293062.003.0001>
- Artus, J. R. (1978). Methods of assessing the long-run equilibrium value of an exchange rate. *Journal of International Economics*, 8(2), 277-299.  
[https://doi.org/10.1016/0022-1996\(78\)90024-7](https://doi.org/10.1016/0022-1996(78)90024-7)
- Assimakopoulos, V., & Nikolopoulos, K. (2000). The theta model: A decomposition approach to forecasting. *International Journal of Forecasting*, 16(4), 521-530.  
[https://doi.org/10.1016/S0169-2070\(00\)00066-2](https://doi.org/10.1016/S0169-2070(00)00066-2)

- Athey, S. (2018). The impact of machine learning on economics. A. Agrawal, J. Gans, & A. Goldfarb (Eds.), *The economics of artificial intelligence: An agenda* (s. 507-547). National Bureau of Economic Research, Inc. <https://EconPapers.repec.org/RePEc:nbr:nberch:14009>
- Baillie, R. T., & Kiliç, R. (2006). Do asymmetric and nonlinear adjustments explain the forward premium anomaly?. *Journal of International Money and Finance*, 25(1), 22-47. <https://doi.org/10.1016/j.jimonfin.2005.10.002>
- Baillie, R. T., Diebold, F. X., Kapetanios, G., & Kim, K. H. (2023). A new test for market efficiency and uncovered interest parity. *Journal of International Money and Finance*, 130, 102765. <https://doi.org/10.1016/j.jimonfin.2022.102765>
- Bakır, M. R., Ibrahim, B., & Emre, O. (2023). Statistical techniques vs. machine learning models: A comparative analysis for exchange rate forecasting in Fragile Five countries. *Economic Computation and Economic Cybernetics Studies and Research*, 57(3), 295-312. <https://doi.org/10.24818/18423264/57.3.23.18>
- Basuchoudhary, A., Bang, J. T., & Sen, T. (2018). *Machine-learning techniques in economics*. Springer International. <https://doi.org/10.1007/978-3-319-69014-8>
- Bekaert, G., Wei, M., & Xing, Y. (2007). Uncovered interest rate parity and the term structure. *Journal of International Money and Finance*, 26(6), 1038-1069. <https://doi.org/10.1016/j.jimonfin.2007.05.004>
- Bengio, Y., Frasconi, P., & Simard, P. (1993). *The problem of learning long-term dependencies in recurrent networks* [Presentation]. IEEE International Conference on Neural Networks, San Francisco, CA, USA. <https://doi.org/10.1109/ICNN.1993.298725>
- Beza-Bojanowska, J., & MacDonald, R. (2009). *The behavioural zloty/euro equilibrium exchange rate*. CESifo Working Paper No. 2568, Center for Economic Studies and ifo Institute (CESifo), Munich. <http://hdl.handle.net/10419/26613>
- Bhattarai, S., Chatterjee, A., & Park, W. Y. (2021). Effects of US quantitative easing on emerging market economies. *Journal of Economic Dynamics and Control*, 122, 104031. <https://doi.org/10.1016/j.jedc.2020.104031>
- Bianchi, F. M., Maiorino, E., Kampffmeyer, M. C., Rizzi, A., & Jenssen, R. (2017). *Recurrent neural networks for short-term load forecasting*. Springer International.

- Bordo, M. D., & Siklos, P. L. (2014). *Central bank credibility, reputation and inflation targeting in historical perspective*. NBER Working Paper Series No. 20693, National Bureau of Economic Research, Cambridge, MA. <https://doi.org/10.3386/W20693>
- Borgersen, T.-A., & Göcke, M. (2007). Exchange rate overshooting and path-dependence in international trade. *Macroeconomic Dynamics*, 11(3), 295-317. <https://doi.org/10.1017/S1365100507060117>
- Brooks, C. (1996). Testing for non-linearity in daily sterling exchange rates. *Applied Financial Economics*, 6(4), 307-317. <https://doi.org/10.1080/096031096334105>
- Brooks, C. (2019). *Introductory econometrics for finance* (4th ed.). Cambridge University Press. <https://doi.org/10.1017/9781108524872>
- Cassel, G. (1918). Abnormal deviations in international exchanges. *The Economic Journal*, 28(112), 413-415. <https://doi.org/10.2307/2223329>
- Chaboud, A., Rime, D., & Sushko, V. (2023). *The foreign exchange market*. BIS Working Papers No 1094, Bank for International Settlements. <https://EconPapers.repec.org/RePEc:bis:biswps:1094>.
- Chen, J. C., Dunn, A., Hood, K., Driessen, A., & Batch, A. (2019). Off to the races: A comparison of machine learning and alternative data for predicting economic indicators. K. G. Abraham, R. S. Jarmin, B. Moyer, & M. D. Shapiro (Eds.), *Big data for twenty-first-century economic statistics* içinde (s. 373-402). University of Chicago Press. <https://doi.org/10.7208/chicago/9780226801391.001.0001>
- Chen, T., & Guestrin, C. (2016). *XGBoost: a scalable tree boosting system* [Presentation]. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, California, USA. <https://doi.org/10.1145/2939672.2939785>
- Chinn, M. D., & Meredith, G. (2004). Monetary policy and long-horizon uncovered interest parity. *IMF Staff Papers*, 51(3), 409-430. <http://www.jstor.org/stable/30035956>.
- Cho, K., van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). On the properties of neural machine translation. D. Wu, M. Carpuat, X. Carreras, & E. M. Vecchi (Eds.), *Proceedings of SSST 2014 - 8th Workshop on Syntax, Semantics and Structure in Statistical Translation* içinde (s. 103-111). Association for Computational Linguistics (ACL). <http://www.scopus.com/inward/record.url?scp=85097641926&partnerID=8YFLogxK>

- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical evaluation of gated recurrent neural networks on sequence modeling* [Presentation]. NIPS 2014 Deep Learning and Representation Learning Workshop. <https://doi.10.48550/arXiv.1412.3555>
- Clarida, R., Galí, J., & Gertler, M. (1998). Monetary policy rules in practice some international evidence. *European Economic Review*, 42(6), 1033-1067. [https://doi.10.1016/S0014-2921\(98\)00016-6](https://doi.10.1016/S0014-2921(98)00016-6)
- Clark, P. B., & MacDonald, R. (2004). Filtering the BEER: A permanent and transitory decomposition. *Global Finance Journal*, 15(1), 29-56. <https://doi.org/10.1016/j.gfj.2003.10.005>
- Cornell, B. (1977). Spot rates, forward rates and exchange market efficiency. *Journal of Financial Economics*, 5(1), 55-65. [https://doi.org/10.1016/0304-405X\(77\)90029-0](https://doi.org/10.1016/0304-405X(77)90029-0)
- Couharde, C., Rey, S., & Sallenave, A. (2016). External debt and real exchange rates' adjustment in the euro area: new evidence from a nonlinear NATREX model. *Applied Economics*, 48(11), 966-986. <https://doi.10.1080/00036846.2015.1090554>
- Devereux, M. B. (1997). Real exchange rates and macroeconomics: Evidence and theory. *The Canadian Journal of Economics*, 30(4a), 773-808. <https://doi.10.2307/136269>
- Dickey, D. A., & Fuller, W. A. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica*, 49(4), 1057-1072. <https://doi.10.2307/1912517>
- Dornbusch, R. (1976). Expectations and exchange rate dynamics. *Journal of Political Economy*, 84(6), 1161-1176. <http://www.jstor.org/stable/1831272>
- Driskill, R. A. (1981). Exchange-rate dynamics: An empirical investigation. *Journal of Political Economy*, 89(2), 357-371. <https://doi.10.1086/260969>
- Driver, R., & Westaway, P. (2005). Concepts of equilibrium exchange rates. *SSRN Electronic Journal*. <https://doi.10.2139/ssrn.723981>
- Dudek, G. (2019). Short-term load forecasting using Theta method. *E3S Web of Conferences*, 84, 01004. <https://doi.10.1051/e3sconf/20198401004>
- Ehsanes Saleh, A. K., Arashi, M., Golam Kibria, B. M., Saleh, A. K. M. E., Arashi, M., & Kibria, B. M. G. (2019). *Theory of ridge regression estimation with applications*. John Wiley & Sons. <https://doi.10.1002/9781118644478>

- Eichengreen, B. (1996). The classical Gold Standard in interwar perspective. B. Eichengreen (Ed.), *Golden fetters: The Gold Standard and the Great Depression, 1919-1939* içinde (s. 29-66). Oxford University Press. <https://doi.10.1093/0195101138.003.0002>
- Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179-211. [https://doi.org/10.1016/0364-0213\(90\)90002-E](https://doi.org/10.1016/0364-0213(90)90002-E)
- Engel, C., & West, K. D. (2005). Exchange rates and fundamentals. *Journal of Political Economy*, 113(3), 485-517. <https://doi.10.1086/429137>
- Engel, C., West, K. D., & Kenneth D. (2006). Taylor rules and the deutschmark-dollar real exchange rate. *Journal of Money, Credit, and Banking*, 38(5), 1175-1194. <https://doi.10.1353/mcb.2006.0070>
- Erem, E. (2023). Forecasting exchange rates using artificial neural networks. *Journal of Finance and Economics*, 11(1), 58-67. <https://doi.10.12691/jfe-11-1-4>
- Escudero, P., Alcocer, W., & Paredes, J. (2021). Recurrent neural networks and ARIMA models for euro/dollar exchange rate forecasting. *Applied Sciences (Switzerland)*, 11(12), 5658. <https://doi.org/10.3390/app11125658>
- Fama, E. F. (1965). The behavior of stock-market prices. *The Journal of Business*, 38(1), 34-105. <http://www.jstor.org/stable/2350752>
- Fendoğlu, S., Çolak, M. S., & Hacıhasanoğlu, Y. S. (2020). Foreign-currency debt and the exchange rate pass-through. *Applied Economics Letters*, 27(8), 657-666. <https://doi.10.1080/13504851.2019.1644423>
- Flood, R. P., & Rose, A. K. (2002). Uncovered interest parity in crisis. *IMF Staff Papers*, 49(2), 252-266. <http://www.jstor.org/stable/3872485>.
- Frankel, J. A. (1979). On the mark: A Theory of floating exchange rates based on real interest differentials. *The American Economic Review*, 69(4), 610-622. <http://www.jstor.org/stable/1808707>
- Frankel, J. A. (1984). Tests of monetary and portfolio balance models of exchange rate determination. In J. F. Bilson, & R. C. Marston (Eds.), *Exchange rate theory and practice* içinde (s. 239-260). University of Chicago Press. <https://doi.org/10.7208/9780226050997-008>

- Frenkel, J. A. (1976). A monetary approach to the exchange rate: Doctrinal aspects and empirical evidence. *The Scandinavian Journal of Economics*, 78(2), 200-224. <https://doi.10.2307/3439924>
- Frenkel, J. A., & Levich, R. M. (1975). Covered interest arbitrage: Unexploited profits?. *Journal of Political Economy*, 83(2), 325-338. <http://www.jstor.org/stable/1830925>
- Galeshchuk, S., & Mukherjee, S. (2017). Deep networks for predicting direction of change in foreign exchange rates. *Intelligent Systesms in Accounting, Finance and Management*, 24(4), 100-110. <https://doi.10.1002/isaf.1404>
- García, F., Guijarro, F., Oliver, J., & Tamošiūnienė, R. (2023). Foreign exchange forecasting models: ARIMA and LSTM comparison. *Engineering Proceedings*, 39(1), 81. <https://doi.10.3390/engproc2023039081>
- Garnett, R. (2023). *Bayesian optimization*. Cambridge University Press. <https://doi.10.1017/9781108348973>
- Gelman, A., & Vehtari, A. (2020). What are the most important statistical ideas of the past 50 years?. *CC BY 4.0*, 1-21. <https://doi.org/10.48550/arXiv.2012.00174>
- Giddy, I. H., & Dufey, G. (1975). The random behavior of flexible exchange rates: Implications for forecasting. *Journal of International Business Studies*, 6(1), 1-32. <http://www.jstor.org/stable/154345>
- Golden, R. M. (2020). Formal machine learning algorithms. R. M. Golden (Ed.), *Statistical machine learning: A unified framework* içinde (s. 83-96). CRC Press. <https://doi.10.1201/9781351051507-3>
- Goldstein, M., Mathieson, D. J., Bayoumi, T., Mussa, M., & Clark, P. B. (1983). The current exchange rate regime. M. Goldstein, D. J. Mathieson, T. Bayoumi, M. Mussa, & P. B. Clark (Eds.), *Improving the international monetary system: Constraints and possibilities* içinde (s. Chapter 2). International Monetary Fund. <https://doi.10.5089/9781557754448.084.ch0002>
- Gonzalo, J., & Granger, C. (1995). Estimation of common long-memory components in cointegrated systems. *Journal of Business & Economic Statistics*, 13(1), 27-35. <https://doi.10.2307/1392518>

- Goulet Coulombe, P., Leroux, M., Stevanovic, D., & Surprenant, S. (2022). How is machine learning useful for macroeconomic forecasting?. *Journal of Applied Economics (Chichester England)*, 37(5), 920-964. <https://doi.10.1002/jae.2910>
- Granger, C. W. J., & Newbold, P. (1974). Spurious regressions in econometrics. *Journal of Econometrics*, 2(2), 111-120. [https://doi.org/10.1016/0304-4076\(74\)90034-7](https://doi.org/10.1016/0304-4076(74)90034-7)
- Gujarati, D. N., & Porter, D. C. (2008). *Basic econometrics* (5th ed.). McGraw-Hill.
- Haffner, P. (2016, 7 Temmuz). What is machine learning – and why is it important?. *Interactions*. <https://www.interactions.com/blog/technology/machine-learning-important/>.
- Hakkio, C. S., & Rush, M. (1989). Market efficiency and cointegration: An application to the sterling and deutschemark exchange markets. *Journal of International Money and Finance*, 8(1), 75-88. [https://doi.org/10.1016/0261-5606\(89\)90015-6](https://doi.org/10.1016/0261-5606(89)90015-6)
- Hatami, N., Gavet, Y., & Debayle, J. (2017, 13-15 Kasım). *Classification of time-series images using deep convolutional neural networks* [Presentation]. International Conference on Machine Vision, Wien, Austria. <https://api.semanticscholar.org/CorpusID:31086935>.
- Hersi, K., & Koy, A. (2020). The relationship between exchange rates and stock markets for the Fragile Five countries. *Journal of International Trade, Logistics and Law*, 6(1), 1-13.
- Higgins, B. (1978). Velocity: Money's second dimension. *Economic Review*, 63, 15-31. <https://EconPapers.repec.org/RePEc:fip:fedker:y:1978:i:jun:p:15-31:n:v.63no.6>.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computing*, 9(8), 1735-1780. <https://doi.10.1162/neco.1997.9.8.1735>
- Hoerl, A. E., & Kennard, R. W. (1970). Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67. <https://doi.10.2307/1267351>
- Hofmann, B., & Bogdanova, B. (2012). Taylor rules and monetary policy: A global “Great Deviation”? *BIS Quarterly Review*, 37-49. [https://www.bis.org/publ/qtrpdf/r\\_qt1209f.pdf](https://www.bis.org/publ/qtrpdf/r_qt1209f.pdf)
- Hossain, M. R., Ismail, M. T., & Hossain, J. (2021, 7-8 Aralık). *Stock price prediction using empirical mode decomposition based theta method and forecast combination* [Presentation]. 2021 International Conference on Decision Aid Sciences and Application (DASA), Sakheer, Bahrain. <https://doi.10.1109/DASA53625.2021.9682235>

- Hsieh, D. A. (1984). International risk sharing and the choice of exchange-rate regime. *Journal of International Money and Finance*, 3(2), 141-151. [https://doi.org/10.1016/0261-5606\(84\)90002-0](https://doi.org/10.1016/0261-5606(84)90002-0)
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice*. OTexts.
- IMF. (2007). The equilibrium exchange rate: Alternative concepts and their applications in IMF surveillance. *Background Document III, An IEO Evaluation of IMF Exchange Rate Policy Advice, 1999-2005* (s. 53-66), Washington D.C., USA.
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning*. Springer International. <https://doi.org/10.1007/978-3-031-38747-0>
- Jirsik, T., Trčka, Š., & Celeda, P. (2019, 8-12 Nisan). *Quality of service forecasting with LSTM neural network* [Presentation]. 2019 IFIP/IEEE Symposium on Integrated Network and Service Management (IM), Washington D.C., USA.
- Jones & John, (2022, 27 Ekim). *Global FX trading hits record \$7.5 trln a day – BIS survey*, REUTERS. <https://www.reuters.com/markets/us/global-fx-trading-hits-record-75-trln-day-bis-survey-2022-10-27/>
- Kaminsky, G., & Peruga, R. (1990). Can a time-varying risk premium explain excess returns in the forward market for foreign exchange?. *Journal of International Economics*, 28(1), 47-70. [https://doi.org/10.1016/0022-1996\(90\)90049-R](https://doi.org/10.1016/0022-1996(90)90049-R)
- Kirchgässner, G., Wolters, J., & Hassler, U. (2007). Introduction to modern time series analysis. *Springer texts in business and economics* (2nd ed.) içinde. Springer. <https://api.semanticscholar.org/CorpusID:53911008>
- Kodres, L. E. (1996). Foreign exchange markets: Structure and systemic risks. *Finance & Development*, 33(4), 1-60. <https://doi.org/10.5089/9781451951899.022>
- Lafrance, R., & Schembri, L. (2002). Purchasing-power parity: Definition, measurement, and interpretation. *Bank of Canada Review*, 2002(Autumn), 27-33. <https://EconPapers.repec.org/RePEc:bca:bcarev:v:2002:y:2002:i:autumn02:p:27-33>.
- Lawal, A., Rehman, S., Alhems, L. M., & Alam, M. M. (2021). Wind speed prediction using hybrid 1D CNN and BLSTM network. *IEEE Access*, 9, 156672-156679. <https://doi.org/10.1109/ACCESS.2021.3129883>

- Lawi, A., Mesra, H., & Amir, S. (2022). Implementation of long short-term memory and gated recurrent units on grouped time-series data to predict stock prices accurately. *Journal of Big Data*, 9(1), 89. <https://doi.org/10.1186/s40537-022-00597-0>
- Leventakis, J. A. (1987). Exchange rate models: Do they work?. *Weltwirtschaftliches Archiv*, 123(2), 363-376. <http://www.jstor.org/stable/40439431>.
- Lewinson, E. (2020). *Python for finance cookbook: Over 50 recipes for applying modern Python libraries to finance data analysis*. Packt Publishing.
- Liao, R., Boonyakunakorn, P., Harnpornchai, N., & Sriboonchitta, S. (2020). Forecasting the exchange rate for USD to RMB using RNN and SVM. *Journal of Physics: Conference Series*, 1616(1), 012050. <https://doi.org/10.1088/1742-6596/1616/1/012050>
- Liew, V., Baharumshah, A. Z., & Lau, E. (2004). Nonlinear adjustment towards purchasing power parity in ASEAN exchange rates. *The IUP Journal of Applied Economics*, 3, 7-18.
- Lily, J., Kogid, M., Mulok, D., & Asid, R. (2012). Revisiting uncovered interest rate parity: An empirical testing using bounds test approach. *Procedia Economics and Finance*, 2, 45-52. [https://doi.org/10.1016/S2212-5671\(12\)00063-9](https://doi.org/10.1016/S2212-5671(12)00063-9)
- Liu, S., You, S., Zeng, C., Yin, H., Lin, Z., Dong, Y., Qiu, W., Yao, W., & Liu, Y. (2021). Data source authentication of synchrophasor measurement devices based on 1D-CNN and GRU. *Electric Power Systems Research*, 196, 107207. <https://doi.org/10.1016/j.epsr.2021.107207>
- Lord, J., & Rahman, R. (2013, 5 Augustos). Global EM investo: The Fragile Five. *Morgan Stanley Research*. <https://web.archive.org/web/20140311151342/http://graphics8.nytimes.com/packages/pdf/business/MorganStanleyFragileFive.pdf>
- MacDonald, R. (1995). Long-run exchange rate modeling: A survey of the recent evidence. *IMF Staff Papers*, 1995(003), A001. <https://doi.org/10.5089/9781451973396.024.A001>
- MacDonald, R. (2004). The long-run real effective exchange rate of Singapore: A behavioural approach. <https://api.semanticscholar.org/CorpusID:56453310>
- MacDonald, R. (2007). *Exchange rate economics*. Routledge. <https://doi.org/10.4324/9780203380185>

- MacDonald, R., & Clark, P. B. (1998). Exchange rates and economic fundamentals: A methodological comparison of BEERs and FEERs. *IMF Working Papers*, 1998(067), A001. <https://doi.10.5089/9781451961683.001.A001>
- Marr, B. (2016, 19 Şubat). A short history of machine learning – every manager should read. *Forbes*. <https://www.forbes.com/sites/bernardmarr/2016/02/19/a-short-history-of-machine-learning-every-manager-should-read/>
- Masum, M., Shahriar, H., Haddad, H., Faruk, M. J. H., Valero, M., Khan, M. A., Rahman, M. A., Adnan, M. I, Cuzzocrea, A., & Wu, F. (2021, 15-18 Aralık). *Bayesian hyperparameter optimization for deep neural network-based network intrusion detection* [Presentation]. 2021 IEEE International Conference on Big Data (Big Data), Orlando, FL, USA. <https://doi.10.1109/BigData52589.2021.9671576>
- Masum, S., Liu, Y., Chiverton, J. (2018). Multi-step time series forecasting of electric load using machine learning models. *Artificial Intelligence and Soft Computing* (s. 148-159). Springer International Publishing: Cham. [https://doi.10.1007/978-3-319-91253-0\\_15](https://doi.10.1007/978-3-319-91253-0_15)
- Meese, R. A., & Rogoff, K. (1983). Empirical exchange rate models of the seventies: Do they fit out of sample?. *Journal of International Economics*, 14(1), 3-24. [https://doi.org/10.1016/0022-1996\(83\)90017-X](https://doi.org/10.1016/0022-1996(83)90017-X)
- Melvin, M., & Norrbin, S. (2023). Chapter 2 - International monetary arrangements. In M. Melvin, & S. Norrbin (Eds.), *International money and finance* (10th ed.) içinde (s. 21-48). Academic Press. <https://doi.org/10.1016/B978-0-323-90621-0.00002-8>
- Mitchell, R., & Frank, E. (2017). Accelerating the XGBoost algorithm using GPU computing. *PeerJ Computer Sciences*, 3(e127), e127. <https://doi.10.7717/peerj-cs.127>
- Molodtsova, T., & Papell, D. H. (2009). Out-of-sample exchange rate predictability with Taylor rule fundamentals. *Journal of International Economics*, 77(2), 167-180. <https://doi.org/10.1016/j.jinteco.2008.11.001>
- Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87-106. <https://doi.10.1257/jep.31.2.87>
- Mussa, M. (1976). The exchange rate, the balance of payments and monetary and fiscal policy under a regime of controlled floating. *The Scandinavian Journal of Economics*, 78(2), 229-248. <https://doi.10.2307/3439926>

- Nechio, F. (2014, Mart). Fed tapering news and emerging markets. *Federal Reserve Bank of San Francisco*. <https://www.frbsf.org/research-and-insights/publications/economic-letter/2014/03/federal-reserve-tapering-emerging-markets>
- Nurhamidah, N., Nusyirwan, N., & Faisol, A. (2020). Forecasting seasonal time series data using the Holt-Winters exponential smoothing method of additive models. *Jurnal Matematika Integratif*, 16(2), 151. <https://doi.10.24198/jmi.v16.n2.29293.151-157>
- Peixeiro, M. (2022). *Time series forecasting in python*. Manning Publications.
- Pustokhina, I. V., & Pustokhin, D. A. (2023). A comparative analysis of traditional forecasting methods and machine learning techniques for sales prediction in E-commerce. *American Journal of Business and Operations Research*, 10(2), 39-51. <https://doi.10.54216/ajbor.100205>
- Qureshi, M., Ahmad, N., Ullah, S., & Raza ul Mustafa, A. (2023). Forecasting real exchange rate (REER) using artificial intelligence and time series models. *Heliyon*, 9(5), e16335. <https://doi.org/10.1016/j.heliyon.2023.e16335>
- Reddy, S. K., & As, B. (2015). Exchange rate forecasting using ARIMA, neural network and fuzzy neuron. *J. Stock Forex Trading*, 4(3), 155. <https://doi.10.4172/2168-9458.1000155>
- Salem, F. M. (2022). *Recurrent neural networks: From simple to gated architectures*. Springer Nature. <https://doi.org/10.1007/978-3-030-89929-5>
- Salman, A. G., Heryadi, Y., Abdurahman, E., & Suparta, W. (2018). Single layer & multi-layer long short-term memory (LSTM) model with intermediate variables for weather forecasting. *Procedia Computer Science*, 135, 89-98. <https://doi.org/10.1016/j.procs.2018.08.153>
- Salvatore, D. (2019). *International economics*. John Wiley & Sons.
- Sarno, L., & Taylor, M. P. (2001). Purchasing power parity and the real exchange rate. *IMF Staff Papers*, 49, 65-105. <https://api.semanticscholar.org/CorpusID:506706>
- Shafer, J. R., Loopesko, B. E., Bryant, R. C., & Dornbusch, R. (1983). Floating exchange rates after ten years. *Brookings Papers on Economic Activity*, 1983(1), 1-86. <https://doi.10.2307/2534352>

- Shen, M.-L., Lee, C.-F., Liu, H.-H., Chang, P.-Y., & Yang, C.-H. (2021). An effective hybrid approach for forecasting currency exchange rates. *Sustainability*, 13(5), 2761. <https://doi.10.3390/su13052761>
- Siregar, R. (2011). *The concepts of equilibrium exchange rate: A survey of literature*. MPRA Paper, University Library of Munich, Germany. <https://EconPapers.repec.org/RePEc:pra:mprapa:28987>
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian optimization of machine learning algorithms. In F. Pereira, & K. Q. Weinberger (Ed.), *Advances in neural information processing systems* içinde (s. 1-9), Curran Associates, Inc. [https://proceedings.neurips.cc/paper\\_files/paper/2012/file/05311655a15b75fab86956663e1819cd-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2012/file/05311655a15b75fab86956663e1819cd-Paper.pdf)
- Sodhi, P., Awasthi, N., & Sharma, V. (2019). Introduction to machine learning and its basic application in python. *SSRN Electronic Journal*, 1354-1375. <https://doi.10.2139/ssrn.3323796>
- Soni, R. S., & Srikanth, D. (2017, 19-20 Mayıs). *Inventory forecasting model using genetic programming and Holt-Winter's exponential smoothing method* [Presentation]. 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT), Bengaluru, India. <https://doi.10.1109/RTEICT.2017.8256967>
- Sönmez, S. (2016). Bretton Woods, Fordizm ve hegemonya. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 34(1), 43-62. <https://doi.org/10.17065/huniibf.309273>
- Spiliotis, E., Assimakopoulos, V., & Nikolopoulos, K. (2019). Forecasting with a hybrid method utilizing data smoothing, a variation of the Theta method and shrinkage of seasonal factors. *International Journal of Production Economics*, 209, 92-102. <https://doi.org/10.1016/j.ijpe.2018.01.020>
- Stein, J. L. (1998). The natural real exchange rate of the United States dollar, and determinants of capital flows. J. L. Stein, & P. R. Allen (Eds.), *Fundamental determinants of exchange rates* içinde (s. 38-84). Oxford University Press. <https://doi.10.1093/0198293062.003.0002>
- Stock, J., & Watson, M. (2011). *Introduction to Econometrics* (3rd ed.). Addison Wesley Longman.

- Takhtamanova, Y. (2008). *Understanding changes in exchange rate pass-through*. Working Paper Series 2008-13, Federal Reserve Bank of San Francisco, USA. <http://www.frbsf.org/publications/economics/papers/2008/wp08-13bk.pdf>
- Taylor, J. B. (1993). Discretion versus policy rules in practice. *Carnegie-Rochester Conference Series on Public Policy*, 39, 195-214. [https://doi.org/10.1016/0167-2231\(93\)90009-L](https://doi.org/10.1016/0167-2231(93)90009-L)
- Taylor, M. P. (1987a). Covered interest parity: A high-frequency, high-quality data study. *Economica*, 54(216), 429-438. <https://doi.org/10.2307/2554178>
- Taylor, M. P. (1987b). Risk premia and foreign exchange: A multiple time series approach to testing uncovered interest-rate parity. *Weltwirtschaftliches Archiv*, 123(4), 579-591. <http://www.jstor.org/stable/40439994>
- Taylor, M. P., & Peel, D. A. (2000). Nonlinear adjustment, long-run equilibrium and exchange rate fundamentals. *Journal of International Money and Finance*, 19(1), 33-53. [https://doi.org/10.1016/S0261-5606\(99\)00044-3](https://doi.org/10.1016/S0261-5606(99)00044-3)
- Tran, T. N. (2021). Grid search of convolutional neural network model in the case of load forecasting. *Archives of Electrical Engineering*, 70(1), 25-30. <https://doi.org/10.24425/aee.2021.136050>
- Valenzuela, O., Rojas, F., Herrera, L. J., Pomares, H., & Rojas, I. (2023). *Theory and applications of time series analysis and forecasting: Contributions to statistics*. Springer International. <https://doi.org/10.1007/978-3-031-14197-3>
- Varian, H. R. (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives*, 28(2), 3-28. <https://doi.org/10.1257/jep.28.2.3>
- Wang, H., Wang, C., Lin, X., & Kang, J. (2014). An improved ARIMA model for precipitation simulations. *Nonlinear Processes in Geophysics*, 21(6), 1159-1168. <https://doi.org/10.5194/npg-21-1159-2014>
- Wang, L., Dernoncourt, F., & Bui, T. (2020). Bayesian optimization for selecting efficient machine learning models. *ArXiv*, abs/2008.00386. <https://api.semanticscholar.org/CorpusID:220936142>
- Wang, P. (2005). *The economics of foreign exchange and global finance*. Springer Verlag. <https://doi.org/10.1007/3-540-28524-5>

- Williamson, J. (1994). *Estimating equilibrium exchange rates*. Peterson Institute for International Economics. <https://EconPapers.repec.org/RePEc:iea:ppress:17>
- Williamson, J. (1983). *The exchange rate system*. MIT Press. <https://api.semanticscholar.org/CorpusID:152770491>
- Wright, K. M. (1954). Dollar pooling in the sterling area, 1939-1952. *The Economic American Review*, 44(4), 559-576. <http://www.jstor.org/stable/1814109>
- Xu, S., Zou, S., Huang, J., Yang, & W., Zeng, F. (2022). Comparison of different approaches of machine learning methods with conventional approaches on container throughput forecasting. *Applied Sciences (Basel)*, 12(19), 9730. <https://doi.10.3390/app12199730>
- Yan, S. (2017, Kasım). Understanding LSTM and its diagrams. *Medium*. <https://blog.mlreview.com/understanding-lstm-and-its-diagrams-37e2f46f1714>
- Yurdakul, F. (1999). Hendry ve Sims yöntemlerinin teorik olarak karşılaştırılması. *Ekonomik Yaklaşım*, 10(33), 84-91. <https://doi.10.5455/ey.10310>
- Zhao, B., Lu, H., Chen, S., Liu, J., & Wu, D. (2017). Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics*, 28(1), 162-169. <https://doi.10.21629/JSEE.2017.01.18>
- Zhao, G., Li, Z., & Yang, M. (2021). Comparison of twelve machine learning regression methods for spatial decomposition of demographic data using multisource geospatial data: An experiment in Guangzhou city, China. *Applied Sciences (Basel)*, 11(20), 9424. <https://doi.10.3390/app11209424>

# EKLER

## EK 1. Naive Drift Kodu

```
!pip install --upgrade --no-cache-dir git+https://github.com/rongardF/tvdatafeed.git
!pip install darts
!pip install scikit-learn
```

```
import pandas as pd
import matplotlib.pyplot as plt
from tvDatafeed import TvDatafeed, Interval
from darts import TimeSeries
from darts.models import NaiveDrift
from darts.metrics import rmse, mape
from sklearn.preprocessing import MinMaxScaler
import numpy as np
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})
```

```
# MDA
def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)

    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    num_correct = np.sum(actual_signs == predicted_signs)
    return num_correct / (len(actual) - 1)
```

```
def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    ss_res = np.sum((y_true - y_pred) ** 2)
    ss_tot = np.sum((y_true - np.mean(y_true)) ** 2)
    r2 = 1 - (ss_res / ss_tot)
    return r2
```

```
tv = TvDatafeed(username='username', password='password')
symbol = 'USDIDR'
start_date = '2013-06-01'
end_date = '2024-06-01'
df = tv.get_hist(symbol, 'FX_IDC', Interval.in_daily, n_bars=5000)
```

```

if df is not None and not df.empty:
    df.reset_index(inplace=True)
    df.rename(columns={'index': 'datetime'}, inplace=True)
    df['datetime'] = pd.to_datetime(df['datetime'])
    df = df[(df['datetime'] >= start_date) & (df['datetime'] <= end_date)]
    df = df[['datetime', 'close']].rename(columns={'close': 'symbol'})
    df.set_index('datetime', inplace=True)
    print(df.head())
else:
    print(f"Veri çekilemedi: {symbol}")
scaler = MinMaxScaler()
data_normalized = pd.DataFrame(scaler.fit_transform(df), columns=df.columns,
index=df.index)

split_index = int(len(data_normalized) * 0.7)
train_data = data_normalized[:split_index]
test_data = data_normalized[split_index:]
model = NaiveDrift()
results = {}

train_data_original = df[:split_index]
test_data_original = df[split_index:]
series = TimeSeries.from_dataframe(train_data, value_cols=[symbol], freq='D')
model.fit(series)
forecast = model.predict(len(test_data))
forecast_values = scaler.inverse_transform(forecast.values()).flatten()
results[symbol] = {'true_train': train_data_original[symbol], 'true_test':
test_data_original[symbol], 'forecast': forecast_values}
print(f"True test length: {len(test_data_original[symbol])}")
print(f"Forecast length: {len(forecast_values)}")
print(f"Index length: {len(test_data_original.index)}")

if len(test_data_original[symbol]) == len(forecast_values):
    results[symbol] = {'true_train': train_data_original[symbol], 'true_test':
test_data_original[symbol], 'forecast': forecast_values}
else:
    min_length = min(len(test_data_original[symbol]), len(forecast_values))
    results[symbol] = {
        'true_train': train_data_original[symbol],
        'true_test': test_data_original[symbol].iloc[:min_length],
        'forecast': forecast_values[:min_length]
    }
plt.style.use('default')
plt.figure()
plt.plot(results[symbol]['true_train'], label='Gerçek Veriler (Eğitim Seti)', color='black')
plt.plot(results[symbol]['true_test'], label='Gerçek Veriler (Test Seti)', color='blue')
plt.plot(test_data_original.index[:len(results[symbol]['forecast'])],
results[symbol]['forecast'], label='Naive Drift Tahmini', color='magenta')
plt.legend()

```

```

plt.title('USDIDR Tahmini')
plt.show()
true_test = results[symbol]['true_test'].values
forecast = results[symbol]['forecast']
metrics = [{
    'Symbol': 'USDIDR',
    'RMSE': rmse_val,
    'MAPE': mape_val,
    'R2': r2_val,
    'MDA': mda_val
}]
metrics_df = pd.DataFrame(metrics)
print(metrics_df)
!pip install openpyxl
with pd.ExcelWriter('/content/forecast_results_IDR.xlsx') as writer:
    df.to_excel(writer, sheet_name='Original Data')
    pd.DataFrame(results[symbol]['forecast'], index=test_data_original.index,
columns=['Forecast']).to_excel(writer, sheet_name='Forecast')
from google.colab import files
files.download('/content/forecast_results_IDR.xlsx')

```

## EK 2. Theta Modeli Kodu

```
!pip install darts
```

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
import matplotlib.pyplot as plt
from darts import TimeSeries
from darts.models import StatsForecastAutoTheta
from darts.models import Theta
from darts.utils.utils import SeasonalityMode, TrendMode, ModelMode
from darts.metrics import mape, mae, r2_score
import warnings
warnings.filterwarnings("ignore")
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})
file_path = '/content/exchange_rates.xlsx'
df = pd.read_excel(file_path)
df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')
def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    num_correct = np.sum(actual_signs == predicted_signs)
    return num_correct / (len(actual) - 1)
    return num_correct / (len(actual) - 1)
def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    ss_res = np.sum((y_true - y_pred) ** 2)
    ss_tot = np.sum((y_true - np.mean(y_true)) ** 2)
    r2 = 1 - (ss_res / ss_tot)
    return r2
currency = 'USDIDR'
data = df[['Date', currency]].rename(columns={'Date': 'ds', currency: 'y'})
scaler = MinMaxScaler(feature_range=(0.01, 0.99))
data['y'] = scaler.fit_transform(data[['y']])
train_size = int(len(data) * 0.70)
train = data.iloc[:train_size].copy()
```

```

test = data.iloc[train_size:].copy()
train_series = TimeSeries.from_dataframe(train, 'ds', 'y')
test_series = TimeSeries.from_dataframe(test, 'ds', 'y')
from darts.utils.statistics import plot_acf, check_seasonality
plot_acf(train_series, alpha=0.05)
thetas = 2*np.linspace(-10, 10, 50)
best_mape = float('inf')
best_theta=0
for theta in thetas:
    model =Theta(theta)
    model.fit(train_series)
    pred_theta=model.predict(len(test_series))
    res=mape(test_series, pred_theta)
    if res<best_mape:
        best_mape=res
        best_theta=theta
best_theta_model=Theta(best_theta)
best_theta_model.fit(train_series)
pred_best_theta=best_theta_model.predict(len(test_series))

print('Best Theta MAPE: {:.2f}, with theta = {}'.format(mape(test_series, pred_best_theta),
best_theta))

seasonality_periods = np.linspace(270, 5, 30).astype(int)
best_mape = float('inf')
best_seasonality_period = 0

for seasonality_period in seasonality_periods:
    model = Theta(theta=best_theta, season_mode=SeasonalityMode.ADDITIVE,
seasonality_period=seasonality_period)
    model.fit(train_series)
    pred_season = model.predict(len(test_series))
    res = mape(test_series, pred_season)
    if res < best_mape:
        best_mape = res
        best_seasonality_period = seasonality_period
print(f'Best Seasonality Period MAPE: {best_mape:.2f}, with seasonality_period =
{best_seasonality_period}')
best_model = Theta(theta=best_theta, season_mode=SeasonalityMode.ADDITIVE,
seasonality_period=best_seasonality_period)
best_model.fit(train_series)
plt.style.use('default')
plt.figure()
best_model = Theta(theta=best_theta, season_mode=SeasonalityMode.ADDITIVE,
seasonality_period=best_seasonality_period)
best_model.fit(train_series)
pred_best_model = best_model.predict(len(test_series))
mape_score = mape(test_series, pred_best_model)
mae_score = mae(test_series, pred_best_model)
mda_score = mda(test_series.values(), pred_best_model.values())

```

```

r2_score = r2_score_manual(test_series.values(), pred_best_model.values())
print(f'MAPE: {mape_score:.5f}')
print(f'MAE: {mae_score:.5f}')
print(f'MDA: {mda_score:.5f}')
print(f'R2 Score: {r2_score:.5f}')
plt.style.use('default')
plt.figure()
from darts import TimeSeries
plt.style.use('default')
pred_best_model_orig = scaler.inverse_transform(pred_best_model.values())
test_series_orig = scaler.inverse_transform(test_series.values())
train_series_orig = scaler.inverse_transform(train_series.values())
train_series_orig_ts = TimeSeries.from_times_and_values(train_series.time_index,
train_series_orig)
test_series_orig_ts = TimeSeries.from_times_and_values(test_series.time_index,
test_series_orig)
pred_best_model_orig_ts = TimeSeries.from_times_and_values(test_series.time_index,
pred_best_model_orig)
plt.figure(figsize=(6, 5))
train_series_orig_ts.plot(label='Gerçek Veriler (Eğitim Seti)', color='black')
test_series_orig_ts.plot(label='Gerçek Veriler (Test Seti)', color='blue')
pred_best_model_orig_ts.plot(label='Optimize Theta Tahmini', linestyle='--',
color='magenta')
plt.xlabel('Tarih')
plt.ylabel('Değer')
plt.title('USDIDR')
plt.legend()
plt.show()
import openpyxl
metrics = [{
    'Symbol': 'USDIDR',
    'MAPE': mape_score,
    'MAE': mae_score,
    'R2': r2_score,
    'MDA': mda_score
}]
metrics_df = pd.DataFrame(metrics)
print(metrics_df)

with pd.ExcelWriter('forecast_results_INR.xlsx') as writer:
    df.to_excel(writer, sheet_name='Original Data')
    pd.DataFrame(pred_best_model_orig, index=test_series.time_index,
columns=['Forecast']).to_excel(writer, sheet_name='Forecast')
    metrics_df.to_excel(writer, sheet_name='Metrics')
from google.colab import files
files.download('forecast_results_INR.xlsx')

```

### EK 3. Holts Winters Üstel Düzleştirme (ETS) Modeli Kodu

```
!pip install darts
```

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
import matplotlib.pyplot as plt
from darts import TimeSeries
from darts.models import StatsForecastAutoTheta
from darts.models import Theta
from darts.models import StatsForecastAutoETS
from darts.utils import SeasonalityMode, TrendMode, ModelMode
from darts.metrics import mape, mae, r2_score
import warnings
warnings.filterwarnings("ignore")
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})
file_path = '/content/exchange_rates.xlsx'
df = pd.read_excel(file_path)
df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')

def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    num_correct = np.sum(actual_signs == predicted_signs)
    return num_correct / (len(actual) - 1)
    return num_correct / (len(actual) - 1)

def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    ss_res = np.sum((y_true - y_pred) ** 2)
    ss_tot = np.sum((y_true - np.mean(y_true)) ** 2)
    r2 = 1 - (ss_res / ss_tot)
    return r2

currency = 'USDZAR'
data = df[['Date', currency]].rename(columns={'Date': 'ds', currency: 'y'})
scaler = MinMaxScaler(feature_range=(0.01, 0.99))
data['y'] = scaler.fit_transform(data[['y']])
train_size = int(len(data) * 0.70)
```

```

train = data.iloc[:train_size].copy()
test = data.iloc[train_size:].copy()
train_series = TimeSeries.from_dataframe(train, 'ds', 'y')
test_series = TimeSeries.from_dataframe(test, 'ds', 'y')
from darts.utils.statistics import plot_acf, check_seasonality
plot_acf(train_series, alpha=0.05)
!pip install scikit-optimize
from darts.models import ExponentialSmoothing
from skopt import forest_minimize
def optimize_exponential_smoothing(params):
    seasonal_period = int(params[0])
    model = ExponentialSmoothing(seasonal_periods=seasonal_period,
trend=ModelMode.ADDITIVE, seasonal=SeasonalityMode.MULTIPLICATIVE)
    model.fit(train_series)
    pred = model.predict(len(test_series))
    error = mape(test_series, pred)
    return error
param_bounds = [(180, 260)] # Example range for seasonal periods
opt_result = forest_minimize(optimize_exponential_smoothing, param_bounds, n_calls=50,
random_state=0)
optimal_seasonal_period = int(opt_result.x[0])
print(f"Optimal Seasonal Period: {optimal_seasonal_period}")
model = ExponentialSmoothing(seasonal_periods=optimal_seasonal_period,
trend=ModelMode.ADDITIVE, seasonal=SeasonalityMode.MULTIPLICATIVE)
model.fit(train_series)
prediction = model.predict(len(test_series))
print("MAPE:", mape(test_series, prediction))
model.model.params
mape_score = mape(test_series, prediction)
mae_score = mae(test_series, prediction)
mda_score = mda(test_series.values(), prediction.values())
r2_score = r2_score_manual(test_series.values(), prediction.values())
print(f'MAPE: {mape_score:.5f}')
print(f'MAE: {mae_score:.5f}')
print(f'MDA: {mda_score:.5f}')
print(f'R2 Score: {r2_score:.5f}')
from darts import TimeSeries
plt.style.use('default')
prediction_orig = scaler.inverse_transform(prediction.values())
test_series_orig = scaler.inverse_transform(test_series.values())
train_series_orig = scaler.inverse_transform(train_series.values())
train_series_orig_ts = TimeSeries.from_times_and_values(train_series.time_index,
train_series_orig)
test_series_orig_ts = TimeSeries.from_times_and_values(test_series.time_index,
test_series_orig)
prediction_orig_ts = TimeSeries.from_times_and_values(test_series.time_index,
prediction_orig)
plt.figure(figsize=(6, 5))
train_series_orig_ts.plot(label='Gerçek Veriler (Eğitim Seti)', color='black')
test_series_orig_ts.plot(label='Gerçek Veriler (Test Seti)', color='blue')

```

```

prediction_orig_ts.plot(label='Optimize ETS Tahmini', linestyle='--', color='magenta')
plt.xlabel('Tarih')
plt.ylabel('Değer')
plt.title('USDZAR')
plt.legend()
plt.show()
import openpyxl
metrics = [{
    'Symbol': 'USDZAR',
    'MAPE': mape_score,
    'MAE': mae_score,
    'R2': r2_score,
    'MDA': mda_score
}]
metrics_df = pd.DataFrame(metrics)
print(metrics_df)

with pd.ExcelWriter('forecast_ETS_ZAR.xlsx') as writer:
    df.to_excel(writer, sheet_name='Original Data')
    pd.DataFrame(prediction_orig, index=test_series.time_index,
columns=['Forecast']).to_excel(writer, sheet_name='Forecast')
    metrics_df.to_excel(writer, sheet_name='Metrics')
from google.colab import files
files.download('forecast_ETS_ZAR.xlsx')

```

#### EK 4. ARIMA Modeli Kodu

```
!pip install darts
!pip install statsmodels
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
import matplotlib.pyplot as plt
from darts import TimeSeries
from statsmodels.tsa.stattools import adfuller
import warnings
warnings.filterwarnings("ignore")
from darts.metrics import mape, mase, mae, mse, ope, r2_score, rmse, rmsle
from darts.models import AutoARIMA
from darts.utils.statistics import check_seasonality, plot_acf, plot_residuals_analysis
from statsmodels.tsa.statespace.sarimax import SARIMAX
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})
MSEAS = 5 # seasonality default
ALPHA = 0.05 # significance level default
file_path = '/content/exchange_rates.xlsx'
df = pd.read_excel(file_path)
df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f"{column} sütununda {len(df[column])} veri var.")

def adf_test(series, series_name):
    result = adfuller(series, autolag='BIC', regression='ct')
    print(f'ADF Statistic for {series_name}: {result[0]}')
    print(f'p-value for {series_name}: {result[1]}')
    for key, value in result[4].items():
        print(f'Critical Value {key} for {series_name}: {value}')
    return result[1], result

currency = 'USDBRL'
data = df[['Date', currency]].rename(columns={'Date': 'ds', currency: 'y'})
scaler = MinMaxScaler(feature_range=(0.01, 0.99))
data['y'] = scaler.fit_transform(data[['y']])

train_size = int(len(data) * 0.70)
train = data.iloc[:train_size].copy()
test = data.iloc[train_size:].copy()
p_value_level, result_level = adf_test(train['y'], 'Level')
if p_value_level > 0.05:
    print(f"\nVeri düzeyde durağan değil (ADF Statistic: {result_level[0]}, p-value: {p_value_level}). Fark alma işlemi uygulanıyor...\n")
    train['y_diff'] = train['y'].diff()
```

```

test['y_diff'] = test['y'].diff()
p_value_diff, result_diff = adf_test(train['y_diff'].dropna(), 'Differenced')
if p_value_diff > 0.05:
    raise ValueError(f"Veri fark alındıktan sonra da durağan değil (ADF Statistic: {result_diff[0]}, p-value: {p_value_diff}).")
    print(f"\nVeri fark alındıktan sonra durağan (ADF Statistic: {result_diff[0]}, p-value: {p_value_diff}).\n")
    train = train.dropna(subset=['y_diff'])
    test = test.dropna(subset=['y_diff'])
    train_series = TimeSeries.from_dataframe(train, 'ds', 'y_diff')
    test_series = TimeSeries.from_dataframe(test, 'ds', 'y_diff')
else:
    print(f"\nVeri düzeyde durağan (ADF Statistic: {result_level[0]}, p-value: {p_value_level}). Fark alma işlemi gerekmiyor.\n")
    train = train.dropna(subset=['y'])
    test = test.dropna(subset=['y'])
    train_series = TimeSeries.from_dataframe(train, 'ds', 'y')
    test_series = TimeSeries.from_dataframe(test, 'ds', 'y')
import matplotlib.pyplot as plt
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
train_arr = train_series.pd_series()
fig, ax = plt.subplots(2, 1, figsize=(6, 5))
plot_acf(train_arr, lags=120, alpha=0.05, fft=True, bartlett_confint=True, use_vlines=True, auto_ylims=True, ax=ax[0])
plot_pacf(train_arr, lags=120, alpha=0.05, use_vlines=True, auto_ylims=True, ax=ax[1])
ax[0].set_title('Otokorelasyon Fonksiyonu (ACF)')
ax[1].set_title('Kısmi Otokorelasyon Fonksiyonu (PACF)')
plt.tight_layout()
plt.show()
auto_arima_model = AutoARIMA()
auto_arima_model.fit(train_series)
pred_auto_arima = auto_arima_model.predict(len(test_series))
mae_score = mae(test_series, pred_auto_arima)
print(f'MAE: {mae_score:.5f}')
best_model_params = auto_arima_model.model.summary()
print(f'En iyi modelin parametreleri: {best_model_params}')
from scipy import stats
data['y_boxcox'], fitted_lambda = stats.boxcox(data['y'])
train_boxcox = data.iloc[:train_size].copy()
test_boxcox = data.iloc[train_size:].copy()
train_series_boxcox = TimeSeries.from_dataframe(train_boxcox, 'ds', 'y_boxcox')
test_series_boxcox = TimeSeries.from_dataframe(test_boxcox, 'ds', 'y_boxcox')
plt.style.use('default')
pred_auto_arima_orig = scaler.inverse_transform(pred_auto_arima.values())
test_series_orig = scaler.inverse_transform(test_series.values())
train_series_orig = scaler.inverse_transform(train_series.values())
train_series_orig_ts = TimeSeries.from_times_and_values(train_series.time_index, train_series_orig)
test_series_orig_ts = TimeSeries.from_times_and_values(test_series.time_index, test_series_orig)

```

```
pred_auto_arima_orig_ts = TimeSeries.from_times_and_values(test_series.time_index,  
pred_auto_arima_orig)  
plt.figure(figsize=(6, 5))  
train_series_orig_ts.plot(label='Gerçek Veriler (Eğitim Seti)', color='black')  
test_series_orig_ts.plot(label='Gerçek Veriler (Test Seti)', color='blue')  
pred_auto_arima_orig_ts.plot(label='AutoARIMA Tahmini', linestyle='--', color='magenta')  
plt.xlabel('Tarih')  
plt.ylabel('Değer')  
plt.title('USDBRL')  
plt.legend()  
plt.show()
```



## EK 5. Optimize Edilmiş RNN Kodu

```
!pip install keras-tuner
!pip install tensorflow
!pip install pandas
!pip install matplotlib
!pip install openpyxl

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
from keras.models import Sequential
from keras.layers import SimpleRNN, Dense, Dropout, BatchNormalization
from keras.optimizers import Adam
from keras_tuner import BayesianOptimization, HyperModel
from keras.callbacks import EarlyStopping
import tensorflow as tf
import warnings
warnings.filterwarnings("ignore")
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})

def rmse_manual(y_true, y_pred):
    return np.sqrt(np.mean((np.array(y_true) - np.array(y_pred)) ** 2))

def mape_manual(y_true, y_pred):
    y_true, y_pred = np.array(y_true), np.array(y_pred)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100

def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)

    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)

    num_correct = np.sum(actual_signs == predicted_signs)

    return num_correct / (len(actual) - 1)

def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    if len(y_true) <= 1 or len(y_pred) <= 1:
        return float('nan') #yeterli veri yoksa NaN döndür
```

```

correlation_matrix = np.corrcoef(y_true, y_pred)
correlation_xy = correlation_matrix[0, 1]
r_squared = correlation_xy ** 2
return r_squared

file_path = '/content/currency_data.xlsx'
df = pd.read_excel(file_path)
df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
df.set_index('Date', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')

df = df.asfreq('B')
df.interpolate(method='linear', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)

for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')
df.to_excel(file_path)
print(f"Düzeltilmiş veriler başarıyla {file_path} dosyasına kaydedildi.")

def prepare_data(currency, look_back=3):
    data = df[[currency]].copy()
    scaler = MinMaxScaler(feature_range=(-1, 1))
    data[currency] = scaler.fit_transform(data[[currency]])

    train_size = int(len(data) * 0.7)
    val_size = int(len(data) * 0.15)

    train_data = data[:train_size]
    val_data = data[train_size:train_size + val_size]
    test_data = data[train_size + val_size:]

def create_dataset(data, look_back=1):
    X, y = [], []
    for i in range(len(data) - look_back):
        X.append(data.iloc[i:(i + look_back)].values)
        y.append(data.iloc[i + look_back].values)
    return np.array(X), np.array(y).flatten()

X_train, y_train = create_dataset(train_data, look_back)
X_val, y_val = create_dataset(val_data, look_back)
X_test, y_test = create_dataset(test_data, look_back)

```

```

    return X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_data.index[look_back:],
    val_data.index[look_back:], test_data.index[look_back:]

```

```

class SimpleRNNHyperModel(HyperModel):
    def __init__(self, input_shape):
        self.input_shape = input_shape

    def build(self, hp):
        model = Sequential()
        model.add(SimpleRNN(units=hp.Int('units', min_value=32, max_value=128, step=32),
input_shape=self.input_shape, return_sequences=True))
        model.add(Dropout(hp.Float('dropout', min_value=0.3, max_value=0.5, step=0.05)))
        model.add(SimpleRNN(units=hp.Int('units_2', min_value=32, max_value=128,
step=32)))
        model.add(Dense(units=hp.Int('dense_units', min_value=32, max_value=128,
step=32), activation=hp.Choice('dense_activation', values=['selu', 'elu', 'tanh'])))
        model.add(Dropout(hp.Float('dropout_2', min_value=0.3, max_value=0.5,
step=0.05)))
        model.add(Dense(1))
        optimizer = Adam(learning_rate=hp.Choice('learning_rate_adam', values=[1e-3, 1e-4,
1e-5]))
        model.compile(optimizer=optimizer, loss='mean_squared_error')
        return model

```

```

results = {}
metrics = []
trial_results = []

```

```

for currency in ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']:
    print(f'Processing {currency}...')
    X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_index, val_index, test_index =
    prepare_data(currency, look_back=3)

```

```

    hypermodel = SimpleRNNHyperModel(input_shape=(X_train.shape[1], 1))

```

```

    tuner = BayesianOptimization(
        hypermodel,
        objective='val_loss',
        max_trials=10,
        executions_per_trial=1,
        directory='tuner_directory',
        project_name=f'simple_rnn_hyperparameter_tuning_{currency}'
    )

```

```

    tuner.search(X_train, y_train, epochs=50, validation_data=(X_val, y_val),
    callbacks=[EarlyStopping(monitor='val_loss', patience=10)])

```

```

    best_model = tuner.get_best_models(num_models=1)[0]

```

```

    # Tahminler

```

```

y_pred = best_model.predict(X_test)
y_pred_inv = scaler.inverse_transform(y_pred)

# NaN kontrolü
if np.isnan(y_pred_inv).any():
    print(f'NaN values found in predictions for {currency}. Handling NaNs.')
    y_pred_inv = np.nan_to_num(y_pred_inv)

# Performans metrikleri
y_test_inv = scaler.inverse_transform(y_test.reshape(-1, 1)).flatten()
mape_score = np.mean(np.abs((y_test_inv - y_pred_inv.flatten()) / y_test_inv)) * 100
rmse_score = np.sqrt(mean_squared_error(y_test_inv, y_pred_inv.flatten()))
mda_score = mda(y_test_inv, y_pred_inv.flatten())
r2 = r2_score_manual(y_test_inv, y_pred_inv.flatten())

metrics.append({
    'Currency': currency,
    'RMSE': rmse_score,
    'MAPE': mape_score,
    'MDA': mda_score,
    'R2': r2
})

results[currency] = {
    'y_test': y_test_inv,
    'y_pred_inv': y_pred_inv.flatten(),
    'model_summary': best_model.to_json(),
    'train_index': train_index,
    'val_index': val_index,
    'test_index': test_index
}

# Tüm iterasyonları kaydet
for trial in tuner.oracle.get_best_trials(num_trials=10):
    trial_results.append({
        'Currency': currency,
        'units': trial.hyperparameters.get('units'),
        'units_2': trial.hyperparameters.get('units_2'),
        'dropout': trial.hyperparameters.get('dropout'),
        'dense_units': trial.hyperparameters.get('dense_units'),
        'dense_activation': trial.hyperparameters.get('dense_activation'),
        'dropout_2': trial.hyperparameters.get('dropout_2'),
        'learning_rate_adam': trial.hyperparameters.get('learning_rate_adam'),
        'Score': trial.score
    })

from google.colab import files
import matplotlib.dates as mdates
fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(12, 10))
axes[2, 1].axis('off')

```

```

currencies = ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']
for i, currency in enumerate(currencies):
    row = i // 2
    col = i % 2
    ax = axes[row, col] if i < 4 else axes[2, 0]

    result = results[currency]
    y_test = result['y_test']
    y_pred_inv = result['y_pred_inv']
    test_index = result['test_index']

    ax.plot(test_index, y_test, label='Gerçek Değerler', color='black')
    ax.plot(test_index, y_pred_inv, label='Optimize RNN Tahmini', linestyle='-',
color='magenta')
    ax.legend()
    ax.set_title(currency)
    ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m'))
    plt.setp(ax.get_xticklabels(), rotation=90)
plt.tight_layout()
plt.savefig('merged_forecast_results_simple_rnn.png')
plt.show()
files.download('merged_forecast_results_simple_rnn.png')
with pd.ExcelWriter('forecast_results_simple_rnn.xlsx') as writer:
    for currency in currencies:
        result = results[currency]
        df_result = pd.DataFrame({
            'Date': result['test_index'],
            'Actual': result['y_test'],
            'Predicted': result['y_pred_inv']
        })
        df_result.set_index('Date', inplace=True)
        df_result.to_excel(writer, sheet_name=f'{currency}_Forecast')

    metrics_df = pd.DataFrame(metrics)
    metrics_df.to_excel(writer, sheet_name='Metrics')
    trials_df = pd.DataFrame(trial_results)
    trials_df.to_excel(writer, sheet_name='Trials')

# Dosyanın indirilmesi
files.download('forecast_results_simple_rnn.xlsx')

```

## EK 6. Optimize Edilmiş LSTM Kodu

```
!pip install keras-tuner
!pip install tensorflow
!pip install pandas
!pip install matplotlib
!pip install openpyxl

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
from keras.models import Sequential
from keras.layers import SimpleRNN, Dense, Dropout, BatchNormalization, LSTM, GRU,
Conv1D, MaxPooling1D, Flatten
from keras.optimizers import Adam
from keras_tuner import BayesianOptimization, HyperModel
from keras.callbacks import EarlyStopping
import tensorflow as tf
import warnings
warnings.filterwarnings("ignore")
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})

def rmse_manual(y_true, y_pred):
    return np.sqrt(np.mean((np.array(y_true) - np.array(y_pred)) ** 2))
def mape_manual(y_true, y_pred):
    y_true, y_pred = np.array(y_true), np.array(y_pred)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    num_correct = np.sum(actual_signs == predicted_signs)
    return num_correct / (len(actual) - 1)
def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    if len(y_true) <= 1 or len(y_pred) <= 1:
        return float('nan')
    correlation_matrix = np.corrcoef(y_true, y_pred)
    correlation_xy = correlation_matrix[0, 1]
    r_squared = correlation_xy ** 2
    return r_squared
file_path = '/content/currency_data.xlsx'
```

```

df = pd.read_excel(file_path)
df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
df.set_index('Date', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.")
df = df.asfreq('B')
df.interpolate(method='linear', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.")
df.to_excel(file_path)
print(f"Düzeltilmiş veriler başarıyla {file_path} dosyasına kaydedildi.")

def prepare_data(currency, look_back=3):
    data = df[[currency]].copy()
    scaler = MinMaxScaler(feature_range=(-1, 1))
    data[currency] = scaler.fit_transform(data[[currency]])

    train_size = int(len(data) * 0.7)
    val_size = int(len(data) * 0.15)

    train_data = data[:train_size]
    val_data = data[train_size:train_size + val_size]
    test_data = data[train_size + val_size:]
    def create_dataset(data, look_back=1):
        X, y = [], []
        for i in range(len(data) - look_back):
            X.append(data.iloc[i:(i + look_back)].values)
            y.append(data.iloc[i + look_back].values)
        return np.array(X), np.array(y).flatten()

    X_train, y_train = create_dataset(train_data, look_back)
    X_val, y_val = create_dataset(val_data, look_back)
    X_test, y_test = create_dataset(test_data, look_back)
    return X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_data.index[look_back:],
    val_data.index[look_back:], test_data.index[look_back:]

class LSTMHyperModel(HyperModel):
    def __init__(self, input_shape):
        self.input_shape = input_shape
    def build(self, hp):
        model = Sequential()
        model.add(LSTM(units=hp.Int('units', min_value=32, max_value=128, step=32),
input_shape=self.input_shape, return_sequences=True))
        model.add(Dropout(hp.Float('dropout', min_value=0.3, max_value=0.5, step=0.05)))
        model.add(LSTM(units=hp.Int('units_2', min_value=32, max_value=128, step=32)))

```

```

        model.add(Dense(units=hp.Int('dense_units', min_value=32, max_value=128,
step=32), activation=hp.Choice('dense_activation', values=['selu', 'elu', 'tanh'])))
        model.add(Dropout(hp.Float('dropout_2', min_value=0.3, max_value=0.5,
step=0.05)))
        model.add(Dense(1))
        optimizer = Adam(learning_rate=hp.Choice('learning_rate_adam', values=[1e-3, 1e-4,
1e-5]))
        model.compile(optimizer=optimizer, loss='mean_squared_error')
        return model

```

```

results = {}
metrics = []
trial_results = []

```

```

for currency in ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']:
    print(f'Processing {currency}...')
    X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_index, val_index, test_index =
prepare_data(currency, look_back=3)
    hypermodel = LSTMHyperModel(input_shape=(X_train.shape[1], 1))
    tuner = BayesianOptimization(
        hypermodel,
        objective='val_loss',
        max_trials=10,
        executions_per_trial=1,
        directory='tuner_directory',
        project_name=f'lstm_hyperparameter_tuning_{currency}'
    )
    tuner.search(X_train, y_train, epochs=50, validation_data=(X_val, y_val),
callbacks=[EarlyStopping(monitor='val_loss', patience=10)])

```

```

best_model = tuner.get_best_models(num_models=1)[0]
y_pred = best_model.predict(X_test)
y_pred_inv = scaler.inverse_transform(y_pred)

```

```

# NaN kontrol et
if np.isnan(y_pred_inv).any():
    print(f'NaN values found in predictions for {currency}. Handling NaNs.')
    y_pred_inv = np.nan_to_num(y_pred_inv)
y_test_inv = scaler.inverse_transform(y_test.reshape(-1, 1)).flatten()
mape_score = np.mean(np.abs((y_test_inv - y_pred_inv.flatten()) / y_test_inv)) * 100
rmse_score = np.sqrt(mean_squared_error(y_test_inv, y_pred_inv.flatten()))
mda_score = mda(y_test_inv, y_pred_inv.flatten())
r2 = r2_score_manual(y_test_inv, y_pred_inv.flatten())
metrics.append({
    'Currency': currency,
    'RMSE': rmse_score,
    'MAPE': mape_score,
    'MDA': mda_score,
    'R2': r2
})

```

```

results[currency] = {
    'y_test': y_test_inv,
    'y_pred_inv': y_pred_inv.flatten(),
    'model_summary': best_model.to_json(),
    'train_index': train_index,
    'val_index': val_index,
    'test_index': test_index
}
for trial in tuner.oracle.get_best_trials(num_trials=10):
    trial_results.append({
        'Currency': currency,
        'units': trial.hyperparameters.get('units'),
        'units_2': trial.hyperparameters.get('units_2'),
        'dropout': trial.hyperparameters.get('dropout'),
        'dense_units': trial.hyperparameters.get('dense_units'),
        'dense_activation': trial.hyperparameters.get('dense_activation'),
        'dropout_2': trial.hyperparameters.get('dropout_2'),
        'learning_rate_adam': trial.hyperparameters.get('learning_rate_adam'),
        'Score': trial.score
    })
from google.colab import files
import matplotlib.dates as mdates
fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(12, 10))
axes[2, 1].axis('off')
currencies = ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']
for i, currency in enumerate(currencies):
    row = i // 2
    col = i % 2
    ax = axes[row, col] if i < 4 else axes[2, 0]
    result = results[currency]
    y_test = result['y_test']
    y_pred_inv = result['y_pred_inv']
    test_index = result['test_index']
    ax.plot(test_index, y_test, label='Gerçek Değerler', color='black')
    ax.plot(test_index, y_pred_inv, label='Optimize LSTM Tahmini', linestyle='-',
color='magenta')
    ax.legend()
    ax.set_title(currency)
    ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m'))
    plt.setp(ax.get_xticklabels(), rotation=90)
plt.tight_layout()
plt.savefig('merged_forecast_results_lstm.png')
plt.show()

files.download('merged_forecast_results_lstm.png')
with pd.ExcelWriter('forecast_results_lstm.xlsx') as writer:
    for currency in currencies:
        result = results[currency]
        df_result = pd.DataFrame({

```

```
'Date': result['test_index'],
'Actual': result['y_test'],
'Predicted': result['y_pred_inv']
})
df_result.set_index('Date', inplace=True)
df_result.to_excel(writer, sheet_name=f'{currency}_Forecast')
metrics_df = pd.DataFrame(metrics)
metrics_df.to_excel(writer, sheet_name='Metrics')
trials_df = pd.DataFrame(trial_results)
trials_df.to_excel(writer, sheet_name='Trials')
# Dosyanın indirilmesi
files.download('forecast_results_lstm.xlsx')
```



## EK 7. Optimize Edilmiş GRU Kodu

```
!pip install keras-tuner
!pip install tensorflow
!pip install pandas
!pip install matplotlib
!pip install openpyxl

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
from keras.models import Sequential
from keras.layers import SimpleRNN, Dense, Dropout, BatchNormalization, LSTM, GRU,
Conv1D, MaxPooling1D, Flatten
from keras.optimizers import Adam
from keras_tuner import BayesianOptimization, HyperModel
from keras.callbacks import EarlyStopping
import tensorflow as tf
import warnings
warnings.filterwarnings("ignore")
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})

def rmse_manual(y_true, y_pred):
    return np.sqrt(np.mean((np.array(y_true) - np.array(y_pred)) ** 2))
def mape_manual(y_true, y_pred):
    y_true, y_pred = np.array(y_true), np.array(y_pred)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    num_correct = np.sum(actual_signs == predicted_signs)
    return num_correct / (len(actual) - 1)
def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    if len(y_true) <= 1 or len(y_pred) <= 1:
        return float('nan')
    correlation_matrix = np.corrcoef(y_true, y_pred)
    correlation_xy = correlation_matrix[0, 1]
    r_squared = correlation_xy ** 2
    return r_squared
```

```

file_path = '/content/currency_data.xlsx'
df = pd.read_excel(file_path)
df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
df.set_index('Date', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')
df = df.asfreq('B')
df.interpolate(method='linear', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)

for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')
df.to_excel(file_path)
print(f'Düzeltilmiş veriler başarıyla {file_path} dosyasına kaydedildi.")
def prepare_data(currency, look_back=3):
    data = df[[currency]].copy()
    scaler = MinMaxScaler(feature_range=(-1, 1))
    data[currency] = scaler.fit_transform(data[[currency]])
    train_size = int(len(data) * 0.7)
    val_size = int(len(data) * 0.15)
    train_data = data[:train_size]
    val_data = data[train_size:train_size + val_size]
    test_data = data[train_size + val_size:]
    def create_dataset(data, look_back=1):
        X, y = [], []
        for i in range(len(data) - look_back):
            X.append(data.iloc[i:(i + look_back)].values)
            y.append(data.iloc[i + look_back].values)
        return np.array(X), np.array(y).flatten()
    X_train, y_train = create_dataset(train_data, look_back)
    X_val, y_val = create_dataset(val_data, look_back)
    X_test, y_test = create_dataset(test_data, look_back)
    return X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_data.index[look_back:],
    val_data.index[look_back:], test_data.index[look_back:]
class GRUHyperModel(HyperModel):
    def __init__(self, input_shape):
        self.input_shape = input_shape
    def build(self, hp):
        model = Sequential()
        model.add(GRU(units=hp.Int('units', min_value=32, max_value=128, step=32),
input_shape=self.input_shape, return_sequences=True))
        model.add(Dropout(hp.Float('dropout', min_value=0.3, max_value=0.5, step=0.05)))
        model.add(GRU(units=hp.Int('units_2', min_value=32, max_value=128, step=32)))
        model.add(Dense(units=hp.Int('dense_units', min_value=32, max_value=128,
step=32), activation=hp.Choice('dense_activation', values=['selu', 'elu', 'tanh'])))

```

```

        model.add(Dropout(hp.Float('dropout_2', min_value=0.3, max_value=0.5,
step=0.05)))
        model.add(Dense(1))
        optimizer = Adam(learning_rate=hp.Choice('learning_rate_adam', values=[1e-3, 1e-4,
1e-5]))
        model.compile(optimizer=optimizer, loss='mean_squared_error')
        return model
results = {}
metrics = []
trial_results = []

for currency in ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']:
    print(f'Processing {currency}...')
    X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_index, val_index, test_index =
prepare_data(currency, look_back=3)
    hypermodel = GRUHyperModel(input_shape=(X_train.shape[1], 1))

    tuner = BayesianOptimization(
        hypermodel,
        objective='val_loss',
        max_trials=10,
        executions_per_trial=1,
        directory='tuner_directory',
        project_name=f'GRU_hyperparameter_tuning_{currency}'
    )

    tuner.search(X_train, y_train, epochs=50, validation_data=(X_val, y_val),
callbacks=[EarlyStopping(monitor='val_loss', patience=10)])

    best_model = tuner.get_best_models(num_models=1)[0]

    y_pred = best_model.predict(X_test)
    y_pred_inv = scaler.inverse_transform(y_pred)
    # NaN kontrolü
    if np.isnan(y_pred_inv).any():
        print(f'NaN values found in predictions for {currency}. Handling NaNs.')
        y_pred_inv = np.nan_to_num(y_pred_inv)
    y_test_inv = scaler.inverse_transform(y_test.reshape(-1, 1)).flatten()
    mape_score = np.mean(np.abs((y_test_inv - y_pred_inv.flatten()) / y_test_inv)) * 100
    rmse_score = np.sqrt(mean_squared_error(y_test_inv, y_pred_inv.flatten()))
    mda_score = mda(y_test_inv, y_pred_inv.flatten())
    r2 = r2_score_manual(y_test_inv, y_pred_inv.flatten())

    metrics.append({
        'Currency': currency,
        'RMSE': rmse_score,
        'MAPE': mape_score,
        'MDA': mda_score,
        'R2': r2
    })

```

```

results[currency] = {
    'y_test': y_test_inv,
    'y_pred_inv': y_pred_inv.flatten(),
    'model_summary': best_model.to_json(),
    'train_index': train_index,
    'val_index': val_index,
    'test_index': test_index
}
for trial in tuner.oracle.get_best_trials(num_trials=10):
    trial_results.append({
        'Currency': currency,
        'units': trial.hyperparameters.get('units'),
        'units_2': trial.hyperparameters.get('units_2'),
        'dropout': trial.hyperparameters.get('dropout'),
        'dense_units': trial.hyperparameters.get('dense_units'),
        'dense_activation': trial.hyperparameters.get('dense_activation'),
        'dropout_2': trial.hyperparameters.get('dropout_2'),
        'learning_rate_adam': trial.hyperparameters.get('learning_rate_adam'),
        'Score': trial.score
    })

from google.colab import files
import matplotlib.dates as mdates
fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(12, 10))
axes[2, 1].axis('off')
currencies = ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']
for i, currency in enumerate(currencies):
    row = i // 2
    col = i % 2
    ax = axes[row, col] if i < 4 else axes[2, 0]
    result = results[currency]
    y_test = result['y_test']
    y_pred_inv = result['y_pred_inv']
    test_index = result['test_index']

    ax.plot(test_index, y_test, label='Gerçek Değerler', color='black')
    ax.plot(test_index, y_pred_inv, label='Optimize GRU Tahmini', linestyle='-',
color='magenta')
    ax.legend()
    ax.set_title(currency)
    ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m'))
    plt.setp(ax.get_xticklabels(), rotation=90)
plt.tight_layout()
plt.savefig('merged_forecast_results_GRU.png')
plt.show()

files.download('merged_forecast_results_GRU.png')
with pd.ExcelWriter('forecast_results_GRU.xlsx') as writer:
    for currency in currencies:
        result = results[currency]

```

```

df_result = pd.DataFrame({
    'Date': result['test_index'],
    'Actual': result['y_test'],
    'Predicted': result['y_pred_inv']
})
df_result.set_index('Date', inplace=True)
df_result.to_excel(writer, sheet_name=f'{currency}_Forecast')
metrics_df = pd.DataFrame(metrics)
metrics_df.to_excel(writer, sheet_name='Metrics')
trials_df = pd.DataFrame(trial_results)
trials_df.to_excel(writer, sheet_name='Trials')
files.download('forecast_results_GRU.xlsx')

```



## EK 8. Optimize Edilmiş CNN Kodu

```
!pip install keras-tuner
!pip install tensorflow
!pip install pandas
!pip install matplotlib
!pip install openpyxl
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
from keras.models import Sequential
from keras.layers import SimpleRNN, Dense, Dropout, BatchNormalization, LSTM, GRU,
Conv1D, MaxPooling1D, Flatten
from keras.optimizers import Adam
from keras_tuner import BayesianOptimization, HyperModel
from keras.callbacks import EarlyStopping
from keras.regularizers import l2
import tensorflow as tf
import warnings
warnings.filterwarnings("ignore")
import logging
logging.disable(logging.CRITICAL)
plt.rcParams.update({'figure.figsize': (20, 12), 'figure.dpi': 150})
def rmse_manual(y_true, y_pred):
    return np.sqrt(np.mean((np.array(y_true) - np.array(y_pred)) ** 2))
def mape_manual(y_true, y_pred):
    y_true, y_pred = np.array(y_true), np.array(y_pred)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)
    num_correct = np.sum(actual_signs == predicted_signs)
    return num_correct / (len(actual) - 1)
def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    if len(y_true) <= 1 or len(y_pred) <= 1:
        return float('nan')
    correlation_matrix = np.corrcoef(y_true, y_pred)
    correlation_xy = correlation_matrix[0, 1]
    r_squared = correlation_xy ** 2
    return r_squared
file_path = '/content/currency_data.xlsx'
df = pd.read_excel(file_path)
```

```

df['Date'] = pd.to_datetime(df['Date'], format='%d/%m/%Y', dayfirst=True)
df.set_index('Date', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')
df = df.asfreq('B')
df.interpolate(method='linear', inplace=True)
missing_data = df.isnull().sum()
print("Eksik veri durumu:")
print(missing_data)
for column in df.columns:
    print(f'{column} sütununda {len(df[column])} veri var.')
df.to_excel(file_path)
print(f'Düzeltilmiş veriler başarıyla {file_path} dosyasına kaydedildi.')
def prepare_data(currency, look_back=10):
    data = df[[currency]].copy()
    scaler = MinMaxScaler(feature_range=(-1, 1))
    data[currency] = scaler.fit_transform(data[[currency]])
    train_size = int(len(data) * 0.7)
    val_size = int(len(data) * 0.15)
    train_data = data[:train_size]
    val_data = data[train_size:train_size + val_size]
    test_data = data[train_size + val_size:]
    def create_dataset(data, look_back=3):
        X, y = [], []
        for i in range(len(data) - look_back):
            X.append(data.iloc[i:(i + look_back)].values)
            y.append(data.iloc[i + look_back].values)
        return np.array(X), np.array(y).flatten()
    X_train, y_train = create_dataset(train_data, look_back)
    X_val, y_val = create_dataset(val_data, look_back)
    X_test, y_test = create_dataset(test_data, look_back)
    return X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_data.index[look_back:],
    val_data.index[look_back:], test_data.index[look_back:]
class CNNHypModel(HyperModel):
    def __init__(self, input_shape):
        self.input_shape = input_shape
    def build(self, hp):
        model = Sequential()
        model.add(Conv1D(filters=hp.Int('filters', min_value=32, max_value=128, step=32),
            kernel_size=hp.Int('kernel_size', min_value=1, max_value=3, step=1),
            activation='selu', input_shape=self.input_shape))
        model.add(MaxPooling1D(pool_size=1))
        model.add(Dropout(hp.Float('dropout', min_value=0.3, max_value=0.5, step=0.05)))
        model.add(Flatten())
        model.add(Dense(units=hp.Int('dense_units', min_value=32, max_value=128,
            step=32),
            activation=hp.Choice('dense_activation', values=['selu', 'elu', 'tanh'])))

```

```

        model.add(Dropout(hp.Float('dropout_2', min_value=0.3, max_value=0.5,
step=0.05)))
        model.add(Dense(1))
        optimizer = Adam(learning_rate=hp.Choice('learning_rate_adam', values=[1e-3, 1e-4,
1e-5]))
        model.compile(optimizer=optimizer, loss='mean_squared_error')
        return model
results = {}
metrics = []
trial_results = []

```

```

for currency in ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']:
    print(f'Processing {currency}...')
    X_train, y_train, X_val, y_val, X_test, y_test, scaler, train_index, val_index, test_index =
prepare_data(currency, look_back=3)
    hypermodel = CNNHyperModel(input_shape=(X_train.shape[1], X_train.shape[2]))
    tuner = BayesianOptimization(
        hypermodel,
        objective='val_loss',
        max_trials=10,
        executions_per_trial=1,
        directory='tuner_directory',
        project_name=f'cnn_hyperparameter_tuning_{currency}'
    )
    tuner.search(X_train, y_train, epochs=50, validation_data=(X_val, y_val),
callbacks=[EarlyStopping(monitor='val_loss', patience=10)])
    best_model = tuner.get_best_models(num_models=1)[0]
    y_pred = best_model.predict(X_test)
    y_pred_inv = scaler.inverse_transform(y_pred.reshape(-1, 1))
    y_test_inv = scaler.inverse_transform(y_test.reshape(-1, 1)).flatten()
    mape_score = np.mean(np.abs((y_test_inv - y_pred_inv.flatten()) / y_test_inv)) * 100
    mae_score = mean_absolute_error(y_test_inv, y_pred_inv.flatten())
    rmse_score = np.sqrt(mean_squared_error(y_test_inv, y_pred_inv.flatten()))
    mda_score = mda(y_test_inv, y_pred_inv.flatten())
    r2 = r2_score_manual(y_test_inv, y_pred_inv.flatten())
    metrics.append({
        'Currency': currency,
        'MAPE': mape_score,
        'MAE': mae_score,
        'RMSE': rmse_score,
        'MDA': mda_score,
        'R2': r2
    })
results[currency] = {
    'y_test': y_test_inv,
    'y_pred_inv': y_pred_inv.flatten(),
    'model_summary': best_model.to_json(),
    'train_index': train_index,
    'val_index': val_index,
    'test_index': test_index
}

```

```

    }
    for trial in tuner.oracle.get_best_trials(num_trials=10):
        trial_results.append({
            'Currency': currency,
            'filters': trial.hyperparameters.get('filters'),
            'kernel_size': trial.hyperparameters.get('kernel_size'),
            'dropout': trial.hyperparameters.get('dropout'),
            'dense_units': trial.hyperparameters.get('dense_units'),
            'dense_activation': trial.hyperparameters.get('dense_activation'),
            'dropout_2': trial.hyperparameters.get('dropout_2'),
            'learning_rate_adam': trial.hyperparameters.get('learning_rate_adam'),
            'Score': trial.score
        })

from google.colab import files
import matplotlib.dates as mdates
fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(12, 10))
axes[2, 1].axis('off')
currencies = ['USDBRL', 'USDIDR', 'USDINR', 'USDZAR', 'USDTRY']
for i, currency in enumerate(currencies):
    row = i // 2
    col = i % 2
    ax = axes[row, col] if i < 4 else axes[2, 0]
    result = results[currency]
    y_test = result['y_test']
    y_pred_inv = result['y_pred_inv']
    test_index = result['test_index']
    ax.plot(test_index, y_test, label='Gerçek Değerler', color='black')
    ax.plot(test_index, y_pred_inv, label='Optimize CNN Tahmini', linestyle='-',
color='magenta')
    ax.legend()
    ax.set_title(currency)
    ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m'))
    plt.setp(ax.get_xticklabels(), rotation=90)
plt.tight_layout()
plt.savefig('merged_forecast_results_CNN.png')
plt.show()
files.download('merged_forecast_results_CNN.png')
with pd.ExcelWriter('forecast_results_CNN.xlsx') as writer:
    for currency in currencies:
        result = results[currency]
        df_result = pd.DataFrame({
            'Date': result['test_index'],
            'Actual': result['y_test'],
            'Predicted': result['y_pred_inv']
        })
        df_result.set_index('Date', inplace=True)
        df_result.to_excel(writer, sheet_name=f'{currency}_Forecast')
    metrics_df = pd.DataFrame(metrics)
    metrics_df.to_excel(writer, sheet_name='Metrics')

```

```

    trials_df = pd.DataFrame(trial_results)
    trials_df.to_excel(writer, sheet_name='Trials')
files.download('forecast_results_CNN.xlsx')
with pd.ExcelWriter('forecast_results_CNN.xlsx') as writer:
    for currency in currencies:
        result = results[currency]
        df_result = pd.DataFrame({
            'Date': result['test_index'],
            'Actual': result['y_test'],
            'Predicted': result['y_pred_inv']
        })
        df_result.set_index('Date', inplace=True)
        df_result.to_excel(writer, sheet_name=f'{currency}_Forecast')

    metrics_df = pd.DataFrame(metrics)
    metrics_df.to_excel(writer, sheet_name='Metrics')
    trials_df = pd.DataFrame(trial_results)
    trials_df.to_excel(writer, sheet_name='Trials')

files.download('forecast_results_CNN.xlsx')

```

## EK 9. Optimize Edilmiş Ridge Regresyon Modeli ve Gecikme Algoritması

```
import numpy as np
import pandas as pd
from sklearn.linear_model import Ridge
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split, KFold, cross_val_score
import matplotlib.pyplot as plt
from itertools import product
import statsmodels.api as sm
import matplotlib.dates as mdates
plt.style.use('seaborn-darkgrid')

file_path = '/content/INR_Dornbusch.xlsx'
data = pd.read_excel(file_path)
data['Date'] = pd.to_datetime(data['Date'], format='%Y-%m-%d')
data.set_index('Date', inplace=True)
data = data.asfreq('M')

y = data['USDINR']
X = data.drop('USDINR', axis=1)

def mda(actual, predicted):
    actual = np.array(actual)
    predicted = np.array(predicted)
    actual_diff = np.diff(actual)
    actual_signs = np.sign(actual_diff)
    predicted_diff = np.diff(predicted)
    predicted_signs = np.sign(predicted_diff)

    num_correct = np.sum(actual_signs == predicted_signs)

    return num_correct / (len(actual) - 1)

def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    correlation_matrix = np.corrcoef(y_true, y_pred)
    correlation_xy = correlation_matrix[0, 1]
    r_squared = correlation_xy ** 2
    return r_squared

def rmse_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    return np.sqrt(np.mean((y_true - y_pred) ** 2))

def mape_manual(y_true, y_pred):
    y_true = np.array(y_true)
```

```

y_pred = np.array(y_pred)
return np.mean(np.abs((y_true - y_pred) / y_true)) * 100

scaler = MinMaxScaler(feature_range=(0, 1))
X_scaled = scaler.fit_transform(X)

X_train_original, X_test_original, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=1, shuffle=False)

X_train = pd.DataFrame(X_train_original, columns=X.columns, index=y_train.index)
X_test = pd.DataFrame(X_test_original, columns=X.columns, index=y_test.index)

test_time_index = y_test.index

print(f"Eğitim seti tarih aralığı: {X_train.index.min()} - {X_train.index.max()}")
print(f"Test seti tarih aralığı: {X_test.index.min()} - {X_test.index.max()}")

def create_lagged_features(X, lags):
    X_lagged = pd.DataFrame()
    for i, lag in enumerate(lags):
        for j in range(1, lag + 1):
            X_lagged[f'{X.columns[i]}_lag_{j}'] = X[X.columns[i]].shift(j)
    return X_lagged

def evaluate_model(X_train, y_train, lags, alpha):
    X_train_lagged = create_lagged_features(X_train, lags)
    X_train_lagged.dropna(inplace=True)
    y_train_lagged = y_train[X_train_lagged.index]
    scaler = MinMaxScaler(feature_range=(0, 1))
    X_train_lagged_scaled = scaler.fit_transform(X_train_lagged)
    ridge = Ridge(alpha=alpha)
    kf = KFold(n_splits=5, shuffle=False)
    scores = cross_val_score(ridge, X_train_lagged_scaled, y_train_lagged, cv=kf,
scoring='neg_mean_squared_error')
    return np.mean(np.sqrt(-scores))

min_lag = 1
max_lag = 5
exog_vars = X.columns
lag_combinations = list(product(range(min_lag, max_lag + 1), repeat=len(exog_vars)))

best_combo = None
best_alpha = None
min_rmse = np.inf

for combo in lag_combinations:
    for alpha in np.logspace(-2, 1, 20):
        rmse = evaluate_model(X_train, y_train, combo, alpha)
        if rmse < min_rmse:
            min_rmse = rmse

```

```

best_combo = combo
best_alpha = alpha

print(f'En iyi gecikme kombinasyonu: {best_combo}')
print(f'En iyi alpha değeri: {best_alpha}')
print(f'En düşük RMSE: {min_rmse}')

X_train_lagged = create_lagged_features(X_train, best_combo)
X_train_lagged.dropna(inplace=True)
y_train_lagged = y_train[X_train_lagged.index]
X_test_lagged = create_lagged_features(X_test, best_combo)
X_test_lagged.dropna(inplace=True)
y_test_lagged = y_test[X_test_lagged.index]

scaler = MinMaxScaler(feature_range=(0, 1))
X_train_lagged_scaled = scaler.fit_transform(X_train_lagged)
X_test_lagged_scaled = scaler.transform(X_test_lagged)

final_ridge = Ridge(alpha=best_alpha)
final_ridge.fit(X_train_lagged_scaled, y_train_lagged)

y_pred = final_ridge.predict(X_test_lagged_scaled)

results = pd.DataFrame({'Gerçek Değerler': y_test_lagged, 'Optimize Ridge Tahmini':
y_pred}, index=y_test_lagged.index)
fig, ax = plt.subplots(figsize=(10, 6))

ax.plot(results.index, results['Gerçek Değerler'], label='Gerçek Değerler', color='black')
ax.plot(results.index, results['Optimize Ridge Tahmini'], label='Optimize Ridge Tahmini',
linestyle='-', color='magenta')
ax.legend()
ax.set_title('USDINR')
ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m'))
plt.setp(ax.get_xticklabels(), rotation=90)
plt.xlabel('Tarih')
plt.ylabel('Değer')
plt.tight_layout()
plt.savefig('ridge_forecast_results.png')
plt.show()

print("Model Özeti:")
print(f'R^2 (Determination Coefficient): {r2_score_manual(y_test_lagged, y_pred):.4f}')
print(f'Mean Absoulte Percentage Error (MAPE): {mape_manual(y_test_lagged,
y_pred):.4f}')
print(f'Root Mean Squared Error (RMSE): {rmse_manual(y_test_lagged, y_pred):.4f}')
print(f'Mean Directional Accuracy (MDA): {mda(y_test_lagged, y_pred):.4f}')

# Katsayılar ve sabit terim
coefficients = final_ridge.coef_
intercept = final_ridge.intercept_

```

```

print("\nKatsayılar:")
for i, col in enumerate(X_test_lagged.columns):
    print(f'{col}: {coefficients[i]:.6f}')
print(f"\nSabit Terim: {intercept:.6f}")

import statsmodels.api as sm

# Statsmodels ile katsayılar ve p
X_train_lagged_const = sm.add_constant(X_train_lagged)
ols_model = sm.OLS(y_train_lagged, X_train_lagged_const).fit()

p_values = ols_model.pvalues
f_value = ols_model.fvalue
f_p_value = ols_model.f_pvalue

# Katsayılar ve sabit terim
coefficients = final_ridge.coef_
intercept = final_ridge.intercept_

print("\nKatsayılar ve P Değerleri:")
for i, col in enumerate(X_test_lagged.columns):
    print(f'{col}: {coefficients[i]:.6f}, p-değeri: {p_values[i+1]:.6f}') # i+1 çünkü
statsmodels sabit terim için bir sütun ekliyor
print(f"\nSabit Terim: {intercept:.6f}, p-değeri: {p_values[0]:.6f}") # 0. indeks sabit terime
karşılık gelir

# Modelin genel anlamlılığı
print(f"\nF Değeri: {f_value:.6f}")
print(f"F Değeri p-değeri: {f_p_value:.6f}")

```

## EK 10. Optimize Edilmiş XGBoost Modeli

```
!pip install bayesian-optimization
```

```
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
import xgboost as xgb
from sklearn.metrics import mean_squared_error
from bayes_opt import BayesianOptimization
import matplotlib.pyplot as plt
import matplotlib.dates as mdates
from sklearn.metrics import r2_score
plt.style.use('seaborn-darkgrid')

file_path = '/content/ZAR_Dornbusch.xlsx'
data = pd.read_excel(file_path)
data['Date'] = pd.to_datetime(data['Date'], format='%Y-%m-%d')
data.set_index('Date', inplace=True)
data = data.asfreq('M')

y = data['USDZAR']
X = data.drop('USDZAR', axis=1)

X_train_original, X_test_original, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=1, shuffle=False)

X_train = pd.DataFrame(X_train_original, columns=X.columns, index=y_train.index)
X_test = pd.DataFrame(X_test_original, columns=X.columns, index=y_test.index)

def create_lagged_features(X, lags):
    X_lagged = pd.DataFrame()
    for i, lag in enumerate(lags):
        for j in range(1, lag + 1):
            X_lagged[f'{X.columns[i]}_lag_{j}'] = X[X.columns[i]].shift(j)
    return X_lagged

best_combo = (5, 1, 4, 1)

X_train_lagged = create_lagged_features(X_train, best_combo)
X_train_lagged.dropna(inplace=True)
y_train_lagged = y_train[X_train_lagged.index]
X_test_lagged = create_lagged_features(X_test, best_combo)
X_test_lagged.dropna(inplace=True)
y_test_lagged = y_test[X_test_lagged.index]

def mda(actual, predicted):
    actual = np.array(actual)
```

```

predicted = np.array(predicted)

actual_diff = np.diff(actual)
actual_signs = np.sign(actual_diff)
predicted_diff = np.diff(predicted)
predicted_signs = np.sign(predicted_diff)

num_correct = np.sum(actual_signs == predicted_signs)

return num_correct / (len(actual) - 1)

def r2_score_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    correlation_matrix = np.corrcoef(y_true, y_pred)
    correlation_xy = correlation_matrix[0, 1]
    r_squared = correlation_xy ** 2
    return r_squared

def rmse_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    return np.sqrt(np.mean((y_true - y_pred) ** 2))

def mape_manual(y_true, y_pred):
    y_true = np.array(y_true)
    y_pred = np.array(y_pred)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100

scaler = MinMaxScaler(feature_range=(0, 1))
X_train_lagged_scaled = scaler.fit_transform(X_train_lagged)
X_test_lagged_scaled = scaler.transform(X_test_lagged)

def xgb_evaluate(max_depth, gamma, colsample_bytree, learning_rate):
    params = {
        'objective': 'reg:squarederror',
        'max_depth': int(max_depth),
        'gamma': gamma,
        'colsample_bytree': colsample_bytree,
        'learning_rate': learning_rate,
        'n_estimators': 100,
        'seed': 1
    }
    xg_reg = xgb.XGBRegressor(**params)
    xg_reg.fit(X_train_lagged_scaled, y_train_lagged)
    y_pred = xg_reg.predict(X_test_lagged_scaled)
    return -mean_squared_error(y_test_lagged, y_pred)

xgb_bo = BayesianOptimization(
    f=xgb_evaluate,

```

```

pbounds={
    'max_depth': (3, 10),
    'gamma': (0, 1),
    'colsample_bytree': (0.3, 1),
    'learning_rate': (0.001, 0.1)
},
random_state=1,
)

xgb_bo.maximize(init_points=10, n_iter=30)

import pandas as pd
results = []
for i, res in enumerate(xgb_bo.res):
    results.append({
        'Iteration': i,
        'max_depth': res['params']['max_depth'],
        'gamma': res['params']['gamma'],
        'colsample_bytree': res['params']['colsample_bytree'],
        'learning_rate': res['params']['learning_rate'],
        'MSE': -res['target']
    })
results_df = pd.DataFrame(results)
results_df.to_excel('/content/xgb_optimization_results.xlsx', index=False)
print("Optimizasyon sonuçları Excel dosyasına kaydedildi.")

params = xgb_bo.max['params']
params['max_depth'] = int(params['max_depth'])
params['objective'] = 'reg:squarederror'
params['n_estimators'] = 100
params['seed'] = 1

xg_reg = xgb.XGBRegressor(**params)
xg_reg.fit(X_train_lagged_scaled, y_train_lagged)
y_pred = xg_reg.predict(X_test_lagged_scaled)

r2_score_value = r2_score_manual(y_test_lagged, y_pred)
mape_value = mape_manual(y_test_lagged, y_pred)
rmse_value = rmse_manual(y_test_lagged, y_pred)
mda_value = mda(y_test_lagged, y_pred)

print("Model Özeti:")
print(f'R^2 (Determination Coefficient): {r2_score_value:.4f}')
print(f'Mean Absoulte Percentage Error (MAPE): {mape_value:.4f}')
print(f'Root Mean Squared Error (RMSE): {rmse_value:.4f}')
print(f'Mean Directional Accuracy (MDA): {mda_value:.4f}')

results = pd.DataFrame({'Gerçek Değerler': y_test_lagged, 'Optimize XGBoost Tahmini':
y_pred}, index=y_test_lagged.index)
fig, ax = plt.subplots(figsize=(10, 6))

```

```

ax.plot(results.index, results['Gerçek Değerler'], label='Gerçek Değerler', color='black')
ax.plot(results.index, results['Optimize XGBoost Tahmini'], label='Optimize XGBoost
Tahmini', linestyle='-', color='magenta')
ax.legend()
ax.set_title('USDZAR')
ax.xaxis.set_major_formatter(mdates.DateFormatter('%Y-%m'))
plt.setp(ax.get_xticklabels(), rotation=90)

plt.xlabel('Tarih')
plt.ylabel('Değer')
plt.tight_layout()
plt.savefig('xgboost_forecast_results.png')
plt.show()

# Özellik önemini hesaplama ve görselleştirme
importances = xg_reg.feature_importances_
importance_df = pd.DataFrame({
    'Feature': X_train_lagged.columns,
    'Importance': importances
}).sort_values(by='Importance', ascending=False)

print("\nÖzellik Önemi:")
print(importance_df)

plt.figure(figsize=(10, 6))
plt.barh(importance_df['Feature'], importance_df['Importance'], color='skyblue')
plt.xlabel('Önem Skoru')
plt.ylabel('Özellikler')
plt.title('Özellik Önemleri')
plt.gca().invert_yaxis()
plt.show()

```

## EK 11. ARIMA Modelleri

Symbol: USDBRL

### SARIMAX Results

```

=====
Dep. Variable:          y      No. Observations:          2008
Model:                SARIMAX(2, 1, 1)  Log Likelihood          6355.417
Date:                Sun, 09 Jun 2024  AIC              -12700.834
Time:                17:47:11  BIC              -12672.812
Sample:                0      HQIC              -12690.547
                        - 2008
Covariance Type:          opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
drift          3.733e-07    2.79e-07      1.338      0.181    -1.74e-07    9.2e-07
ar.L1         -0.7166      0.308     -2.326      0.020     -1.321     -0.113
ar.L2         -0.0088      0.025     -0.353      0.724     -0.058     0.040
ma.L1          0.6751      0.312      2.167      0.030      0.064     1.286
sigma2         0.0001     1.78e-06    58.586      0.000      0.000      0.000
=====
Ljung-Box (L1) (Q):          0.01  Jarque-Bera (JB):          2398.19
Prob(Q):          0.91  Prob(JB):          0.00
Heteroskedasticity (H):      2.62  Skew:          -0.07
Prob(H) (two-sided):      0.00  Kurtosis:          8.35
=====

```

Symbol: USDIDR

### SARIMAX Results

```

=====
Dep. Variable:          y      No. Observations:          2008
Model:                SARIMAX(3, 1, 0)  Log Likelihood          6681.703
Date:                Sun, 09 Jun 2024  AIC              -13353.407
Time:                17:47:26  BIC              -13325.385
Sample:                0      HQIC              -13343.120
                        - 2008
Covariance Type:          opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
drift          5.042e-08    1.52e-07      0.332      0.740    -2.47e-07    3.48e-07
ar.L1          0.0282      0.012      2.441      0.015      0.006     0.051
ar.L2          0.0887      0.013      6.827      0.000      0.063     0.114
ar.L3          0.1199      0.015      7.745      0.000      0.090     0.150
sigma2         7.524e-05    1.04e-06    72.610      0.000      7.32e-05    7.73e-05
=====
Ljung-Box (L1) (Q):          0.02  Jarque-Bera (JB):          12190.27
Prob(Q):          0.88  Prob(JB):          0.00
Heteroskedasticity (H):      1.46  Skew:          -0.09
Prob(H) (two-sided):      0.00  Kurtosis:          15.07
=====

```

Symbol: USDINR

#### SARIMAX Results

```

=====
Dep. Variable:          y      No. Observations:          2008
Model:                SARIMAX(5, 1, 0)  Log Likelihood          5799.176
Date:                Sun, 09 Jun 2024  AIC              -11584.351
Time:                17:47:49    BIC              -11545.120
Sample:                0      HQIC              -11569.949
                             - 2008

```

Covariance Type: opg

```

=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
drift          2.133e-07    2.87e-07      0.743      0.458     -3.49e-07     7.76e-07
ar.L1          -0.0327      0.010     -3.151      0.002     -0.053     -0.012
ar.L2          -0.1269      0.013     -9.944      0.000     -0.152     -0.102
ar.L3          -0.0358      0.014     -2.627      0.009     -0.063     -0.009
ar.L4           0.0794      0.014      5.698      0.000      0.052      0.107
ar.L5           0.0930      0.011      8.514      0.000      0.072      0.114
sigma2          0.0002     2.52e-06     71.016      0.000      0.000      0.000
=====

```

```

=====
Ljung-Box (L1) (Q):          0.02    Jarque-Bera (JB):          11783.78
Prob(Q):                    0.90    Prob(JB):              0.00
Heteroskedasticity (H):      0.68    Skew:                  0.93
Prob(H) (two-sided):         0.00    Kurtosis:              14.72
=====

```

Symbol: USDZAR

#### SARIMAX Results

```

=====
Dep. Variable:          y      No. Observations:          2008
Model:                SARIMAX(2, 1, 0)  Log Likelihood          5672.103
Date:                Sun, 09 Jun 2024  AIC              -11336.206
Time:                17:48:01    BIC              -11313.788
Sample:                0      HQIC              -11327.976
                             - 2008

```

Covariance Type: opg

```

=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
drift          9.205e-08    2.59e-07      0.355      0.723     -4.16e-07      6e-07
ar.L1           0.0505      0.020      2.545      0.011      0.012      0.089
ar.L2          -0.0519      0.016     -3.158      0.002     -0.084     -0.020
sigma2          0.0002     3.92e-06     52.454      0.000      0.000      0.000
=====

```

```

=====
Ljung-Box (L1) (Q):          0.00    Jarque-Bera (JB):          1362.48
Prob(Q):                    0.97    Prob(JB):              0.00
Heteroskedasticity (H):      2.13    Skew:                  0.13
Prob(H) (two-sided):         0.00    Kurtosis:              7.03
=====

```

Symbol: USDTRY

SARIMAX Results

```
=====
Dep. Variable:          y      No. Observations:      2008
Model:                SARIMAX(0, 1, 5)  Log Likelihood      7111.819
Date:                Sun, 09 Jun 2024  AIC              -14209.637
Time:                17:48:49    BIC              -14170.406
Sample:                0      HQIC              -14195.235
                  - 2008
Covariance Type:      opg
=====
```

|        | coef      | std err  | z       | P> z  | [0.025   | 0.975]   |
|--------|-----------|----------|---------|-------|----------|----------|
| drift  | 3.105e-07 | 1.25e-07 | 2.487   | 0.013 | 6.58e-08 | 5.55e-07 |
| ma.L1  | 0.1029    | 0.012    | 8.424   | 0.000 | 0.079    | 0.127    |
| ma.L2  | -0.0291   | 0.013    | -2.286  | 0.022 | -0.054   | -0.004   |
| ma.L3  | -0.0701   | 0.008    | -9.121  | 0.000 | -0.085   | -0.055   |
| ma.L4  | -0.0206   | 0.015    | -1.351  | 0.177 | -0.051   | 0.009    |
| ma.L5  | 0.0691    | 0.014    | 4.917   | 0.000 | 0.042    | 0.097    |
| sigma2 | 4.956e-05 | 4.08e-07 | 121.434 | 0.000 | 4.88e-05 | 5.04e-05 |

```
=====
Ljung-Box (L1) (Q):      0.08  Jarque-Bera (JB):      326118.60
Prob(Q):                0.77  Prob(JB):              0.00
Heteroskedasticity (H):  17.12  Skew:                2.53
Prob(H) (two-sided):    0.00  Kurtosis:            65.24
=====
```

## EK 12. RNN Modeli İçin Optimizasyon Parametreleri

| Döviz Kuru | Nöron Sayısı | Nöron Sayısı | İlk Seyreltme | Gizli Katman Nöron Sayısı | Gizli Katman Aktivasyon Fonksiyonu | İkinci Seyreltme Oranı | Öğrenme Oranı | Deneme Başarı Oranı |
|------------|--------------|--------------|---------------|---------------------------|------------------------------------|------------------------|---------------|---------------------|
| USDBRL     | 64           | 32           | 0,3           | 128                       | tanh                               | 0,35                   | 0,001         | 0,000942            |
| USDBRL     | 128          | 128          | 0,5           | 64                        | tanh                               | 0,4                    | 0,0001        | 0,001050            |
| USDBRL     | 128          | 128          | 0,5           | 64                        | elu                                | 0,45                   | 0,0001        | 0,001055            |
| USDBRL     | 128          | 32           | 0,4           | 128                       | tanh                               | 0,5                    | 0,001         | 0,001152            |
| USDBRL     | 96           | 96           | 0,35          | 32                        | tanh                               | 0,45                   | 0,0001        | 0,001152            |
| USDBRL     | 96           | 96           | 0,5           | 96                        | elu                                | 0,5                    | 0,001         | 0,001160            |
| USDBRL     | 32           | 128          | 0,35          | 32                        | elu                                | 0,35                   | 0,001         | 0,001293            |
| USDBRL     | 128          | 64           | 0,35          | 32                        | elu                                | 0,5                    | 0,001         | 0,001675            |
| USDBRL     | 128          | 128          | 0,4           | 64                        | selu                               | 0,4                    | 0,00001       | 0,003153            |
| USDBRL     | 32           | 32           | 0,4           | 128                       | elu                                | 0,4                    | 0,00001       | 0,004414            |
| USDIDR     | 128          | 128          | 0,35          | 64                        | tanh                               | 0,35                   | 0,0001        | 0,000112            |
| USDIDR     | 128          | 96           | 0,35          | 64                        | tanh                               | 0,4                    | 0,001         | 0,000120            |
| USDIDR     | 96           | 96           | 0,4           | 32                        | selu                               | 0,45                   | 0,001         | 0,000122            |
| USDIDR     | 64           | 64           | 0,4           | 96                        | elu                                | 0,4                    | 0,001         | 0,000124            |
| USDIDR     | 128          | 32           | 0,3           | 32                        | selu                               | 0,5                    | 0,001         | 0,000139            |
| USDIDR     | 128          | 96           | 0,45          | 32                        | selu                               | 0,5                    | 0,001         | 0,000144            |
| USDIDR     | 128          | 128          | 0,45          | 64                        | selu                               | 0,5                    | 0,0001        | 0,000171            |
| USDIDR     | 32           | 32           | 0,45          | 96                        | elu                                | 0,5                    | 0,0001        | 0,000182            |
| USDIDR     | 128          | 64           | 0,35          | 96                        | elu                                | 0,5                    | 0,00001       | 0,000187            |
| USDIDR     | 64           | 32           | 0,4           | 32                        | selu                               | 0,35                   | 0,00001       | 0,000323            |
| USDINR     | 64           | 128          | 0,3           | 96                        | tanh                               | 0,3                    | 0,0001        | 0,000340            |
| USDINR     | 96           | 128          | 0,35          | 64                        | elu                                | 0,4                    | 0,001         | 0,000345            |
| USDINR     | 96           | 32           | 0,35          | 64                        | selu                               | 0,3                    | 0,001         | 0,000442            |
| USDINR     | 32           | 128          | 0,5           | 128                       | elu                                | 0,45                   | 0,001         | 0,000448            |
| USDINR     | 96           | 32           | 0,35          | 32                        | selu                               | 0,35                   | 0,0001        | 0,000532            |
| USDINR     | 96           | 32           | 0,45          | 64                        | selu                               | 0,45                   | 0,001         | 0,000588            |
| USDINR     | 64           | 64           | 0,45          | 128                       | tanh                               | 0,45                   | 0,0001        | 0,000644            |
| USDINR     | 96           | 128          | 0,4           | 32                        | selu                               | 0,5                    | 0,0001        | 0,000683            |
| USDINR     | 128          | 32           | 0,3           | 64                        | elu                                | 0,5                    | 0,00001       | 0,000883            |
| USDINR     | 96           | 128          | 0,3           | 32                        | elu                                | 0,45                   | 0,00001       | 0,001291            |
| USDZAR     | 128          | 128          | 0,35          | 64                        | tanh                               | 0,5                    | 0,0001        | 0,000660            |
| USDZAR     | 128          | 128          | 0,35          | 64                        | selu                               | 0,35                   | 0,0001        | 0,000671            |
| USDZAR     | 96           | 96           | 0,4           | 128                       | elu                                | 0,35                   | 0,001         | 0,000674            |
| USDZAR     | 32           | 96           | 0,3           | 64                        | selu                               | 0,5                    | 0,001         | 0,000701            |
| USDZAR     | 96           | 128          | 0,45          | 32                        | tanh                               | 0,3                    | 0,001         | 0,000705            |
| USDZAR     | 32           | 64           | 0,3           | 32                        | selu                               | 0,4                    | 0,001         | 0,000730            |
| USDZAR     | 64           | 96           | 0,5           | 96                        | selu                               | 0,4                    | 0,0001        | 0,000769            |
| USDZAR     | 96           | 96           | 0,35          | 32                        | selu                               | 0,5                    | 0,001         | 0,000795            |
| USDZAR     | 96           | 64           | 0,3           | 32                        | selu                               | 0,35                   | 0,0001        | 0,000797            |
| USDZAR     | 96           | 64           | 0,4           | 32                        | selu                               | 0,45                   | 0,00001       | 0,001465            |
| USDTRY     | 32           | 128          | 0,5           | 96                        | selu                               | 0,3                    | 0,001         | 0,000425            |
| USDTRY     | 64           | 64           | 0,3           | 32                        | elu                                | 0,45                   | 0,001         | 0,000497            |
| USDTRY     | 128          | 128          | 0,3           | 128                       | selu                               | 0,5                    | 0,001         | 0,000575            |
| USDTRY     | 64           | 128          | 0,5           | 32                        | selu                               | 0,45                   | 0,0001        | 0,000591            |
| USDTRY     | 128          | 96           | 0,5           | 64                        | selu                               | 0,4                    | 0,0001        | 0,000623            |
| USDTRY     | 96           | 96           | 0,3           | 96                        | selu                               | 0,45                   | 0,0001        | 0,000680            |
| USDTRY     | 128          | 64           | 0,3           | 32                        | selu                               | 0,45                   | 0,00001       | 0,000720            |
| USDTRY     | 96           | 32           | 0,45          | 32                        | selu                               | 0,4                    | 0,001         | 0,001009            |
| USDTRY     | 64           | 64           | 0,35          | 96                        | selu                               | 0,3                    | 0,0001        | 0,001844            |
| USDTRY     | 32           | 96           | 0,45          | 128                       | tanh                               | 0,3                    | 0,00001       | 0,002631            |

### EK 13. LSTM Modeli İçin Optimizasyon Parametreleri

| Döviz Kuru | Nöron Sayısı | Nöron Sayısı | İlk Seyreltme | Gizli Katman Nöron Sayısı | Gizli Katman Aktivasyon Fonksiyonu | İkinci Seyreltme Oranı | Öğrenme Oranı | Deneme Başarı Oranı |
|------------|--------------|--------------|---------------|---------------------------|------------------------------------|------------------------|---------------|---------------------|
| USDBRL     | 128          | 96           | 0.4           | 64                        | elu                                | 0.35                   | 0.001         | 0.001225            |
| USDBRL     | 32           | 64           | 0.4           | 128                       | elu                                | 0.5                    | 0.001         | 0.001542            |
| USDBRL     | 96           | 128          | 0.5           | 96                        | selu                               | 0.4                    | 0.0001        | 0.001542            |
| USDBRL     | 96           | 64           | 0.4           | 128                       | tanh                               | 0.5                    | 0.0001        | 0.001555            |
| USDBRL     | 128          | 128          | 0.4           | 64                        | tanh                               | 0.3                    | 0.0001        | 0.001567            |
| USDBRL     | 96           | 32           | 0.35          | 64                        | elu                                | 0.35                   | 0.001         | 0.001582            |
| USDBRL     | 128          | 64           | 0.3           | 96                        | tanh                               | 0.45                   | 0.0001        | 0.001582            |
| USDBRL     | 64           | 96           | 0.45          | 64                        | elu                                | 0.3                    | 0.0001        | 0.001585            |
| USDBRL     | 128          | 32           | 0.35          | 32                        | tanh                               | 0.3                    | 0.001         | 0.001627            |
| USDBRL     | 64           | 64           | 0.45          | 128                       | tanh                               | 0.5                    | 0.00001       | 0.002143            |
| USDIDR     | 128          | 64           | 0.3           | 64                        | tanh                               | 0.35                   | 0.001         | 0.000132            |
| USDIDR     | 64           | 64           | 0.5           | 128                       | selu                               | 0.5                    | 0.001         | 0.000177            |
| USDIDR     | 64           | 64           | 0.45          | 128                       | elu                                | 0.3                    | 0.001         | 0.000216            |
| USDIDR     | 32           | 96           | 0.4           | 128                       | tanh                               | 0.3                    | 0.001         | 0.000217            |
| USDIDR     | 32           | 32           | 0.3           | 128                       | elu                                | 0.3                    | 0.0001        | 0.000221            |
| USDIDR     | 64           | 128          | 0.5           | 128                       | selu                               | 0.35                   | 0.001         | 0.000221            |
| USDIDR     | 96           | 96           | 0.5           | 64                        | tanh                               | 0.45                   | 0.0001        | 0.000236            |
| USDIDR     | 96           | 128          | 0.3           | 32                        | tanh                               | 0.5                    | 0.00001       | 0.000616            |
| USDIDR     | 128          | 96           | 0.45          | 32                        | selu                               | 0.5                    | 0.00001       | 0.001120            |
| USDIDR     | 32           | 32           | 0.35          | 32                        | selu                               | 0.35                   | 0.00001       | 0.001539            |
| USDINR     | 64           | 32           | 0.4           | 128                       | selu                               | 0.5                    | 0.001         | 0.000543            |
| USDINR     | 128          | 32           | 0.35          | 128                       | tanh                               | 0.35                   | 0.0001        | 0.000574            |
| USDINR     | 32           | 96           | 0.45          | 96                        | tanh                               | 0.3                    | 0.0001        | 0.000611            |
| USDINR     | 64           | 128          | 0.5           | 64                        | elu                                | 0.35                   | 0.0001        | 0.000633            |
| USDINR     | 32           | 32           | 0.4           | 32                        | tanh                               | 0.45                   | 0.001         | 0.000651            |
| USDINR     | 32           | 96           | 0.5           | 32                        | tanh                               | 0.45                   | 0.001         | 0.000680            |
| USDINR     | 32           | 96           | 0.35          | 32                        | tanh                               | 0.3                    | 0.0001        | 0.000694            |
| USDINR     | 32           | 32           | 0.45          | 96                        | elu                                | 0.4                    | 0.00001       | 0.202580            |
| USDINR     | 64           | 96           | 0.45          | 64                        | tanh                               | 0.35                   | 0.00001       | 0.207103            |
| USDINR     | 96           | 32           | 0.35          | 32                        | selu                               | 0.35                   | 0.00001       | 0.212604            |
| USDZAR     | 96           | 96           | 0.3           | 32                        | tanh                               | 0.4                    | 0.001         | 0.000710            |
| USDZAR     | 64           | 32           | 0.5           | 64                        | selu                               | 0.45                   | 0.001         | 0.000919            |
| USDZAR     | 128          | 128          | 0.35          | 128                       | selu                               | 0.4                    | 0.0001        | 0.001172            |
| USDZAR     | 64           | 128          | 0.3           | 96                        | selu                               | 0.3                    | 0.0001        | 0.001200            |
| USDZAR     | 128          | 64           | 0.3           | 96                        | selu                               | 0.35                   | 0.0001        | 0.001217            |
| USDZAR     | 96           | 128          | 0.4           | 96                        | elu                                | 0.4                    | 0.0001        | 0.001232            |
| USDZAR     | 64           | 64           | 0.3           | 96                        | elu                                | 0.5                    | 0.0001        | 0.001262            |
| USDZAR     | 64           | 64           | 0.5           | 32                        | selu                               | 0.45                   | 0.00001       | 0.056132            |
| USDZAR     | 32           | 64           | 0.5           | 128                       | elu                                | 0.3                    | 0.00001       | 0.056462            |
| USDZAR     | 64           | 32           | 0.3           | 32                        | tanh                               | 0.3                    | 0.00001       | 0.059073            |
| USDTRY     | 96           | 64           | 0.3           | 128                       | elu                                | 0.4                    | 0.001         | 0.000583            |
| USDTRY     | 64           | 96           | 0.4           | 32                        | selu                               | 0.35                   | 0.001         | 0.001568            |
| USDTRY     | 64           | 128          | 0.4           | 32                        | elu                                | 0.3                    | 0.0001        | 0.012947            |
| USDTRY     | 128          | 128          | 0.3           | 128                       | elu                                | 0.3                    | 0.0001        | 0.021012            |
| USDTRY     | 64           | 96           | 0.3           | 64                        | selu                               | 0.45                   | 0.00001       | 0.025631            |
| USDTRY     | 64           | 32           | 0.5           | 64                        | tanh                               | 0.5                    | 0.0001        | 0.026080            |
| USDTRY     | 64           | 96           | 0.45          | 32                        | selu                               | 0.35                   | 0.00001       | 0.026711            |
| USDTRY     | 32           | 96           | 0.3           | 96                        | selu                               | 0.45                   | 0.00001       | 0.029550            |
| USDTRY     | 96           | 32           | 0.3           | 32                        | selu                               | 0.45                   | 0.0001        | 0.032430            |
| USDTRY     | 32           | 32           | 0.3           | 128                       | elu                                | 0.4                    | 0.00001       | 0.034738            |

#### EK 14. GRU Modeli İçin Optimizasyon Parametreleri

| Döviz Kuru | Nöron Sayısı | Nöron Sayısı | İlk Seyreltme | Gizli Katman Nöron Sayısı | Gizli Katman Aktivasyon Fonksiyonu | İkinci Seyreltme Oranı | Öğrenme Oranı | Deneme Başarı Oranı |
|------------|--------------|--------------|---------------|---------------------------|------------------------------------|------------------------|---------------|---------------------|
| USDBRL     | 128          | 64           | 0.45          | 128                       | selu                               | 0.5                    | 0.001         | 0.000964            |
| USDBRL     | 32           | 64           | 0.45          | 64                        | tanh                               | 0.45                   | 0.001         | 0.001136            |
| USDBRL     | 96           | 96           | 0.45          | 64                        | selu                               | 0.45                   | 0.001         | 0.001162            |
| USDBRL     | 96           | 128          | 0.45          | 64                        | tanh                               | 0.45                   | 0.001         | 0.001181            |
| USDBRL     | 128          | 32           | 0.3           | 96                        | tanh                               | 0.3                    | 0.0001        | 0.001257            |
| USDBRL     | 32           | 32           | 0.5           | 32                        | selu                               | 0.5                    | 0.001         | 0.001263            |
| USDBRL     | 96           | 64           | 0.5           | 64                        | selu                               | 0.4                    | 0.0001        | 0.001321            |
| USDBRL     | 64           | 32           | 0.4           | 32                        | elu                                | 0.45                   | 0.0001        | 0.001392            |
| USDBRL     | 64           | 96           | 0.45          | 96                        | tanh                               | 0.35                   | 0.00001       | 0.001486            |
| USDBRL     | 96           | 32           | 0.45          | 128                       | elu                                | 0.45                   | 0.00001       | 0.001775            |
| USDIDR     | 128          | 64           | 0.3           | 96                        | tanh                               | 0.3                    | 0.001         | 0.000102            |
| USDIDR     | 64           | 96           | 0.35          | 32                        | elu                                | 0.45                   | 0.001         | 0.000126            |
| USDIDR     | 128          | 96           | 0.35          | 96                        | selu                               | 0.45                   | 0.0001        | 0.000171            |
| USDIDR     | 32           | 96           | 0.45          | 32                        | selu                               | 0.4                    | 0.001         | 0.000182            |
| USDIDR     | 32           | 96           | 0.35          | 128                       | elu                                | 0.4                    | 0.001         | 0.000185            |
| USDIDR     | 32           | 96           | 0.35          | 64                        | elu                                | 0.45                   | 0.001         | 0.000186            |
| USDIDR     | 32           | 128          | 0.35          | 64                        | selu                               | 0.4                    | 0.0001        | 0.000188            |
| USDIDR     | 64           | 32           | 0.3           | 96                        | selu                               | 0.35                   | 0.0001        | 0.000193            |
| USDIDR     | 64           | 128          | 0.3           | 128                       | elu                                | 0.5                    | 0.0001        | 0.000206            |
| USDIDR     | 128          | 96           | 0.4           | 128                       | tanh                               | 0.45                   | 0.00001       | 0.000220            |
| USDINR     | 96           | 128          | 0.4           | 96                        | selu                               | 0.45                   | 0.001         | 0.000327            |
| USDINR     | 96           | 128          | 0.45          | 128                       | tanh                               | 0.5                    | 0.001         | 0.000363            |
| USDINR     | 128          | 32           | 0.5           | 96                        | tanh                               | 0.4                    | 0.001         | 0.000429            |
| USDINR     | 64           | 128          | 0.4           | 32                        | selu                               | 0.4                    | 0.0001        | 0.000463            |
| USDINR     | 64           | 64           | 0.4           | 128                       | selu                               | 0.35                   | 0.0001        | 0.000485            |
| USDINR     | 64           | 64           | 0.5           | 32                        | tanh                               | 0.5                    | 0.0001        | 0.000587            |
| USDINR     | 64           | 96           | 0.4           | 32                        | tanh                               | 0.5                    | 0.0001        | 0.000692            |
| USDINR     | 64           | 64           | 0.3           | 128                       | tanh                               | 0.3                    | 0.00001       | 0.000949            |
| USDINR     | 32           | 64           | 0.3           | 128                       | tanh                               | 0.35                   | 0.00001       | 0.001000            |
| USDINR     | 32           | 64           | 0.4           | 64                        | tanh                               | 0.3                    | 0.00001       | 0.001275            |
| USDZAR     | 128          | 32           | 0.3           | 128                       | elu                                | 0.45                   | 0.001         | 0.000630            |
| USDZAR     | 128          | 128          | 0.35          | 96                        | selu                               | 0.3                    | 0.001         | 0.000641            |
| USDZAR     | 64           | 96           | 0.3           | 32                        | elu                                | 0.3                    | 0.001         | 0.000971            |
| USDZAR     | 128          | 64           | 0.35          | 64                        | tanh                               | 0.35                   | 0.0001        | 0.001045            |
| USDZAR     | 96           | 128          | 0.5           | 64                        | selu                               | 0.35                   | 0.00001       | 0.001087            |
| USDZAR     | 32           | 96           | 0.35          | 32                        | elu                                | 0.5                    | 0.0001        | 0.001109            |
| USDZAR     | 96           | 96           | 0.5           | 96                        | elu                                | 0.35                   | 0.00001       | 0.001122            |
| USDZAR     | 96           | 128          | 0.4           | 128                       | tanh                               | 0.4                    | 0.00001       | 0.001137            |
| USDZAR     | 96           | 128          | 0.4           | 32                        | tanh                               | 0.35                   | 0.00001       | 0.001197            |
| USDZAR     | 96           | 32           | 0.35          | 128                       | elu                                | 0.45                   | 0.00001       | 0.050359            |
| USDTRY     | 32           | 96           | 0.35          | 96                        | selu                               | 0.3                    | 0.001         | 0.000476            |
| USDTRY     | 96           | 96           | 0.5           | 96                        | tanh                               | 0.45                   | 0.0001        | 0.000986            |
| USDTRY     | 64           | 128          | 0.3           | 32                        | selu                               | 0.5                    | 0.00001       | 0.014981            |
| USDTRY     | 64           | 96           | 0.4           | 96                        | elu                                | 0.45                   | 0.00001       | 0.015309            |
| USDTRY     | 64           | 128          | 0.5           | 32                        | tanh                               | 0.45                   | 0.00001       | 0.016681            |
| USDTRY     | 96           | 32           | 0.5           | 96                        | selu                               | 0.5                    | 0.00001       | 0.017710            |
| USDTRY     | 32           | 96           | 0.45          | 96                        | elu                                | 0.5                    | 0.00001       | 0.018476            |
| USDTRY     | 64           | 32           | 0.35          | 64                        | selu                               | 0.3                    | 0.00001       | 0.018591            |
| USDTRY     | 96           | 128          | 0.4           | 32                        | tanh                               | 0.35                   | 0.00001       | 0.018716            |
| USDTRY     | 32           | 64           | 0.35          | 64                        | tanh                               | 0.45                   | 0.00001       | 0.019765            |

## EK 15. CNN Modeli İçin Optimizasyon Parametreleri

| Döviz Kuru | Filtre Sayısı | Kernel Boyutu | İlk Seyreltme Oranı | Gizli Katman Nöron Sayısı | Gizli Katman Aktivasyon Fonksiyonu | İkinci Seyreltme Oranı | Öğrenme Oranı | Deneme Başarı Oranı |
|------------|---------------|---------------|---------------------|---------------------------|------------------------------------|------------------------|---------------|---------------------|
| USDBRL     | 128           | 2             | 0.4                 | 64                        | elu                                | 0.45                   | 0.001         | 0.000798            |
| USDBRL     | 96            | 2             | 0.5                 | 32                        | tanh                               | 0.3                    | 0.001         | 0.000846            |
| USDBRL     | 96            | 2             | 0.4                 | 128                       | tanh                               | 0.35                   | 0.0001        | 0.000865            |
| USDBRL     | 128           | 2             | 0.4                 | 128                       | elu                                | 0.3                    | 0.0001        | 0.000885            |
| USDBRL     | 64            | 3             | 0.45                | 64                        | elu                                | 0.3                    | 0.0001        | 0.000974            |
| USDBRL     | 96            | 1             | 0.35                | 128                       | selu                               | 0.4                    | 0.001         | 0.001090            |
| USDBRL     | 96            | 1             | 0.35                | 32                        | elu                                | 0.5                    | 0.0001        | 0.001167            |
| USDBRL     | 32            | 1             | 0.35                | 128                       | tanh                               | 0.4                    | 0.001         | 0.001171            |
| USDBRL     | 64            | 1             | 0.45                | 64                        | elu                                | 0.3                    | 0.0001        | 0.001200            |
| USDBRL     | 32            | 2             | 0.45                | 96                        | selu                               | 0.3                    | 0.0001        | 0.001372            |
| USDIDR     | 32            | 3             | 0.3                 | 32                        | tanh                               | 0.45                   | 0.001         | 0.000107            |
| USDIDR     | 64            | 2             | 0.4                 | 96                        | tanh                               | 0.45                   | 0.001         | 0.000116            |
| USDIDR     | 96            | 1             | 0.5                 | 128                       | tanh                               | 0.4                    | 0.0001        | 0.000148            |
| USDIDR     | 128           | 3             | 0.3                 | 96                        | selu                               | 0.3                    | 0.00001       | 0.000161            |
| USDIDR     | 32            | 3             | 0.5                 | 64                        | tanh                               | 0.5                    | 0.0001        | 0.000176            |
| USDIDR     | 64            | 2             | 0.45                | 96                        | tanh                               | 0.35                   | 0.00001       | 0.000184            |
| USDIDR     | 64            | 1             | 0.3                 | 96                        | tanh                               | 0.3                    | 0.00001       | 0.000184            |
| USDIDR     | 128           | 3             | 0.45                | 32                        | elu                                | 0.45                   | 0.00001       | 0.000219            |
| USDIDR     | 64            | 3             | 0.35                | 64                        | selu                               | 0.4                    | 0.00001       | 0.000402            |
| USDIDR     | 32            | 2             | 0.35                | 32                        | selu                               | 0.4                    | 0.00001       | 0.000547            |
| USDINR     | 128           | 2             | 0.3                 | 64                        | tanh                               | 0.4                    | 0.001         | 0.000289            |
| USDINR     | 96            | 3             | 0.45                | 64                        | tanh                               | 0.4                    | 0.0001        | 0.000311            |
| USDINR     | 96            | 2             | 0.35                | 64                        | tanh                               | 0.35                   | 0.001         | 0.000312            |
| USDINR     | 96            | 2             | 0.5                 | 32                        | tanh                               | 0.3                    | 0.0001        | 0.000345            |
| USDINR     | 64            | 1             | 0.35                | 96                        | selu                               | 0.3                    | 0.001         | 0.000392            |
| USDINR     | 32            | 2             | 0.45                | 128                       | elu                                | 0.3                    | 0.0001        | 0.000423            |
| USDINR     | 64            | 1             | 0.45                | 96                        | elu                                | 0.5                    | 0.0001        | 0.000428            |
| USDINR     | 64            | 1             | 0.45                | 64                        | elu                                | 0.3                    | 0.001         | 0.000437            |
| USDINR     | 96            | 2             | 0.5                 | 32                        | selu                               | 0.45                   | 0.0001        | 0.000534            |
| USDINR     | 96            | 3             | 0.5                 | 64                        | elu                                | 0.3                    | 0.00001       | 0.001017            |
| USDZAR     | 128           | 2             | 0.4                 | 64                        | elu                                | 0.4                    | 0.0001        | 0.000663            |
| USDZAR     | 32            | 2             | 0.3                 | 128                       | tanh                               | 0.4                    | 0.001         | 0.000704            |
| USDZAR     | 96            | 2             | 0.3                 | 32                        | selu                               | 0.45                   | 0.0001        | 0.000853            |
| USDZAR     | 128           | 1             | 0.35                | 32                        | selu                               | 0.3                    | 0.0001        | 0.000861            |
| USDZAR     | 96            | 3             | 0.4                 | 128                       | selu                               | 0.45                   | 0.0001        | 0.000877            |
| USDZAR     | 128           | 2             | 0.45                | 64                        | selu                               | 0.35                   | 0.0001        | 0.000884            |
| USDZAR     | 32            | 1             | 0.35                | 128                       | tanh                               | 0.4                    | 0.001         | 0.000884            |
| USDZAR     | 32            | 3             | 0.45                | 128                       | tanh                               | 0.35                   | 0.0001        | 0.000899            |
| USDZAR     | 32            | 2             | 0.3                 | 128                       | tanh                               | 0.5                    | 0.00001       | 0.001209            |
| USDZAR     | 32            | 3             | 0.5                 | 32                        | tanh                               | 0.5                    | 0.0001        | 0.001340            |
| USDTRY     | 96            | 2             | 0.45                | 32                        | selu                               | 0.3                    | 0.0001        | 0.000474            |
| USDTRY     | 128           | 2             | 0.3                 | 32                        | tanh                               | 0.5                    | 0.001         | 0.000480            |
| USDTRY     | 64            | 1             | 0.45                | 32                        | selu                               | 0.5                    | 0.00001       | 0.000592            |
| USDTRY     | 96            | 2             | 0.35                | 96                        | selu                               | 0.4                    | 0.001         | 0.000681            |
| USDTRY     | 64            | 1             | 0.35                | 96                        | selu                               | 0.35                   | 0.001         | 0.000766            |
| USDTRY     | 32            | 2             | 0.4                 | 64                        | tanh                               | 0.35                   | 0.001         | 0.002081            |
| USDTRY     | 64            | 1             | 0.5                 | 96                        | tanh                               | 0.4                    | 0.001         | 0.002182            |
| USDTRY     | 32            | 3             | 0.4                 | 64                        | tanh                               | 0.4                    | 0.00001       | 0.004060            |
| USDTRY     | 128           | 3             | 0.4                 | 128                       | tanh                               | 0.35                   | 0.00001       | 0.004566            |
| USDTRY     | 32            | 3             | 0.4                 | 128                       | elu                                | 0.3                    | 0.00001       | 0.006223            |

**EK 16. USDBRL İin XGBoost Modeli Optimizasyon Parametreleri**

| İterasyon | Maksimum Derinlik | Gamma Katsayısı | Ağaç Başına Sütun Örneklemi | Öğrenme Oranı | Ortalama Karesel Hata |
|-----------|-------------------|-----------------|-----------------------------|---------------|-----------------------|
| 0         | 5.116             | 0.720           | 0.592                       | 0.010         | 3.160                 |
| 1         | 5.419             | 0.092           | 0.403                       | 0.064         | 3.789                 |
| 2         | 7.797             | 0.539           | 0.578                       | 0.132         | 3.630                 |
| 3         | 7.693             | 0.878           | 0.443                       | 0.018         | 3.321                 |
| 4         | 4.387             | 0.559           | 0.592                       | 0.051         | 3.595                 |
| 5         | 7.846             | 0.968           | 0.861                       | 0.101         | 3.594                 |
| 6         | 3.273             | 0.895           | 0.913                       | 0.035         | 3.582                 |
| 7         | 5.948             | 0.878           | 0.419                       | 0.039         | 3.413                 |
| 8         | 5.209             | 0.533           | 0.971                       | 0.211         | 3.888                 |
| 9         | 8.251             | 0.835           | 0.781                       | 0.015         | 3.465                 |
| 10        | 8.353             | 0.162           | 0.305                       | 0.216         | 3.843                 |
| 11        | 8.209             | 0.413           | 0.610                       | 0.169         | 3.848                 |
| 12        | 7.687             | 0.851           | 0.433                       | 0.049         | 3.426                 |
| 13        | 7.915             | 0.808           | 0.315                       | 0.290         | 3.582                 |
| 14        | 5.118             | 0.731           | 0.675                       | 0.055         | 3.579                 |
| 15        | 5.074             | 0.708           | 0.600                       | 0.011         | 3.215                 |
| 16        | 5.103             | 0.708           | 0.524                       | 0.010         | 3.131                 |
| 17        | 8.261             | 0.636           | 0.527                       | 0.126         | 3.572                 |
| 18        | 5.151             | 0.624           | 0.551                       | 0.010         | 3.158                 |
| 19        | 5.243             | 0.721           | 0.495                       | 0.010         | 3.108                 |
| 20        | 6.345             | 0.550           | 0.307                       | 0.057         | 3.528                 |
| 21        | 5.203             | 0.904           | 0.473                       | 0.031         | 3.403                 |
| 22        | 9.644             | 0.447           | 0.464                       | 0.170         | 3.726                 |
| 23        | 5.236             | 0.620           | 0.381                       | 0.010         | 3.019                 |
| 24        | 5.379             | 0.599           | 0.409                       | 0.010         | 3.086                 |
| 25        | 5.235             | 0.660           | 0.320                       | 0.164         | 3.655                 |
| 26        | 8.298             | 0.837           | 0.768                       | 0.031         | 3.604                 |
| 27        | 5.273             | 0.527           | 0.457                       | 0.010         | 3.118                 |
| 28        | 5.047             | 0.471           | 0.414                       | 0.015         | 3.340                 |
| 29        | 4.127             | 0.164           | 0.873                       | 0.014         | 3.579                 |
| 30        | 5.041             | 0.481           | 0.452                       | 0.033         | 3.583                 |
| 31        | 7.715             | 0.898           | 0.456                       | 0.071         | 3.465                 |
| 32        | 5.284             | 0.615           | 0.517                       | 0.026         | 3.562                 |
| 33        | 5.298             | 0.554           | 0.367                       | 0.010         | 3.013                 |
| 34        | 3.654             | 0.783           | 0.896                       | 0.272         | 3.683                 |
| 35        | 5.319             | 0.655           | 0.356                       | 0.010         | 3.020                 |
| 36        | 5.952             | 0.392           | 0.677                       | 0.282         | 3.949                 |
| 37        | 7.481             | 0.064           | 0.642                       | 0.106         | 3.981                 |
| 38        | 5.445             | 0.695           | 0.350                       | 0.025         | 3.397                 |
| 39        | 9.349             | 0.218           | 0.759                       | 0.214         | 4.013                 |

**EK 17. USDİDR İçin XGBoost Modeli Optimizasyon Parametreleri**

| İterasyon | Maksimum Derinlik | Gamma Katsayısı | Ağaç Başına Sütun Örneklemi | Öğrenme Oranı | Ortalama Karesel Hata |
|-----------|-------------------|-----------------|-----------------------------|---------------|-----------------------|
| 0         | 5.116             | 0.720           | 0.592                       | 0.010         | 1278683.868           |
| 1         | 5.419             | 0.092           | 0.403                       | 0.064         | 454734.590            |
| 2         | 7.797             | 0.539           | 0.578                       | 0.132         | 546739.369            |
| 3         | 7.693             | 0.878           | 0.443                       | 0.018         | 920093.174            |
| 4         | 4.387             | 0.559           | 0.592                       | 0.051         | 606115.846            |
| 5         | 7.846             | 0.968           | 0.861                       | 0.101         | 795786.004            |
| 6         | 3.273             | 0.895           | 0.913                       | 0.035         | 609986.317            |
| 7         | 5.948             | 0.878           | 0.419                       | 0.039         | 572109.524            |
| 8         | 5.209             | 0.533           | 0.971                       | 0.211         | 748106.582            |
| 9         | 8.251             | 0.835           | 0.781                       | 0.015         | 1142736.117           |
| 10        | 8.353             | 0.162           | 0.305                       | 0.216         | 843221.987            |
| 11        | 8.209             | 0.413           | 0.610                       | 0.169         | 750794.787            |
| 12        | 8.633             | 0.223           | 0.736                       | 0.288         | 779364.169            |
| 13        | 7.915             | 0.808           | 0.315                       | 0.290         | 871351.678            |
| 14        | 9.801             | 0.022           | 0.555                       | 0.054         | 599600.298            |
| 15        | 3.312             | 0.325           | 0.997                       | 0.247         | 528826.374            |
| 16        | 6.126             | 0.270           | 0.987                       | 0.245         | 697314.727            |
| 17        | 8.261             | 0.636           | 0.527                       | 0.126         | 493536.967            |
| 18        | 5.211             | 0.677           | 0.514                       | 0.170         | 387715.692            |
| 19        | 5.415             | 0.194           | 0.578                       | 0.025         | 797355.063            |
| 20        | 6.345             | 0.550           | 0.307                       | 0.057         | 674998.135            |
| 21        | 8.746             | 0.485           | 0.533                       | 0.131         | 492540.607            |
| 22        | 9.644             | 0.447           | 0.464                       | 0.170         | 463469.217            |
| 23        | 4.022             | 0.551           | 0.383                       | 0.153         | 397327.502            |
| 24        | 7.491             | 0.022           | 0.484                       | 0.059         | 468520.383            |
| 25        | 3.491             | 0.400           | 0.437                       | 0.159         | 457857.943            |
| 26        | 7.536             | 0.272           | 0.427                       | 0.243         | 537428.178            |
| 27        | 6.970             | 0.508           | 0.394                       | 0.268         | 714497.383            |
| 28        | 9.124             | 0.204           | 0.406                       | 0.205         | 491806.858            |
| 29        | 4.127             | 0.164           | 0.873                       | 0.014         | 1034044.262           |
| 30        | 8.223             | 0.708           | 0.990                       | 0.179         | 717533.566            |
| 31        | 5.181             | 0.452           | 0.929                       | 0.126         | 688331.143            |
| 32        | 5.410             | 0.097           | 0.416                       | 0.037         | 554956.579            |
| 33        | 3.988             | 0.509           | 0.337                       | 0.105         | 384621.275            |
| 34        | 3.654             | 0.783           | 0.896                       | 0.272         | 486205.571            |
| 35        | 4.065             | 0.510           | 0.379                       | 0.079         | 483688.708            |
| 36        | 5.952             | 0.392           | 0.677                       | 0.282         | 648526.760            |
| 37        | 7.481             | 0.064           | 0.642                       | 0.106         | 686678.875            |
| 38        | 3.976             | 0.443           | 0.359                       | 0.161         | 352700.713            |
| 39        | 9.349             | 0.218           | 0.759                       | 0.214         | 795281.225            |

**EK 18. USDINR İçin XGBoost Modeli Optimizasyon Parametreleri**

| İterasyon | Maksimum Derinlik | Gamma Katsayısı | Ağaç Başına Sütun Örneklemi | Öğrenme Oranı | Ortalama Karesel Hata |
|-----------|-------------------|-----------------|-----------------------------|---------------|-----------------------|
| 0         | 5.116             | 0.720           | 0.592                       | 0.010         | 102.858               |
| 1         | 5.419             | 0.092           | 0.403                       | 0.064         | 75.098                |
| 2         | 7.797             | 0.539           | 0.578                       | 0.132         | 69.782                |
| 3         | 7.693             | 0.878           | 0.443                       | 0.018         | 86.748                |
| 4         | 4.387             | 0.559           | 0.592                       | 0.051         | 70.962                |
| 5         | 7.846             | 0.968           | 0.861                       | 0.101         | 67.431                |
| 6         | 3.273             | 0.895           | 0.913                       | 0.035         | 64.255                |
| 7         | 5.948             | 0.878           | 0.419                       | 0.039         | 71.675                |
| 8         | 5.209             | 0.533           | 0.971                       | 0.211         | 63.533                |
| 9         | 8.251             | 0.835           | 0.781                       | 0.015         | 87.784                |
| 10        | 8.353             | 0.162           | 0.305                       | 0.216         | 74.357                |
| 11        | 8.209             | 0.413           | 0.610                       | 0.169         | 63.745                |
| 12        | 8.633             | 0.223           | 0.736                       | 0.288         | 73.000                |
| 13        | 7.915             | 0.808           | 0.315                       | 0.290         | 67.898                |
| 14        | 9.801             | 0.022           | 0.555                       | 0.054         | 71.181                |
| 15        | 3.312             | 0.325           | 0.997                       | 0.247         | 65.890                |
| 16        | 6.126             | 0.270           | 0.987                       | 0.245         | 64.746                |
| 17        | 8.261             | 0.636           | 0.527                       | 0.126         | 69.520                |
| 18        | 5.211             | 0.677           | 0.514                       | 0.170         | 74.127                |
| 19        | 3.322             | 0.292           | 0.977                       | 0.262         | 67.607                |
| 20        | 6.345             | 0.550           | 0.307                       | 0.057         | 75.377                |
| 21        | 8.089             | 0.484           | 0.552                       | 0.169         | 68.166                |
| 22        | 9.644             | 0.447           | 0.464                       | 0.170         | 74.271                |
| 23        | 8.263             | 0.470           | 0.558                       | 0.293         | 72.229                |
| 24        | 7.491             | 0.022           | 0.484                       | 0.059         | 69.119                |
| 25        | 8.217             | 0.414           | 0.574                       | 0.025         | 78.896                |
| 26        | 8.216             | 0.405           | 0.601                       | 0.137         | 69.084                |
| 27        | 6.970             | 0.508           | 0.394                       | 0.268         | 78.647                |
| 28        | 8.146             | 0.413           | 0.680                       | 0.232         | 65.289                |
| 29        | 4.127             | 0.164           | 0.873                       | 0.014         | 86.340                |
| 30        | 5.227             | 0.540           | 0.974                       | 0.204         | 63.806                |
| 31        | 5.262             | 0.437           | 1.000                       | 0.300         | 62.181                |
| 32        | 5.269             | 0.455           | 0.875                       | 0.226         | 66.317                |
| 33        | 5.202             | 0.374           | 1.000                       | 0.175         | 64.743                |
| 34        | 3.654             | 0.783           | 0.896                       | 0.272         | 67.695                |
| 35        | 5.393             | 0.384           | 1.000                       | 0.218         | 62.884                |
| 36        | 9.810             | 0.010           | 0.560                       | 0.070         | 71.595                |
| 37        | 7.481             | 0.064           | 0.642                       | 0.106         | 70.880                |
| 38        | 5.424             | 0.530           | 1.000                       | 0.300         | 62.871                |
| 39        | 9.349             | 0.218           | 0.759                       | 0.214         | 66.264                |

**EK 19. USDZAR İin XGBoost Modeli Optimizasyon Parametreleri**

| İterasyon | Maksimum Derinlik | Gamma Katsayısı | Ağaç Başına Sütun Örneklemi | Öğrenme Oranı | Ortalama Karesel Hata |
|-----------|-------------------|-----------------|-----------------------------|---------------|-----------------------|
| 0         | 5.116             | 0.720           | 0.592                       | 0.001         | 13.139                |
| 1         | 5.419             | 0.092           | 0.403                       | 0.019         | 10.578                |
| 2         | 7.797             | 0.539           | 0.578                       | 0.043         | 7.956                 |
| 3         | 7.693             | 0.878           | 0.443                       | 0.004         | 12.481                |
| 4         | 4.387             | 0.559           | 0.592                       | 0.015         | 8.635                 |
| 5         | 7.846             | 0.968           | 0.861                       | 0.032         | 5.608                 |
| 6         | 3.273             | 0.895           | 0.913                       | 0.009         | 7.791                 |
| 7         | 5.948             | 0.878           | 0.419                       | 0.011         | 11.137                |
| 8         | 5.209             | 0.533           | 0.971                       | 0.069         | 4.637                 |
| 9         | 8.251             | 0.835           | 0.781                       | 0.003         | 11.222                |
| 10        | 8.353             | 0.162           | 0.305                       | 0.071         | 10.196                |
| 11        | 8.209             | 0.413           | 0.610                       | 0.055         | 7.624                 |
| 12        | 8.633             | 0.223           | 0.736                       | 0.096         | 5.880                 |
| 13        | 7.915             | 0.808           | 0.315                       | 0.097         | 9.784                 |
| 14        | 5.188             | 0.571           | 0.953                       | 0.094         | 4.566                 |
| 15        | 5.066             | 0.493           | 1.000                       | 0.100         | 4.703                 |
| 16        | 5.136             | 0.312           | 0.930                       | 0.095         | 4.616                 |
| 17        | 8.261             | 0.636           | 0.527                       | 0.041         | 8.237                 |
| 18        | 4.884             | 0.184           | 0.963                       | 0.079         | 4.327                 |
| 19        | 5.063             | 0.075           | 0.986                       | 0.032         | 5.252                 |
| 20        | 6.345             | 0.550           | 0.307                       | 0.017         | 10.754                |
| 21        | 4.544             | 0.009           | 0.991                       | 0.023         | 5.366                 |
| 22        | 9.644             | 0.447           | 0.464                       | 0.055         | 8.179                 |
| 23        | 4.727             | 0.074           | 0.685                       | 0.055         | 6.375                 |
| 24        | 7.562             | 1.000           | 1.000                       | 0.100         | 4.553                 |
| 25        | 7.637             | 0.656           | 1.000                       | 0.100         | 4.611                 |
| 26        | 8.625             | 0.226           | 0.711                       | 0.066         | 6.795                 |
| 27        | 8.822             | 0.124           | 1.000                       | 0.100         | 4.608                 |
| 28        | 8.849             | 0.460           | 1.000                       | 0.100         | 4.510                 |
| 29        | 4.127             | 0.164           | 0.873                       | 0.002         | 11.081                |
| 30        | 8.508             | 0.240           | 1.000                       | 0.100         | 4.567                 |
| 31        | 8.516             | 0.255           | 0.997                       | 0.079         | 4.602                 |
| 32        | 7.621             | 0.140           | 1.000                       | 0.100         | 4.423                 |
| 33        | 7.236             | 0.338           | 1.000                       | 0.100         | 4.816                 |
| 34        | 7.324             | 0.000           | 0.717                       | 0.001         | 13.033                |
| 35        | 7.115             | 0.761           | 0.968                       | 0.019         | 5.521                 |
| 36        | 5.952             | 0.392           | 0.677                       | 0.094         | 6.424                 |
| 37        | 7.481             | 0.064           | 0.642                       | 0.034         | 7.415                 |
| 38        | 7.842             | 0.106           | 0.777                       | 0.100         | 6.709                 |
| 39        | 9.349             | 0.218           | 0.759                       | 0.071         | 6.009                 |

**EK 20. USDTRY İin XGBoost Modeli Optimizasyon Parametreleri**

| İterasyon | Maksimum Derinlik | Gamma Katsayısı | Ağaç Başına Sütun Örnekleme | Öğrenme Oranı | Ortalama Karesel Hata |
|-----------|-------------------|-----------------|-----------------------------|---------------|-----------------------|
| 0         | 5.116             | 0.720           | 0.592                       | 0.010         | 231.489               |
| 1         | 5.419             | 0.092           | 0.403                       | 0.064         | 224.138               |
| 2         | 7.797             | 0.539           | 0.578                       | 0.132         | 222.437               |
| 3         | 7.693             | 0.878           | 0.443                       | 0.018         | 227.971               |
| 4         | 4.387             | 0.559           | 0.592                       | 0.051         | 225.992               |
| 5         | 7.846             | 0.968           | 0.861                       | 0.101         | 230.644               |
| 6         | 3.273             | 0.895           | 0.913                       | 0.035         | 227.172               |
| 7         | 5.948             | 0.878           | 0.419                       | 0.039         | 224.516               |
| 8         | 5.209             | 0.533           | 0.971                       | 0.211         | 230.610               |
| 9         | 8.251             | 0.835           | 0.781                       | 0.015         | 234.223               |
| 10        | 7.721             | 0.392           | 0.515                       | 0.167         | 224.744               |
| 11        | 8.209             | 0.413           | 0.610                       | 0.169         | 224.999               |
| 12        | 7.909             | 0.461           | 0.671                       | 0.300         | 230.586               |
| 13        | 7.915             | 0.808           | 0.315                       | 0.290         | 237.069               |
| 14        | 5.922             | 0.918           | 0.433                       | 0.042         | 224.180               |
| 15        | 7.696             | 0.523           | 0.582                       | 0.010         | 233.317               |
| 16        | 7.793             | 0.490           | 0.530                       | 0.182         | 222.049               |
| 17        | 8.261             | 0.636           | 0.527                       | 0.126         | 228.185               |
| 18        | 7.888             | 0.517           | 0.512                       | 0.128         | 226.532               |
| 19        | 7.771             | 0.542           | 0.611                       | 0.257         | 224.359               |
| 20        | 6.345             | 0.550           | 0.307                       | 0.057         | 223.619               |
| 21        | 7.755             | 0.639           | 0.488                       | 0.206         | 233.846               |
| 22        | 9.644             | 0.447           | 0.464                       | 0.170         | 231.404               |
| 23        | 7.738             | 0.488           | 0.649                       | 0.155         | 225.710               |
| 24        | 7.491             | 0.022           | 0.484                       | 0.059         | 223.671               |
| 25        | 6.259             | 0.623           | 0.331                       | 0.053         | 223.382               |
| 26        | 8.216             | 0.405           | 0.601                       | 0.137         | 226.310               |
| 27        | 6.970             | 0.508           | 0.394                       | 0.268         | 242.385               |
| 28        | 6.192             | 0.476           | 0.302                       | 0.027         | 222.714               |
| 29        | 4.127             | 0.164           | 0.873                       | 0.014         | 236.973               |
| 30        | 7.899             | 0.509           | 0.527                       | 0.126         | 229.236               |
| 31        | 5.181             | 0.452           | 0.929                       | 0.126         | 232.375               |
| 32        | 6.251             | 0.513           | 0.379                       | 0.071         | 224.417               |
| 33        | 6.169             | 0.558           | 0.300                       | 0.107         | 223.687               |
| 34        | 3.654             | 0.783           | 0.896                       | 0.272         | 227.305               |
| 35        | 7.818             | 0.492           | 0.458                       | 0.092         | 229.458               |
| 36        | 5.952             | 0.392           | 0.677                       | 0.282         | 227.143               |
| 37        | 7.481             | 0.064           | 0.642                       | 0.106         | 225.316               |
| 38        | 7.758             | 0.432           | 0.576                       | 0.262         | 232.606               |
| 39        | 9.349             | 0.218           | 0.759                       | 0.214         | 227.058               |

## TEZ DEĞERLENDİRME FORMU

|                                                                                                                                     |                                                                                                                                       |             |
|-------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------|-------------|
| <b>Öğrencinin Adı Soyadı:</b> Muhammed Raşid BAKIR                                                                                  |                                                                                                                                       | <b>EVET</b> |
| <b>Kapak</b>                                                                                                                        |                                                                                                                                       |             |
| 1                                                                                                                                   | Tez Başlığı tutanaktaki başlıkla aynı mı?                                                                                             |             |
| 2                                                                                                                                   | Kapaktaki ay ve yıl savunmaya girilen tarihle tutarlı mı?                                                                             |             |
| 3                                                                                                                                   | Kapak format kılavuzdaki kapak formatına uygun mu?                                                                                    |             |
| 4                                                                                                                                   | Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?                                                                                 |             |
| <b>İçindekiler</b>                                                                                                                  |                                                                                                                                       |             |
| 5                                                                                                                                   | Sayfa numaraları tam verilmiş mi?                                                                                                     |             |
| 6                                                                                                                                   | Şekil, Çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?                                                                        |             |
| 7                                                                                                                                   | Özet, Abstract, Giriş, Sonuçlar vb. bölümler var mı?                                                                                  |             |
| 8                                                                                                                                   | Yazım hataları kontrolü yapıldı mı?                                                                                                   |             |
| <b>Giriş</b>                                                                                                                        |                                                                                                                                       |             |
| 9                                                                                                                                   | Hazırlanan tezin önemini anlatıyor mu?                                                                                                |             |
| 10                                                                                                                                  | İkinci ve Üçüncü dereceden başlık içermemeli kuralına uyuldu mu?                                                                      |             |
| <b>Özet/Abstract</b>                                                                                                                |                                                                                                                                       |             |
| 11                                                                                                                                  | Kılavuza uygun mu?                                                                                                                    |             |
| 12                                                                                                                                  | Ay ve yıl savunmaya girilen tarihle tutarlı mı?                                                                                       |             |
| 13                                                                                                                                  | Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?                                                           |             |
| 14                                                                                                                                  | Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?                                                               |             |
| <b>Kaynakça</b>                                                                                                                     |                                                                                                                                       |             |
| 15                                                                                                                                  | Kaynakların tamamına metin içinde atıf yapıldı mı?                                                                                    |             |
| 16                                                                                                                                  | Kaynak formatı kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?                                                              |             |
| 17                                                                                                                                  | Atıf formatı kılavuzdaki atıf formatına uygun mu?                                                                                     |             |
| <b>Atıf Yöntemi</b> <b>APA 7</b> <input type="checkbox"/> <b>CMS</b> <input type="checkbox"/> <b>İSNAD</b> <input type="checkbox"/> |                                                                                                                                       |             |
| <b>Genel Değerlendirme</b>                                                                                                          |                                                                                                                                       |             |
| 18                                                                                                                                  | Etik Beyan açıklaması okundu, uyuldu ve imzalandı mı?                                                                                 |             |
| 19                                                                                                                                  | Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?                                                                   |             |
| 20                                                                                                                                  | Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi? |             |
| 21                                                                                                                                  | Sayfa kenar boşlukları ve sayfa numaraları kılavuzdaki formatına uygun mu?                                                            |             |
| 22                                                                                                                                  | Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?                                              |             |
| 23                                                                                                                                  | Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?                                                                            |             |
| 24                                                                                                                                  | Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?                                                               |             |
| 25                                                                                                                                  | Şekil, Çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış mı?                                       |             |

**Danışman Adı Soyadı**

**İmza**