



**KRİPTO PARA FİYATLARININ  
TAHMINİNDE MAKİNE ÖĞRENMESİ  
MODELLERİNİN KARŞILAŞTIRMALI  
ANALİZİ VE ÇKKV TEKNİKLERİ İLE EN  
İYİ YÖNTEMİN BELİRLENMESİ**

**Doktora Tezi**

**Yunus Emre KORKMAZ**

**Eskişehir 2025**

**KRİPTO PARA FİYATLARININ TAHMİNİNDE MAKİNE ÖĞRENMESİ  
MODELLERİNİN KARŞILAŞTIRMALI ANALİZİ VE ÇKKV TEKNİKLERİ  
İLE EN İYİ YÖNTEMİN BELİRLENMESİ**

**Yunus Emre KORKMAZ**

**DOKTORA TEZİ**

**İşletme Ana Bilim Dalı**

**Finansman Programı**

**Danışman: Prof. Dr. Serpil ALTINIRMAK**

**Anadolu Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Aralık 2025**

**Eskişehir**

## JÜRİ VE ENSTİTÜ ONAYI

Yunus Emre KORKMAZ'ın "Kripto Para Fiyatlarının Tahmininde Makine Öğrenmesi Modellerinin Karşılaştırmalı Analizi ve ÇKKV Teknikleri ile En İyi Yöntemin Belirlenmesi" başlıklı tezi 27/11/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Anadolu Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri uyarınca, İşletme Ana Bilim Dalı Finansman Programında Doktora tezi olarak kabul edilmiştir.

|                  | <u>Ünvanı Adı Soyadı</u>    | <u>İmza</u> |
|------------------|-----------------------------|-------------|
| Üye (Danışman) : | Prof. Dr. Serpil ALTINIRMAK | .....       |
| Üye :            | Prof. Dr. Ash AFŞAR         | .....       |
| Üye :            | Prof. Dr. Nurullah UÇKUN    | .....       |
| Üye :            | Doç. Dr. İlkay BADURLAR     | .....       |
| Üye :            | Dr. Öğr. Üy. Behlül ERSOY   | .....       |

Prof. Dr. Nafiz Öncü CAN  
Anadolu Üniversitesi  
Lisansüstü Eğitim Enstitüsü Müdürü

## ÖZET

### KRİPTO PARA FİYATLARININ TAHMİNİNDE MAKİNE ÖĞRENMESİ MODELLERİNİN KARŞILAŞTIRMALI ANALİZİ VE ÇKKV TEKNİKLERİ İLE EN İYİ YÖNTEMİN BELİRLENMESİ

Yunus Emre KORKMAZ

İşletme Ana Bilim Dalı

Finansman Programı

Anadolu Üniversitesi, Lisansüstü Eğitim Enstitüsü, Aralık 2025

Danışman: Prof. Dr. Serpil ALTINIRMAK

Kripto para birimleri son yıllarda büyük bir ilgi odağı haline gelmiştir ve birçok kişi tarafından yatırım fırsatı olarak görülmektedir. Ancak, kripto para piyasası oldukça volatil bir yapıya sahip olduğundan, fiyat tahminleri yapmak zorlu bir görev haline almıştır. Bu kapsamda bu tezin amacı; kripto para birimlerinin fiyat tahmini için farklı makine öğrenmesi modellerini karşılaştırmak ve Çok Kriterli Karar Verme (ÇKKV) teknikleri aracılığıyla en etkili yöntemi belirlemektir. Çalışmada, kripto paralara ait geçmiş fiyat hareketleri, teknik analiz göstergeleri, makroekonomik değişkenler ve yatırımcı duyarlılığına ilişkin göstergeler bir arada değerlendirilmiş ve 2018–2023 dönemine ait günlük veriler kullanılarak SVM, LSTM, RF ve XGBoost algoritmalarıyla tahmin modelleri geliştirilmiştir. Modellerin performansları  $R^2$ , MAE, MSE ve RMSE gibi istatistiksel hata metrikleriyle ölçülmüştür. Ayrıca değişkenlerin önem düzeyleri, SVM ve LSTM için permütasyon önem analizi ile, RF ve XGBoost'un ise gömülü önem hesaplama yöntemleri ile analiz edilmiştir. Son aşamada, en iyi yöntemi ÇKKV teknikleriyle belirlemek amacıyla; CRITIC yöntemi ile kriter ağırlıkları belirlenerek TOPSIS, ARAS ve CODAS yöntemleriyle sıralamalar yapılmış ve genel sıralama Copeland yöntemi ile elde edilmiştir. Sonuçlara göre dört yöntemde kripto para fiyatlarını tahmin etmede başarılı olmuştur. Copeland yöntemine göre en yüksek genel başarıyı XGBoost algoritmasının sağladığı görülmektedir. LSTM algoritması ikinci sırada yer alırken, RF üçüncü ve SVM dördüncü sırada yer almıştır.

**Anahtar Sözcükler:** Kripto para, Fiyat tahmini, Makine öğrenmesi, ÇKKV.

## ABSTRACT

### COMPARATIVE ANALYSIS OF MACHINE LEARNING MODELS FOR CRYPTOCURRENCY PRICE PREDICTION AND SELECTION OF THE OPTIMAL METHOD USING MCDM TECHNIQUES

Yunus Emre KORKMAZ

Department of Business Administration

Programme in Finance

Graduate School of Anadolu University, December 2025

Supervisor: Prof. Dr. Serpil ALTINIRMAK

In recent years, cryptocurrencies have become a major focus of attention and are widely regarded as investment opportunities. However, due to the highly volatile nature of the cryptocurrency market, price prediction has become a challenging task. In this context, the aim of this thesis is to compare different machine learning models for predicting cryptocurrency prices and to identify the most effective method using Multi-Criteria Decision Making (MCDM) techniques. The study integrates historical price movements of cryptocurrencies, technical indicators, macroeconomic variables, and investor sentiment indicators. Prediction models were developed using SVM, LSTM, RF, and XGBoost algorithms, based on daily data from the period 2018–2023. The performance of the models was evaluated using statistical error metrics such as  $R^2$ , MAE, MSE, and RMSE. In addition, the importance of variables was analyzed using permutation importance for SVM and LSTM, and embedded feature importance methods for RF and XGBoost. In the final stage, in order to determine the best method via MCDM techniques, the CRITIC method was used to assign weights to the criteria, and the TOPSIS, ARAS, and CODAS methods were employed for ranking. The overall ranking was obtained through the Copeland method. According to the results, all four methods performed successfully in predicting cryptocurrency prices. Among them, the XGBoost algorithm demonstrated the highest overall performance based on the Copeland method, followed by LSTM in second place, RF in third, and SVM in fourth.

**Keywords:** Cryptocurrency, Price prediction, Machine learning, MCDM.

## TEŞEKKÜR

Bu tez çalışmasının her aşamasında bilgi, rehberlik ve desteğini esirgemeyen, akademik birikimiyle bana yol gösteren değerli danışmanım saygıdeğer hocam Sayın Prof. Dr. Serpil ALTINIRMAK'a en içten teşekkürlerimi sunarım. Kendisinin katkıları ve yönlendirmeleri, tezimin bilimsel niteliğinin gelişmesinde büyük rol oynamıştır.

Tez İzleme Komitesi üyeleri hocalarım Sayın Doç. Dr. İlkey BADURLAR ve Sayın Prof. Dr. Aslı AFŞAR'a, yapıcı değerlendirme ve kıymetli katkıları için şükranlarımı sunarım. Görüş ve önerileri, çalışmamın daha sağlam bir temele oturmasına büyük katkı sağlamıştır.

Ayrıca, çalışmamda kullandığım Çok Kriterli Karar Verme (ÇKKV) teknikleri konusunda bilgi ve desteğini paylaşan hocam Sayın Doç. Dr. Çağlar KARAMAŞA'ya değerli katkılarından dolayı teşekkür ederim.

Hayatım boyunca yanımda olan, sevgisi ve desteğiyle beni her zaman güçlü kılan aileme sonsuz teşekkür ederim. Özellikle bu zorlu süreçte sabrıyla, sevgisiyle ve anlayışıyla yanımda olan canım eşim Büşra KORKMAZ'a minnettarım. Varlığı, bu yolculukta bana güç ve ilham kaynağı olmuştur.

Yunus Emre KORKMAZ

## **ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ**

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Anadolu Üniversitesi tarafından kullanılan “Bilimsel İntihal Tespit Programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Yunus Emre KORKMAZ

## **ÜRETKEN YAPAY ZEKÂ KULLANIM BEYANI**

Bu tezi hazırlarken (örneğin ChatGPT, Gemini, DALL-E vb.) üretken yapay zekâ programlarından destek aldığımı/almadığımı beyan ederim. Tezin hazırlığı aşamasında üretken yapay zekâ programlarından (örneğin çeviri, bilimsel makale vb.) desteği aldım. Üretken yapay zekâ programlarından aldığım bilgilerin doğruluğunu kontrol ettiğimi bildiririm. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Yunus Emre KORKMAZ

## İÇİNDEKİLER

|                                                              | <u>Sayfa</u> |
|--------------------------------------------------------------|--------------|
| BAŞLIK SAYFASI.....                                          | i            |
| JÜRİ VE ENSTİTÜ ONAYI .....                                  | ii           |
| ÖZET .....                                                   | iii          |
| ABSTRACT.....                                                | iv           |
| TEŞEKKÜR .....                                               | v            |
| ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ .....            | vi           |
| ÜRETKEN YAPAY ZEKÂ KULLANIM BEYANI .....                     | vii          |
| İÇİNDEKİLER.....                                             | viii         |
| TABLolar DİZİNİ .....                                        | xi           |
| ŞEKİLLER DİZİNİ.....                                         | xii          |
| SİMGELER VE KISALTMALAR DİZİNİ .....                         | xiii         |
| 1 GİRİŞ .....                                                | 1            |
| 2 KRİPTO PARA PİYASALARININ TARİHÇESİ VE GELİŞİMİ.....       | 3            |
| 2.1 Kriptoloji, Kriptografi ve Kriptanaliz Nedir?.....       | 4            |
| 2.2 Blok Zinciri (Blockchain) Teknolojisi.....               | 5            |
| 2.2.1 Blok zinciri teknolojisinin çalışma prensibi .....     | 7            |
| 2.2.2 Blok zinciri teknolojisinin avantajları .....          | 7            |
| 2.2.3 Blok zinciri teknolojisinin dezavantajları .....       | 8            |
| 2.3 Kripto Paraların Evrimi ve Modern Ekonomiye Etkisi.....  | 9            |
| 2.3.1 Kripto paranın tanımı ve tarihçesi .....               | 9            |
| 2.3.2 Kripto paranın özellikleri .....                       | 11           |
| 2.3.3 Kripto Para çeşitleri .....                            | 12           |
| 2.3.3.1 Bitcoin (BTC) .....                                  | 12           |
| 2.3.3.2 Ethereum (ETH) .....                                 | 15           |
| 2.3.3.3 Binance (BNB).....                                   | 17           |
| 2.3.3.4 Ripple (XRP) .....                                   | 18           |
| 2.3.3.5 Dogecoin (DOGE) .....                                | 19           |
| 2.3.4 Kripto paraların kullanım alanları.....                | 21           |
| 2.3.5 Kripto paraların avantajları ve dezavantajları.....    | 23           |
| 2.3.5.1 Kripto paraların avantajları.....                    | 23           |
| 2.3.5.2 Kripto paraların avantajları ve dezavantajları ..... | 24           |

|                                                                      |           |
|----------------------------------------------------------------------|-----------|
| 2.3.6 Kripto para borsaları .....                                    | 24        |
| 2.3.6.1 Merkezi borsalar (CEX).....                                  | 25        |
| 2.3.6.2. Merkeziyetsiz borsalar (DEX) .....                          | 26        |
| 2.3.7 Kripto paralara ülkelerin yaklaşımları ve düzenlemeleri .....  | 27        |
| 2.3.7.1 Dünyada kripto paralara yaklaşımlar ve düzenlemeler.....     | 27        |
| 2.3.7.2 Türkiye’de kripto paralara yaklaşımlar ve düzenlemeler ..... | 28        |
| <b>3 TAHMİN MODELİNDE KULLANILAN MAKROEKONOMİK,</b>                  |           |
| <b>DUYARLILIK VE TEKNİK GÖSTERGELER.....</b>                         | <b>30</b> |
| <b>3.1 Makroekonomik Göstergeler .....</b>                           | <b>30</b> |
| 3.1.1 Spot altın fiyatı (XAU) .....                                  | 31        |
| 3.1.2 Ham petrol vadeli işlem fiyatı (WTI).....                      | 31        |
| 3.1.3 Faiz oranları (ABD FED).....                                   | 32        |
| 3.1.4 Enflasyon (ABD tüketici fiyat endeksi (CPI)).....              | 32        |
| 3.1.5 ABD dolar endeksi (DXY).....                                   | 32        |
| 3.1.6 Ekonomi politikası belirsizliği (EPU) .....                    | 33        |
| <b>3.2 Yatırımcı Duyarlılığı Göstergeleri .....</b>                  | <b>34</b> |
| 3.2.1 Hisse senedi belirsizliği (VIX).....                           | 34        |
| 3.2.2 Petrol piyasası belirsizliği (OVX).....                        | 34        |
| 3.2.3 Bitcoin korku ve açgözlülük endeksi .....                      | 35        |
| 3.2.4 Google arama eğilimleri.....                                   | 36        |
| <b>3.3 Teknik Analiz Göstergeleri .....</b>                          | <b>36</b> |
| 3.3.1 Göreceli güç göstergesi (RSI) .....                            | 37        |
| 3.3.2 Hareketli ortalama yakınsama/uzaklaşma (MACD) .....            | 37        |
| 3.3.3 Stokastik Osilatör .....                                       | 38        |
| 3.3.4 İlerleme-düşüş çizgisi (ADX).....                              | 38        |
| 3.3.5 Fiyat değişim oranı (ROC) .....                                | 39        |
| 3.3.6 Denge hacmi (OBV).....                                         | 39        |
| 3.3.7 Hareketli ortalamalar.....                                     | 40        |
| 3.3.8 Williams birikim ve dağılımı (WAD) .....                       | 40        |
| <b>4 LİTERATÜR TARAMASI.....</b>                                     | <b>41</b> |
| 4.1 Ulusal Çalışmalar .....                                          | 41        |
| 4.1 Uluslararası Çalışmalar .....                                    | 43        |
| <b>5 VERİ SETİ VE METODOLOJİ .....</b>                               | <b>52</b> |

|                                                                             |     |
|-----------------------------------------------------------------------------|-----|
| 5.1 Araştırmanın Problemi .....                                             | 52  |
| 5.2 Araştırmanın Amacı.....                                                 | 53  |
| 5.3 Araştırmanın Evreni, Örneklemi ve Sınırlılıkları.....                   | 54  |
| 5.4 Araştırmanın Yöntemi .....                                              | 56  |
| 5.4.1 Verilerin toplanması .....                                            | 57  |
| 5.4.2. Veri ön işleme .....                                                 | 57  |
| 5.4.3 Veri ölçeklendirme.....                                               | 58  |
| 5.4.4 Model seçimi ve eğitimi .....                                         | 58  |
| 5.4.4.1 Destek Vektör Makineleri.....                                       | 59  |
| 5.4.4.2. Rastgele Ormanlar.....                                             | 61  |
| 5.4.4.3 Aşırı Gradyan Artırma .....                                         | 62  |
| 5.4.4.4 Uzun Kısa Süreli Bellek.....                                        | 62  |
| 5.4.5 İstatistiki performans göstergeleri.....                              | 63  |
| 5.4.6 Değişkenlerin önem analizi.....                                       | 65  |
| 5.4.7 Çok kriterli karar verme yöntemleriyle en iyi yöntemin seçilmesi..... | 65  |
| 6 BULGULAR VE DEĞERLENDİRME .....                                           | 67  |
| 6.1 Araştırmanın Bulguları .....                                            | 67  |
| 6.1.1 Destek vektör makinesi yöntemi ile kripto para fiyat tahmini.....     | 68  |
| 6.1.2 Rastgele ormanlar yöntemi ile kripto para fiyat tahmini.....          | 74  |
| 6.1.3 Aşırı gradyan artırma yöntemi ile kripto para fiyat tahmini.....      | 79  |
| 6.1.4 Uzun kısa süreli bellek yöntemi ile kripto para fiyat tahmini.....    | 84  |
| 6.1.5 ML Yöntemlerinin Hata Metriklerine Göre Karşılaştırılması.....        | 89  |
| 6.2 ML Yöntemlerinin ÇKKV Tekniklerine Göre Değerlendirilmesi .....         | 90  |
| 6.2.1 İstatistiki performans metriklerinin ağırlıklarının hesaplanması..... | 90  |
| 6.2.2 İstatistiki performans metriklerimim çkkv ile sıralanması.....        | 91  |
| 6.2.3 Duyarlılık Analizi.....                                               | 94  |
| 7 SONUÇ VE ÖNERİLER.....                                                    | 97  |
| 7.1 Sonuç .....                                                             | 97  |
| 7.2 Öneriler .....                                                          | 100 |
| KAYNAKÇA .....                                                              | 102 |

## TABLÖLER DİZİNİ

### Sayfa

|                                                                                                                        |    |
|------------------------------------------------------------------------------------------------------------------------|----|
| <b>Tablo 5.1</b> Araştırmada Kullanılan Değişkenler ve Literatürdeki Kaynaklar.....                                    | 54 |
| <b>Tablo 5.2</b> Kullanılan Yöntemler ve Literatürdeki Referanslar .....                                               | 59 |
| <b>Tablo 5.3</b> Performans Metrikleri ve Literatürdeki Kaynaklar .....                                                | 64 |
| <b>Tablo 6.1</b> SVM Modeli için Yapılan Hiperparametre Optimizasyonu Sonuçları.....                                   | 68 |
| <b>Tablo 6.2</b> SVM Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi.....                             | 69 |
| <b>Tablo 6.3</b> Destek Vektör Makinesi Yöntemi İçin Değişkenlerin Önem Düzeyi .....                                   | 73 |
| <b>Tablo 6.4</b> RF Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi .....                             | 74 |
| <b>Tablo 6.5</b> Rastgele Orman Yöntemi İçin Değişkenlerin Önem Düzeyi .....                                           | 78 |
| <b>Tablo 6.6</b> XGBoost Yöntemi ile Kripto Para Fiyat Tahmini Performans<br>Değerlendirmesi .....                     | 79 |
| <b>Tablo 6.7</b> XGBoost Yöntemi İçin Değişkenlerin Önem Düzeyi .....                                                  | 83 |
| <b>Tablo 6.8</b> LSTM Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi .....                           | 84 |
| <b>Tablo 6.9</b> LSTM Yöntemi İçin Değişkenlerin Önem Düzeyi .....                                                     | 88 |
| <b>Tablo 6.10</b> ML Yöntemlerinin Hata Metriklerine Göre Sıralaması .....                                             | 89 |
| <b>Tablo 6.11</b> Performans Metriklerinin CRITIC Yöntemi ile Ağırlıklarının<br>Hesaplanması .....                     | 91 |
| <b>Tablo 6.12</b> ÇKVV Teknikleri ile ML Yöntemlerinin İstatistikî Performans<br>Göstergelerine Göre Sıralanması ..... | 92 |
| <b>Tablo 6.13</b> Copeland İkili Karşılaştırma Matrisi.....                                                            | 93 |
| <b>Tablo 6.14</b> Galibiyet, Yenilgi ve Copeland Puanları ile Genel Sıra .....                                         | 93 |

## ŞEKİLLER DİZİNİ

|                                                                                                            | <b>Sayfa</b> |
|------------------------------------------------------------------------------------------------------------|--------------|
| <b>Şekil 2.1</b> Blok Zinciri Teknolojisinin Çalışma Prensibi .....                                        | 7            |
| <b>Şekil 2.2</b> Dijital Para ve Kripto Paranın Karşılaştırılması.....                                     | 13           |
| <b>Şekil 2.3</b> BTC/USD Tarihsel Fiyat Grafiği.....                                                       | 15           |
| <b>Şekil 2.4</b> Bitcoin'in Yıllara Göre Piyasa Değeri .....                                               | 15           |
| <b>Şekil 2.5</b> ETH/USD Tarihsel Fiyat Grafiği.....                                                       | 17           |
| <b>Şekil 2.6</b> BNB/USD Tarihsel Fiyat Grafiği .....                                                      | 18           |
| <b>Şekil 2.7</b> XRP/USD Tarihsel Fiyat Grafiği.....                                                       | 19           |
| <b>Şekil 2.8</b> DOGE/USD Tarihsel Fiyat Grafiği .....                                                     | 21           |
| <b>Şekil 5.1</b> Kripto Para Fiyat Tahmin Yöntemleri ve Süreçleri .....                                    | 56           |
| <b>Şekil 5.2</b> SVM için 2 Özellikli Hiper Düzlem Örneği.....                                             | 60           |
| <b>Şekil 5.3</b> Random Forest Modelinin Kavramsal Yapısı.....                                             | 61           |
| <b>Şekil 5.4</b> LSTM Yapısı .....                                                                         | 63           |
| <b>Şekil 6.1</b> SVM Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması.....                | 69           |
| <b>Şekil 6.2</b> SVM Yöntemi İçin Değişkenlerin Önem Düzeylerinin Grafiği.....                             | 72           |
| <b>Şekil 6.3</b> Rastgele Ormanlar Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması ..... | 75           |
| <b>Şekil 6.4</b> RF Yöntemi İçin Değişkenlerin Önem Düzeylerinin Grafiği .....                             | 77           |
| <b>Şekil 6.5</b> XGboost ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması .....                   | 80           |
| <b>Şekil 6.6</b> Aşırı Gradyan Artırma Yöntemi İçin Değişkenlerin Önem Düzeyi .....                        | 82           |
| <b>Şekil 6.7</b> LSTM Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması ...                | 85           |
| <b>Şekil 6.8</b> LSTM Yöntemi İçin Değişkenlerin Önem Düzeyi .....                                         | 87           |
| <b>Şekil 6.9</b> ÇKKV Tekniklerine Göre Yöntemlerin Sıralanması.....                                       | 92           |
| <b>Şekil 6.10</b> Oluşturulan Senaryolara Göre Kriter Ağırlıklarında Gözlenen Değişimler ..                | 94           |
| <b>Şekil 6.11</b> Oluşturulan Senaryolara Göre ML Yöntemlerinin Sıralanması (CRITIC-TOPSIS).....           | 95           |
| <b>Şekil 6.12</b> Oluşturulan Senaryolara Göre ML Yöntemlerinin Sıralanması (CRITIC-ARAS) .....            | 95           |
| <b>Şekil 6.13</b> Oluşturulan Senaryolara Göre ML Yöntemlerinin Sıralanması (CRITIC-CODAS).....            | 96           |

## SİMGELER VE KISALTMALAR DİZİNİ

|         |                                                               |
|---------|---------------------------------------------------------------|
| AML     | : Kara Para Aklama                                            |
| ARAS    | : Eklemeli Nispi Değerlendirme                                |
| BNB     | : Binance                                                     |
| BTC     | : Bitcoin                                                     |
| Cex     | : Merkezi Borsalar                                            |
| ÇKKV    | : Çok Kriterli Karar Verme                                    |
| CODAS   | Birleştirilebilir Uzaklık Tabanlı Değerlendirme               |
| CRITIC  | : Kriterler Arası Korelasyon Yoluyla Kriterlerin Önem Tespiti |
| DeFi    | : Merkeziyetsiz Finans                                        |
| Dex     | : Merkeziyetsiz Borsalar                                      |
| DOGE    | : Dogecoin                                                    |
| ETH     | : Ethereum                                                    |
| FGI     | : Korku Ve Açgözlülük Endeksi                                 |
| FOMO    | : Aşırı Açgözlü Davranarak Fırsatı Kaçırma Korkusu            |
| KYC     | : Müşteri Tanıma Yükümlülükleri                               |
| LSTM    | : Uzun Kısa Süreli Bellek                                     |
| MAE     | : Mutlak Ortalama Hata                                        |
| ML      | : Makine Öğrenmesi                                            |
| MSE     | : Ortalama Kare Hatası                                        |
| NFT     | : Değiştirilemez Tokenler, Dijital Koleksiyon Ürünleri        |
| RF      | : Rastgele Orman                                              |
| RMSE    | : Kök Ortalama Kare Hatası                                    |
| $R^2$   | : Belirleme Katsayısı                                         |
| XGBosst | : Aşırı Gradyan Artırma                                       |
| XRP     | : Ripple                                                      |
| TOPSIS  | : İdeal Çözüme Benzerliğe Göre Sıralama                       |

## 1 GİRİŞ

Kripto para kavramı, ilk olarak Satoshi Nakamoto'nun 2008 yılında yayımladığı teknik raporla ortaya çıkmış ve Bitcoin'in 2009'da hayata geçmesiyle finans dünyasında yeni bir dönemi başlatmıştır (Nakamoto, 2008). Bitcoin'in başarısı ile Ethereum, Litecoin gibi pek çok alternatif kripto para birimi ortaya çıkmıştır. Günümüzde binlerce farklı kripto para aktif olarak işlem görmektedir. Kripto paralar başlangıçta dar bir kitleye hitap ederken, özellikle son yıllarda hem bireysel yatırımcılar hem de kurumsal aktörler tarafından benimsenmeye başlanmış ve hızla büyüyen bir piyasa haline gelmiştir (Lee ve Wang, 2024). Nitekim toplam kripto para piyasa değeri 2025 yılı itibarıyla 3.9 trilyon ABD dolarını aşarak küresel finans sistemi içindeki etkisini pekiştirmiştir. Kripto para piyasalarının bu denli büyümesi ve geleneksel finansal sistemde oynadığı rolün artması, onları akademik araştırmalar ve yatırım stratejileri açısından son derece önemli bir konu haline getirmiştir. Özellikle kripto varlık fiyatlarının öngörülebilmesi, portföy yönetimi ve riskten korunma gibi konularda kritik bir karar destek unsuru olarak görülmektedir (Bouteska vd., 2024).

Kripto para fiyatlarındaki yüksek volatilité, bu piyasanın en belirgin özelliklerinden biridir. Örneğin, Bitcoin fiyatı 1 Ocak 2025'te yaklaşık 94 bin ABD doları seviyesindeyken, ocak ayında 104 bin ABD dolarını aşmış, ancak Şubat 2025'te 84 bin ABD doları seviyelerine kadar gerilemiştir. Benzer şekilde, birçok kripto parada çok kısa zaman dilimlerinde aşırı dalgalanmalar yaşanabilmektedir. Bu ölçüde yüksek volatilité, fiyat tahminlerini güçleştirmekte ve yatırımcılar için belirsizlik yaratmaktadır (Somayajulu vd., 2025). Ani ve sert fiyat hareketleri, piyasalarda ciddi riskler doğurarak doğru tahmin ihtiyacını gündeme getirmektedir. Nitekim kripto para fiyatlarındaki büyük dalgalanmalar, bu varlıkların gelecekteki hareketlerini isabetli bir şekilde öngörebilecek modellere acil bir ihtiyaç doğurduğunu göstermektedir. Bu ihtiyaç, hem piyasa katılımcılarının olası kayıplarını azaltmak hem de genel finansal istikrar açısından önemlidir.

Makine öğrenmesi teknikleri, kripto para piyasalarındaki öngörü sorununa yönelik en umut verici çözüm alanlarından biri olarak ortaya çıkmıştır. ML yaklaşımları, kripto para piyasalarındaki belirsizlikleri ve ihtiyaçları aşmak için önemli fırsatlar sunmaktadır. Zaman serisi analizinde sıkça kullanılan geleneksel istatistiksel modeller (örneğin ARIMA), kripto piyasalarının doğrusal olmayan ve yüksek oynaklığa sahip yapısı

karşısında sınırlı başarı gösterirken, ML tabanlı algoritmalar, karmaşık örüntüleri öğrenebilme ve doğrusal olmayan ilişkileri modelleyebilme kapasiteleriyle öne çıkmaktadır. Özellikle derin öğrenme temelli yöntemler, büyük veri kümeleri içinde gizli ilişkileri keşfedebilmekte ve uzun vadeli bağımlılıkları etkili biçimde yakalayabilmektedir. Bu modeller, piyasa koşullarındaki ani değişimlere uyum sağlayarak fiyat tahminlerinde daha yüksek doğruluk sunmaktadır. Bu bağlamda literatürdeki bulgular, ML ve derin öğrenme modellerinin kripto varlık fiyat tahmininde geleneksel yöntemlere kıyasla daha başarılı sonuçlar verdiğini göstermektedir (Hua, 2020; Latif vd., 2023; Omole ve Enke, 2024; Bouteska vd., 2024).

Kripto varlık piyasalarındaki fiyat hareketlerinin yalnızca rasyonel beklentilerle açıklanması mümkün değildir. Davranışsal finans bakış açısı, aşırı iyimserlik, belirsizlikten kaçınma, hataları yanlış değerlendirme, sürü davranışı, kumarbaz yanılışı, aşırı güven, kayıptan kaçınma gibi irrasyonel davranışlarının yatırımcı kararını etkilediğini vurgular (Doğan ve Evlimoğlu, 2022). Bununla birlikte piyasa mikro yapısı perspektifi, yüksek işlem yoğunluğu, likidite koşulları ve emir akımlarının fiyat aralıkları üzerindeki etkileri aracılığıyla anlık fiyat oluşumuna yön verdiğini ortaya koymaktadır (Kayalı ve Ünal, 2015). Kripto piyasalarının 7/24 açık ve merkeziyetsiz yapısı, bu davranışsal ve mikro yapısal unsurların etkisini daha da artırmaktadır. Dolayısıyla kripto varlık fiyatlarının doğru tahmini için yatırımcı psikolojisini ve piyasa işleyişine özgü mikro mekanizmaları dikkate alan modeller kurulmalı ve bu yaklaşımlar ampirik analizlere entegre edilmelidir.

Bu çalışmanın amacı, kripto para birimlerinin fiyat tahmini için farklı makine öğrenimi modellerini karşılaştırmayı ve çok kriterli karar verme tekniklerini kullanarak en iyi yöntemi seçmektir. Kripto para piyasalarının yüksek volatilité ve çok boyutlu veri yapısı nedeniyle, tahmin süreci oldukça karmaşık bir hâl almaktadır. Bu kapsamda, çalışmada teknik analiz göstergeleri, makroekonomik göstergeler ve yatırımcı duyarlılığı göstergeleri bir arada kullanılarak tahminleme yapılmıştır. İlk olarak, 2018–2023 dönemine ait veri seti oluşturulmuş ile SVM, LSTM, RF ve XGBoost algoritmalarıyla tahmin modelleri eğitilmiştir. Elde edilen tahmin sonuçları istatistiksel hata metrikleri olan  $R^2$ , MAE, MSE ve RMSE ile değerlendirilmiştir. Ayrıca değişkenlerin tahmin üzerindeki etkileri permütasyon analizi, FR ve XGBoost algoritmaları aracılığıyla analiz edilmiştir. Son aşamada, farklı modellerin performansları Çok Kriterli Karar Verme (ÇKKV) yöntemleri kullanılarak karşılaştırılması amacıyla CRITIC yöntemiyle kriter

ağırlıkları belirlenmiş ve TOPSIS, ARAS, CODAS ile sıralama yapılmış, nihai sıralama Copeland yöntemiyle elde edilmiştir. Bu çalışma, kripto para fiyat tahmininde kullanılabilecek en uygun yöntemin belirlenmesi açısından literatüre katkı sunmayı ve yatırım kararlarına ışık tutmayı amaçlamaktadır.

Bu tez yedi bölümden oluşmaktadır. Giriş bölümü olan birinci bölümde konunun önemi, çalışmanın amacı, kapsamı ve önemi ile tezin bölümleri açıklanarak okuyucuya genel bir çerçeve sunulmuştur. İkinci bölümde kripto para piyasalarının tarihçesi, gelişimi ve temelini oluşturan blok zincir teknolojisi detaylı bir şekilde ele alınmıştır. Ayrıca, kripto para türleri, kullanım alanları, avantaj ve dezavantajları ile dünya ve Türkiye ölçeğinde yasal düzenlemelere yönelik bilgiler sunulmuştur. Üçüncü bölümde, kripto para fiyat tahmininde kullanılan makroekonomik göstergeler, yatırımcı duyarlılığı göstergeleri ve teknik analiz göstergeleri teorik olarak açıklanmıştır. Dördüncü bölümde ulusal ve uluslararası literatür taramasına yer verilerek benzer çalışmalar incelenmiş ve bu çalışmanın literatürdeki yeri ortaya konmuştur. Beşinci bölümde, araştırmanın veri seti, kullanılan değişkenler, veri ön işleme ve ölçeklendirme süreçleri açıklanmış, destek vektör makineleri, rastgele ormanlar, aşırı gradyan artırma ve uzun kısa süreli bellek modelleri detaylandırılmıştır. Ayrıca, istatistiksel performans metrikleri ve değişken önem düzeyi analizleri ile çok kriterli karar verme yöntemlerine yer verilmiştir. Altıncı bölümde, tüm yöntemlere ilişkin tahmin sonuçları değerlendirilmiş ve karşılaştırmalı olarak yorumlanmış, ÇKKV yöntemleri ile genel sıralama yapılmıştır. Son olarak yedinci bölümde, çalışmanın genel bulguları özetlenmiş ve gelecek araştırmalara yönelik öneriler sunulmuştur.

## **2 KRİPTO PARA PİYASALARININ TARİHÇESİ VE GELİŞİMİ**

Son yıllarda finansal pazarların vazgeçilmez bir parçası haline gelen kripto paraların, özellikle teknolojik ve ekonomik alanlarda yarattığı dönüşüm, onları sadece bir yatırım aracı olmanın ötesine taşımıştır. Bu çalışmanın birinci bölümünde, kripto paraların temelini oluşturan kriptoloji, kriptografi ve kriptanaliz konularının ne olduğu ve bu disiplinlerin kripto para sistemleri ile olan ilişkileri; Kripto paraların temelini oluşturan blockchain teknolojisinin işleyişi, avantajları, kripto para birimlerinin ortaya çıkışı ve evrimi, dijital ekonomide nasıl bir rol oynadıkları, piyasadaki önde gelen kripto para birimleri olan Bitcoin, Ethereum, Binance, Ripple ve Dogecoin hakkında temel bilgiler, kripto paraların, ödeme sistemlerinden, yatırım araçlarına ve hatta sosyal medya bahşiş

sistemlerine kadar geniş bir kullanım alanı, kripto para birimlerinin alım satımının yapıldığı platformlar olan borsalar ve bu borsaların işleyişi ve dünya genelinde farklı ülkelerin kripto paralara olan yaklaşımları, ve düzenlemeleri detaylı bir şekilde açıklanmaya çalışılmıştır..

## 2.1 Kriptoloji, Kriptografi ve Kriptanaliz Nedir?

Kriptoloji terimi, eski Yunanca'da "kryptos" ve "logos" sözcüklerinin birleşmesiyle oluşur. Burada "kryptos", "gizli dünya" anlamına gelirken, "logos" ise mantıksal düşünce ve neden sonuç ilişkisi kurma yeteneği anlamını ifade eder. Kriptoloji, gönderici ile alıcı arasında gerçekleşen iletişimin güvenli bir şekilde sürdürülmesini sağlayan, çoğunlukla karmaşık matematiksel problemlere dayanan teknikler ve uygulamalar topluluğu olarak açıklanır. Bu disiplin, elektronik, matematik ve bilgisayar bilimleri gibi çeşitli alanları kapsayan bir bilim dalı olarak kabul edilir (Avaroğlu, 2017).

Kriptoloji, kriptografi ve kriptanaliz olmak üzere iki ana dalda incelenir. Kriptografi, bir bilginin istenmeyen taraflarca anlaşılmayacak bir hale dönüştürülmesinde kullanılan tekniklerin bütünü olarak açıklanabilir. Kriptanaliz ise şifrelenmiş yani anlamsız bir metinden doğru metni bulma yöntemidir (Akleyek vd., 2011)

Kriptografi, mesajların gizliliğini koruma yöntemleri geliştirirken, kriptanaliz bu şifreleri çözmeye çalışır. Kriptografi uygulaması sonucunda elde edilen orijinal mesajlara düz metin, şifrelenmiş hallerine ise şifreli metin ya da kriptogram denir. Kriptograflar, şifreleme işlemini gizli bir anahtarla kontrol ederler ve bu anahtarı genellikle güvenli yollarla alıcıya iletirler. Kriptografinin temel prensiplerinden biri, düşman kriptanalistin şifreli metne erişiminin olabileceğidir ve güvenliğin gizli anahtara dayandığı kabul edilir. Kriptograflar, düşmanın şifreleme sistemi hakkında bilgi sahibi olabileceğini, ancak gizli anahtarı bilemeyeceğini varsayarlar. Sistem tasarımında, düşmanın düz metin-şifreli metin çiftlerine ya da şifreli metinleri anlamlandırma yeteneğine erişimi olabileceği senaryolar dikkate alınır. Modern şifreleme sistemleri, genellikle bu tür saldırılara karşı dayanıklı olacak şekilde hazırlanır. (Massey. 1988).

Kriptografi kullanmanın birçok nedeni vardır ve bu nedenler genellikle bilgi güvenliğinin temel unsurlarıyla ilişkilidir: (Tilborg, 2002)

**Gizlilik:** Veri iletimi sırasında, iletilen mesajların içeriğinin yetkisiz kişiler ya da dinleyiciler tarafından anlaşılmasını engellemek önemlidir. Aynı durum, örneğin hackerler tarafından yapılabilecek yetkisiz erişimlere karşı korunması gereken

depolanmış veriler için de geçerlidir. Kriptoloji, iletişimde ve veri depolamada gizliliği sağlamak için kritik bir araçtır.

**Doğrulama:** Bu özellik, bir imzanın eşdeğeridir. Mesajın alıcısı, mesajın belirli bir tarafa ait olduğuna ve başka birisi tarafından gönderilmediğine dair kanıt istemektedir. Bu, mesajın orijinal göndericisi daha sonra inkâr etmek istese bile geçerlidir. Kripto sistemler, mesajların ve verilerin güvenilir bir şekilde doğrulanmasını sağlayarak, iletişimin kimlik doğrulama süreçlerinde kilit bir rol oynar.

**Bütünlük:** Alıcı, alınan verilerin üçüncü bir taraf tarafından değiştirilmediğine dair kanıtlara sahip olmak ister. Kriptografik yöntemler, verilerin değiştirilmediğini doğrulamak için kullanılır. Böylece iletilen bilginin bütünlüğünü korumak mümkün olur. Kripto sistemler, herhangi bir değişiklik yapılmasını tespit edebilir, bu da verilerin orijinalliğinin ve güvenilirliğinin korunmasına yardımcı olur.

Kriptografi, binlerce yıldır özellikle askeri ve diplomatik mesajların korunması amacıyla kullanılmaktadır. Gerçekten de hükümetlerin bu alandaki net ihtiyacı, geçmişte kriptografinin devlet tekelinde olmasına yol açmıştır. Birçok hükümet, kriptografik araştırmalar üzerinde tam bir kontrol sağlamasa da kriptografik cihazların kullanımı üzerinde belirli düzeyde denetimler uygulamaktadır. Örneğin, ABD kriptografik cihazları, askeri silahların tabi olduğu benzer ihracat ve ithalat kontrolüne tabi tutmuştur. Ancak Bilgi Çağı'nın gelmesi ile özel sektörde kriptografiye olan acil ihtiyaç belirginleşmiştir. Günümüzde, sağlık ve hukuk kayıtları, finans işlemleri, kredi derecelendirmeleri gibi hassas veriler, kamu iletişim ağları üzerinden bilgisayarlara büyük ölçekte aktarılıyor. Toplum, bu tür hassas bilgilerin gizliliğini ve doğruluğunu korumada kriptografların desteğini beklemektedir (Massey. 1988).

## 2.2 Blok Zinciri (Blockchain) Teknolojisi

2009 yılında Bitcoin'in piyasaya sürülmesiyle birlikte, blok zinciri teknolojisi de gündeme gelmiş ve büyük ilgi uyandırmıştır. Günümüzde internet üzerinden yapılan para transferleri, insanların işlemlerini hızlı bir şekilde gerçekleştirmesine olanak sağlayan teknolojik imkânlardan biridir. Özellikle e-ticaretin gelişmesi, ürün ve hizmetlerin internet aracılığıyla çeşitli ödeme seçenekleriyle elde edilmesine imkân tanıyarak yeni bir ekonomik düzenin oluşmasına yol açmıştır (Taş ve Kiani, 2018). Blok zinciri terimi, ilk kez dolaylı olarak, Satoshi Nakamoto tarafından 2008 yılında yayımlanan “Bitcoin: A Peer-to-Peer Electronic Cash System-Bitcoin: Eşler Arası Elektronik Nakit Sistemi”

başlıklı makalede dile getirilmiştir. Her ne kadar makalesinde blok zinciri terimini kullanmamış olsa da kripto paranın temelini oluşturan teknolojiyi, kriptografik olarak birbirine bağlı veri bloklarından oluşan bir zincir olarak tanımlamıştır (Nakamoto, 2008). Bir blok zinciri, temel olarak, yürütülen ve katılımcı taraflar arasında paylaşılan tüm işlemlerin ya da dijital olayların dağıtılmış bir veri tabanı ya da genel bir defteridir. Genel defterdeki her işlem, sistemdeki katılımcıların çoğunluğunun mutabakatı ile doğrulanır. Bilgi bir kez girildikten sonra asla silinemez. Blok zinciri, bugüne kadar yapılmış her bir işlemin kesin ve doğrulanabilir bir kaydını içerir (Crosby vd., 2016).

Blok zinciri teknolojisi ile gerçekleştirilen her işlem, zaman damgalı olarak kaydedilir ve benzersiz bir sembol ile geniş çapta yayımlanır. İşlemler, blok zincirine eklenir ve her blok, benzersiz bir karma fonksiyon (kriptografik özel ve genel anahtarlarla kodlanan verilerden oluşan alfanümerik dize), blok için benzersiz bir sayı olan nonce ve önceki bloğun karma fonksiyonundan oluşur. İlk blok, genesis bloğu olarak adlandırılır. Bu nedenle, bir bloğu sahtekarlıkla değiştirme girişimi, önceki blokları da değiştirme gerekliliğini içerir. Bu, mekanizmayı işlem değişikliklerine karşı güvenli ve emniyetli hale getirir (Karamitsos vd. 2018).

Blok zinciri sisteminin ilk uygulaması olan Bitcoin'in açıklaması şu şekilde yapılabilir: Bitcoin blok zinciri, her on dakikalık periyotta Bitcoin ile yapılan işlemlerin kayıtlarını içeren bir fiziksel defter olarak düşünülebilir. Bir sayfa yeni işlemlerle dolduğunda, zaman damgası ve benzersiz bir seri numarası ile imzalanarak deftere eklenir. Bu benzetmede, sayfalar blokları, seri numaralar ise bloklar arasındaki bağlantıyı temsil eder. Seri numarası, o sayfadaki işlemlerin bir sonucudur ve bitişik sayfaların seri numaraları, sağlam bir sayfalar zinciri oluşturmak üzere matematiksel bir fonksiyonla birbirine bağlanır. Bu durum, sayfanın seri numarasını değiştirmeden herhangi bir işlemi değiştirmeyi ve dolayısıyla o sayfa ile sonraki sayfa arasındaki bağlantıyı bozmayı imkânsız kılar. Defterdeki bir işlemi değiştirmek için, işlemden sonraki tüm sayfaları çıkarıp yeni işlemlerle doldurmak, yeni seri numaralar oluşturmak ve tüm sayfaları tekrar deftere eklemek gerekir. Bu defterin kullanıcıları, her zaman, en fazla sayfaya sahip olan kitabı geçerli defter olarak kabul ederler. Bu nedenle, defter sürekli olarak her on dakikada bir yeni sayfa eklenmesiyle büyümeye devam eder ve bu şekilde defterdeki bir işlem geçmişini başarıyla yeniden yazmak isteyen kişinin, topluluğun geri kalanından daha hızlı çalışması gerekecektir. Dolayısıyla, bu işlemi tek bir kişinin gerçekleştirebilmesi için


gereken çaba, bir kişinin yapabileceğinin çok ötesindedir, bu yüzden bu yapı oldukça güvenlidir (Hampton, 2016'dan aktaran Avunduk ve Aşan, 2018).

### 2.2.1 Blok zinciri teknolojisinin çalışma prensibi

Şekil 2.1'de yer verilen blok zinciri teknolojisinin çalışma prensibini göre, blok zincirinde her işlem ya da veri girişi, ağdaki katılımcıların çoğunluğunun mutabakatı ile doğrulanır ve bu süreç, güvenilir ve doğrulanabilir verilerin blok zincirine eklenmesini sağlar. Bir kez blok zincirine girildikten sonra, veriler değiştirilemez ya da silinemez. Her blok, kendinden önceki blokla kriptografik olarak bağlanır ve bu da verilerin güvenliğini sağlar. Ayrıca blok zinciri, tüm işlemlerin ve veri girişlerinin tarihsel kaydını tutar. Bu, geçmişe dönük tüm verilerin izlenebilir ve doğrulanabilir olmasını sağlar ve her yeni blok, önceki blokların bütünlüğünü koruyarak zincire eklenir. Bitcoin, iki isteklinin internet üzerinden çevrimiçi bir işlem gerçekleştirmesi için üçüncü taraf güven mekanizması yerine kriptografik kanıt kullanır. Her işlem dijital bir imza ile korunur, alıcının açık anahtarına gönderilir ve gönderenin özel anahtarı kullanılarak dijital olarak imzalanır. Kripto para birimini harcamak için, sahibinin özel anahtarın mülkiyetini kanıtlaması gerekir (Crosby vd., 2016).

Şekil 2.1

Blok Zinciri Teknolojisinin Çalışma Prensibi



Kaynak: (Crosby vd., 2016)

### 2.2.2 Blok zinciri teknolojisinin avantajları

Blok zincirlerin çoğu, merkeziyetsiz dijital defter olarak işlev gören veri tabanları olarak tasarlanmıştır. Bu defterler, verileri bloklar halinde kaydeder ve depolar, bu bloklar kronolojik sırayla düzenlenir ve kriptografik kanıtlarla birbirine bağlanır. Blok zincir teknolojisi, birçok endüstride sağladığı avantajlara aşağıda yer verilmiştir.

**Merkeziyetsizlik:** kullanıcıların bilgiye erişirken herhangi bir merkezi otoriteyi atlamalarını sağlar. Blok zinciri üzerindeki bilgiler, tümü aynı defter kopyalarına sahip olan bir bilgisayar ağı (düğüm) üzerinde saklanır. Yeni bir blok eklendiğinde, her düğüm güncellenir. Bilgilerin bu şekilde ağda saklanması, güvenliği artırır ve ele geçirmeyi son derece zorlaştırır (http-1; http-2).

**Şeffaflık:** Blok zincirindeki işlemler, herkesin erişebileceği halka açık bir deftere kaydedilir. Herkes, güvenlik amacıyla kripto paraları denetleyebilecek denetçiler dahil olmak üzere kaynak kodunu görebilir. Ayrıca, merkezi bir otorite olmadığı için, sistem çoğunluğun yeni kod sürümünü kabul etmesi şartıyla herkesin önerilerine göre güncellenebilir (http-1; http-3; http-4).

**Dağıtılmış Sistem:** Blok zinciri verileri, düğüm ağındaki birçok cihazda saklandığından, sistem teknik arızalara ve kötü niyetli saldırılara karşı oldukça dayanıklıdır. Her ağ düğümü, veri tabanının bir kopyasını saklayabilir, bu nedenle tek bir düğümün devre dışı kalması ağın güvenliğini ya da kullanılabilirliğini etkilemez. Bu, geleneksel veri tabanlarının aksine, verilerin merkezi bir arıza noktasına sahip olmasını önler (http-5).

**Kararlılık:** Onaylanmış bloklar genellikle geri alınamaz, bu da blok zincire kaydedilen verilerin değiştirilmesinin ya da kaldırılmasının son derece zor olduğu anlamına gelir. Bu özellik, finansal kayıtlar ya da denetim izi gerektiren diğer verilerin saklanması için blok zinciri ideal kılar çünkü her değişiklik izlenir ve kalıcı olarak kaydedilir (http-2; http-5).

**Güvene Dayalı Olmayan Sistem:** Geleneksel ödeme sistemlerinde, işlemler genellikle bir aracıya bağlıdır. Blok zincir teknolojisi, düğüm ağının işlemleri doğrulaması sayesinde aracıya ihtiyaç duymadan çalışır. Bu, sistemin tek bir kuruluşa güvenme riskini ortadan kaldırır ve aracılara ortadan kaldırarak maliyetleri ve işlem ücretlerini azaltır (http-4; http-5).

### 2.2.3 Blok zinciri teknolojisinin dezavantajları

Blok zinciri teknolojisi, birçok endüstride sağladığı avantajların yanı sıra merkeziyetsiz yapısı bazı dezavantajları da beraberinde getirir.

**Ölçeklenebilirlik Sorunları:** Blok zincirin tasarımı gereği, işlem sayısı arttıkça ölçeklenebilirlik sorunları yaşanır. Bu, işlem hızının yavaşlamasına ve maliyetlerin artmasına neden olabilir (http-4).

**Yüksek Enerji Tüketimi:** Özellikle Bitcoin gibi bazı kamu blok zincirlerinde madencilik, işlemlerin doğrulanması için karmaşık matematiksel bulmacaların

çözülmesini gerektirir. Bu, önemli ölçüde hesaplama gücü ve enerji tüketimi gerektirir (http-4; http-5).

**Yasal ve Düzenleyici Zorluklar:** Blok zincirin merkeziyetsiz yapısı, benzersiz yasal ve düzenleyici zorluklar sunar. Merkezi bir otorite olmadan, anlaşmazlık çözümü gibi konular karmaşık hale gelebilir. Ayrıca, blok zincir ve ilgili teknolojilerin yasal statüsü ve düzenleyici çerçevesi dünya genelinde büyük farklılıklar gösterir, bu da belirsizlik yaratır (http-3; http-4).

**Kötüye Kullanım Potansiyeli:** Blok zinciri güvenlik ve gizlilik sağlar, ancak bu özellikler kara para aklama ya da yasadışı ticaret gibi yasa dışı faaliyetler için de kullanılabilir (http-2, http-3).

**Karmaşıklık ve Teknolojik Anlayış:** Blok zincirin teknik karmaşıklığı, ortalama bir kişinin bunu anlamasını ve kullanmasını zorlaştırabilir. Bu engel, teknolojinin yaygın olarak benimsenmesini engeller (http-3; http-4).

## **2.3 Kripto Paraların Evrimi ve Modern Ekonomiye Etkisi**

Kripto paralar, dijital çağın getirdiği en yenilikçi finansal araçlardan biridir. Geleneksel finansal sistemlere alternatif olarak ortaya çıkan kripto paralar, merkezi olmayan yapıları, şeffaf işlem kayıtları ve güçlü kriptografik güvenlik özellikleri ile dikkat çekmektedir. İlk olarak Bitcoin ile başlayan bu devrim, kısa sürede birçok yeni kripto para biriminin doğmasına ve küresel finansal sistemde önemli bir yer edinmesine yol açmıştır.

Bu bölümde, kripto paraların tanımından tarihçesine, çeşitlerinden kullanım alanlarına kadar geniş bir perspektif sunulacaktır. Ayrıca, kripto paraların avantajları ve dezavantajları, ticaret platformları ve borsaları ve ülkelerin kripto paralara yönelik yaklaşımları da detaylı bir şekilde ele alınmaktadır.

### **2.3.1 Kripto paranın tanımı ve tarihçesi**

Kripto para, güvenli, merkeziyetsiz ve dağıtık ekonomik işlemlerin gerçekleştirilmesini sağlayan kriptografi ilkelerine dayanan dijital bir değişim aracı olarak tanımlanmaktadır. Kripto paralar, elektronik sanal parayı kriptografi ilkeleriyle birleştirir. Kripto paranın temel prensibi, hiçbir bireyin (ya da organizasyonun) belirli bir para biriminin üretimini hızlandıramaması ya da önemli ölçüde kötüye kullanamamasıdır. Tipik olarak, belirli bir miktarda kripto para birimi, tüm kripto para sistemi tarafından topluca üretilir. Üretim oranı, önceden tanımlanmış bir değerle belirlenir ve kamuya açıktır. Kripto paralar,

bilgisayar eşler arası ağı aracılığıyla istemci uygulamaları arasında neredeyse maliyetsiz kripto para birimi birimlerinin transferini sağlar (Vejačka, 2014).

Kripto paraların kökenleri, 1980'lerin sonlarına ve 1990'ların başlarına dayanmaktadır. Bu dönemde, kriptografi ve dijital para birimleri üzerine yapılan çalışmalar, modern kripto paraların temelini oluşturmaktadır.

David Chaum, dijital para birimleri konusunda öncü bir isim olarak kabul edilir. 1983 yılında, “Blind Signatures for Untraceable Payments” adlı makalesinde anonim dijital ödeme sistemlerinin temelini atmıştır. Bu makalede, kullanıcıların kimliklerini gizleyerek dijital para transferleri yapmalarını sağlayacak kriptografik yöntemleri tanıtmıştır (Chaum, 1983; http-6).

David Chaum, 1989 yılında Amsterdam'da DigiCash adlı şirketi kurmuştur. DigiCash, dijital para birimi olarak geliştirdiği “eCash”, kullanıcıların bankalardan dijital banknotlar çekmelerine ve bunları anonim olarak kullanmalarına olanak tanıyordu. DigiCash, kamu ve özel anahtar kriptografisini kullanarak, elektronik ödemelerin güvenli ve anonim olmasını sağlamıştır (http-7; http-8). eCash, Chaum'un geliştirdiği kör imza (blind signature) teknolojisini kullanarak işlemleri anonim hale getirerek bankaların işlem yapılan dijital banknotların kim tarafından oluşturulduğunu bilmeden imzalamalarına olanak tanımıştır. Bu sayede, kullanıcılar dijital banknotları herhangi bir üçüncü tarafın gözetimi olmadan güvenle transfer edebilmelerine olanak sağlamıştır (http-6; http-8).

Kripto para birimleri dolar ya da euro gibi merkezi bankalar tarafından ihraç edilen geleneksel para birimlerinden farklı olarak, yerleşik finansal sistemler dışında işlev görür. Altın gibi somut varlıklara bağlı değildirler ya da merkezi finans kurumları tarafından yönetilmezler. Bunun yerine, yeni işlemlerin yaratılması ve doğrulanmasıyla sonuçlanan karmaşık matematiksel problemleri çözmek için hesaplama gücünü kullanan madencilik adı verilen bir hesaplama süreciyle oluşturulurlar (Shahzad vd. 2024).

İlk ve en ünlü kripto para birimi, 2009 yılında Satoshi Nakamoto takma adıyla bir kişi ya da grup tarafından yaratılan Bitcoin'dir. Bu tarihten itibaren, her biri farklı özelliklere ve amaçlara sahip binlerce kripto para birimi geliştirilmiştir. Güvenlik amacıyla kriptografi kullanan ve merkezi olmayan bir yapıya sahip olan kripto para birimleri, bankalar ya da ödeme işlemcileri gibi aracı kurumlara ihtiyaç duymadan çalışabilirler. Bu merkeziyetsiz yapı, bireyler arasında doğrudan eşler arası (P2P) işlemleri mümkün kılar. Bununla birlikte, insanlar kripto para birimlerine fiziksel cüzdanlar ya da banka hesapları yerine benzersiz kripto cüzdanları ya da kripto borsaları aracılığıyla erişir. Buna rağmen kripto

para birimleri cüzdanlarda saklanmaz, her zaman blockchain üzerinde kalır ve kripto borsaları, kullanıcıların bu fonlara erişimini sağlayan özel anahtarları tutar. Ayrıca geleneksel fiat para birimleri gibi, kripto paralar da bir değişim aracı olarak kullanılabilir. Ancak, zamanla kullanım alanları önemli ölçüde genişlemiş ve akıllı sözleşmeler, merkeziyetsiz finans (DeFi), değer saklama, yönetim ve değiştirilemez tokenler (NFT) gibi çeşitli alanları içermeye başlamıştır (<http-1>).

### 2.3.2 Kripto paranın özellikleri

Bitcoin'in ilk maliyeti, madencilik sırasında tüketilen elektrik maliyetidir, ikincil maliyet ise bu kripto para birimine olan talep tarafından belirlenir. Bitcoin madenciliğinin karmaşık süreci, işlemlerin kaçınılmazlığını garanti etme gerekliliğinden kaynaklanmaktadır. Bir kullanıcı işlem geçmişini yeniden yazmaya çalışırsa, aynı anda diğer tüm bloklardaki veriler bozulur. Zincir prensibi, verilerin manipüle edilmesini neredeyse imkansız hale getirirken, aynı zamanda her kullanıcının belirli bir dönemde belirli bir cüzdana kaç Bitcoin bulunduğunu öğrenmesini sağlar. Kripto paralarının finansal doğası, bu özellikleriyle birlikte oluşmaktadır (Omelchuk vd. 2021)

**Merkeziyetsizlik ve erişilebilirlik:** Kripto para ağı, kullanıcıların cüzdanlarının bir birleşimi ile zincirdeki her bilgisayarda tutulan dağıtılmış bir blok zinciri veritabanından oluşur. Bu blok zinciri, sistemde gerçekleşen tüm işlemleri görüntülemek için tamamen açıktır. Kendi cüzdanınızla ya da özel izleme hizmetlerinin web arayüzü üzerinden, şifre ya da herhangi bir yetkilendirme olmaksızın bu kayda erişebilirsiniz.

**Ödemelerin tam şeffaflığı:** Herhangi bir ödemenin geçmişi, kripto paranın üretildiği ana kadar izlenebilir. Bu bilgiler veri tabanından hiçbir zaman silinmez. Yalnızca kripto para cüzdan adresini bilerek, bu adresten gönderilen ya da alınan herhangi bir işlemi herhangi bir zamanda görebilirsiniz.

**Esnek cüzdan seçenekleri:** Kullanıcılar, tüm işlem geçmişini saklayan resmi Bitcoin Core istemcisini indirebilir. Pil ömrü ya da blok zinciri analizi gerektirmeyen hafif ya da mobil cüzdanlar da kurulabilir. Maksimum güvenlik için ek koruma katmanlarına sahip donanım cüzdanları ya da diğer ismiyle soğuk cüzdanlar kullanılabilir.

**Ağ üzerinde kontrol eksikliği:** Blok zinciri, eşler arası bir veri tabanı olduğundan, ağ üzerinde hesapları dondurabilen, birim sayısını değiştirebilen, ödemeleri engelleyebilen ya da iptal edebilen bir kontrol merkezi yoktur. İşlem ücretleri pratikte neredeyse

hissedilmez ve transfer miktarına bağılı değildir. Sistemdeki işlemler nakit işlemler kadar geri alınamazdır.

**Anonim ödeme seçenekleri:** Kripto para, uygun ve anonim bir ödeme aracı sunar; adres, sahibine bağılı olmayan bir hesap numarasıdır. Böyle bir hesap açmak için herhangi bir belge gerekmemektedir. Örneğin bir adres şu şekilde görünür: 1BQ9qza7fn9snSCyJQB3ZcN46biBtk t4ee. Kolaylık için bu adres bir QR kodu ya da başka bir iki boyutlu koda dönüştürülebilir.

**Eşsiz güvenlik:** Her yeni blok ile birlikte, madencilerin tüm zinciri baştan hesaplamak için ihtiyaç duydukları hesaplama gücü artar. Zincir ne kadar uzunsa, ağı kırmak o kadar zor olur. Günümüzde Bitcoin ağı, dünyanın tüm süper bilgisayarlarının toplam işlem gücünü aşmıştır. Sınırlı bir kontrol elde etmek için bile muazzam kaynaklar ve yüz milyonlarca dolarlık maliyet gereklidir

### 2.3.3 Kripto Para çeşitleri

Kripto para birimleri dolar ya da euro gibi merkezi bankalar tarafından ihraç edilen geleneksel para birimlerinden farklı olarak, kripto para birimleri yerleşik finansal sistemler dışında işlev görür. Altın gibi somut varlıklara bağılı değildirler ya da merkezi finans kurumları tarafından yönetilmezler. Bunun yerine, yeni işlemlerin yaratılması ve doğrulanmasıyla sonuçlanan karmaşık matematiksel problemleri çözmek için hesaplama gücünü kullanan madencilik adı verilen bir hesaplama süreciyle oluşturulurlar (Shahzad vd. 2024).

Sadece bir ödeme aracı olmanın ötesine geçerek çeşitli alanlarda kullanılmakta olan ve yatırım aracı olarak da tercih edilebilen kripto paraların binlerce çeşidi bulunmaktadır. Ancak bu bölümde çalışmaya dahil edilen Bitcoin (BTC), Ethereum (ETH), Binance (BNB), Ripple (XRP) ve Dogecoin (DOGE) detaylı bir şekilde incelenmektedir.


#### 2.3.3.1 Bitcoin (BTC)

2008 yılında Satoshi Nakamoto "Bitcoin: A Peer-to-Peer Electronic Cash System" başlıklı makalesinde, güvene dayalı üçüncü taraflara ihtiyaç duymadan elektronik işlemleri gerçekleştiren bir sistem olan Bitcoin'i tanıtmıştır. Makalesinde, geleneksel finansal sistemlerin tersine çevrilemez işlemler yapamama ve yüksek işlem maliyetleri gibi sorunlarını ele almaktadır. Bitcoin, işlemleri doğrulamak ve çifte harcama sorununu çözmek için bir zaman damgası sunucusu ve iş kanıtı (proof-of-work) sistemi kullanır. Nakamoto ayrıca makalesinde, Bitcoin'in güvenilir üçüncü taraflara bağımlılığı azaltarak

güvenli, düşük maliyetli ve tersine çevrilemez işlemler yapma imkânı sunduğunu vurgulamıştır (Nakamoto, 2008).

## Şekil 2.2

*Dijital Para ve Kripto Paranın Karşılaştırılması*



*Kaynak: Chiu ve Koepl, 2017*

Şekil 2.2’de dijital para ile kripto paranın karşılaştırılması verilmiştir. Dijital bir para birimi sisteminde, ödeme aracı sadece bir bit dizisidir. Bu, bir sorun teşkil eder çünkü bu bit dizileri, diğer dijital kayıtlar gibi kolayca kopyalanabilir ve ödeme için tekrar kullanılabilir. Geleneksel olarak, bu sorun, bir ücret karşılığında merkezi bir defter tutan ve alıcı ile satıcıların hesaplarına bakiyeleri kredi ve borç olarak kaydeden güvenilir bir üçüncü tarafa dayanılarak çözülmüştür. Bu üçüncü taraf genellikle dijital para biriminin ihraççısı olup, PayPal buna örnek verilebilir ve para biriminin değeri, kullanıcıların bu üçüncü tarafın çift harcamayı önleyeceğine olan güveninden kaynaklanır.

Bitcoin gibi kripto paralar, güvenilir bir üçüncü tarafa olan ihtiyacı ortadan kaldırır. Bunun yerine, defterin kopyalarını tutan ve güncelleyen merkezi olmayan bir doğrulayıcılar ağına dayanırlar. Bu, doğrulayıcılar arasında doğru işlem kaydı üzerinde bir uzlaşma gerektirir, böylece kullanıcılar bakiyeleri alma ve sahiplenme konusunda emin olabilirler. Ancak, böyle bir uzlaşmanın, kullanıcıların para birimini çift harcamaması ve doğrulayıcıların defteri doğru şekilde güncelleyeceğine güvenebilmesi gereklidir. Bitcoin bu zorlukları, işlem geçmişlerinin dağıtılmış şekilde doğrulanmasını, güncellenmesini ve depolanmasını sağlayan bir blok zincire dayanarak aşar. Bu, bir blok zinciri oluşturarak gerçekleştirilir. Bir blok, kripto para birimi kullanıcıları arasında gerçekleştirilen bir dizi işlemten oluşur. Bu bloklardan, geçmiş işlemleri içeren bir zincir

oluşturulur ve bu, bir kullanıcının sahip olduğu bakiyelerin ya da para biriminin miktarını herkesin doğrulamasını sağlayan bir defter oluşturur. Dolayısıyla, bir blok zinciri, tüm geçmiş işlemleri içeren bir defter gibidir ve bir blok, tüm mevcut işlemleri kaydeden yeni bir sayfadır. Zinciri yeni bir blokla güncelleme hakkı rekabetle belirlenir. Bu rekabet çeşitli şekillerde olabilir. Bitcoin’de, bu süreç madencilik olarak bilinir. Madenciler (işlem doğrulayıcıları), proof-of-work (PoW) adı verilen hesaplama açısından maliyetli bir problemi çözmek için yarışır. Madencilik sürecinin kazananı, zinciri yeni bir blokla güncelleme hakkını elde eder. İşlem doğrulama ve madencilik maliyetli olduğundan, madencilik için bir ödül sistemi gereklidir. Örneğin, Bitcoin’de bu ödüller, yeni coinlerin oluşturulması ve işlem ücretleri ile finanse edilmektedir (Chiu ve Koepl, 2017).

Bitcoin kullanıcıları, elektronik bankacılık uygulamalarına benzer dijital cüzdan kullanırlar. Bu cüzdan, Bitcoin nakit yönetimi için, yani Bitcoin ile ödeme göndermek ve almak için kullanılan bir yazılımdır. Bitcoinler sadece bir bilgisayar ya da mobil cihazdaki dosyalarda bilgi olarak mevcuttur. Bu dosyalara erişim, parayı güvence altına almak için kullanılan özel anahtarın sahibine özeldir. Eğer cüzdan dosyası yedeklenmediyse, bilgisayardaki dosya sistemi zarar görürse ya da cüzdan dosyası yanlışlıkla silinirse, cüzdan dosyası ve içindeki Bitcoinler sonsuza kadar kaybolur. Cüzdanın genel adresi hala var olsa da yalnızca silinmiş olan özel anahtarla erişilebilir. Sistemde yerleşik olan çok güvenli şifreleme kırılmadıkça, kaybolan coinleri kurtarmak mümkün olmaz ve Bitcoin ağında kullanılan şifrelemeyi zorla kırmak pratik olarak imkansızdır (Vejačka, 2014).

Bitcoin’in dolar türünden tarihsel fiyat grafiği Şekil 2.3’te, piyasa değeri ise Şekil 2.4’te gösterilmektedir. Bitcoin’in (BTC) 2014’ten 2024’e kadar olan fiyat hareketlerini gösteren grafiğe göre BTC sürekli artış eğilimindedir. BTC, 2017 ve 2021’de önemli zirveler yaptıktan sonra, 2023-2024’te yeniden yükselerek 70000 dolar seviyesine ulaşmıştır.

Şekil 2.4’teki piyasa değeri grafiğine göre ise, Bitcoin’in piyasa değeri 2011-2016’da düşük ve sabit seyrederken, 2017’de 300 milyar dolara ulaşmış, 2018-2020’de düşüş ve yatay seyir izlerken, 2021’de 1 trilyon doları aşmamasına rağmen 2022’de büyük bir düşüş yaşayıp toparlanmış ve 2023-2024’te yeniden yükselerek 1.4 trilyon dolara yaklaştığı gözlenmektedir.

Bu grafiklerdeki fiyat dalgalanmaları ve piyasa değerindeki değişimler, kripto para piyasasındaki volatilitiyi göz önüne sermektedir. Bitcoin’in piyasa değerinin yüksek volatilitiyeye sahip olduğunu ve büyük fiyat dalgalanmaları yaşadığını göstermektedir.

Bitcoin'in popülaritesinin arttığı ve yatırımcıların ilgisini çektiği dönemlerde piyasa değeri hızlı bir şekilde yükselmektedir.

### Şekil 2.3


*BTC/USD Tarihsel Fiyat Grafiği*



Kaynak: <http-12> (Erişim tarihi: 26.05.2024)

### Şekil 2.4

*Bitcoin'in Yıllara Göre Piyasa Değeri*



Kaynak: <http-12> (Erişim tarihi: 26.05.2024)

#### 2.3.3.2 Ethereum (ETH)

Ethereum, merkezi olmayan uygulamaların (dApp) ve akıllı sözleşmelerin geliştirilmesi için tasarlanmış açık kaynaklı bir blok zinciri platformudur. 2013 yılında Vitalik Buterin tarafından geliştirilmiştir (Tevetoğlu, 2021). Ethereum, Bitcoin'in aksine yalnızca dijital

para transferine odaklanmamakta, aynı zamanda geliştiricilerin kendi uygulamalarını ve protokollerini oluşturmalarına olanak tanımaktadır (Demiroğlu, 2020).

Ethereum (ETH) ve Bitcoin (BTC), dijital para dünyasında en tanınmış iki isimdir. Her ikisi de kripto para birimlerinin yükselmesi ve meşruiyet kazanmasında büyük rol oynamıştır. Ethereum ve Bitcoin, her ikisi de blok zinciri teknolojisi üzerine kuruludur ve bu blok zincirleri, dağıtılmış halka açık defterlerle güvence altına alınır. Her ikisi de merkezi olmayan kripto paralardır, bu yüzden güvenlik ve dolandırıcılığa karşı koruma sağlamak için ağına tamamına güvenirlir. Ethereum ve Bitcoin arasında bazı belirgin farklar vardır. Bu farkları aşağıdaki gibi sıralanabilir ([http-9](http://9)).

- Bitcoin geleneksel para birimine bir alternatif olarak geliştirilmiştir ve genellikle altın gibi bir değer saklama aracı olarak kullanılır. Bitcoin'in amacı, dijital bir para birimi olarak merkezi olmayan bir şekilde değer transferi ve saklanması sağlamaktır.

Öte yandan, Ethereum bir platform olarak tasarlanmıştır ve birçok uygulama için kullanılabilir. Ethereum, akıllı sözleşme yetenekleri sayesinde ağına çok çeşitli uygulamaların çalışmasına olanak tanır. Bu platform, Ethereum'un kripto para birimi olan ETH ile desteklenir.

- Bitcoin orijinal dijital para birimidir. Bitcoin'in amacı, değer depolama ve değişim aracı olarak işlev görmektir. Ethereum ise, açık uçlu ve merkezi olmayan bir yazılım platformudur. Ethereum'un yerel kripto para birimi olan ETH, ağı çalıştırmak için kullanılır. Ancak, Ethereum'un kullanım alanları daha geniştir; akıllı sözleşmeler ve merkezi olmayan uygulamalar (dApps) için yaygın olarak kullanılır. Ethereum'un amacı, ağına kullanımını ve desteklenmesini sağlamaktır.
- Bitcoin, iş ispatı (Proof of Work - PoW) modelinde çalışır. PoW, bilgisayarların karmaşık matematik problemlerini çözerek işlemleri doğrulamasını ve yeni bloklar eklemesini gerektirir. Bir "madenci" bu problemleri tamamlarsa, bir işlem bloğunu işleme yeteneği kazanır ve kripto para ile ödüllendirilir. Bu süreç, yüksek enerji tüketimi nedeniyle çevresel etkiler nedeniyle eleştirilmektedir. Ethereum ise başlangıçta PoW modelinde çalışırken, Ethereum 2.0 ile pay ispatı (Proof of Stake - PoS) modeline geçmiştir. PoS modelinde, kullanıcılar kripto paralarını "pay" olarak ayırarak işlem bloklarını doğrulamak üzere seçilirler. En fazla parayı paylaşanlar, blokları doğrulama ve kripto para ile ödüllendirilme olasılığı en yüksek olanlardır. Bu model, enerji tüketimini önemli ölçüde azaltır.

- Ethereum ağı daha hızlı işlem yapılmasını sağlar. Ortalama olarak, Ethereum işlemleri Bitcoin'e göre daha hızlı işler. Ancak, Ethereum'un işlem ücretleri daha yüksektir. Bitcoin ağı saniyede yaklaşık 7 işlem yaparken, Ethereum ağı saniyede 10 ile 15 işlem yapmaktadır.

Ethereum'un dolar türünden tarihsel fiyat grafiği, Şekil 2.5'te gösterilmektedir. 2016-2024 yılları arasındaki fiyat hareketlerine göre, ETH İlk önemli fiyat artışını 2017 sonları, 2018 başlarında yaşamıştır. Büyük bir düşüş yaşadıkdan sonra tekrar başlayan bir yükseliş trendi ile, 2021'in ortalarında 4500 dolar seviyesinde yeni zirvesine ulaşmıştır. Tekrar ciddi bir düzeltmenin ardından 2022 ve 2023 yıllarında 1200-2400 dolar aralığında seyreden fiyatlar, 2024'te tekrar yükselişe geçen ETH 4000 dolar seviyesine ulaşmasına rağmen 2021 yılındaki zirvesine henüz ulaşamamıştır.

**Şekil 2.5**

*ETH/USD Tarihsel Fiyat Grafiği*



*Kaynak:* <http-13> (Erişim tarihi: 26.05.2024)

### **2.3.3.3 Binance (BNB)**

Binance borsası, Binance Coin adlı kendi kripto parasını işletmektedir ve bu para birimi BNB sembolüyle işlem görmektedir. Binance Coin (BNB), Ethereum, Litecoin ve Bitcoin gibi diğer kripto paralarla takas edilebilir ya da işlem yapılabilir. İlk olarak Temmuz 2017'de çıkarılan Binance Coin, başlangıçta Ethereum blok zincirinde ERC-20 tokeni olarak çalışmaktaydı. Daha sonra Binance'in kendi blok zinciri olan Binance Chain'in yerel para birimi haline gelmiştir. Günümüzde, Binance Coin dünya çapında en popüler

kripto paralar arasında bulunmaktadır. Maksimum arzı 200 milyon BNB tokeni ile sınırlıdır (Mallick, 2020).

Binance borsası “Otomatik Yakım Programı” diye adlandırdığı program ile toplam arzını uzun vadede %50 azaltacak sistem kurmuş ve düzenli olarak BNB tedavülünden kaldırılmaktadır (http-10).

BNB coinin dolar türünden tarihsel fiyat grafiği, Şekil 2.6’de gösterilmektedir. 2017-2019 yılları arasında BNB'nin fiyatı sabit kalırken, 2020 sonunda 30-40 dolara yükseldiği görülmektedir. 2021’de büyük bir artışla 700 dolara ulaşmış, ancak yılın ortasında 300-400 dolara düşmesine rağmen yılı 500-600 dolar aralığında kapatmıştır. 2022’de 200-300 dolara gerileyen fiyatlar 2023’te toparlanarak 300-500 dolar aralığına çıkmıştır. 2024’te ise güçlü bir yükselişle tekrar 600 doları aştığı görülmektedir.

**Şekil 2.6**

*BNB/USD Tarihsel Fiyat Grafiği*



*Kaynak:* http-14 (Erişim tarihi: 27.05.2024)

#### **2.3.3.4 Ripple (XRP)**

Ripple, blockchain teknolojisi ve dijital ödeme sistemleri üzerinde çalışan bir fintech şirkettir. 2012 yılında geleneksel bankacılık sistemindeki uzun işlem süreleri ve yüksek işlem maliyetlerinin ortadan kaldırılması amacıyla kurulmuştur (Ahmadova ve Erek, 2022).

RippleNet adı verilen küresel ödeme ağı, bankalar ve ödeme sağlayıcıları arasında güvenli ve anında para transferi yapılmasını sağlar. RippleNet, blok zinciri tabanlı defterlerin tamamen bir şirket tarafından yönetildiği bir yapıya sahip olup, işlemlerin

doğruluğunu ve güvenliğini sağlamak için XRP Ledger (XRPL) adı verilen blok zinciri teknolojisini kullanır (Şahin, 2020)

XRP, Ripple tarafından kullanılan dijital para birimidir ve işlemler arası köprü para birimi olarak işlev görür. XRP'nin diğer kripto para birimlerinden en büyük farkı, enerji tüketiminin düşük olması ve hızlı işlem onayıdır. Bitcoin gibi proof-of-work algoritmasına dayanan kripto para birimlerinin aksine XRP, daha çevre dostu olan konsensüs protokolünü kullanır. Bu, XRP işlemlerinin daha hızlı ve maliyet etkin olmasını sağlar (http-11).

XRP'nin dolar türünden tarihsel fiyat grafiği, Şekil 2.7'de gösterilmektedir. 2014- 2017 yılları arasında fiyatlar aynı düzeyde kalan XRP fiyatı, 2018 yılının başlarında büyük bir artışla yaklaşık 3,50 dolara ulaşmış, ancak aynı yıl hızla 0,50 dolar seviyelerine gerilemiştir. 2019-2020 yılları arasında 0,20-0,30 dolar aralığında seyreden fiyatlar, 2021'de fiyat tekrar 1,50 dolara yükselmesine rağmen ancak yıl sonunda 0,50-1,00 dolar aralığına düşmüştür. 2022, 2023 ve 2024 yıllarında fiyat istikrarlı bir şekilde 0,50 dolar civarında kalmaya devam etmektedir.

#### Şekil 2.7

*XRP/USD Tarihsel Fiyat Grafiği*



Kaynak: http-15 (Erişim tarihi: 27.05.2024)

#### 2.3.3.5 Dogecoin (DOGE)

Dijital iletişim çerçevesinde popüler bir eğlence aracı haline gelen internet memleri (memes), yeni kripto para birimlerinin ortaya çıkmasına vesile olmakta ve bu para birimlerinin kripto para piyasasında dikkat çekmesini sağlamaktadır. Postmodern

dönemde, internet memleri ve kripto para kavramlarının birleşimi olarak ortaya çıkan “meme coin” terimi, internette yoğun ilgi gören ve yüksek etkileşim alan paylaşımlardan esinlenerek piyasaya sürülen, sosyal medyada etkili isimlerin dikkatini çekerek kısa sürede popüler hale gelen kripto paraları tanımlamaktadır. Meme coinlerin en belirgin özellikleri arasında belirli bir temaya sahip olmaları, genellikle mizahi amaçlarla yaratılmaları, ilgi çekici görsellerle ortaya çıkmaları ve geniş çevrimiçi kitlelere viral paylaşımlar yoluyla ulaşmaları bulunmaktadır. Dogecoin de, "Doge" olarak bilinen efsanevi bir internet memesinden ve Shiba Inu cinsi bir köpekten esinlenmiştir. 2013 yılında piyasaya sürülen Dogecoin, kısa sürede büyük ilgi görmüş ve özellikle Elon Musk’ın yoğun sosyal medya paylaşımları sayesinde milyar dolarlık değere ulaşan önemli bir kripto varlık haline gelmiştir (Başbuğ ve Lokmanoğlu, 2021).

Dogecoin, Billy Markus tarafından 2013 yılında "eğlenceli bir kripto para birimi" yaratma amacıyla oluşturulmuştur ve Jackson Palmer'in desteğiyle hayata geçirilmiştir. Dogecoin, Luckycoin'e dayanmakta olup, Mart 2014'te statik bir blok ödülü sistemine geçmiştir. Litecoin'den farklı olarak, Dogecoin'in blok süresi 1 dakikadır ve zorluk yeniden hedefleme süresi her blok için bir kezdır. Dogecoin'in toplam arzı başlangıçta 100 milyar olarak planlanmış, ancak daha sonra sınırsız arz ile enflasyonist bir yapıya geçilmiştir. Dogecoin, başlangıçta blok ödülleri rastgele dağıtan bir sisteme sahipken, 145,000. bloktan itibaren sabit ödüller verilmeye başlanmıştır. Dogecoin 2014'te 60 milyon dolarlık hacme sahipken, 2021'de ortası 10 milyar milyon dolarlık hacme ulaşmıştır (Chohan, 2021).

Dogecoin'in dolar türünden tarihsel fiyat grafiği, Şekil 2.8'de gösterilmektedir. Grafikte Dogecoin'in 2014-2024 yılları arasındaki fiyat hareketlerine göre, 2021'in başlarında büyük bir fiyat patlaması yaşanmış ve Dogecoin'in fiyatı 0,70 dolar seviyesine kadar çıkmıştır. Ardından hızlı bir düşüş yaşayan fiyatlar, 2022 ve 2023 yılları boyunca daha düşük ve yatay bir seyir izlemiştir. 2024'te tekrar bir toparlanma göstererek 0,17 dolar seviyesine ulaşmıştır. Dogecoin'in bu fiyat hareketleri yüksek volatilitesiyle şekillenen dalgalanmaları yansıtmaktadır.

Şekil 2.8

DOGE/USD Tarihsel Fiyat Grafiği



Kaynak: http-16 (Erişim tarihi: 27.05.2024)

### 2.3.4 Kripto paraların kullanım alanları

Blok zincir teknolojisi üzerine inşa edilmiş kripto paralar, geniş bir kullanım alanı sunmaktadır. Kripto paraların bazı yaygın kullanım alanlarına aşağıda yer verilmektedir.

**Ödeme ve Para Transferi:** İnternetin yaygınlığı arttıkça, geleneksel nakit ödemelerden çevrimiçi işlem yöntemlerine geçiş hızlandı ve küresel para sistemleri yeniden şekillenmiştir. Dijital gelişmeler ve teknolojik erişilebilirlik, tüketicilerin kripto para birimleri aracılığıyla çevrimiçi işlemlere katılımında da bir artışa neden olmuştur. Birçok kişi için kripto paranın çekiciliği sınır tanımayan doğasında, basitliğinde ve hızında yatmaktadır. Kripto paralar, sınır ötesi ödemeler ve para transferleri için hızlı, ucuz ve güvenli bir yöntem sunmakta ve mal ve hizmet alımlarında ödeme aracı olarak kullanılmaktadır (Shahzad vd. 2024).

**Yatırım ve Ticaret:** Kripto para birimleri, küresel finansal piyasalarda popüler bir varlık sınıfı haline gelmiş olup, piyasası hızlı bir gelişme göstermiş ve dünyanın dört bir yanına hem gelişmiş hem de gelişmekte olan ülkelere yayılmıştır. Bu durum, kripto para piyasasını dünyanın en hızlı büyüyen finansal piyasalarından biri yapmış ve kripto paralar, yatırımcılar için yeni bir varlık sınıfı olarak önemli bir yer almıştır. Yatırımcılar kripto borsaları aracılığıyla alım-satım işlemleri yapılabilir duruma gelmiştir (Almeida ve Gonçalves, 2023)

**Merkezi Olmayan Finans (DeFi):** DeFi uygulamaları, geleneksel finansal araçlara ihtiyaç duymadan borç verme, borç alma, ticaret ve sigorta gibi hizmetler sunar. Akıllı sözleşmeler aracılığıyla gerçekleştirilen bu işlemler, Ethereum gibi platformlar üzerinde çalışır. DeFi uygulamaları, merkezi olmayan uygulamalar (DApps) kullanarak mevcut

finansal hizmetleri kopyalar ve merkezi kurumlara ihtiyaç duymadan işlemleri gerçekleştirir. Merkeziyetsiz finansın en önemli özelliklerinden biri, bu hizmetlerin açık ve merkeziyetsiz olmasıdır. Örneğin, bir kullanıcı merkeziyetsiz borsalar aracılığıyla dolar sabitlenmiş varlıklar (stablecoins) satın alabilir, bu varlıkları merkeziyetsiz bir borç verme platformuna taşır ve faiz kazancı elde edilebilir (Schar, 2021).

**Dijital Kimlik ve Güvenlik:** Blok zincir teknolojisi, dijital kimlik doğrulama ve güvenlik için kullanılabilir. Kullanıcıların kimlik bilgilerini güvenli bir şekilde saklamaları ve paylaşmaları mümkün olmaktadır. Aynı zamanda tüm kripto paralar, kamu/özel anahtarlar ve dijital imzalar gibi Blok zincir güvenli mekanizmaları ile korunur. Kripto para birimlerinde, gönderenin ve alıcının kimliği yüksek derecede gizlidir (Murugappan vd. 2023).

**Oyun ve Dijital Koleksiyonlar:** Kripto paralar, oyun içi para birimi olarak kullanılabilir ve dijital koleksiyon ürünleri (NFT) alım-satımında kullanılabilir. NFT'ler, sanat eserleri, müzik, videolar ve diğer dijital varlıkların mülkiyetini temsil eder (Xu vd. 2022).

**Tedarik Zinciri Yönetimi:** Blok zinciri teknolojisi, ürünlerin tedarik zinciri boyunca izlenebilirliğini ve doğrulanabilirliğini artırır. Kripto paralar, bu süreçte ödeme ve işlem aracı olarak kullanılabilir (An vd. 2023). Ayrıca blok zincir teknolojisi ile tedarik zincirlerinde izlenebilirlik, köken bilgisi, mülkiyet bilgisi ve sahteciliği önleme gibi avantajlar sunabilen, zaman damgalı değişmez veri kayıtları serisi tutulmasına olanak vermektedir. Blok zincir tabanlı tedarik zincirlerinde ticaret, mülkiyet ve konum gibi olaylar, kriptografik karma işlemleriyle (hash) özetlenerek blok zincir işlemlerine eklenir. Bu işlemler, kriptografik karmalarla birbirine bağlanan bloklar hâlinde gruplanarak değiştirilemez hale getirilir (Malik vd. 2019).

**Akıllı Sözleşmeler:** Akıllı sözleşmeler, kod ile yazılan anlaşmalar olup, güvenli ve doğrulanabilir bir şekilde çalıştırılırlar ve bu sayede manipülasyon ve keyfi müdahaleler minimize edilir. Akıllı sözleşmeler, finansal hizmetlerin daha şeffaf, erişilebilir ve etkin bir şekilde sunulmasını sağlar (Schar, 2021). Akıllı sözleşmeler, önceden belirlenmiş koşullar sağlandığında otomatik olarak yürütülen anlaşmalardır. Ethereum gibi platformlar üzerinde çalışan bu sözleşmeler, çeşitli iş süreçlerini otomatikleştirir. (An vd. 2023).

**Mikro Ödemeler:** Kripto paralar, geleneksel ödeme sistemlerinin maliyet etkin olmadığı küçük miktartlı ödemeler için kullanılabilir. Kripto para işlemleri, potansiyel olarak neredeyse gerçek zamanlı mikro ödemelere olanak tanır. Örneğin, Kredi kartları

internetten bir ürün ya da hizmet indirmek üzere bir sentlik bir ücret için kullanılmak üzere tasarlanmamıştır. Kripto para sistemleri, mikro ödemeleri sorunsuz hale getirmeyi ve işletmelerin ürünlerinin gerçek zamanlı kullanım başına ödeme tüketimini sunmasını vaat eder. Örneğin, içerik üreticileri, oyun geliştiricileri ve hizmet sağlayıcılar mikro ödeme çözümleri sunabilir (Hardle vd. 2020).

Kripto para birimlerinin kullanım alanları sadece yukarıda bahsedilenler ile sınırlı değildir. Hem endüstride hem de akademide geniş çapta tartışılan bir konu haline gelmiştir. Online oylama, tıbbi kayıtlar, sigorta poliçeleri, mülk ve emlak kayıtları, telif hakları ve lisanslar gibi çeşitli gelişen uygulamalar bulunmaktadır (Wang vd. 2024)

### **2.3.5 Kripto paraların avantajları ve dezavantajları**

Kripto para kullanımının birçok avantajlara sahip olmasının yanı sıra dezavantajlarını da bulunmaktadır. Aşağıda Kripto paraların avantajları ve dezavantajları detaylı olarak incelenmektedir.

#### **2.3.5.1 Kripto paraların avantajları**

**Merkeziyetsizlik:** Kripto paralar, merkezi bir otoriteye bağlı olmayan, dağıtık bir ağ üzerinden çalışır. Bu, bankalar ve hükümetler gibi merkezi otoritelerin işlem üzerinde kontrol sahibi olmadığı anlamına gelmektedir. Böylece, hükümet müdahaleleri ya da bankaların iflas etmesi gibi risklerden bağımsız olarak işlem yapma olanağı sağlamaktadır (Nakamoto, 2008).

**Güven:** Blok zincir teknolojisi sayesinde, işlemler kriptografik yöntemlerle güvence altına alındığından blok zincirine eklenen her işlem, geri dönülmez şekilde kayıt altına alınmaktadır. Kripto paraların anonim olması yalnız yasa dışı işler için kullanan kişiler açısından değil, işlemler sırasında kişisel bilgilerini gizli tutmak isteyen kullanıcılar açısından da somut bir yarar sağlamaktadır (Üzer, 2017).

**Şeffaflık:** Blockchain, tüm işlemlerin halka açık bir defterde kaydedilmesini sağlar. Bu, işlemlerin şeffaf olmasını ve herhangi bir zamanda herkes tarafından doğrulanabilmesini mümkün kılar (Swan, 2015).

**Düşük İşlem Ücretleri:** Kripto para işlemleri, geleneksel bankacılık sistemlerine göre genellikle daha düşük ücretlerle gerçekleştirilir. Bu, özellikle uluslararası para transferlerinde belirgin hale gelir (Arıcı vd. 2022).

**Hızlı Transferler:** Geleneksel bankacılık işlemleri günler sürebilirken, kripto para transferleri dakikalar içinde tamamlanabilir (Üzer, 2017).

### 2.3.5.2 Kripto paraların avantajları ve dezavantajları

**Yüksek Oynaklık (Volatilite):** Kripto paralar, fiyatlarında kısa süreler içinde büyük dalgalanmalar yaşayabilir. Bu durum, yatırımcılar için önemli riskler doğurur. Bu oynaklık ellerindeki kripto paraları nakde çevirmek isteyecek ya da mal ve hizmet satın almak isteyecek kullanıcılar açısından sorun teşkil etmektedir. Ayrıca yüksek fiyat oynaklıklarına müdahale edecek merkezi bir otoritenin bulunmaması da riski daha da çok artırmaktadır (Üzer, 2017).

**Yasal Sorunlar:** Kripto paraların merkeziyetsiz oluşu kullanıcılar açısından avantaj sağlarken, hükümetler açısından dezavantaja sahip olmaktadır. Birçok ülkede tam olarak kripto para düzenlenmeleri yapılmadığı ve işlemlerin izlenemediği için kripto paraların kara para aklama, vergi kaçırma, dolandırıcılık, karaborsa gibi yasa dışı faaliyetler ve uluslararası terörizmin finansmanı için kullanılabilir olması, hükümetlerin en büyük endişelerinden biridir (Arıcı vd. 2022).

**Hacker Saldırıları:** Kripto para borsaları ve cüzdanları, siber saldırılara maruz kalabilir. Bu, kullanıcıların varlıklarının çalınmasına yol açabilir (Oosthoek ve Doerr, 2020).

**Geri Döndürülemez İşlemler:** Kripto para işlemleri geri döndürülemez olduğundan, bir kere gerçekleşen bir dolandırıcılık ya da hata düzeltilemez.

**Yüksek Enerji Tüketimi:** Özellikle Bitcoin gibi kripto paraların madenciliği, yüksek işlemci (CPU) gücüne ihtiyaç duyduğu için büyük miktarda enerji tüketir. Bu durum, çevrese olumsuz etki yaratmaktadır (Arıcı vd. 2022).

### 2.3.6 Kripto para borsaları

Son yıllarda dijital varlık ticareti büyük bir genişleme göstermiştir ve merkezi borsalar (CEX), kripto para ve para birimlerinin alım satımını kolaylaştırmak için ana mekanizma olarak hizmet vermektedir. Kripto para piyasalarındaki merkezi borsalar, geleneksel hisse senedi piyasalarına benzer bir altyapıyı koruyarak, likidite sağlama ve fiyat keşfi süreçlerini destekleyen protokoller ve işlem yürütme kuralları ile çalışmaktadır. Ancak, kripto para piyasalarının düzenlenmemiş yapısı, borsalardaki karşı taraf riski ile birleştiğinde yatırımcıları önemli kayıplara karşı savunmasız bırakmaktadır. Son yıllarda, Bitfinex ve Binance gibi önde gelen borsalardan milyarlarca doların hackerlar tarafından çalındığı kamu kayıtlarına geçmiştir. Bu tür sorunlar ve kripto paraların güvenli ve güvenilir bir şekilde değişimini sağlama ihtiyacı, merkeziyetsiz borsaların (DEX) yatırımcılar için gerçek bir alternatif olarak ortaya çıkmasına yol açmıştır. DEX'ler, kripto

paraların alım satımında bir aracı borsaya ihtiyaç duymadan doğrudan token değişimini kolaylaştırır. Bu durum, daha çeşitli kripto para ticaretine olanak tanıyarak kripto para ekosistemine daha aktif bir katılımı teşvik etmektedir (Aspris vd., 2021).

#### **2.3.6.1 Merkezi borsalar (CEX)**

Merkezi kripto para borsaları ya da CEX platformları, kullanıcıların dijital varlıkları, kripto paraları ya da NFT'leri para birimleri ya da diğer kripto paralar karşılığında alıp satmalarına ve ticaret yapmalarına imkan tanıyan çevrimiçi platformlardır. Bu borsalar, dijital varlıkların transferini ve kullanıcı fonlarının muhafazasını yöneten merkezi ve özel bir otorite tarafından sahiplenilmekte ve işletilmektedir. Merkezi kripto para borsaları, alıcılar ve satıcılar arasında bir aracı rolü üstlenmekte olup, komisyonlar ve işlem ücretleri aracılığıyla gelir elde etmektedir (Gan, 2023). Önemli merkezi borsalardan bazılarının aşağıda yer verilmektedir.

**Binance:** 2017 yılında Changpeng Zhao tarafından kurulan Binance, günlük 76 milyar dolarlık işlem hacmiyle dünyanın en büyük kripto borsasıdır ve Ağustos 2022 itibarıyla dünya çapında 90 milyon müşteriye sahiptir. Platform, kullanıcıların dijital varlıklarını alıp satabilecekleri ve depolayabilecekleri güvenilir bir kripto alanı olarak kendini kanıtlamıştır. Ayrıca, 350'den fazla kripto para birimi ve binlerce işlem çifti sunmaktadır (http-17).

**Coinbase Exchange:** 2012 kurulan borsa, kullanıcıların kripto para birimlerini kolayca alıp satabildikleri, takas edebildikleri ve saklayabildikleri, ABD merkezli bir kripto ticaret ve yatırım platformudur. Platform, temel işlemler, dijital cüzdan ve PayPal çekimleri için destek sunarak kullanıcı dostu ve başlangıç seviyesindekilere hitap edecek şekilde tasarlanmıştır. Daha ileri düzeydeki yatırımcılar için ise Coinbase Pro, daha profesyonel ticaret uygulamaları ve daha düşük ücretler sunmaktadır (http-18).

**Bybit:** kripto yatırımcıları için her seviyede ultra hızlı eşleştirme motoru, kaliteli müşteri hizmeti ve çok dilli topluluk desteği sunan profesyonel bir platform sağlayan merkezi bir kripto borsasıdır. Mart 2018'de kurulan Bybit, 10 milyondan fazla kullanıcıya ve kuruma hizmet vermekte olup, Spot ve Vadeli İşlemler ile Opsiyonlar gibi kripto türevleri, launchpad projeleri, NFT Pazaryeri ve daha fazlasını kapsayan 100'den fazla varlık ve sözleşmeye erişim sunmaktadır (http-19).

### **2.3.6.2. Merkeziyetsiz borsalar (DEX)**

Merkeziyetsiz Borsalar (DEX), kullanıcıların merkezi bir aracıya ihtiyaç duymadan kripto para birimlerini işlemelerine olanak tanır. Bu borsalar, işlemleri doğrudan blok zincirine kaydeden akıllı sözleşmeler aracılığıyla çalışır. Bir DEX'in temel bileşenleri arasında blok zincir platformları, karşı taraf keşif mekanizmaları, emir eşleştirme algoritmaları ve işlem takas protokolleri bulunur. DEX'lerin zincir üzerinde takas özelliği, kullanıcıların işlemlerini halka açık defterinde doğrulamasını sağlar ve merkezi borsalarda sıkça görülen hack olaylarına karşı koruma sunar (Aspris vd., 2021). Önemli merkeziyetsiz borsalardan bazılarına aşağıda yer verilmektedir.

**Uniswap:** Kasım 2018'de piyasaya sürülen ve en popüler kripto para merkeziyetsiz borsalarından biridir. Uniswap, Ethereum blok zincirinde çalışmakta olup, kullanıcılar arasında ERC-20 token'larını güvenli bir şekilde takas etmek için bir dizi akıllı sözleşme kullanmaktadır. Protokolün merkeziyetsiz yapısı, borsayı yöneten ve işleten tek bir merkezi otorite olmadığı anlamına gelir; bunun yerine, takas işlemleri eşler arası (P2P) bir şekilde gerçekleştirilir. Uniswap, toplam DEX işlem hacminin %46,5'inden fazlasını sahiptir ve Mayıs 2022'de toplam 1 trilyon dolarlık işlem hacmine ulaşmıştır (http-20).

**Raydium,** Solana tabanlı bir merkeziyetsiz borsa (DEX) olup, otomatik piyasa yapıcı modeline sahiptir. Kullanıcılar token takası yapabilir, ticaret yapabilir ve likidite sağlayıcıları olabilirler. Borsa, merkezi emir defteri modeline sahip bir başka Solana tabanlı borsa olan Serum'a likidite sağlar. Bu nedenle, Raydium kullanıcıları Serum'un emir akışına ve likiditesine erişebilir ve aynı şekilde Serum kullanıcıları da Raydium'un likiditesinden yararlanabilir. Ayrıca, platform, bir token takasının likidite havuzundan mı yoksa Serum emir defterinden mi geçerek daha ucuz olduğunu otomatik olarak belirleyen en iyi fiyat takas özelliği sunduğunu iddia etmektedir (http-21).

**PancakeSwap:** 2020 yılında piyasaya sürülen BNB Chain üzerinde BEP-20 token takaslarına olanak tanıyan merkeziyetsiz borsadır. BNB Chain ekosisteminin en büyük borsası olup, piyasa payı açısından en üst sıralarda yer alan DEX'lerden biridir. Kullanıcılar likidite sağlayıcısı olarak likidite havuzuna katkıda bulunabilir ve bunun karşılığında LP tokenları alabilirler. Bu tokenlar, kullanıcıları borsanın işlem ücretlerinden bir pay alma hakkı sağlamaktadır (http-22).

### 2.3.7 Kripto paralara ülkelerin yaklaşımları ve düzenlemeleri

Kripto paraların küresel ekonomide hızla yükselişi, çeşitli ülkelerin bu yeni finansal teknolojiye yönelik yaklaşımlarını ve düzenlemelerini belirlemelerine ihtiyaç duymuştur. Her ülke, kendi ekonomik, siyasi ve sosyal dinamiklerine göre farklı politikalar üretmekte ve kripto paraların küresel uyumu ve regülasyonu üzerinde çalışmalar yapmaktadır. Dünya genelinde Çin, İran ve Rusya gibi bazı ülkeler kripto paraları yasaklarken yaklaşık 111 ülke kripto işlemlerine izin vermektedir (Crumbley vd., 2023).

#### 2.3.7.1 Dünyada kripto paralara yaklaşımlar ve düzenlemeler

**Amerika Birleşik Devletleri**, kripto paralara yasaklayıcı değil fakat parçalı bir düzenleyici yaklaşım sergilemektedir. Federal düzeyde henüz kapsamlı bir kripto yasası bulunmamakla birlikte, farklı kurumlar kripto varlıklara kendi yetki alanları içinde müdahale etmektedir. Örneğin, Menkul Kıymetler ve Borsa Komisyonu (SEC) bazı token'ları menkul kıymet sayıp kayıt dışı ihraçlara dava açarken, Emtia Vadeli İşlemler Komisyonu (CFTC) büyük kripto paraları emtia olarak görmektedir. Düzenleyici çerçevenin bu şekilde dağınık olması, kripto piyasasında belirsizlik yaratmış ve regülasyonların görece yavaş ilerlemesine neden olmuştur (Poynton, 2022). Federal kurumlar dışında, eyaletler düzeyinde de farklı yaklaşımlar söz konusudur; örneğin New York eyaleti BitLicense lisans rejimiyle sıkı kurallar uygularken Wyoming gibi eyaletler kripto dostu yasalar çıkarmıştır. Bu durum, eyaletler arasında kripto varlıkların tanımı ve vergilendirilmesinde farklı uygulamalara yol açmıştır (Duchow, 2025).

Kara para aklama (AML) ve müşteri tanıma (KYC) yükümlülükleri ABD'de kripto sektörüne erken dönemde uygulanmaya başlamıştır. Hazine Bakanlığı'na bağlı FinCEN, 2013'ten itibaren kripto borsalarını para hizmeti işletmesi olarak tanımlamış ve müşteri kimlik doğrulama, şüpheli işlem bildirme gibi yükümlülükler getirmiştir. Kripto borsaları ve araçlar, Banka Gizlilik Yasası kapsamında AML/KYC kurallarına uymak zorundadır. Bu çerçevede ABD, kripto para platformlarını geleneksel finansal kuruluşlara benzer şekilde denetleyerek terörizmin finansmanı ve kara para aklamayla mücadele etmeye çalışır. Ancak düzenlemelerin bütüncül olmayışı, bazı platformların regülasyon boşluklarından yararlanmasına (ör. faaliyetlerini başka ülkelerde sürdürme) yol açabilmektedir (Duchow, 2025).

**Çin**, kripto paralara karşı en katı yaklaşımı benimsemiş ülkelerden biridir. 2013'ten itibaren kripto işlemlerine sınırlamalar getirilmiş, 2017'de ICO'lar yasaklanmış, 2021'de

ise kripto ticareti tamamen yasa dışı ilan edilmiştir. Ülke aynı zamanda çevresel nedenlerle Bitcoin madenciliğini de yasaklamıştır. Çin, bu politikalarıyla sermaye kontrolünü sağlamak, finansal istikrarı korumak ve yasa dışı faaliyetleri engellemek istemektedir (Hu, 2024; Cheng, 2024).

**Almanya**, kripto varlıkları finansal araç olarak tanımış ve lisans zorunluluğu ile sıkı bir düzenleme getirmiştir. 2020 itibariyle yürürlüğe giren yasa ile kripto saklama hizmeti sunanlar denetime tabi tutulmuştur. Vergilendirme açısından bir yıl elde tutulan kripto kazançları vergiden muaftır. Kara para aklama ve müşteri tanıma kuralları kapsamlı biçimde uygulanmakta ve yatırımcı koruması ön plandadır. Bu sayede Almanya hem inovasyonu destekleyen hem de güvenliği sağlayan bir sistem geliştirmiştir (http-23).

**El Salvador**, Eylül 2021’de Bitcoin’i resmî para birimi olarak kabul eden ilk ülke olmuştur. Bu yasa ile Bitcoin tüm işletmeler için yasal ödeme aracı haline gelmiştir. Hükümet, bu dönüşümü teşvik için dijital cüzdan (Chivo) dağıtmış, vatandaşlara Bitcoin vermiştir. Ancak bu yaklaşım, yüksek volatilité ve düzenleme eksikliği nedeniyle IMF gibi kurumlarca eleştirilmiştir. Regülasyon çerçevesi zamanla genişletilse de yatırımcı koruması zayıf kalmıştır (Quirk, 2021).

**Avrupa Birliği (AB)**, kripto varlıkları düzenlemek için kapsamlı “Kripto Varlık Piyasaları Regülasyonu’nu (MiCA) 2023’te kabul etmiştir. MiCA, ihraççılar ve kripto hizmet sağlayıcıları için lisanslama, rezerv, bilgi açıklama ve yatırımcı koruma yükümlülükleri getirmektedir. AML/KYC yükümlülükleri 5. Kara Para Aklama Direktifi ile yaygınlaştırılmış, stablecoinler ve cüzdan sağlayıcılar da denetim kapsamına alınmıştır. (http-23).

### **2.3.7.2 Türkiye’de kripto paralara yaklaşımlar ve düzenlemeler**

Türkiye, son yıllarda kripto paralara olan ilginin artmasıyla birlikte bu alanda çeşitli düzenlemeler yapmaya başlamıştır. Türkiye’nin kripto paralara yönelik düzenlemeleri hem kullanıcıların korunması hem de finansal sistemin istikrarının sağlanması amacıyla şekillendirilmektedir.

Türkiye Cumhuriyet Merkez Bankası (TCMB) tarafından 16 Nisan 2021’de yayımlanan “Ödemelerde Kripto Varlıkların Kullanılmamasına Dair Yönetmelik” kripto varlıklara ilişkin ilk resmî düzenleme yapılmıştır. Bu yönetmelik ile kripto varlık kavramı “dağıtılmış defter teknolojisi ya da benzer teknoloji kullanılarak sanal ortamda oluşturulan ve dijital ağlar üzerinden dağıtılan, ancak itibari para, kaydi para, elektronik

*para, ödeme aracı, menkul kıymet ya da diğer sermaye piyasası aracı olarak nitelendirilemeyen gayrimaddi varlıklar*” şeklinde tanımlanmıştır. Böylece kripto paralar ilk kez resmî bir metinde tanımlanmış, aynı zamanda bu varlıkların ödeme amaçlı kullanılması yasaklanmıştır. Yönetmelik, kripto varlıkların doğrudan ya da dolaylı şekilde ödemelerde kullanılmasını ve ödeme hizmeti kuruluşlarının kripto varlık kullanımına yönelik hizmet sunmasını yasaklayarak, finansal sistemde kripto paraların ödeme aracı olmasının önüne geçmiştir.

Bu düzenleme, kripto varlıkların alım satımını ya da elde tutulmasını yasaklamamış, yalnızca ödeme alanında kullanımını kısıtlamıştır. Bu yaklaşım, kripto paraların fiyat oynaklığı, tüketici korunması, suç amaçlı kullanım gibi risklerine karşı önleyici bir tedbir olarak değerlendirilmektedir. TCMB, 16 Nisan 2021 tarihli 2021-17 sayılı “*Ödemeler Alanına İlişkin Basın Duyurusu*” ile kripto varlıkların denetimsiz yapısı, yüksek volatilitesi, yasa dışı faaliyetlerde kullanılabilme potansiyeli ve geri dönülemez işlemler gibi risklerini söz konusu düzenlemeye gerekçe göstermiştir.

TCMB’nin bu düzenlemesinden hemen sonra Mali Suçları Araştırma Kurulu (MASAK), 01 Mayıs 2021 tarihli 31471 sayılı Resmî Gazete’de yayımlanan yönetmelik değişikliğiyle, *Suç Gelirlerinin Aklanmasının ve Terörün Finansmanının Önlenmesine Dair Tedbirler Hakkında Yönetmelik*” kapsamına kripto varlık hizmet sağlayıcıları da eklemiştir. Bu durumun, kripto para alım satımına aracılık eden borsalar ve benzeri hizmet sağlayıcılar, tıpkı bankalar, finans kuruluşları ya da ödeme kuruluşları gibi MASAK düzenlemelerine tabii olduğu anlamı taşımaktadır. Nitekim de 04 Mayıs 2021 tarihinde de MASAK tarafından “*Kripto Varlık Hizmet Sağlayıcılar Rehberi*” yayımlanmıştır. Bu rehber ile, kripto şirketleri için müşteri kimlik tespiti, şüpheli işlem bildirimi, bilgi ve belge verme, devamlı bilgi bildirme ve kayıt tutma gibi yükümlülükler yasal zorunluluk haline getirilmiştir.

Türkiye’deki ilk kripto varlık yasası ise 26 Haziran 2024’te TBMM Genel Kurulu’nda kabul edilen ve 2 Temmuz 2024 tarihinde Resmî Gazete ’de yayımlanan 7518 sayılı “*Sermaye Piyasası Kanununda Değişiklik Yapılmasına Dair Kanun*” ile kripto varlıklara dair temel çerçeve oluşturmuştur. Bu kanun ile “*kripto varlık*”, “*cüzdan*”, “*kripto varlık hizmet sağlayıcı*”, “*kripto varlık saklama hizmeti*” ve “*platform*” gibi kavramlar ilk kez tanımlanmıştır. Bu kanunla Türkiye, genel kripto para politikasını yasaklayıcı bir politikadan ziyade düzenleyici ve denetleyici bir politika belirlemiştir. Kanunla platformlarda fiyatların serbestçe oluşacağı kayıt altına alınmıştır Ancak, SPK yurt dışı

piyasalarda yaygın olarak işlem göre ve fiyatı yurt dışı piyasalarda da oluşan kripto varlıklara ilişkin işlemler hariç, platformlarda gerçekleştirilen işlemlerin makul ve ekonomik bir gerekçeyle açıklanamayan ve işlemlerin güven, açıklık ve istikrar içinde çalışmasını bozacak nitelikteki eylem ve işlemlere kanun gereğince müdahale edebileceği belirtilmiştir.

7518 sayılı Kanun’la kripto varlık hizmet sağlayıcıların kurulabilmesi ve faaliyete başlaması için SPK’dan izin alınması zorunlu hale getirilmiştir. Bunların kuruluşlarına ve faaliyete başlamalarına, ortaklarına, yöneticilerine, çalışanlarına, organizasyonuna, sermayelerine ve sermaye yeterliliğine, yükümlülüklerine, bilgi sistemleri ve teknolojik altyapılarına, pay devirlerine, yapabilecekleri faaliyetlere, faaliyetlerinin geçici ya da sürekli olarak durdurulmasına ilişkin esaslar SPK tarafından çıkarılacak yönetmelikle belirlenir. Ayrıca SPK’dan izin almaksızın kripto varlık hizmet sağlayıcı olarak faaliyet yürüttüğü tespit edilen gerçek kişiler ve tüzel kişilerin yetkilileri üç yıldan beş yıla kadar hapis ve beş bin günden on bin güne kadar adli para cezası ile cezalandırılmasına da kanunda yer verilmiştir.

Kanunda yatırımcıların kripto para alım ve satım kazançlarının vergilendirilmesi ile ilgili bir düzenleme bulunmamaktadır. Halihazırda kripto para kazançlarının vergilendirilmesi konusunda belirsizlik devam etmektedir. Ancak, kripto para platformlarının faiz gelirleri hariç tüm gelirlerinin yüzde biri SPK, yüzde biri ise blok zincir ve ilgili bilişim teknolojilerinin geliştirilmesinde kullanılmak üzere TÜBİTAK bütçesine gelir olarak kaydedilmesi kanun ile belirlenmiştir.

### **3 TAHMİN MODELİNDE KULLANILAN MAKROEKONOMİK, DUYARLILIK VE TEKNİK GÖSTERGELER**

Bu bölümde, kripto para birimlerinin fiyatlarının tahmin edilmesinde kullanılan değişkenler detaylı biçimde ele alınmıştır. Bu kapsamda, makroekonomik göstergeler, yatırımcı duyarlılığına ilişkin göstergeler ve finansal teknik analiz göstergeleri açıklanmıştır.

#### **3.1 Makroekonomik Göstergeler**

Bu çalışmada kullanılan makroekonomik göstergeler; spot altın fiyatı (XAU), ham petrol vadeli işlem fiyatı, faiz oranları (ABD FED), enflasyon (ABD Tüketici Fiyat Endeksi), ABD doları endeksi (DXY) ve ekonomi politikası belirsizliği (EPU) olarak belirlenmiştir. Bu bölümde, söz konusu göstergelere ilişkin açıklamalara yer verilecek

olup, bu göstergelerin araştırma kapsamına dâhil edilmesinde dikkate alınan akademik kaynaklara ise “5.3 Araştırmanın Evreni, Örneklemi ve Sınırlılıkları” başlıklı bölümde yer verilmiştir.

### **3.1.1 Spot altın fiyatı (XAU)**

Spot altın piyasası genellikle altının fiziksel olarak hemen teslimle alınıp satıldığı piyasayı ifade eder. İşlemlerin ödemesi ve teslimatı kısa süre içinde (genellikle işlem gününden iki iş günü sonra) gerçekleşir. Spot altın fiyatı, altının anlık piyasa değerini gösterir ve uzun vadeli arz-talep eğilimleri bu fiyatın en önemli belirleyicisidir (Polat, 2013). Ekonomik belirsizlik dönemlerinde, spot altın güvenli liman özelliğiyle öne çıkar. Yatırımcılar, enflasyon, döviz kuru dalgalanmaları ve faiz oranlarındaki değişimlere karşı korunma amacıyla altına yönelirler. Altının korunma aracı olarak görülmesi fikri, itibari para birimlerinin aksine altının arzının neredeyse sabit olması gerçeğiyle bağlantılıdır. Ancak bu özellik, birçok başka emtia tarafından da paylaşılmaktadır. Bu durum, altın talebini artırarak fiyatların yükselmesine neden olur ve finansal piyasalarda volatilitateyi etkiler (Barsky vd., 2021)

### **3.1.2 Ham petrol vadeli işlem fiyatı (WTI)**

Günümüzde enerji kaynakları arasında kritik bir öneme sahip olan petrol, ülkelerin ekonomileri üzerinde ciddi etkiler yaratmaktadır. Bunun temel sebebi, petrolün birçok sektörde temel enerji kaynağı olarak kullanılmasıdır. Petrol fiyatlarındaki dalgalanmalar, işletmeler için önemli bir maliyet unsuru olduğundan piyasalar açısından yakından takip edilmektedir. Petrol fiyatlarındaki artış, firmaların maliyetlerini yükselterek genel fiyat seviyesinin yukarı yönlü hareket etmesine yol açmaktadır. Bu durum, hem genel satın alma gücünü düşürmekte hem de talepte azalmaya neden olmaktadır. Sonuç olarak, ekonomik olumsuzluklar üretim ve diğer yatırım alanlarını da olumsuz etkilemektedir (Kılıç, 2022).

Aynı zamanda ham petrol, ulusal ekonomik kalkınma için önemli bir stratejik kaynaktır ve küresel ekonomik ve finansal sistemlerin istikrarının korunmasında hayati bir rol oynamaktadır. Bu nedenle, yatırımcılar, devlet kurumları ve diğer paydaşlar açısından, ham petrol fiyat oynaklığını etkileyebilecek çeşitli faktörlerin araştırılması büyük önem taşımaktadır. Öte yandan, ham petrol fiyatları da enflasyon, kişisel tüketim ve iş gücü arzı gibi kanallar üzerinden toplumsal ve ekonomik gelişmeleri etkileyerek, politika

yapıcıların kararlarını şekillendirir ve ekonomik politika belirsizliğini artırabilir (Zhang ve Yan, 2020).

### **3.1.3 Faiz oranları (ABD FED)**

ABD Merkez Bankası (FED), faiz oranlarını belirleyerek para politikasını uygular. Temel amacı ise enflasyonu kontrol altında tutarak fiyat istikrarını sağlamak ve maksimum istihdamı desteklemektir. FED'in para politikası, ekonomideki toplam mal ve hizmet talebinin büyümesini teşvik ederek ya da sınırlandırarak işlevsellik kazanır. Ekonomik toplam talebin, üretim kapasitesine göre yavaşladığı dönemlerde, işsizlik oranlarında artış gözlemlenebilirken, enflasyonist baskılar düşüş eğilimi gösterir. Bu tür durumlarda FED, faiz oranlarını düşürerek uyguladığı genişlemeci para politikası aracılığıyla toplam talebi canlandırabilir ve ekonomik istikrarı destekleyebilir. Buna karşılık, toplam talebin üretim kapasitesinin üzerine çıktığı, yani ekonomik faaliyetlerin aşırı arttığı koşullarda, işsizlik oranları aşırı düşebilir ve enflasyonist artabilir. Bu gibi durumlarda ise, FED faiz oranlarını artırarak sıkı para politikası uygular. Böylece talep düzeyini daha sürdürülebilir bir seviyeye çekmeyi ve fiyat istikrarını korumayı amaçlar. Bu çerçevede, FED'in para politikasını gevşetme ya da sıkılaştırma yönündeki kararları, istihdam ve enflasyon hedefleri doğrultusunda ekonomik dengeyi sağlama işlevi görmektedir (Federal Reserve Board, 2021).

### **3.1.4 Enflasyon (ABD tüketici fiyat endeksi (CPI))**

Tüketici Fiyat Endeksi (TÜFE), hane halkları tarafından satın alınan tüketim mal ve hizmetlerinin tahmini ortalama fiyat düzeyini ifade eder. TÜFE, belirli bir mal ve hizmet grubuna ait fiyat değişimlerini esas alarak, bu ürünlerin fiyatlarında meydana gelen artış ve azalışları aylık bazda ölçer. Bu endeks, önceden belirlenmiş bir mal grubundaki fiyat değişimlerinin ağırlıklı ortalaması alınarak hesaplanır. TÜFE, perakende düzeyindeki fiyat değişimlerinin en önemli göstergelerinden biri olarak kabul edilir (Subhani, 2009). TÜFE'deki değişimin doğru bir şekilde öngörülmesi, ekonomiyle ilgili birçok alan açısından büyük önem taşır. Buna maliye politikası, finansal piyasalar ve verimlilik gibi konular örnek verilebilir (Nyoni, 2019).

### **3.1.5 ABD dolar endeksi (DXY)**

Dolar Endeksi (DXY), ABD dolarının başlıca para birimleri karşısındaki değerini gösteren bir göstergedir. Bretton Woods sisteminin sona ermesinden sonra serbest döviz

kuru rejimine geçilmesiyle birlikte, doların ve döviz kurlarının genel durumunu belirlemek amacıyla oluşturulan DXY, ilk kez 1971 yılında hesaplanmaya başlanmış ve 6 gelişmiş ülke para biriminin döviz kurlarının geometrik ortalamasıyla hesaplanan kritik bir endekstir (Erek, 2009).

DXY, Forex ve hisse senedi piyasalarında işlem yapan yatırımcılara yön gösterir. Örneğin, DXY'nin yükselmesi, dolarla ilişkili tüm döviz kurlarında artış yaşanabileceğine işaret ederken, endeksin düşmesi FED'in faiz oranı kararlarında önemli değişikliklere gidebileceğinin bir sinyali olabilir (Erek, 2009).

### **3.1.6 Ekonomi politikası belirsizliği (EPU)**

Ekonomik ve politik belirsizlikler yatırımcıların, karar alıcıların ve tüketicilerin davranışlarında değişikliklere neden olduğu bilinen bir gerçek olmakla birlikte ülkelerin ekonomik performanslarının olumsuz etkilenmesine neden olabilir. Hane halkı (tüketiciler) artan ekonomik politik belirsizlik karşısında harcamalarını kısma ve tasarruflarını artırma konusunda daha ihtiyatlı davranarak davranışlarını değiştirebilirler (Nazlıoğlu, 2024). Ekonomiler üzerinde önemli etkiler yaratan belirsizliğin ölçülmesine yönelik ilk çalışmalardan biri, Baker, Bloom ve Davis (2012) tarafından ABD için geliştirilmiş olan Ekonomi Politikası Belirsizliği Endeksi'dir (Economic Policy Uncertainty – EPU). Bu endeks, 1985 yılından itibaren ABD'nin önde gelen 10 gazetesindeki makalelerde geçen, ikisi “ekonomi” ve “belirsizlik” olmak üzere toplam üçlü terimlerin sıklığını dikkate alarak oluşturulmuştur. Üçlü terimler, örneğin “millet meclisi”, “bütçe açığı”, “merkez bankası”, “yasama”, “düzenleme” veya “Beyaz Saray” gibi bir veya daha fazla kelimedenden meydana gelmektedir. Daha sonra benzer yöntem kullanılarak başka ülkeler için de ekonomi belirsizliği endeksleri geliştirilmiştir (Gemici, 2020).

Ekonomik ve politik belirsizliklerin, yatırımcıların, karar vericilerin ve tüketicilerin davranışlarını önemli ölçüde etkilediği bilinmektedir. Bu tür belirsizlikler, ülkelerin ekonomik performanslarını olumsuz yönde etkileyebilir. Özellikle hane halkları, artan ekonomik ve politik belirsizlik ortamında harcamalarını azaltma ve tasarrufa yönelme eğilimi göstererek daha temkinli bir tutum sergileyebilirler (Nazlıoğlu, 2024). Ekonomiler açısından etkisi oldukça önemli olan belirsizliğin ölçülmesi konusunda ilk çalışmalardan biri Baker, Bloom ve Davis (2012) tarafından ABD için geliştirilen Ekonomi Politikası Belirsizliği Endeksidir (EPU). Söz konusu endeks, ABD'nin önde

gelen 10 gazetesinde yer alan ve “ekonomi” ile “belirsizlik” kelimelerinin yanı sıra “millet meclisi”, “bütçe açığı”, “merkez bankası”, “yasama”, “düzenleme” veya “Beyaz Saray” gibi politika ile ilişkili terimlerin aynı anda geçtiği haber makalelerinin sıklığına dayanarak hazırlanmıştır. Endeks, 1985 yılından itibaren aylık olarak oluşturulmuştur. Bu yöntem, daha sonraki yıllarda farklı ülkelere uygulanarak, benzer yapıda ülke bazlı ekonomik belirsizlik endekslerinin oluşturulmasına olanak sağlamıştır (Gemici, 2020).

### **3.2 Yatırımcı Duyarlılığı Göstergeleri**

Bu çalışmada kullanılan yatırımcı duyarlılığı göstergeleri, hisse senedi belirsizliği (VIX), petrol piyasası belirsizliği (OVX), Bitcoin Korku ve Açgözlülük Endeksi ile Google Arama Eğilimleri olarak belirlenmiştir. Bu bölümde, söz konusu göstergelere ilişkin açıklamalara yer verilecek olup, bu göstergelerin araştırma kapsamına dâhil edilmesinde dikkate alınan akademik kaynaklara ise “5.3 Araştırmanın Evreni, Örneklemi ve Sınırlılıkları” başlıklı bölümde yer verilmiştir.

#### **3.2.1 Hisse senedi belirsizliği (VIX)**

Şikago Opsiyon Borsası (CBOE) tarafından 1993 yılından itibaren hesaplanan hisse senedi belirsizliği (VIX), günümüzde S&P 100 endeksi üzerinden hesaplanmaktadır. VIX endeksinin hisse senetleri opsiyon fiyatlarından alınmakta ve alım ile satım opsiyonları arasındaki fark alınarak bulunmaktadır. VIX değerleri, alım ile satım opsiyon fiyatları arasındaki fark yüksek ise yüksek çıkmakta, fark düşük ise düşük çıkmaktadır. %30’ un üzerinde bir VIX endeksi çıkarsa, piyasada belirsizliğin fazla olduğu anlamına gelir. Eğer VIX endeksi %20’nin altına düşer ise, piyasadaki riskin azaldığı anlamı taşır. VIX endeksi özellikle kriz dönemlerinde endeksin artış göstermesiyle korkuya neden olduğu için “Korku Endeksi” olarak da adlandırılmaktadır. Amerikan ekonomisi hisse senedi piyasalarının en önemli göstergelerinden biri olması nedeniyle VIX endeksi, diğer ülkelerin finansal piyasaları tarafından da yakından takip edilmektedir (Ercan ve Demirbaş, 2020).

#### **3.2.2 Petrol piyasası belirsizliği (OVX)**

Ham petrol, reel ekonomi açısından büyük öneme sahiptir. Petrol fiyatlarındaki değişimlerin reel ekonomi ve finansal piyasalar üzerindeki etkileri, birçok araştırmaya konu olmaktadır. Opsiyon fiyatlaması, portföy optimizasyonu ve risk değerlemesi hesaplamalarında hayati bir girdidir. Bu nedenle, petrol piyasası katılımcıları, finansal

yatırımcılar ve politika yapıcılar için petrol volatilitesine dair doğru tahminler gerekmektedir. OVX, VIX metodolojisinin petrol opsiyonlarına uygulanmasıyla elde edilmiştir ve Mayıs 2007’den beri yayımlanmaktadır. Bu endeks, ham petrol getirilerinin 30 günlük volatilitesine ilişkin piyasa beklentisini yansıtır (Chen vd., 2018).

### 3.2.3 Bitcoin korku ve açgözlülük endeksi

Kripto para piyasalarının davranışları büyük ölçüde yatırımcı duyarlılığına bağlıdır. Yatırımcılar, fiyatların yükseldiği dönemlerde genellikle aşırı açgözlü davranarak fırsatı kaçırma korkusu (FOMO) yaşarken fiyatların düştüğü dönemlerde ise irrasyonel şekilde panik satışları gerçekleştirebilirler. Bu bağlamda, Korku ve Açgözlülük Endeksi, yatırımcıların bu tür duygusal aşırılıklardan kaçınmalarına yardımcı olmayı amaçlamaktadır. Endeks, iki temel varsayıma dayanır: Aşırı korku, yatırımcıların fazla endişeli olduğunu ve bunun potansiyel bir alım fırsatı sunduğunu gösterebilir. Aşırı açgözlülük ise piyasanın yakın zamanda bir düzeltme sürecine girebileceğine işaret edebilir. Bu çerçevede, endeks piyasa duyarlılığını 0 ile 100 arasında bir ölçekte sayısal olarak ifade eder; burada 0 "Aşırı Korku" 100 ise "Aşırı Açgözlülük" anlamına gelir. Bitcoin piyasasındaki duyguyu ölçmek için endeks beş ana veri kaynağından toplanan bilgilerle oluşturulmaktadır. Kullanılan veri kaynakları ise aşağıda ayrıntılı şekilde açıklanmıştır (http-24);

**Volatilité (%25)**, Bitcoin’in güncel volatilitesi ve maksimum değer kayıpları, son 30 ve 90 günlük ortalamalarla karşılaştırılarak ölçülür. Oynaklıktaki alışılmadık artışlar, piyasadaki korku düzeyinin yüksek olduğuna işaret eder.

**Piyasa Momentumu ve Hacim (%25)**, Güncel işlem hacmi ve fiyat momentumu, yine 30 ve 90 günlük ortalamalarla karşılaştırılır. Yükselen piyasalarda gözlenen yüksek alım hacimleri, genellikle piyasanın aşırı açgözlü veya boğa (yükseliş beklentili) davrandığını gösterir.

**Sosyal Medya (%15)**, Twitter’da Bitcoin ile ilgili hashtag’ler üzerinden atılan gönderiler analiz edilerek, etkileşim oranlarına ve zaman içerisindeki değişimlere bakılır. Yüksek etkileşim oranları, kamuoyunun artan ilgisini ve dolayısıyla açgözlülüğü işaret eder.

**Anketler (%15) – (Şu Anda Durdurulmuştur)**, Strawpoll.com üzerinden haftalık olarak düzenlenen kamuoyu anketleriyle piyasa algısı ölçülmekteydi. Anket sonuçları, başlangıç aşamasında faydalı olmakla birlikte, artık endeks hesaplamalarında aktif olarak kullanılmamaktadır.

**Hakimiyet(%10)**, Bitcoin hâkimiyetindeki artış, yatırımcıların daha az riskli varlıklara yöneldiğini, Bitcoin'in kripto paralar için güvenli bir liman haline geldiğini ve piyasada korkunun arttığını gösterebilir. Tersine, Bitcoin dışı coin'lere yönelim arttığında bu durum risk iştahının yükseldiğini ve açgözlü bir piyasa ortamını işaret eder.

**Arama Trendleri (%10)**, Google Trends verileri kullanılarak, Bitcoin ile ilgili arama sorgularındaki değişiklikler analiz edilir. Özellikle ani artışlar veya dikkat çekici yeni arama terimleri (örneğin, bitcoin fiyat manipülasyonu) piyasa korkusunun sinyali olarak değerlendirilir ve endekse dahil edilir.

### 3.2.4 Google arama eğilimleri

Belirli bir anahtar kelimenin ya da konunun Google'da ne kadar popüler olduğunu gösteren ve kullanıcıların belirli bir terimi aramaya olan ilgisini yansıtabilen bir araç olan Google Trends, belirli bir coğrafi bölgede kullanıcıların Google arama motoruna girdikleri sorguların hacmini zamana bağlı olarak gösteren bir zaman serisi endeksidir. Bu sorgu indeksi, sorgu payına dayanmaktadır. Başka bir ifadeyle, belirli bir bölgede belirli bir dönemde yapılan tüm aramalar arasından hedeflenen arama teriminin aldığı pay hesaplanmaktadır. Bu hesaplama sonucunda, incelenen zaman aralığındaki en yüksek sorgu payı 100 olacak şekilde normalize edilirken, zaman serisinin başlangıcındaki sorgu payı sıfır kabul edilerek normalize edilmektedir. Sorgular, geniş eşleşme prensibiyle değerlendirilir. Örneğin kullanılmış otomobiller gibi ifadelerin, otomobil terimiyle ilişkili sorgu indeksi hesaplamalarına dahil edilmektedir. Google Trends verileri, 1 Ocak 2004 tarihine erişilebilecek kadar geri dönük sunulmaktadır (Choi ve Varian, 2012).

### 3.3 Teknik Analiz Göstergeleri

Çalışmada kullanılan finansal teknik göstergeler, göreceli güç göstergesi (RSI), hareketli ortalama yakınsama/uzaklaşma (MACD), stokastik osilatör, İlerleme-düşüş çizgisi (ADX), fiyat değişim oranı (ROC), Denge hacmi (OBV), hareketli ortalamalar, Williams birikim ve dağılımı (WAD) olarak belirlenmiştir. Bu bölümde, söz konusu göstergelere ilişkin açıklamalara yer verilecek olup, bu göstergelerin araştırma kapsamına dâhil edilmesinde dikkate alınan akademik kaynaklara ise “5.3 Araştırmanın Evreni, Örneklemi ve Sınırlılıkları” başlıklı bölümde yer verilmiştir.

### 3.3.1 Göreceli güç göstergesi (RSI)

Amerikalı analist J. Welles Wilder tarafından geliştirilen göreceli güç endeksi, grafikler üzerinde 0 ile 100 arasında değişen değerler vermekte ve fiyatların gücünü ölçmekte kullanılmaktadır. RSI trend yönünü belirlemede de teknik analistlere yardımcıdır. RSI indikatörü daha çok kısa ve orta vadeli analizlerde kullanılmaktadır (Münyas ve Atasoy, 2021).

Fiyat grafiği ile RSI arasında uyumlu bir görünüm bulunur. RSI indikatörünün, kısa sürede tepki vermesinden dolayı zaman zaman fiyatlardan önce hareket ettiği görülebilir. RSI, 0 ile 100 arasında değişen bir göstergedir. Referans değerleri 30-70 seviyeleridir. 30 referans değerinin altını aşırı satım bölgesini gösterir ve trendin yukarı (al sinyali) dönebileceğini, 70 referans değeri üzerindeki hareketler aşırı alım bölgesini gösterir ve trendin aşağı (sat sinyali) dönebileceği sinyalini verir. RSI için önerilen gün sayısı 14'tür. 9 günlük ve 20 günlük RSI göstergesi yaygın olarak kullanılır. Gün sayısı azaltıldıkça göstergenin oynaklığı artar. RSI sıfır ile yüz (0-100) arasında değişen bir göstergedir. RSI göstergesinin yorumlanmasında uyumsuzluklara dikkat edilmelidir. Fiyat grafiği yeni bir tepe yaparken RSI yeni bir tepe yapmıyorsa, ya da fiyat yeni bir dibe ulaştığında RSI yeni bir dip yapmıyorsa, bu hareketin sona ermek üzere olduğu biçiminde yorumlanır. RSI aşağıdaki formülle hesaplanır (Yaslıdağ, 2024).

RSI formülü;

$$RSI=100-[100/1+(U/D)]$$

RSI-Relatif Güç Göstergesi

U=Yükseliş günlerinin farklarının ortalaması

D=Düşüş günlerinin farklarının ortalaması

### 3.3.2 Hareketli ortalama yakınsama/uzaklaşma (MACD)

MACD (Hareketli Ortalama Yakınsama/Uzaklaşma), fiyatlar ile hareketli ortalamalar arasındaki ilişkiyi gösteren bir trend göstergesi kategorisindedir. MACD, 1970'lerde Gerald Appel tarafından tanıtılmıştır. Bu gösterge, 26 ve 12 günlük üstel hareketli ortalamalar arasındaki farktır. Alım ve satım fırsatlarını göstermek amacıyla MACD'nin üzerine yerleştirilen ve 9 günlük başka bir üstel ortalamadan oluşan bir grafik daha vardır; bu göstergeye "tetik" ya da "sinyal" denir. MACD hesaplaması oldukça basittir; 26 ve 12 günlük üstel hareketli ortalamalar arasındaki fark alınarak bulunur. Üzerine yerleştirilen

9 günlük üstel ortalama da uzun/kısa pozisyon sinyalleri sağlamak amacıyla kullanılır (Yazdi ve Lashkari, 2013)

MACD göstergesi tetik çizgisini aşağıdan yukarı kestiği zaman alım, yukardan aşağı kestiği zaman ise satım kararı verilir. MACD çizgisinin sinyal çizgisini aşağıdan yukarı doğru kesmesi ile Al sinyali, MACD çizgisinin sinyal çizgisini yukardan gelerek aşağı doğru kesmesi ile de sat sinyali verilir. MACD çizgisi bazen fiyat grafikleri birlikte hareket etmeyebilir, örneğin yükselen fiyatlara rağmen MACD çizgisinin yükselmemesi yükseliş trendinin sonuna gelindiği ya da düşen fiyatlara rağmen MACD çizgisinin düşmemesi ise düşüş trendinin sonuna gelindiği şeklinde kabul edilir (Münyas ve Atasoy, 2021).

### **3.3.3 Stokastik Osilatör**

Stokastik osilatör, bir yatırım aracının kapanış fiyatını belirli bir tarih aralığındaki en yüksek ve en düşük kapanış fiyatları ile karşılaştıran teknik bir göstergedir. 0-100 arasında değişen değerleri ile Hızlı-K, Hızlı-D ve Yavaş-D olmak üzere üç çizgiden oluşur. Teknik analistler, bu çizgilerin 20'nin altında olmasını aşırı satış, 80'in üzerinde olmasını ise aşırı alım sinyali olarak değerlendirir (Oğuz vd., 2019).

Stokastik indikatör, yalnızca trend dönüşlerini tespit etmekle kalmayıp, aşırı alım ve aşırı satım seviyelerinin belirlenmesinde de kullanılan teknik bir göstergedir. Yatırım aracının kapanış fiyatını belirli bir periyottaki fiyat aralığı ile karşılaştırarak trendin gücünü ve olası sona yaklaşan noktalarını gösterir. 0-100 arasında değişen kısa vadeli bir gösterge olan stokastik osilatörde, 0-20 arası aşırı satım, 80-100 arası ise aşırı alım durumunu işaret eder. Beş günlük yüksek, düşük ve kapanış değerlerinden hesaplanan %K ile bunun üç günlük hareketli ortalaması olan %D çizgisinin kesişim noktaları alım veya satım sinyali olarak yorumlanabilir. %K çizgisinin %D'nin üzerinden geçmesi trendde olası bir değişime işaret ederken, çizginin 80'in üzerinde olması güçlü artan, 20'nin altında olması ise güçlü azalan bir trendi gösterir (Yaslıdağ, 2024).

### **3.3.4 İlerleme-düşüş çizgisi (ADX)**

Her gün kapanışta yükselen hisse senetlerinin sayısından düşenlerin sayısının çıkarılmasıyla elde edilen kümülatif bir değerdir. Bu gösterge, hisse senedi piyasasındaki hareket ve trendleri ölçmek için kullanılır, ancak bireysel hisse senetlerindeki değişiklikleri tanımlayamaz. Normal koşullar altında ADL ve piyasa endeksi aynı anda

yükseldiğinde, piyasanın yükseliş trendinin devam edeceği ve bu dönemde yatırımcı duyarlılığının nispeten yüksek olacağı öngörülür (Bai, 2023).

### 3.3.5 Fiyat değişim oranı (ROC)

ROC, fiyat hareketinin hızını gösteren bir momentum göstergesidir. Genellikle en son kapanış fiyatını, önceki kapanış fiyatıyla karşılaştırarak hesaplanır. Uzmanlar, bu göstergenin hareketini yorumlayarak fiyatın belirli bir trend içinde olup olmadığını, yani yükseliş ya da düşüş trendinde olup olmadığını belirlemeye çalışır. ROC, belirli bir süre boyunca bir değişkenin ne kadar hızlı değiştiğine bakan momentum göstergelerinden biridir. Uygulamada, uzmanlar bir değişkenin diğerine göre ne kadar hızlı değiştiğini dikkatle izler. Kısaca, ROC fiyat hareketlerinin arkasındaki momentumu belirler ve yüzde değişimini ölçer. Çoğu durumda, mevcut fiyat ve ROC birlikte hareket etmelidir. Mevcut fiyat ve ROC birbirinden ayrıldığında, teknik analist ROC'ye bakarak altta yatan trend hakkında daha net bir fikir edinmeye çalışır. ROC formülü, mevcut fiyattan N gün önceki fiyatın çıkarılması ve ardından bu farkın N gün önceki fiyata bölünmesi ile hesaplanır. ROC formülü aşağıdaki denklemde gösterilmektedir (M'ng ve Jean, 2014):

$$ROC = \frac{\text{Mevcut Fiyat} - N \text{ Gün Önceki Fiyat}}{N \text{ Gün Önceki Fiyat}} \times 100$$

Bu formül, fiyat değişim hızını yüzdesel olarak belirler ve analistlere fiyatın momentumunu değerlendirme imkânı sunar.

### 3.3.6 Denge hacmi (OBV)

OBV, "Dengeli Hacim" (On Balance Volume) anlamına gelir ve bir hacim göstergesidir. Bu göstergeye dair hipotez, hacim değişimlerinin fiyat değişimlerinden önce geldiğidir. Bu varsayım, bir hissenin yükselişinden önce hacim artışının meydana gelmesinin muhtemel olduğu fikrine dayanır. OBV, alış ve satış baskısını kümülatif bir hacim endeksi olarak ölçer. Hisse fiyatının yükseldiği günlerde endeksi artırır; hisse fiyatının düştüğü günlerde ise endeksten çıkarır. OBV'nin hesaplanmasında kullanılan formül aşağıdaki gibidir, burada "t" alt simgesi zamanı temsil eder:

- Eğer  $Kapanış_t > Kapanış_{t-1}$  ise:  $OBV_t = OBV_{t-1} + Hacim_t$
- Eğer  $Kapanış_t < Kapanış_{t-1}$  ise:  $OBV_t = OBV_{t-1} - Hacim_t$
- Eğer  $Kapanış_t = Kapanış_{t-1}$  ise:  $OBV_t = OBV_{t-1}$

Burada:

$Kapanış_t$  = Dönemin kapanış fiyatı (gün) t

$Hacim_t = \text{Dönemdeki işlem sayısı (gün) } t$

Yükselen bir OBV, daha yüksek fiyatlara yol açabilecek olumlu bir hacim baskısını yansıtır. Aksine, düşen bir OBV, daha düşük fiyatların habercisi olabilecek olumsuz bir hacim baskısını gösterir. Ancak OBV'nin tek başına bir gösterge olmadığına dikkat etmek önemlidir. OBV, bir alım ya da satım sinyalini desteklemek amacıyla trend ya da momentum gibi diğer göstergelerle birlikte kullanılmak üzere tasarlanmıştır (Gold, 2015).

### 3.3.7 Hareketli ortalamalar

Hareketli ortalamalar, fiyat grafikleri üzerinde en sık kullanılan teknik göstergelerden biridir. Bu gösterge, yatırım araçlarının belirli bir zaman dilimindeki fiyat ortalamalarını yansıtarak, fiyatların matematiksel analizini sağlar. Fiyatlar değiştikçe hareketli ortalama da yukarı veya aşağı doğru hareket eder. Hareketli ortalamalar, genellikle son X dönemin fiyat ortalamasını alarak grafikte işaretler ve mevcut fiyatın geçmiş ortalamadan ne kadar uzaklaştığını gösterir. Bu sapmaların ve farklı verilerin birleştirilmesi, yatırımcılara alım ve satım kararlarında yol gösterici olur (Yaslıdağ, 2024).

Hareketli ortalamalar, trendlerin yönünü ve dönüş noktalarını belirlemede kullanılır, ancak trend değişikliklerini önceden tahmin edemezler. Mevcut trendin devam edip etmediğini ya da değiştiğini gösterirler. Piyasa fiyatı hareketli ortalamanın üzerinde olduğu sürece trend yükseliş olarak değerlendirilir. İki farklı hareketli ortalamanın üzerinde oluşan fiyatlar ise hissenin güçlü olduğunu gösterir. Uzun dönemli hareketli ortalamalar, örneğin 50 ve 200 günlük ortalamalar, hissenin uzun vadeli görünümünün kuvvetli olduğunu gösterir. Fiyatın 50 günlük ortalamanın altına inmesi kısa vadeli bir düşüş sinyali olarak kabul edilirken, 200 günlük ortalamanın altına inmesi ana trendin değiştiğinin ve olumsuz bir durumun işareti olarak değerlendirilir (Çetinyokuş ve Gökçen, 2002).

### 3.3.8 Williams birikim ve dağılımı (WAD)

Bu indeks yatırım araçlarının fiyatlarındaki değişimi işlem hacmi ile birleştirir. Fiyatlardaki değişimin ne kadar yüksek işlem hacmi ile gerçekleşirse o kadar güçlü olacağından hareket ederek bir trendin var olup olmadığını ve var olan trendin sürüp sürmeyeceğini belirler.

Kapanış fiyatı ile günün en düşük fiyatı farkından, günün en yüksek fiyatı ile kapanış fiyatı farkının çıkarılarak, günün yükseği ile günün düşüğü farkına bölünmesi ile elde

edilen değerin hacimle çarpılmasıyla elde edilir. Hesaplama yönteminin sonucu olarak kapanış fiyatı günün yükseğine yaklaştıkça WAD değeri artar, kapanış fiyatı günün düşüğüne yaklaştıkça da WAD değeri azalır. Kapanışın günün yüksek ve düşüğüne eşit mesafelerde olduğu durumlarda WAD değeri aynı kalır. WAD değeri yükseliyorsa yatırım aracının fiyatının toplanmakta olduğu, WAD düşüyorsa da yatırım aracından çıkılmakta olduğu düşünülür (Yaslıdağ, 2024).

#### **4 LİTERATÜR TARAMASI**

Bu bölümde makine öğrenmesi yöntemleri kullanılarak kripto para birimlerinin fiyatını ve yönünü tahmin eden ulusal ve uluslararası çalışmalara yer verilmiştir. Bu çalışmalarda kullanılan yöntem, veri seti ve elde edilen sonuçlar hakkında bilgi verilmiştir.

##### **4.1 Ulusal Çalışmalar**

Atlan vd. (2018), Bitcoin'in Türkiye borsalarındaki değerinin yapay zeka teknikleri ile tahmini gerçekleştirmek amacıyla yaptıkları çalışmalarında, 23 Temmuz 2017- 22 Temmuz 2018 tarihleri arasındaki Bitcoin'in TL cinsinden fiyatını ve günlük verilerini kullanmışlardır. Yapay zeka tekniklerinden Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS ) ve polimonsal eğri uydurma yöntemleriyle yapılan tahmin sonuçlarına göre, her iki yönetiminde Bitcoin fiyatını başarılı tahmin ettiği, en iyi sonuca ise % 4-5 hata payıyla ANFIS yönteminin ulaştığı belirlenmiştir.

Sakız ve Kutlugün (2018), Bitcoin fiyatlarını yapay zeka algoritmaları ile tahmin etmeyi amaçlamışlardır. 01.02.2017 ile 02.02.2018 tarihleri arasındaki 1 yıllık Bitcoin fiyatları ile yapay sinir ağları yöntemi uygulanarak 2018 yılı şubat ayı Bitcoin fiyat ortalamasını 170.730.000 \$ olarak bulmuşlardır.

Karasu vd. (2018), makine öğrenmesi yöntemlerinden Destek Vektör Makinesi (SVM) ve Doğrusal Regresyon (DR) ile 2012-2018 yılları arasındaki günlük Bitcoin kapanış fiyatı, en yüksek fiyat ve en düşük fiyatlarından oluşan veri seti ile Bitcoin fiyat tahmini yaptıkları çalışmalarında, SVM modelinin DR modeline kıyasla Bitcoin veri seti için tahmin başarımının yüksek olduğu görülmektedir ayrıca modellerin performansları istatistiksel göstergelerden Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE), Ortalama Hata Kareleri Karekökü (RMSE), Pearson korelasyon yardımıyla ölçülmüştür. Yavuz vd. (2020), Yapay Sinir Ağları (YSA) yöntemi kullanarak yaptıkları çalışmalarında Bitcoin'in 01.01.2009- 23.07.2018 tarihleri arasındaki günlük açılış, kapanış, en yüksek ve en düşük fiyatları, Hacim ve Bitcoin Maliyeti, Bitcoin Tahmini İşlem Hacmi (BTC),

Bitcoin Tahmini İşlem Hacmi (USD), Bitcoin Toplam Çıkış Hacmi, Bitcoin Toplam İşlem Sayısı, Dolaşımdaki Toplam Bitcoin Miktarı verilerini kullanılmışlardır. Araştırma sonuçlarına göre Bitcoin fiyat tahmininde %99 oranında tahminsel başarı gözlemlenmiştir.

Bitcoin, Ethereum ve Ripple için Türk Lirası cinsinden online ortamda fiyat tahmini yapmayı amaçlayan Atlan vd, (2020), (ANFIS), Yapay sinir ağları (YSA), polinomsal eğri uydurma ve uzun kısa-vadeli bellek (LSTM) yapay zeka yöntemlerini kullanmışlardır. Bitcoin, Ethereum ve Ripple için hazırlanan model, 21.09.2019 ile 20.11.2019 tarihleri arasında her gün 00.00'da çalıştırılmıştır. Çalıştırılan model ile 24 saatlik veriler ile sonraki 1 saati, 1 haftalık veriler ile sonraki 8 saati ve 1 aylık veriler ile sonraki 36 saat tahmin edilmiştir. Sonra tahmin edilen değerler ile gerçek değerler karşılaştırılmış olup, performansları tespit edilmiştir. Sonuç olarak, en yakın tahmini ANFIS yöntemi vermiş olup, en iyi değerler 1 günlük verilerle elde edilmiştir.

Çağlar ve Yavuz (2021), finansal haberlerin Bitcoin üzerindeki etkilerini ölçmek için yapay zeka yöntemleri kullanarak bir araştırma yapmışlardır. 01.01.2009 ile 23.07.2018 tarihleri arasındaki Bitcoin hakkında olumlu ve olumsuz içerikli tüm haberler ile blok zincir verileri (*Bitcoin Cüzdanı Sayısı, Zorluk Derecesi, Bitcoin Cüzdanı Günlük İşlem Sayısı, Bitcoin Cüzdanı Günlük İşlem Hacmi, Ortalama Blok, Medyan İşlem Onay Süresi (Dk), Madencilik getirisi (USD, Hash Hızı (Th/s), İşlem Başına Bitcoin Maliyeti, Bitcoin Tahmini İşlem Değeri, Bitcoin Tahmini İşlem Değeri (USD): , Bitcoin Toplam Çıkış Değeri (USD), Bitcoin Toplam İşlem Sayısı, Bitcoin İşlem Onaylanan İşlem Sayısı, Dolaşımdaki Toplam Bitcoin Miktarı, Bitcoin Ağ Açığı Ethereum USD fiyatları*) ele alınarak yapay sinir ağları ile bu veriler arasındaki anlamsal ilişki kurulmuştur. Sonuç olarak Bitcoin içerikli finansal haberlerin, Bitcoin fiyatı tahmini üzerine anlamlı bir etkisi bulunamamıştır ancak blok zincir verilerinin Bitcoin fiyat tahmininde yüksek oranlı ilişki gözlenmiştir.

Karğın vd. (2022), bitcoin'in fiyat tahminlemesini gerçekleştirdikleri araştırmalarında, 1 Ocak 2018 ile 1 Ocak 2022 arasında Bitcoin fiyat verilerinden faydalanarak LSTM yöntemini kullanmışlardır. Araştırma da kullanılan tarihsel veri setinin %80'i eğitim, %20'si ise test verisi olarak kullanılmıştır (01.01.2018 – 15.03.2021 tarihine arası eğitim, 16.03.2021– 01.01.2022 tarihi arası test). Ayrıca Çalışmada tahmin hatası ölçümü için RMSE yöntemi kullanılmıştır. (RMSE değeri = 58,10). Çalışma sonucuna göre elde

edilen tahmin sonuçları ve gerçek fiyatlar görsel olarak karşılaştırıldığında gerçekleştirilen analiz yönteminin başarılı fiyat tahmini yaptığı ifade edilmiştir.

Budak ve Aytekin (2022), çalışmalarında, makine öğrenmesi algoritmalarından Doğrusal Regresyon modeli kullanılarak, Bitcoin (BTC), Ethereum (ETH), Binance Coin (BNB), Solana (SOL), Cardano (ADA), Ripple (XRP), Terra (LUNA), Polkadot (DOT), Avalanche (AVAX) ve Dogecoin (DOGE) kripto varlıklarının gelecekteki 7, 14, 28 ve 60 günlük fiyatlarının tahmin edilmiştir. Sonuçlara göre, basit doğrusal regresyon modelinin 7 günlük fiyat tahminlerinde 14, 28 ve 60 günlük fiyat tahminlerine göre daha yüksek güven aralığında başarılı tahminlere ulaştığı gözlemlenmiştir.

#### 4.1 Uluslararası Çalışmalar

Hitam ve İsmail (2018), çalışmalarında Kripto para fiyat tahmini için makine öğrenimi algoritmalarının performansını karşılaştırmıştır. Araştırmada Litecoin ve Ethereum, Bitcoin, Stellar, Ripple ve Nem'in 2013 ile 2017 yılları arasındaki günlük açılış fiyatı, kapanış fiyatı, en yüksek fiyat ve en düşük fiyat verilerini kullanarak makine öğrenimi algoritmalarından Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (SVM) ve BoostedNN yöntemleri kullanılmıştır. Önerilen yapay zeka modelleri değerlendirmek için RMSE kullanmıştır. Sonuçlar, Destek vektör makineleri algoritmasının Ethereum ve ardından Litecoin için iyi çalıştığını göstermektedir. YSA'nın en çok Bitcoin'de ve ardından Nem'de çalıştığı görülüyor. Ripple ve Stellar, BoostedNN için en iyi performans doğruluğuna sahiptir. Ancak tüm modeller arasında %95,5 performans doğruluğu ile en iyi performansı Destek vektör makineleri vermektedir.

Phaladisailoed ve Numnonda (2018), 1 Ocak 2012 ile 8 ocak 2018 yılları arasında Bitcoin'in açılış, kapanış, en yüksek ve en düşük fiyatları ile Hacim (BTC), Hacim (Para Birimi), Zaman damgası (veri kayıt zamanı) değişkenlerinden oluşan veri seti ile Bitcoin fiyatını tahmin etmek için Makine öğrenme modellerinden Theil-Sen Regresyonu, Huber Regresyonu, LSTM, GRU ve Tahmin doğruluğunu ölçmek için temel performans göstergelerinden Ortalama Karesel Hatanın (MSE) ve R2 kullanarak bir araştırma yapmışlardır. Sonuçlar, GRU ve LSTM'nin Theil-Sen regresyonu ve Huber regresyonundan daha iyi sonuç verdiğini göstermektedir. Ek olarak yazarlar bu verilerin, bitcoin fiyatlarını tahmin etmek için yeterli olmayabileceğini belirtmişlerdir. Çünkü sosyal medyadan gelen tepkiler, politikalar ve her ülkenin dijital para birimiyle başa çıkmak için açıkladığı yasalar gibi çeşitli faktörlerin tümü Bitcoin fiyatlarının

yükselmesine ve düşmesine katkıda bulunabileceğine ve modellerin en iyi sonuçları için, her zaman güncellenmiş verilerin toplanması gerektiğine değinmişlerdir.

Hitam vd. (2019), kripto para fiyat tahmini yaptıkları araştırmalarında 2013 ile 2018 yılları arasında altı kripto para biriminin günlük açılış/kapanış ve en yüksek/en düşük fiyatını kullanmışlardır. (Litecoin ve Ethereum, Bitcoin, Stellar, Ripple ve Nem). Makine öğrenim yöntemlerinden YSA, SVM, Derin Öğrenme ve PSO ile optimize edilmiş Destek Vektör Makineleri (SVM-PSO) kullandıkları çalışma sonuçlarında göre, Tüm modeller arasında Optimize Edilmiş SVM-PSO %97 performans doğruluğu ile diğer modellere göre en iyi performansı göstermektedir. Ethereum için %97, Bitcoin ise %90.4 başarılı tahmin sonuçlarına ulaşılmıştır.

Zhao vd. (2019), araştırmalarında Temmuz 2015 ile kasım 2019 arasındaki zaman diliminde Bitcoin (BTC), Ethereum (ETH) ve Litecoin (LTC) e ait açılış, kapanış, en yüksek, en düşük ve hacim verileri kullanılmıştır. Ayrıca teknik analiz yöntemlerinden Bollinger Bantları, Macd ve RSİ da deneylere dahil edilmiştir. Rastgele Orman, XGBoost, Destek Vektör Makinesi yöntemleri kullanılan araştırma sonuçlarına göre, Kripto para fiyat tahminin de en iyi sonucu Destek Vektör Makinesi vermiştir.

Rathan vd. (2019), çalışmaların 2011 ile 2019 yılları arasında Bitcoin'in günlük açılış, kapanış, en yüksek ve en düşük fiyatları ile Hacim (BTC), Hacim (Para Birimi) ve Ağırlıklı Fiyat verilerini kullanarak karar ağaçları ve doğrusal regresyon yöntemlerini kullanarak Bitcoin fiyatını tahmin etmişlerdir. Her iki yöntemde başarılı sonuçlar vermesini rağmen en iyi performansı regresyon yöntemleri göstermiştir.

Atsalakis vd. (2019), araştırmalarında 3 Eylül 2011 ile 12 Ekim 2017 tarihleri arasında Bitcoin günlük kapanış fiyatlarına ait toplam 2201 gözlemden oluşan veri seti ile yapay sinir ağları (ANN), Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) ve Nöro-bulanık denetleyici tahmin sistemi (PATSON) yöntemlerini kullanarak Bitcoin fiyat değişiminin yönünü tahmin etmeye çalışmışlardır. Modellerin performansını ölçmek için MAE, MSE ve RMSE kullanılmıştır. Sonuç olarak PATSON modelinin daha başarılı sonuçlar verdiği gözlemlenmiştir. Ayrıca, önerilen modelin sinyallerine dayanan bir ticaret simülasyonu ile elde edilen yatırım getirileri, saf bir al ve tut stratejisiyle elde edilenlerden %71,21 daha yüksek olduğu da tespit edilmiştir.

Bitcoin'in fiyat yönünü, maksimum, minimum ve kapanış fiyatlarının makine öğrenimi tekniklerini tahmin edilmesini amaçlayan çalışmalarında Mallqui ve Fernandes (2019), makine öğrenim tekniklerinden Yapay Sinir Ağları (YSA), Destek Vektör Makineleri

(SVM), Tekrarlayan Sinir Ağları ve k-Means kümeleme yöntemleriyle model oluşturmuştur ve Modellerin performansını ölçmek için MAE, MAPE ve RMSE kullanılmıştır. 9 Ağustos 2013 ile 19 Temmuz 2016 tarihleri arasındaki bilgileri kapsayan araştırmanın veri seti iç ve dış kaynaklar olarak ikiye ayrılmıştır. İç veri kaynaklarını, açılış, en yüksek, en düşük ve kapanış fiyatı, işlem hacmi, toplam işlem ücretleri, işlem sayısını, işlem başına maliyeti ve ortalama hash oranı oluşturmaktadır. Dış veriler olarak ise uluslararası ekonomik göstergelerden elde edilmiştir Bunlar, ham petrol vadeli fiyatları, altın vadeli fiyatları, S&P500 vadeli, NASDAQ vadeli ve DAX endeks fiyatıdır. Sonuçlara göre Destek Vektör Makinesi algoritması, Bitcoin döviz kurlarını tahmin etmek için en iyi sonuçları elde etti. Ayrıca ulaşılan sonuçlara göre, Bitcoin fiyat tahmininin iyileştirilmesi gerektiğine değinilmiştir. İyileştirme için ise ticaret yapanlar tarafından yaygın olarak kullanılan Larry Williams (%R), Göreceli Güç Endeksi (RSI) Stokastik osilatörler (%K ve %D), Hareketli Ortalama Yakınsama/İraksama (MACD) osilatörü teknik göstergeler ile ekonomik göstergeler ve Blockchain bilgilerinin araştırmalara dahil edilebileceğine işaret etmişlerdir.

Aggarwal vd. (2019), 2018 yılının farklı aylarına ait Twitter tweetleri (Bir zaman aralığında duygu, takipçi sayısı, beğeni ve tweet sayısına göre Tweet duyarlılık puanını oluşturulmuştur.), günlük altın fiyatlarını ve Bitcoin fiyatlarını kullanarak, Bitcoin'in fiyatını tahmin etmeyi amaçladıkları çalışmalarında Evrişimli Sinir Ağı (CNN), Uzun Kısa Süreli Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) makine öğrenimi yöntemlerini ve temel performans göstergelerinden Kök Ortalama Kare Hatası (RMSE) kullanmışlardır. Sonuçlara göre, LSTM, CNN ve GRU ile karşılaştırıldığında uzun vadeli bağımlılıkları tahmin etmede daha yetenekli olduğunu gözlemlenmiştir. Bunun nedeni, LSTM modeli tarafından yakalanan geçmiş fiyatlara bağımlılığın ancak GRU ve CNN modelleri tarafından yakalanmamasından kaynaklandığı belirtilmiştir. Ayrıca, bitcoin fiyat tahmini için altın fiyatı parametre olarak kullanıldığında, LSTM altın fiyatı ile bitcoin fiyatı arasında pozitif bir ilişki göstermemiştir. Ancak Twitter duygusal analizi kullanılarak yapılan bitcoin fiyat tahmininin sonuçları ise pozitif bir korelasyon göstermiştir.

Makine öğrenimi algoritmalarıyla Bitcoin fiyat tahmini yatıkları çalışmalarında Chen vd. (2020), 2 Şubat 2017 ile 1 Şubat 2019 yılları arasındaki bitcoinin ağ verilerini, ticaret ve piyasa verilerini, medya ve yatırımcıların dikkatini ve altın spot fiyatını kullanmışlardır. Bunlar; blok boyutu, hash oranı, madencilik zorluğu, bloklar arasındaki süre, dakika

başına işlem sayısı, işlem sayısı, gün başına onaylanan işlemler, mempool işlem sayısı, piyasa değeri, tahmini işlem değeri, toplam işlem ücretleri, mempool boyutu, google trend arama hacmi endeksi, baidu medya arama hacmi, altın spot fiyatıdır. Lojistik regresyon, doğrusal diskriminant analizi, rastgele orman, xgboost, karesel ayırıcı analiz, destek vektör makinesi ve uzun kısa süreli bellek yöntemleri kullandıkları çalışma sonuçlarına göre, 5 dakikalık fiyat tahmininde manine öğrenme algoritmaları istatistiksel yöntemlere göre daha iyi sonuçlar vermiştir. Günlük fiyat tahmininde ise istatistiksel yöntemlerin ortalama doğruluğu %65,0 olup, makine öğrenimi modellerinin ortalama doğruluğundan (%55,3) daha yüksektir. Lojistik regresyon modeli, %66,0 doğrulukla en iyi sonuçları elde etti. Makine öğrenimi modelleri arasında %48,3 doğrulukla XGBoost en kötü performansı gösterirken, Destek Vektör Makinesi %65,3 doğrulukla istatistiksel yöntemlerle rekabet edecek şekilde en iyisi gözlemlenmiştir.

Chowdhury vd. (2020), çalışmalarında Bitcoin Cash, Bitcoin, Dash, Doge coin (DOGE), Ethereum, IOTA (MIOTA), Litecoin, NEM, NEO kripto paralarının 2013 ile 2018 tarihleri arasındaki açılış, kapanış, en yüksek ve en düşük fiyatları, Hacim (BTC), piyasa sermayesi ve işlem tarihleri verilerini kullanarak bu kripto paraların ve cci30 endeksinin Ocak ayı kapanış fiyatlarını hesaplamışlardır. Gradyan artırılmış ağaçlar, yapay sinir ağı, topluluk öğrenimi, k-en yakın komşu yöntemlerini kullanarak yaptıkları araştırmanın sonuçlarına göre, en iyi tahmini %92,4 doğruluk oranı ile topluluk öğrenme yöntemi göstermiştir. Ayrıca, en düşük performans ise K-NN modeline aittir.

Aggarwal vd. (2020), Bitcoin fiyatlarını tahmin etmek için 03.02.2012- 01.10.2018 tarihleri arasındaki günlük Bitcoin fiyat verilerini kullanarak yaptıkları çalışmada, Bitcoin fiyatlarını tahmin edip edemeyeceğini bulmak için destek vektör makinesi (SVM) öğrenme algoritmasını kullanılmış ve SVM'nin kısa vadeli, orta vadeli, uzun vadeli ve genel Bitcoin fiyat seviyesi için Bitcoin fiyatlarını beş adım önceden tahmin ettiği tespit edilmiştir.

Destek vektör makinesini geliştirilmiş sinüs kosinüs algoritmasıyla (eSCA) optimize ederek kripto para birimi fiyatlarını tahmin eden Salb vd. (2021), 2013 ile 2018 yılları arasında Litecoin ve Ethereum, Bitcoin, Stellar, Ripple ve Nem kripto para birimlerinin günlük açılış/kapanış ve en yüksek/en düşük fiyatını kullanarak, Destek Vektör Makineleri (SVM), Derin Öğrenme ve PSO ile optimize edilmiş Destek Vektör Makineleri(SVM-PSO), SVM-eSCA yöntemleri uygulamışlardır. Sonuç olarak bu makalede standart SVM algoritması, SVM-PSO ve SVM-eSCA karşılaştırılmıştır. En

iyi sonucu ise önerilen SVM-eSCA yaklaşımı vermiştir. Bitcoin için SVM %78.90, SVM-PSO %90.40, SVM-eSCA ise %91.21 doğruluğa sahiptir.

Guo vd. (2021), Bitcoin fiyatını tahmin etmek için, dalgacık dönüşümü (wt) ve rasgele çok başlı dikkat (CA) ve zamansal konvolüsyon açısından yararlanan bir fiyat tahmin modeli WT-CATCN önermişlerdir ve modeli otoregresif entegre hareketli ortalama (ARIMA), ARIMAX, konvolüsyonel sinir ağları (CNN), çok katmanlı perceptron (MLP), LSTM, Seq2Seq. Bir Diziden Diziye, Bayes Sinir Ağları (BNN), Durum Frekans Belleği (SFM) yöntemleriye karşılaştırmışlardır. Sonuçlara göre, önerdikleri modelin fiyat tahmin performansını %25 oranında iyileştirdiğini göstermektedir. Modellerin performansını ölçmek için MAE, MSE ve RMSE kullanılmıştır. Veri seti olarak 1 ocak 2016 ile 3 aralık 2018 tarihleri arasında Bitcoin'in günlük verileri, Google arama eğilimleri ve borsalar arası işlemler değişkenleri kullanılmıştır.

Bitcoin fiyatını etkileyen 40 değişkene sahip bir özellik sistemi oluşturarak Bitcoin fiyatını tahmin etmeyi amaçlayan, Liu vd. (2021) çalışmalarında Bitcoin fiyatını tahmin etmek için yığılmış gürültü giderici otomatik kodlayıcılar (SDAE) adlı derin bir öğrenme yöntemi kullanmışlardır. Sonuçlar, geri yayılım sinir ağı (BPNN) ve destek vektörü regresyon (SVR) yöntemleri gibi en popüler makine öğrenimi yöntemleriyle karşılaştırıldığında, SDAE modelinin diğer iki modele göre hem yön hem de seviye tahmininde daha iyi performans gösterdiğini gözlemlenmiştir. Ayrıca modellerin performansını ölçmek için ortalama mutlak yüzde hatası (MAPE), kök ortalama karesel hata (RMSE) ve yönlü doğruluk (DA) teknikleri kullanılmıştır. 40 değişkene sahip sistem oluştururken ise Temmuz 2013 ile Ağustos 2019 arasındaki verilerden yararlanılarak şu değişkenlere yer verilmiştir; Ortalama hashrate, Dow Jones endüstri ortalaması, Bitcoin piyasa değeri, New York Borsası Altın vadeli işlemleri Bitcoin ticaret hacmi, HuShen 300 endeksi, Litecoin piyasa değeri, Kore bileşik endeksi, Litecoin fiyatı, Singapore Straits Times endeksi, Litecoin ticaret hacmi, Standard & Poor's 500 endeks, Madencilik ödülü, ABD dolarının Avustralya dolarına döviz kuru, Madencilik zorluğu, ABD dolarının İngiliz sterlinine döviz kuru, Adres sayısı, ABD dolarının Kanada dolarına döviz kuru, Blok hacmi, ABD dolarının Danimarka'ya döviz kuru Kron, Ripple piyasa değeri, ABD dolarının Japon yenine döviz kuru, Ripple fiyatı, ABD dolarının Yeni Zelanda dolarına döviz kuru, Ripple hacmi, ABD dolarının Norveç kronuna döviz kuru, Komisyon ücretleri, ABD dolarının İsveç kronuna döviz kuru , Bitcoin madenciliği karlılığı, ABD dolarının Euro karşısındaki kuru, Baidu endeksi Kamuoyunun dikkati, ABD dolarının

İsviçre frangı karşısındaki kuru, Google trendler endeksi, FTSE 100 endeksi, Brent ham petrol vadeli işlemleri, Tokyo'nun Nikkei endeksi, CBOE volatilite endeksi, ABD dolar endeksi, NYSE Bakır vadeli işlemleri, WTI petrol vadeli işlemleri.

Mittal ve Geettha (2022), çalışmalarında GRU adlı derin öğrenmeye dayalı bir yapay sinir ağı modeli oluşturarak, 2014 ile 2020 yılları arasındaki günlük Bitcoin Açılış, Kapanış, En Yüksek, En Düşük fiyatları ile Hacim verilerini kullanarak Bitcoin fiyatlarını tahmin etmeye çalışmışlardır. Tahmin doğruluğunu ölçmek için temel performans göstergelerinden RMSE ve MAPE uygulanan araştırmanın sonuçlarına, GRU modelinin Bitcoin fiyatını tahmin etme başarılı olduğu gözlemlenmiştir.

Ranjan vd. (2022), çeşitli makine öğrenimi tekniklerini kullanarak Bitcoin fiyatlarını günlük ve 5 dakikalık olarak tahmin etmeyi amaçlayan çalışmışlarında, 1 ocak 2017 ile 31 aralık 2019 tarihleri arasındaki Piyasa değeri, hash oranı, madencilik zorluğu, Bloklar arasındaki süre, Dakika başına işlem, Günlük işlem sayısı, Günlük onaylanmış işlemler, Mempool işlem sayısı, tahmini işlem değeri, toplam işlem ücreti, bellek boyutu, google trend arama hacmi endeksi, altın spot fiyatı verileri kullanılarak lojistik regresyon, lineer diskriminant analizi, rastgele orman, XGBoost, karesel diskriminant analizi, k-en yakın komşular, karar ağacı, destek vektör makinesi modelleri oluşturulmuştur. Sonuçlara göre, Lojistik regresyon günlük fiyatı %64,84 doğrulukla, Kuadratik Ayrım Analizi ise günlük fiyatı %44,7'lik bir doğruluklar tespit etmiştir. Ayrıca 5 dakikalık fiyat tahmini için XGBoost %59,4 doğruluk, Karar Ağacı modeli ise %53'lük bir doğruluk göstermiştir.

Erfanian vd. (2022), çalışmalarında ekonomik teorilere dayanan makroekonomik, mikroekonomik, teknik ve blockchain göstergelerinin Bitcoin fiyatını tahmin edip etmediğini araştırmak için makine öğrenimi tekniklerinden sıradan en küçük kareler (OLS), Topluluk öğrenme, destek vektör regresyonu (SVR) ve çok katmanlı algılayıcı (MLP) yöntemlerini kullanmışlardır. Araştırmada 18 ağustos 2010 ile 17 eylül 2018 tarihleri arasındaki verilerden makro ekonomik değişkenler olarak, Piyasa değeri, dolaşımdaki BTC'ler, ABD federal fon oranı, S&P500 borsa endeksi, Nasdaq bileşik, DJIA borsa endeksi, Crude Oil WTI, altın sabitleme fiyatı, başabaş enflasyon oranı; Blockchain bilgi göstergeleri olarak ise Karma oranı, madencilik zorluğu, blok başına işlem sayısı, blok boyutu, ortalama blok boyutu, medyan onay süresi, yetim bloklar, işlem başına maliyet, işlem ücretleri, tahmini işlem değeri (BTC), tahmini işlem değeri (USD), toplam çıkış değeri verilerine yer verilmiştir. Sonuçlara göre SVR'nin Bitcoin'in fiyatını tahmin etmede diğer makine öğrenimi ve geleneksel modellerden daha üstün olduğu

tespit edilmiştir. Aynı zamanda makroekonomik ve blok zinciri göstergelerinin, arz, talep ve maliyete dayalı fiyatlandırma teorilerinin BTC fiyat tahmininin altında yatan teoriler olduğuna da değinilmiştir.

Nagula ve Alexakis (2022), bitcoin fiyatlarını tahmin etmek için sınıflandırma ve regresyon modellerini kapsayan hibrit bir model önermek amacıyla yaptıkları çalışmalarında, Şubat 2014 ile Eylül 2021 yılları arasındaki Bitcoin'in Açılış, Yüksek, Düşük ve Kapanış fiyatı, Hacim, Bitcoin Vadeli Kapanış Fiyatı, S&P500 Kapanış fiyatı, Benzersiz aktif adreslerin sayısı, Bitcoin ağının hash oranı, Metcalfe'nin Bitcoin hesaplama değeri için bitcoin dolaşım ve cüzdan sayısı, Risksiz getiriler için hazine bonusu oranları ve teknik indikatörlerden oluşan veri seti ile hibrit model oluşturulmuştur. Hibrit model, %100 yönlü bir isabet oranı öngörmüş ve örneklem dışı dönem için getirilerde sabit oynaklığı sürdürmüştür. Ayrıca hibrit modelin bitcoin vadeli işlem stratejisinin, satın al ve tut kıyaslama stratejilerinden daha iyi performans gösterdiği sonucuna varılmıştır.

Faiz oranları, enflasyon ve piyasa oynaklığı değişkenlerinin Bitcoin ve altın fiyatlarını tahmin etmek için önemli olup olmadığını araştıran Basher ve Sadorsky (2022), çalışmalarında ağaç tabanlı makine öğrenimi yöntemlerinden Rastgele ormanlar ve torbalama (bagging) modeli oluşturmuşlardır. Bu çalışmanın verileri 27 Eylül 2014 ile 29 Aralık 2021 yılları arasındaki günlük Bitcoin ve altın fiyatları ile makroekonomik değişkenler ve teknik göstergelerden oluşmaktadır. Teknik göstergelerin Araştırmada teknik göstergeler olarak; göreceli güç göstergesi (RSI), stokastik osilatör (yavaş, hızlı), ilerleme-düşüş çizgisi (ADX), hareketli ortalama çapraz sapma (MACD), fiyat değişim oranı (ROC), denge hacmi (OBV), 50 günlük hareketli ortalama, 200 günlük hareketli ortalama, para akış endeksi (MFI) ve Williams birikim ve dağılımı (WAD) ve makroekonomik değişkenler olarak ise; faiz oranları (ABD on yıllık tahvilinin (Tenyrbond), üç aylık T-bonosunun (ThreemTbill)), ekonomi politikası belirsizliği (EPU), piyasa oynaklığı, enflasyon, hisse senedi belirsizliği (VIX) ve petrol piyasası belirsizliği (OVX) verileri alınmıştır. Sonuçlara göre; enflasyon oranı, Bitcoin fiyat yönünün güçlü bir göstergesi değildir, bu da Bitcoin'in enflasyon için çok iyi bir korunma aracı olmadığını gösterir. MA50, MA200, WAD ve MACDSignal gibi teknik göstergelerin hem Bitcoin hem de altın fiyat yönü için önemli tahmin ediciler olduğuna ulaşılmıştır. Petrol fiyatı oynaklık endeksi, hem Bitcoin fiyat yönü hem de altın fiyatı yönü için önemli bir tahmin edicidir ve Bitcoin'in bu tür oynaklığı çeşitlendirmede altının

yerine geçtiğini gösterir. On yıllık tahvil getirileri de Bitcoin fiyat yönünü tahmin etmek için önemlidir. Altın fiyatları Bitcoin'den daha fazla enflasyondan etkilenir, bu da altının enflasyona karşı bir koruma ya da çeşitlendirme varlığı olarak kullanılabileceğini gösterir.

Gradojevic vd. (2023), Bitcoin fiyatlarını yapay Sinir ağları, Rastgele Orman ve , Destek Vektör Makinesi modellerini oluşturarak tahmin etmeye çalışmışlardır. 11 Mayıs 2015 ile 7 Mart 2019 yılları arasında Bitcoin'in saatlik ve günlük verileri kullanılmıştır. Araştırmada korku ve açgözlülük endeksi, Google araştırma trendi ve Bitcoin hacminin yanı sıra teknik göstergeler olarak ise göreceli güç göstergesi (RSI), hareketli ortalama çapraz sapma (MACD), fiyat değişim oranı (ROC), denge hacmi (OBV), 50 günlük hareketli ortalama (MA50), 200 günlük hareketli ortalama (MA200), Stokastik/Williams%R değişkenleri yer almıştır. Sonuç olarak, kurulan tüm modeller başarılı sonuçlar vermektedir. Ancak rastgele orman modelini Bitcoin'i tahmin etmede en doğru model olarak tespit etmişlerdir. Ayrıca Bitcoin piyasasının korku ve açgözlülük, hacim ve Google arama eğilimleri gibi duyarlılık göstergeleri tarafından yönlendirilen bir piyasaya dönüştüğünü gözlemlemişlerdir.

Penmetsa ve Vemula (2023), Bitcoin, Ethereum ve Litecoin fiyatlarını tahmin etmek için tarihsel fiyat verileriyle birlikte teknik göstergeler kullanan LSTM ve Transformer tabanlı derin öğrenme modelleri geliştirmişlerdir. 2019–2023 dönemine ait günlük açılış, kapanış, en yüksek ve en düşük fiyat verilerine ek olarak işlem hacmi, RSI, MACD, sinyal hattı, histogram ve BB göstergeleri kullanılmıştır. Karşılaştırma sonuçları, teknik göstergelerin tüm modellerin doğruluğunu artırdığını ve özellikle Transformer modelinin en düşük MAE, RMSE ve MAPE değerleriyle en başarılı tahminleri sağladığını göstermiştir.

Labba Khaniki ve Manthouri (2024), Bitcoin, Ethereum ve Litecoin fiyatlarını tahmin etmek için teknik göstergelerle (RSI, basit ve üssel hareketli ortalamalar, BB ve emtia kanal endeksi (CCI)) zenginleştirilmiş verileri kullanan Performer (FAVOR+) tabanlı Transformer ile çift yönlü uzun kısa süreli bellek (BiLSTM) katmanını birleştiren bir derin öğrenme modeli geliştirmişlerdir. 2018–2024 dönemine ait günlük ve saatlik verilerle yapılan analizde, teknik göstergelerin trend, momentum ve volatilité bilgisi sağlayarak modelin karmaşık ilişkileri yakalamasına ve tahmin doğruluğunun artmasına önemli katkı sunduğu; Performer + BiLSTM modelinin ise LSTM, GRU, BiLSTM ve

klasik Transformer yöntemlerine göre en düşük MSE, RMSE ve MSLE ile en yüksek  $R^2$  değerlerini elde ettiği belirlenmiştir.

Hafid vd. (2024), Bitcoin fiyatlarını tahmin etmek için XGBoost yöntemini kullanmışlardır. Çalışmada 1 Şubat 2021–1 Şubat 2022 dönemine ait 15 dakikalık kapanış fiyatları, açılış, en yüksek, en düşük fiyatlar ve hacim gibi piyasa verileri ile çok sayıda teknik gösterge kullanılmıştır. Bu göstergeler arasında üssel hareketli ortalamalar, RSI, momentum, MACD, stokastik osilatör ve ROC yer almaktadır. Sonuçlar, XGBoost modelinin en düşük MAE ve RMSE ve en yüksek  $R^2$  değerlerini sağlayarak Bitcoin fiyat tahmininde yüksek doğruluk sunduğunu göstermiştir.

Lee ve Xu (2024), Bitcoin fiyat hareketlerini kısa vadede tahmin etmek için teknik göstergelerle (stokastik osilatör, RSI ve MACD) zenginleştirilmiş verileri kullanan Dikkat Mekanizmalı GRU modeli geliştirmişlerdir. 2018-2024 dönemine ait günlük açılış, kapanış, en yüksek, en düşük fiyat ve hacim verileriyle yürütülen çalışmada, teknik göstergelerin trend, momentum ve volatilitiyi temsil ederek modelin karmaşık ilişkileri yakalamasına katkı sağladığı belirtilmiştir. Karşılaştırma sonuçları, göstergesiz modele kıyasla MACD eklenmesiyle doğruluğun %72'den %75'e yükseldiğini; RSI'nın olumlu, stokastik osilatörün ise sınırlı etki yaptığını ortaya koymuştur. Böylece Dikkat Mekanizmalı GRU modeli, özellikle MACD desteğiyle en yüksek doğruluk ve güçlü genelleme başarısı göstermiştir.

Islam vd. (2025), kripto varlık fiyat hareketlerini tahmin etmek amacıyla ML tabanlı modeller geliştirmişlerdir. Çalışmada, açılış, kapanış, en yüksek ve en düşük fiyatlar; işlem hacmi ve teknik göstergeler (basit ve üssel hareketli ortalamalar, RSI, BB) kullanılmıştır. Lojistik regresyon, RF ve XGBoost modelleri karşılaştırılmış; en yüksek doğruluk oranı %56,03 ile lojistik regresyon modeli tarafından elde edilmiştir. Sonuçlar, teknik göstergelerin ML modellerinin tahmin gücünü artırdığını ve kripto para fiyat yönünün tahmininde özellikle lojistik regresyonun öne çıktığını göstermiştir.

Ben Hamadou vd. (2025), yatırımcı duyarlılığının Bitcoin getirilerinin tahminine etkisini incelemiştir. Çalışmada 2014–2022 dönemine ait günlük veriler kullanılmış ve dönem, COVID-19 öncesi ve COVID-19 dönemi olarak ikiye ayrılmıştır. Bitcoin'in kapanış fiyatı, işlem hacmi, piyasa değeri, Parkinson volatilitesi, zincir verileri, finansal stres endeksi (FSI), EPU, S&P500, petrol ve altın fiyatları ile Google Trends verilerine dayalı özgün bir yatırımcı duyarlılığı endeksi modele dâhil edilmiştir. Çalışmada tek boyutlu evrişimli sinir ağı (1D-CNN), çift yönlü uzun kısa süreli bellek (BLSTM) ve SVR

kullanılmıştır. Bulgular, yatırımcı duyarlılığının her iki dönemde de en etkili değişken olduğunu; EPU ve FSI'nin öneminin COVID-19 sırasında azaldığını; S&P500 ve altının ise güçlü öngörü gücünü koruduğunu göstermiştir.

Sonuç olarak, literatürde kripto varlık fiyatlarının tahmini için pek çok ML yöntemi (SVR, LSTM, GRU, YSA, RF, XGBoost, LR, ANFIS vb.) kullanılmıştır. Bazı çalışmalarda yalnızca fiyat ve hacim gibi teknik veriler yer alırken; Aggarwal vd. (2019), Chen vd. (2020), Liu vd. (2021), Erfanian vd. (2022), Basher ve Sadorsky (2022), Nagula ve Alexakis (2022), Gradojevic vd. (2023), Penmetsa ve Vemula (2023), Labbaf Khaniki ve Manthouri (2024), Hafid vd. (2024), Lee ve Xu (2024), Islam vd. (2025), Ben Hamadou vd. (2025) gibi araştırmalarda modeller, yatırımcı duyarlılığı, makroekonomik faktörler ve teknik göstergeleri içerecek şekilde daha kapsamlı olarak tasarlanmıştır.

Genellikle kripto varlık fiyatlarının tahminine yönelik literatürde, veri türleri genellikle birbirinden bağımsız biçimde ele alınmakta; teknik göstergeler, makroekonomik veriler veya yatırımcı duyarlılığı göstergeleri çoğu zaman tek başına kullanılmaktadır. Bu durum, piyasanın çok boyutlu yapısını yeterince yansıtamamakta ve tahmin modellerinin bütüncül doğruluk düzeyini sınırlayabilmektedir. Ayrıca, birçok çalışmada yalnızca model performansları karşılaştırılmakta, kullanılan değişkenlerin tahmin sürecine katkı düzeyleri model bazında detaylı şekilde incelenmemektedir. Bu bağlamda, bu çalışma teknik analiz, yatırımcı duyarlılığı ve makroekonomik verileri birlikte içeren çok boyutlu bir veri seti ile gerçekleştirilmiştir.

## **5 VERİ SETİ VE METODOLOJİ**

### **5.1 Araştırmanın Problemi**

Günümüzde, kripto para piyasaları yatırımcıların yüksek getiri elde etmek için yatırım yaptıkları piyasalardan biri haline gelmiştir. Yatırımcılar yatırım kararı verirken kripto para fiyatlarının gelecekte ne olacağını tahmin etmek isterler. Ancak Kripto para piyasasının volatil doğası ve birçok faktörün etkisi, fiyat tahminlerini zorlaştırmaktadır. Bu nedenle, araştırma bu karmaşıklığı ele alarak, farklı makine öğrenimi modellerini karşılaştırmak, geçmiş fiyat verilerinin rolünü incelemek, teknik analiz göstergelerini araştırmak, makro ekonomik göstergelerin etkilerini değerlendirmek ve yatırımcı duyarlılığı göstergelerini analiz etmek suretiyle kripto para fiyat tahmininde kullanılabilecek en iyi yöntemi belirlemeyi amaçlamaktadır. Bu temel problem, kripto para piyasasındaki belirsizliklerin ve değişkenlerin anlaşılmasını ve yönetilmesini

hedefleyen bir araştırma çerçevesi sunmaktadır. Bu sayede kripto para birimlerinin fiyat tahmini için etkili bir yöntem geliştirmek, yatırımcıların da daha bilinçli kararlar almalarına yardımcı olabilir.

## **5.2 Araştırmanın Amacı**

Kripto para birimleri son yıllarda büyük bir ilgi odağı haline gelmiştir ve birçok kişi tarafından yatırım fırsatı olarak görülmektedir. Ancak, kripto para piyasası oldukça volatil bir yapıya sahip olduğundan, fiyat tahminleri yapmak zorlu bir görev haline gelmiştir. Bu nedenle bu çalışma, kripto para birimi fiyat tahmini için farklı makine öğrenimi modellerini karşılaştırmayı ve çok kriterli karar verme tekniklerini kullanarak en iyi yöntemi seçmeyi amaçlamaktadır. Bu ana amaç doğrultusunda, araştırmanın amaçları ve soruları aşağıdaki gibi oluşturulmuştur.

### **Araştırmanın Amaçları:**

1. Kripto para birimi fiyat tahmini için farklı makine öğrenimi modellerini karşılaştırmak.
2. Kripto para geçmiş fiyat verilerinin gelecek fiyat tahminindeki rolünü incelemek.
3. Teknik analiz göstergelerinin kripto para fiyatlarını nasıl etkileyebileceğini araştırmak.
4. Makro ekonomik göstergelerin kripto para fiyatları üzerindeki etkisini incelemek.
5. Yatırımcı duyarlılığı göstergelerinin kripto para fiyatlarını nasıl etkilediğini analiz etmek.
6. En iyi yöntemi seçmek için çok kriterli karar verme tekniklerini kullanmak.

### **Araştırmanın Soruları:**

1. Kripto para birimi fiyatlarını etkileyebilecek faktörler nelerdir ve ne kadar önemlidirler?
2. Kripto para fiyatları hangi değişkenlere bağlı olarak değişmektedir?
3. Hangi makro ekonomik göstergelerin kripto para birimi fiyatları üzerindeki etkisi vardır?
4. Hangi teknik göstergeler kripto para fiyatlarını tahmin etmede en etkili olabilir?
5. Kripto para piyasasının duygusal durumu ve yatırımcı psikolojisi, fiyatları nasıl etkilemektedir?
6. İstatistiki ölçütlere dayanarak her bir kripto para birimi için en iyi sonucu hangi makine öğrenim yöntemi vermektedir?

7. Çok kriterli karar verme tekniklerini kullanarak hangi makine öğrenimi modeli, kripto para birimi fiyat tahminleri için en iyi performansı göstermektedir?

### 5.3 Araştırmanın Evreni, Örneklemi ve Sınırlılıkları

Bu araştırma, kripto para fiyatlarını tahmin etmeyi amaçlamaktadır. Araştırmanın evreni, kripto para piyasalarıdır. Veriler, 1 Ocak 2018 ile 31 Aralık 2022 tarihleri arasındaki 5 yıllık süreçte günlük olarak elde edilmiştir. Araştırmada, 1 Ocak 2023 tarihinde piyasa değeri en yüksek 5 kripto para birimi belirlenmiştir.

Araştırmada, 1 Ocak 2018'den sonra işlem görmeye başlayan kripto paralar ve değeri ABD dolarına sabitlenen stable coin olarak adlandırılan kripto paralar çalışmaya dahil edilmemiştir. Çalışmaya dahil edilen kripto paralar şunlardır: Bitcoin (BTC), Ethereum (ETH), Binance (BNB), Ripple (XRP), Dogecoin (DOGE).

Kripto para fiyat tahmini yapmak için oluşturulacak modellerde, literatürde sıkça kullanılan değişkenler kullanılmıştır. Kripto para değişkenleri olarak açılış, kapanış, en yüksek, en düşük fiyat ve hacim değerleri belirlenmiştir. Teknik gösterge değişkenleri olarak göreceli güç göstergesi (RSI), hareketli ortalama çapraz sapma (MACD), stokastik osilatör (yavaş, hızlı), ilerleme-düşüş çizgisi (ADX), fiyat değişim oranı (ROC), denge hacmi (OBV), 50 günlük hareketli ortalama, 200 günlük hareketli ortalama ve Williams birikim ve dağılımı (WAD) belirlenmiştir.

Makro ekonomik göstergeler olarak spot altın fiyatı, ham petrol fiyatı, faiz oranları (ABD FED), enflasyon (ABD Tüketici Fiyat Endeksi), ABD dolar endeksi ve ekonomi politikası belirsizliği (EPU) dahil edilmiştir.

Bunların yanı sıra, hisse senedi belirsizliği (VIX) ve petrol piyasası belirsizliği (OVX) ile belirli bir anahtar kelimenin ya da konunun Google'da ne kadar popüler olduğunu gösteren ve kullanıcıların belirli bir terimi aramaya olan ilgisini yansıtabilen bir araç olan Google Trend arama endeksi hacmi ve kripto para piyasasının duygusal durumunu ve yatırımcıların genel psikolojisini yansıtan bir gösterge olan Korku ve açgözlülük endeksi araştırmaya yatırımcı duyarlılığı değişkenleri olarak araştırmaya dahil edilmiştir. Değişken listesine ve alınan kaynaklara Tablo 5.1'de yer verilmiştir.

**Tablo 5.1***Araştırmada Kullanılan Değişkenler ve Literatürdeki Kaynaklar*


| Değişkenler                       | Sembol                       | Grup                               | Referanslar                                                                                                                                                                                                |
|-----------------------------------|------------------------------|------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Açılış Fiyatı                     | Open                         | Kripto Para Değişkenleri           | Hitam ve İsmail (2018); Phaladisailoed ve Numnonda (2018); Hitam vd. (2019); Zhao vd. (2019); Rathan vd. (2019); Mallqui ve Fernandes (2019)                                                               |
| Kapanış Fiyatı                    | Close                        |                                    | Hitam ve İsmail (2018); Phaladisailoed ve Numnonda (2018); Karasu vd. (2018); Hitam vd. (2019); Zhao vd. (2019); Rathan vd. (2019); Atsalakis vd. (2019); Mallqui ve Fernandes (2019); Aggarwal vd. (2019) |
| En Yüksek Fiyat                   | High                         |                                    | Hitam ve İsmail (2018); Phaladisailoed ve Numnonda (2018); Karasu vd. (2018); Hitam vd. (2019); Zhao vd. (2019); Rathan vd. (2019); Mallqui ve Fernandes (2019)                                            |
| En Düşük Fiyat                    | Low                          |                                    | Hitam ve İsmail (2018); Phaladisailoed ve Numnonda (2018); Karasu vd. (2018); Hitam vd. (2019); Zhao vd. (2019); Rathan vd. (2019); Mallqui ve Fernandes (2019)                                            |
| Hacim (USD)                       | Volume                       |                                    | Phaladisailoed ve Numnonda (2018); Zhao vd. (2019); Rathan vd. (2019); Gradojevic vd. (2023);                                                                                                              |
| Göreceli Güç Göstergesi           | RSI                          | Teknik Analiz Göstergeleri         | Zhao vd. (2019); Basher ve Sadorsky (2022); Gradojevic vd. (2023); Penmetsa ve Vemula (2023); Labbaf Khaniki ve Manthouri (2024); Hafid vd. (2024); Lee ve Xu (2024); Islam vd. (2025)                     |
| Hareketli Ortalama Çapraz Sapma   | MACD, MACD_Signal            |                                    | Zhao vd. (2019); Basher ve Sadorsky (2022); Gradojevic vd. (2023); Penmetsa ve Vemula (2023); Hafid vd. (2024); Lee ve Xu (2024)                                                                           |
| Stokastik Osilatör (Yavaş, Hızlı) | Yavaş_%D, Hızlı_%D, Hızlı_%K |                                    | Basher ve Sadorsky (2022); Hafid vd. (2024); Lee ve Xu (2024)                                                                                                                                              |
| İlerleme-Düşüş Çizgisi            | ADX                          |                                    | Basher ve Sadorsky (2022)                                                                                                                                                                                  |
| Fiyat Değişim Oranı               | ROC10, ROC50                 |                                    | Basher ve Sadorsky (2022); Gradojevic vd. (2023); Hafid vd. (2024)                                                                                                                                         |
| Denge Hacmi                       | OBV                          |                                    | Basher ve Sadorsky (2022); Gradojevic vd. (2023)                                                                                                                                                           |
| 50 Günlük Hareketli Ortalama      | MA50                         |                                    | Basher ve Sadorsky (2022); Gradojevic vd. (2023); Labbaf Khaniki ve Manthouri (2024); Islam vd. (2025)                                                                                                     |
| 200 Günlük Hareketli Ortalama     | MA200                        |                                    | Basher ve Sadorsky (2022); Gradojevic vd. (2023); Labbaf Khaniki ve Manthouri (2024); Islam vd. (2025)                                                                                                     |
| Williams Birikim Ve Dağılımı      | WAD                          |                                    | Basher ve Sadorsky (2022); Gradojevic vd. (2023)                                                                                                                                                           |
| Spot Altın Fiyatı                 | XAU                          | Makroekonomik Göstergeler          | Aggarwal vd. (2019); Chen vd. (2020); Ranjan vd. (2022); Ben Hamadou vd. (2025)                                                                                                                            |
| Ham Petrol Vadeli İşlem Fiyatı    | WTI                          |                                    | Liu vd. (2021); Erfanian vd. (2022); Ben Hamadou vd. (2025)                                                                                                                                                |
| Faiz Oranları                     | FED                          |                                    | Basher ve Sadorsky (2022)                                                                                                                                                                                  |
| Enflasyon                         | CPI                          |                                    | Basher ve Sadorsky (2022)                                                                                                                                                                                  |
| ABD Dolar Endeksi                 | DXY                          |                                    | Liu vd. (2021)                                                                                                                                                                                             |
| Ekonomi Politikası Belirsizliği   | EPU                          |                                    | Basher ve Sadorsky (2022); Ben Hamadou vd. (2025)                                                                                                                                                          |
| CBOE Hisse Senedi Belirsizliği    | VIX                          | Yatırımcı Duyarlılığı Göstergeleri | Basher ve Sadorsky (2022)                                                                                                                                                                                  |
| CBOE Petrol Piyasası Belirsizliği | OVX                          |                                    | Basher ve Sadorsky (2022)                                                                                                                                                                                  |
| Korku ve Açgözlülük Endeksi       | FGI                          |                                    | Gradojevic vd. (2023)                                                                                                                                                                                      |
| Google Arama Eğilimleri           | GTRENDS                      |                                    | Chen vd. (2020); Guo vd. (2021); Liu vd. (2021); Ranjan vd. (2022); Gradojevic vd. (2023); Ben Hamadou vd. (2025)                                                                                          |

## 5.4 Araştırmanın Yöntemi

Bu çalışmada kripto para fiyat tahminine yönelik izlenen yöntem ve süreçler Şekil 5.1’de gösterildiği gibi yedi temel aşamadan oluşmaktadır.

Şekil 5.1

*Kripto Para Fiyat Tahmin Yöntemleri ve Süreçleri*



İlk aşamada verilerin toplanması gerçekleştirilmiş, kripto para fiyatları, teknik analiz göstergeleri, makroekonomik değişkenler ve yatırımcı duyarlılığına ilişkin veriler temin edilmiştir.

İkinci aşamada, veri ön işleme süreci kapsamında farklı kaynaklardan elde edilen veriler birleştirilmiş, eksik ya da hatalı veriler düzeltilmiş ve veriler eğitim ve test kümelerine ayrılmıştır.

Üçüncü aşamada, veri ölçeklendirme adımı uygulanarak Min-Max normalizasyon yöntemiyle değişkenler aynı ölçeğe getirilmiştir.

Dördüncü aşamada, model seçimi, eğitimi ve tahminlerin yapılması aşamasında SVM, LSTM, RF ve XGBoost gibi makine öğrenmesi algoritmaları kullanılarak modeller eğitilmiş ve tahminlemeler yapılmıştır.

Beşinci aşamada, performans değerlendirmesi gerçekleştirilmiş; modellerin başarımı  $R^2$ , MSE, RMSE ve MAE gibi hata metrikleri ile ölçülmüştür.

Altıncı aşamada, değişkenlerin önem analizine yer verilmiş; permütasyon yöntemi, RF ve XGBoost algoritmaları aracılığıyla değişkenlerin fiyat tahmini üzerindeki göreceli etkileri belirlenmiştir.

Son olarak, yedinci aşamada Çok Kriterli Karar Verme (ÇKKV) yöntemleri kullanılarak modellerin performanslarına göre genel sıralaması yapılmıştır. Bu bağlamda, CRITIC yöntemi ile kriterler ağırlıklandırılmış, TOPSIS, ARAS ile CODAS yöntemleriyle modeller karşılaştırılmış ve Copeland yöntemi ile de genel sıralama yapılmıştır.

#### **5.4.1 Verilerin toplanması**

Bu çalışmada kullanılan değişkenler farklı kaynaklardan elde edilmiştir. Kripto para değişkenleri investing.com, Yahoo Finance ve Binance.com üzerinden edilmiş olup, teknik gösterge değişkenleri kripto para verileri kullanılarak hesaplanmıştır. EPU endeksine ait veriler <https://www.policyuncertainty.com/> web sitesinden, ABD faiz oranı ve ABD tüketici fiyat endeksi(CPI) Fred Economic Data (<https://fred.stlouisfed.org/>) sitesinden, Hisse senedi belirsizliği (VIX) ve petrol piyasası belirsizliği (OVX) değişkenleri <https://www.cboe.com/> sitesinden, Spot altın (XAU), Ham petrol Vadeli işlem Fiyatı (WTI) ve ABD dolar endeksi (DXY) investing.com sitesinden, Google arama eğilimleri <https://trends.google.com/> adresinden, Bitcoin korku ve açgözlülük endeksi ise <https://alternative.me/crypto/fear-and-greed-index/> adresinden temin edilmiştir.

#### **5.4.2. Veri ön işleme**

Bu çalışmanın veri ön işleme aşamasında, farklı kaynaklardan temin edilen veriler tutarlı ve analiz edilebilir bir bütün oluşturacak şekilde tek bir yapıda birleştirilmiştir. Bu süreçte, veri setlerinde yer alan eksik ya da hatalı gözlemler titizlikle incelenmiş ve analiz sürecini olumsuz etkilememesi amacıyla uygun yöntemlerle işlenmiştir. Özellikle eksik veriler, zaman serisi analizinin doğasına uygun olarak bir sonraki günün gözlem değeri ile doldurularak veri bütünlüğü korunmuştur. Böylece elde edilen temiz ve tutarlı veri seti, makine öğrenmesi modellerinin etkin bir biçimde eğitilmesine ve test edilmesine olanak sağlayacak nitelikte hazırlanmıştır.

Bu işlemlerin ardından veriler, makine öğrenmesi modellerinin performansını değerlendirebilmek amacıyla eğitim ve test kümelerine ayrılmıştır. Eğitim verileri, modelin öğrenmesini sağlamak amacıyla 1 Ocak 2018 ile 31 Aralık 2022 tarihleri arasındaki dönemi kapsamaktadır. Modelin tahmin yeteneğini test etmek için ayrılan test verileri ise 1 Ocak 2023 ile 31 Aralık 2023 tarihleri arasındaki dönemden oluşmaktadır. Böylece model, geçmiş yıllardaki verilerle eğitilmiş ve geleceğe yönelik tahminleme gücü, hiç görmediği yeni verilerle objektif biçimde sınanmıştır.

#### **5.4.3 Veri ölçeklendirme**

Veri setindeki özniteliklerin (features) farklı aralıklarda veya birimlerde olması, bazı algoritmaların performansını olumsuz etkiler. Ölçeklemenin temel avantajı, daha büyük sayısal aralıklara sahip özniteliklerin, daha küçük aralıklara sahip olanlara baskın olmasını önlemektir. Bir diğer avantaj ise, hesaplama sırasında sayısal zorlukların önüne geçmektir (Hsu Vd., 2003). Veri ölçeklendirme işlemleri StandardScaler ya da MinMaxScaler kullanılarak yapılır.

StandardScaler ile ölçeklendirmede, StandardScaler, her özneliğin değerinden ortalamasını çıkarır ve standart sapmaya böler. Böylece her özellik ortalaması 0, standart sapması 1 olacak şekilde dönüştürülür (http-25). Büyük sayısal aralıklara sahip özniteliklerin, daha küçük aralıklara sahip olanları domine etmemesi için SVM, lojistik regresyon, k-NN ve sinir ağları gibi algoritmalar genellikle StandardScaler ile eğitim öncesi standartlaştırılır (http26).

MinMaxScaler ile ölçeklendirme ise her özneliği veri kümesindeki minimum ve maksimum değerlere göre sabit bir aralığa (örneğin, 0 ile 1 arası) ölçeklendirir. MinMaxScaler değerlerin etkisini azaltmaz, ancak bunları doğrusal olarak sabit bir aralığa ölçeklendirir ve en büyük oluşan veri noktası maksimum değere ve en küçüğü minimum değere karşılık gelir (http-27). LSTM gibi derin öğrenme modelleri genellikle MinMaxScaler ile (0,1) aralığı kullanılarak ölçeklendirilir (http-28).

Rastgele Orman ve XGBoost gibi ağaç-tabanlı topluluk yöntemleri ise verilerdeki farklılıklara duyarlı olmadıkları için özellik ölçeklemesinin yapılmasını gerektirmezler (http-29).

#### **5.4.4 Model seçimi ve eğitimi**

Kripto para birimi fiyatlarını tahmin etmeyi amaçlayan bu araştırmada, kripto para verilerinin yanı sıra teknik analiz araçları, makro ekonomik göstergeler ve duygusal

durumun dikkate alınmasıyla çeşitli faktörlerin kripto para fiyatlarını nasıl etkileyebileceği farklı makine öğrenme metotları ile karşılaştırılması ve en iyi yönteminin çok kriterli karar verme teknikleri kullanılarak seçilmesi hedeflenmektedir. Araştırmanın araştırma deseni, kripto para birimi fiyatlarını tahmin etmek için çeşitli faktörlerin analiz edilmesini ve farklı makine öğrenme modellerinin karşılaştırılmasını sağlamaktadır.

Araştırmada, kripto para verileri, makro ekonomik göstergeler, teknik analiz göstergeleri ve yatırımcı duyarlılığı göstergelerinden oluşan çeşitli faktörlerin kripto para fiyatlarını nasıl etkileyebileceği farklı çalışma prensibine sahip literatürde de yer verilen 4 makine öğrenme yöntemi ile araştırılacaktır. Bu yöntemler literatürde başarılı sonuçlar elde edilen yöntemler olup, XGBoost, Destek Vektör Makineleri, Rastgele Ormanlar, Uzun Kısa Süreli Bellek olarak seçilmiştir. Kullanılacak yöntemlere ve literatürdeki kaynaklara Tablo 5.2’de yer verilmiştir.

**Tablo 5.2**

*Kullanılan Yöntemler ve Literatürdeki Referanslar*

| Yöntemler                       | Referanslar                                                                                                                                                                               |
|---------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Aşırı Gradyan Artırma (XGBoost) | Zhao vd. (2019); Chen vd. (2020); Ranjan vd. (2022); Chowdhury vd. (2020);                                                                                                                |
| Destek Vektör Makineleri (SVM)  | Hitam ve İsmail (2018); Karasu vd. (2018); Hitam vd. (2019); Mallqui ve Fernandes (2019); Aggarwal vd. (2020); Chen vd. (2020); Salb vd. (2021); Ranjan vd. (2022); Gradojevic vd. (2023) |
| Uzun Kısa Süreli Bellek (LSTM)  | Aggarwal vd. (2019); Altan vd. (2020); Guo vd. (2021); Kargın vd. (2022); Phaladisailoed ve Numnonda (2018)                                                                               |
| Rastgele Ormanlar (RF)          | Zhao vd. (2019); Chen vd. (2020); Basher ve Sadorsky (2022); Ranjan vd. (2022); Gradojevic vd. (2023)                                                                                     |

#### **5.4.4.1 Destek Vektör Makineleri**

Destek Vektör Makineleri (SVM), Vapnik ve Cortes tarafından 1995 yılında geliştirilen bir makine öğrenmesi teknolojisidir. SVM hem regresyon hem de sınıflandırma analizleri için kullanılan popüler bir denetimli öğrenme modelidir. Algoritma kategorileri ayırt eden iki sınıf arasında düz bir çizgi oluşturarak analizini gerçekleştirir (Lyu, 2022).


SVM, maksimum marj hiper düzlemleri, destek vektörleri, konveks (çıkıntılı) yapılar, gevşeklik değişkenleri ve Mercer çekirdeği (kernel) gibi kavramları içerir. Bu teknik teori, özellikle küçük, basit, yüksek boyutlu ve doğrusal olmayan problemler için oldukça idealdir ve makine öğrenimi ile genelleme açısından yüksek bir kapasiteye sahiptir. (Salb vd., 2021).

Şekil 5.2’de SVM için iki özellikli hiper düzlem örneğine yer verilmiştir. Destek vektörleri hiper düzleme en yakın olan veri noktaları olarak ifade edilir. Destek vektörleri,

modelin karar sınırını belirler ve hiper düzleme paralel şekilde bir düzlem üzerinde yer alır. Destek vektörlerinin üzerinde yer aldığı ve kesikli çizgilerle yer alan düzlemlere ise marjin ya da sınır düzlemleri denir. Marjin düzlemlerinin tam ortasından geçen düzleme ise hiper düzlem denir (Ayhan ve Erdoğan, 2014).

**Şekil 5.2**

*SVM için 2 Özellikli Hiper Düzlem Örneği*



Bu çalışmada, SVM bir regresyon aracı olarak kullanılmış olup, bu durumda modele Destek Vektör Regresyonu (SVR) adı verilir.

SVR modeli, modelin yakın çevresindeki belirli bir eşik ( $\epsilon$ ) içinde kalan örnekleri göz ardı ettiğinden, eğitim verilerinin yalnızca seçili bir kısmını dikkate alır. Veriler doğrusal olmayan ancak ayrılabilir özellikler gösterdiğinde, çekirdek (kernel) yöntemi faydalı olur. Bağımsız değişkenler uzayında doğrusal olarak çözilemeyen birçok regresyon problemi, uygun bir dönüştürme ile daha yüksek boyutlu bir öznitelik uzayına ( $x \mapsto \phi(x)$ ) aktarılabilir, bu da etkili bir regresyonu mümkün kılar. SVR çerçevesinde amaç, gözlenen bir değer  $t$  için gerçek bir çıktı  $y$ 'yi tahmin etmektir (Menendez-García vd., 2024).

Regresyon problemleriyle ilgilenirken, SVM verileri ayıran ve yakın veri noktalarından mümkün olduğunca uzak olan en iyi çizgiyi oluşturur. Bir SVM modeli oluşturulurken, kullanılan farklı çekirdek (kernel) fonksiyonlarına bağlı olarak sonuçlar değişebilir. Çekirdek fonksiyonu, verilen veriyi gerekli forma dönüştürür. Bu fonksiyonlar; lineer, doğrusal olmayan, polinom ve radyal tabanlı fonksiyon (RBF) gibi farklı türlerde olabilir. Bu fonksiyonlar arasında, RBF çekirdeği sabit (stationary) bir çekirdek olup, alan (hafıza) karmaşıklığı problemini aşma konusundaki avantajları nedeniyle yaygın olarak kullanılmaktadır (Lyu, 2022).

Bu çalışmada, üstün performansı nedeniyle Radyal Taban Fonksiyonu (Radial Basis Function - RBF) çekirdeği kullanılmıştır

Ayrıca, SVR modelini başarılı şekilde oluşturabilmek için  $C$ ,  $\epsilon$  ve  $\gamma$  olmak üzere bazı hiperparametrelerin belirlenmesi gereklidir. Parametreleri belirlemek için, hızlı ve doğru sonuçlar veren sağlam bir hiperparametre arama algoritmaları kullanılmaktadır. Hiperparametre kombinasyonları, "grid search" (ızgara arama) yöntemi ile belirlenmiştir.


#### 5.4.4.2. Rastgele Ormanlar

Rastgele Ormanlar algoritması, Leo Breiman tarafından 2001 yılında geliştirilmiş ve sınıflandırma ile regresyon problemlerine yönelik güçlü bir topluluk (ensemble) öğrenme yöntemidir. Bu yöntem, birçok karar ağacının bir araya getirilmesiyle oluşturulur ve her bir ağaç, bootstrap yöntemiyle oluşturulan rastgele örneklem kümeleri üzerinden inşa edilir. Her ağacın büyüme sürecinde, düğümlerde tüm öznitelikler arasından en iyi ayrımı aramak yerine, rastgele seçilen özniteliklerin alt kümesinden en iyi bölünme tercih edilir. Bu sayede modelde çeşitlilik sağlanır ve aşırı öğrenme riski azaltılır (Lyu, 2022).

Karar ağaçları, öznitelik uzayını yinelemeli olarak bölmek için ağaç yapısını benimser ve her bir düğüm, saflığı (purity) maksimize etmek amacıyla bölünmeye devam eder. Bu süreç, düğümlerin yalnızca tek sınıfa ait örnekler içerdiği noktaya kadar sürer. Bu tamamen saf düğümler yaprak düğümler olarak adlandırılır. Bir test örneği karar ağacına verildiğinde, bu örnek ağacın dallarından yaprak düğüme kadar izlenir ve böylece bir sınıf etiketi atanabilir. Bootstrap (toplama) işlemi uygulanarak, her ağacın büyümesinde kullanılacak öznitelik uzayının rastgele bir alt kümesi belirlenir (Chen vd., 2020).

Şekil 5.3

*Random Forest Modelinin Kavramsal Yapısı*



Kaynak: Mbedzi, 2022

Şekil 5.3'te'de gösterildiği gibi, hedef bilgi her bir ağaç modeline girdi olarak verildiğinde, ağaç modelleri doğaları gereği birbirinden bağımsız şekilde kendi sonuçlarını üretir. Ormanın çıktısı, bu sonuçların çoğunluk kararı ile belirlenir ya da bu çıktıların aritmetik ortalaması alınır. Bu tahminde, sınıflandırma ağaçlarından oluşan bir RF modeli, oy birliğiyle verilmiş bir karar üretirken, regresyon ağaçlarından oluşan bir RF modeli ise aritmetik ortalama ile tahmin yapar. (Mbedzi, 2022).

#### **5.4.4.3 Aşırı Gradyan Artırma**

Aşırı Gradyan Artırma (XGBoost), karar ağacının geliştirilmiş bir versiyonudur. Bu algoritmanın amacı ağaçların büyütülmesi için gereken süreyi en aza indirmek ve optimizasyon sürecini hızlandırmaktır (Chen vd. 2020).

(XGBoost), karar ağaçlarını yinelemeli (iteratif) olarak oluşturur. Yüksek hataya sahip her ağaç, zayıf öğrenici olarak adlandırılır. Gradyan artırma tekniği, başlı başına tatmin edici performansa sahip olmayan basit bir ilk ağaç oluşturarak başlar. Daha sonra, bu ilk ağacın başaramadığı tahminleri yapacak şekilde eğitilen başka bir ağaç oluşturulur ve bu ağaç da zayıf bir öğrenicidir. Bu süreç, her biri bir öncekini düzelten daha fazla zayıf öğrenici inşa edilerek sırayla devam eder. Bu, oluşturulacak ağaç sayısı gibi bir durdurma koşuluna ulaşılan kadar sürer (Ranjan vd., 2022).


Gradyan artırmalı karar ağaçları, birçok zayıf sınıflandırıcının sonuçlarını birleştirerek güçlü bir tahminde bulunan bir sınıflandırıcıdır. Çünkü her bir ağaç, çok sayıda regresyon fonksiyonu ile yaklaşık olarak temsil edilir. Önceki ağaçtaki artıklar daha iyi sınıflandırılmaya çalışıldıkça, sınıflandırma hatası ardışık olarak azalabilir. Her bir ağaç en iyi şekilde oluşturulduktan sonra, yapının puanları ve kazancı hesaplanarak en iyi bölünme belirlenir. Son olarak, tüm modelin tahmin sonucu, her karar ağacının çıktısının toplamıdır (Chen vd. 2020).

#### **5.4.4.4 Uzun Kısa Süreli Bellek**

LSTM, uzun kısa süreli bellek bloklarından oluşan RNN (Yinelenen Sinir Ağı) yapısının bir varyasyonudur. Standart RNN'lerin sahip olduğu gradyan kaybolması sorununa LSTM ile çözüm bulunmuştur. LSTM ağı, hücre durumu ve gizli durum olmak üzere iki duruma ve giriş, çıkış ve unutma kapısı olmak üzere üç kapıya sahiptir. Bu sayede, ne zaman hatırlanacağına ve unutulacağına karar vererek uzun vadeli bağımlılıkları öğrenme yeteneğine sahip olur (Aggarwal vd., 2019).

Şekil 5.4

LSTM Yapısı



Kaynak: Daniels, 2022

Şekil 5.4'te yer verilen LSTM yapısına göre işlemler şu şekildedir; Unutma kapısı ( $F_t$ ), bellek hücresi durumuna bilgiyi seçici olarak ekler ya da çıkarır. Ağ, öncelikle ne kadar bilginin atılması gerektiğine karar vererek başlar. Bu işlem için bilgi önce unutma kapısından geçirilir ve buna ek olarak, önceki LSTM hücresinden gelen çıktı ( $H_t - 1$ ), yani gizli durum da kullanılır. Daha sonra, önceki hücre durumuna ( $C_t - 1$ ) eklenip saklanması gereken yeni bilgiler iki adımda gerçekleşir. İlk olarak, giriş kapısı hangi değerlerin güncellenmesi gerektiğine karar verir. Tanh fonksiyonunun çıktısı, önceki hücre durumunu ( $C_t - 1$ ) güncelleyerek, aday değerler kümesi ( $C_t$ ) oluşturur. Bu da yeni bellek hücresi durumunu ( $C_t$ ) oluşturur. Son olarak, yeni bellek hücresi durumu ve ( $O_t$ )ten gelen bilgi kullanılarak, çıktı kapısından sonuç elde edilir (Daniels, 2022).

#### 5.4.5 İstatistiki performans göstergeleri

Bu bölümde, makine öğrenme modellerinin performansını değerlendirmek için kullanılacak performans göstergeleri tanıtılmaktadır. Kurulan modellerin performanslarını değerlendirmek için istatistiksel analiz ve makine öğrenmesi alanlarında literatürde sıkça kullanılan performans göstergeleri seçilmiştir. Literatürde yaygın olarak kullanılan dört ölçüt, Kök Ortalama Kare Hatası (RMSE), Ortalama Kare Hatası (MSE), Belirleme Katsayısı ( $R^2$ ) ve Mutlak Ortalama Hata (MAE) makine öğrenme yöntemlerini değerlendirmek için seçilmiştir. Bu metrikleri kullanan kaynaklara da Tablo 5.3' de yer verilmiştir. Ayrıca hata metriklerinin açıklamaları aşağıda yer almaktadır.

**Tablo 5.3***Performans Metrikleri ve Literatürdeki Kaynaklar*

| Performans Metrikleri | Referanslar                                                                                                                                                                                    |
|-----------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| $R^2$                 | Phaladisailoed ve Numnonda (2018); Ustalı vd. (2020); Erfanian vd. (2020)                                                                                                                      |
| MAE                   | Karasu vd. (2018); Atsalakis vd. (2019); Mallqui ve Fernandes (2019); Guo vd. (2021);                                                                                                          |
| MSE                   | Phaladisailoed ve Numnonda (2018); Karasu vd. (2018); Atsalakis vd. (2019); Guo vd. (2021)                                                                                                     |
| RMSE                  | Hitam ve İsmail (2018); Karasu vd. (2018); Atsalakis vd. (2019); Mallqui ve Fernandes (2019); Aggarwal vd. (2019); Guo vd. (2021); Liu vd. (2021); Karğın vd. (2022); Mittal ve Geettha (2022) |

**Kök Ortalama Kare Hatası (RMSE)**, gerçek ve tahmin edilen değerler arasındaki farkın karelerinin ortalamasının kareköküdür. Artıkların standart sapmasını ölçer ve model tahminlerinin gözlemlenen değerlerden ne kadar sapma gösterdiğini belirtir. Düşük bir RMSE değeri, modelin verilere daha iyi uyduğunu gösterirken, yüksek olması modelin veriye uyum sağlamakta zorlandığını gösterir. RMSE değerinin sıfır olması ise , tahmin edilen ve gözlemlenen veriler arasında tam bir uyum olduğunu ifade eder. Formülü aşağıdaki gibidir (Menendez-García vd., 2024):

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

**Ortalama Kare Hatası (MSE)**, gerçek ve tahmin edilen değerler arasındaki farkın başka bir ifadeyle hataların karelerinin ortalamasıdır. Aşağıdaki şekilde tanımlanır (Agrawal vd., 2022):

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \bar{y}_t)^2$$

**Belirleme Katsayısı ( $R^2$ )**, bir tahmin modelinin ne kadar iyi uyum sağladığını gösteren bir ölçüttür.  $R^2$  değeri, gerçek değerlerin ne kadarını tahmin modelinin açıkladığını gösterir.  $R^2$ , 1'e yaklaştıkça, modelin daha iyi bir uyum sağlamaktadır (Özgür vd., 2023).  $R^2$  formülü aşağıdaki gibi ifade edilmektedir (He vd., 2024):

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \bar{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y}_t)^2}$$

**Mutlak Ortalama Hata (MAE)**, tahmin edilen ve gerçek gözlemler arasındaki mutlak farkların ortalamasıdır. MAE, doğrusal bir skordur. Bu, tüm bireysel farkların ortalama

eşit şekilde dikkate alındığı anlamına gelir. Dolayısıyla, daha büyük hatalar toplam hataya doğrusal olarak katkıda bulunmaktadır. Formülü aşağıdaki gibidir (Ayala vd., 2021):

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \bar{y}_t|$$

#### 5.4.6 Değişkenlerin önem analizi

Bu çalışmada kullanılan makine öğrenmesi modelleri olan Destek Vektör Makineleri (SVM), Uzun Kısa Süreli Bellek (LSTM), Rastgele Orman (RF) ve Aşırı Gradyan Artırma (XGBoost) için değişkenlerin tahmin üzerindeki etkilerini analiz edebilmek amacıyla farklı değişken önem analiz teknikleri uygulanmıştır.

SVM ve LSTM gibi modellerde doğrudan bir değişken önem ölçütü bulunmamaktadır. Bu nedenle, bu modellerde değişken önemini değerlendirmek için permütasyon önem analizi yöntemi tercih edilmiştir. Permütasyon yöntemi, her bir özelliğin değerlerinin rastgele karıştırılmasıyla model performansındaki değişimi ölçerek çalışır. Bir değişkenin model performansına olan katkısı, bu değişkenin permütasyonu sonrasında oluşan performans düşüşü ile değerlendirilir (http-30).

Rastgele Ormanlar ve Aşırı Gradyan Artırma algoritmaları, makine öğrenmesi alanında hem sınıflandırma hem de regresyon problemleri için yaygın olarak kullanılmakta olup, aynı zamanda değişken önem düzeylerini hesaplama yetenekleri de bulunmaktadır. Bu nedenle RF ve XGBoost modelleri için ise kendi bünyelerinde hesapladıkları ağaç tabanlı önem ölçütleri kullanılmıştır.

#### 5.4.7 Çok kriterli karar verme yöntemleriyle en iyi yöntemin seçilmesi

Kripto paraların fiyat tahmininde kullanılan makine öğrenmesi yöntemlerinin istatistiksel performans metriklerini kullanarak çok kriterli karar verme teknikleriyle en iyi yöntemi belirlemek için, kriterlerin ağırlıkları CRITIC yöntemiyle hesaplanarak TOPSIS, ARAS ve CODAS yöntemleriyle yöntemlerin sıralaması elde edilecektir. Yöntemlerin genel sıralama ise Copeland birleştirme yöntemi ile tespit edilecektir.

**CRITIC yöntemi**, Diakoulaki ve arkadaşları (1995) tarafından önerilen standart sapma temelli bir kriter ağırlıklandırma tekniğidir. Bu yöntem, karar problemlerinde kullanılan kriterlerin hem varyansını hem de birbirleriyle olan korelasyonlarını dikkate alarak hesaplama yapmayı amaçlamaktadır. CRITIC yöntemi, karar vericinin subjektif değerlendirmelerine ihtiyaç duymaksızın, kriterlerin bilgilendiricilik düzeyine göre ağırlıklandırılmasına olanak tanır. Yöntemin uygulanması dört temel adımdan

oluşmaktadır. İlk olarak, karar matrisinin elemanları normalize edilerek fayda ve maliyet yönlü kriterler için uygun dönüşümler uygulanır. İkinci adımda, kriterler arası ilişkinin derecesini belirlemek amacıyla korelasyon katsayısı hesaplanır. Üçüncü adımda, her bir kriter için standart sapma ve korelasyon değerlerinden faydalanılarak toplam bilgi değeri hesaplanır. Son adımda ise bu bilgi değerleri kullanılarak her bir kriterin göreceli ağırlığı belirlenir. Bu yaklaşım, kriterler arasındaki bağımlılıkları ve değişkenlikleri dikkate alarak daha dengeli ve objektif ağırlıklar sunar (Ersoy, 2022).

**TOPSIS yöntemi**, Yoon ve Hwang tarafından 1980 yılında ELECTRE metoduna alternatif olarak geliştirilmiş çok kriterli karar verme (ÇKKV) tekniklerinden biridir. Temel varsayımı, en uygun alternatifin ideal çözüme en yakın ve negatif-ideal çözüme en uzak olan alternatif olduğudur. Yöntemde, her bir kriterin tekdüze bir biçimde artan ya da azalan fayda eğilimine sahip olduğu varsayılır. Uygulama süreci altı temel adımdan oluşur. İlk adımda, karar matrisindeki değerler normalize edilir. İkinci adımda, normalize değerler, ilgili kriterlerin ağırlıklarıyla çarpılarak ağırlıklı normalize değerler hesaplanır. Üçüncü adımda, pozitif-ideal ve negatif-ideal çözümler belirlenir. Dördüncü adımda, her alternatifin ideal ve negatif-ideal çözüme olan uzaklıkları, Öklid uzaklığı yaklaşımıyla hesaplanır. Beşinci adımda, bu mesafeler kullanılarak her alternatifin ideal çözüme olan göreceli yakınlık değeri elde edilir. Son adımda ise, alternatifler bu yakınlık değerlerine göre sıralanarak en uygun alternatife ulaşılır. TOPSIS yöntemi, karar vericilere alternatifler arasında nicel farklılıkları dikkate alarak rasyonel bir tercih yapma imkânı sunar (Dumanoglu, 2010).

**ARAS yöntemi**, karar problemlerinde alternatiflerin fayda değerlerine göre değerlendirilmesini esas alan ÇKKV yöntemlerinden biridir. Yöntem, alternatiflerin değerlendirilmesinde ideal çözümün doğrudan karşılaştırılmasını değil, her alternatifin fayda fonksiyonu değerlerinin analizini temel alır. Süreç, karar matrisinin oluşturulması, bu matrisin normalize edilmesi, ağırlıklandırılmış normalize değerlerin hesaplanması ve nihayetinde her alternatifin optimalite fonksiyon değerinin belirlenerek göreceli olarak değerlendirilmesi adımlarını içerir. Son adımda ise her alternatifin etkinliği, elde edilen fayda değerinin en yüksek fayda değerine oranlanmasıyla bulunur ve bu oran, alternatiflerin nihai sıralamasını oluşturur. (Yıldırım, 2015).

**CODAS yöntemi**, Keshavarz Ghorabae ve arkadaşları (2016) tarafından geliştirilmiş, çok kriterli karar verme problemlerine yönelik yenilikçi bir yaklaşımdır. Yöntem, alternatiflerin negatif ideal çözümden olan uzaklıklarına dayalı olarak değerlendirilmesini

esas alır ve bu uzaklıklar Öklid ve Taksicab metrikleri ile hesaplanır. Öncelikle karar matrisi oluşturulup kriter tipine göre normalize edilir ve ardından ağırlıklandırılmış normalize matris elde edilir. Negatif ideal çözüm belirlendikten sonra, her alternatifin bu çözüme olan Öklid ve Taksicab uzaklıkları hesaplanır. Alternatifler arasındaki farklılıkları daha belirgin hale getirmek amacıyla görelî değerlendirme matrisi oluşturulur. Eğer alternatiflerin Öklid uzaklıkları arasındaki fark belirli bir eşik değerden küçükse, karşılaştırma Taksicab uzaklıklarıyla yapılır. Son adımda her alternatifin değerlendirme puanı hesaplanır ve bu puanlara göre alternatifler büyükten küçüğe sıralanarak en uygun seçenek belirlenir (Tuş ve Adalı, 2018).

**Copeland yöntemi**, Condorcet ilkesine dayanarak alternatifler arasındaki ikili karşılaştırmalar üzerinden en uygun seçeneğin belirlenmesini amaçlayan bir çok kriterli karar verme tekniğidir. Bu yöntemde, her bir alternatifin diğerlerine karşı galibiyet ve mağlubiyet sayıları hesaplanır ve bu fark üzerinden Copeland skoru elde edilir. Bu veriler yardımıyla alternatifler karşılıklı olarak değerlendirilir ve galibiyet, mağlubiyet ya da eşitlik durumlarına göre +1, -1 veya 0.5 puanlar verilir. Bu puanlar toplanarak her alternatif için galibiyet ve yenilgi puanları belirlenir. Son adımda, bu iki puanın toplamı Copeland puanını verir ve alternatifler bu puana göre sıralanır. En yüksek puana sahip olan alternatif en iyi seçenek olarak değerlendirilir. Eşitlik durumunda, indeks değeri daha düşük olan alternatif öne çıkar. Bu yöntem, özellikle çok sayıda karar verici ya da kriter bulunduğu, alternatiflerin genel üstünlüğünü daha sistematik biçimde ortaya koyar (Çakır, 2017).

## **6 BULGULAR VE DEĞERLENDİRME**

### **6.1 Araştırmanın Bulguları**

Bu çalışmada, kripto para birimlerinin fiyat tahmini amacıyla makine öğrenme algoritmalarından biri olan SVM, RF, XGBoost ve LSTM yöntemi kullanılmıştır. Öncelikle, zaman serisi formatında hazırlanan veri setinin günlük frekansta olması sağlanarak eksik gözlemler uygun biçimde doldurulmuştur. Model eğitimi ve testi için veri seti, 01.01.2018 ile 31.12.2022 tarihleri arası eğitim; 01.01.2023 ile 31.12.2023 tarihleri arası ise test verisi olarak ayrılmıştır. Tahmin değişkeni olarak kapanış fiyatı (Close) belirlenmiş, açıklayıcı değişkenler olarak ise fiyat hareketleri, teknik analiz göstergeleri, makroekonomik göstergeler ve yatırımcı duyarlılığı göstergeleri olmak üzere toplam 27 değişken kullanılmıştır.

### 6.1.1 Destek vektör makinesi yöntemi ile kripto para fiyat tahmini

Kripto paraların fiyat tahmininde Destek Vektör Regresyonu (SVR) modeli kullanılırken, tüm değişkenler StandardScaler yöntemiyle ölçeklendirilmiştir. Bu adım, özellikle mesafeye duyarlı algoritmalar arasında yer alan SVM tabanlı modellerde oldukça kritik bir rol oynamaktadır. Çünkü farklı ölçeklerdeki değişkenler, modelin öğrenme sürecini olumsuz etkileyerek hatalı ağırlıklandırmalara neden olabilir.

Modelin eğitimi sürecinde SVR algoritması uygulanmış ve hiperparametre optimizasyonu amacıyla GridSearchCV yöntemi tercih edilmiştir. "C", "gamma" ve "kernel" parametreleri için farklı kombinasyonlar oluşturularak 5 katlı çapraz doğrulama ile test edilmiş, böylece en uygun parametre seti belirlenmiştir. Tablo 6.1’de sunulan hiperparametre sonuçları, farklı kripto para birimlerinde elde edilen en iyi parametrelerin birbirinden farklı olduğunu göstermektedir. Bu durum, farklı kripto para birimlerinin fiyat yapılarının modele duyarlılığının değiştiğini ve optimal hiperparametrelerin varlık bazında farklılık gösterebildiğini ortaya koymaktadır

**Tablo 6.1**

*SVM Modeli için Yapılan Hiperparametre Optimizasyonu Sonuçları*

| Kripto Para | C   | Gamma | Kernel |
|-------------|-----|-------|--------|
| Bitcoin     | 100 | 0,01  | linear |
| Ethereum    | 100 | 0,01  | linear |
| Ripple      | 0,1 | 0,1   | linear |
| BNB         | 100 | 0,01  | linear |
| Dogecoin    | 0,1 | 0,1   | linear |

En iyi hiperparametrelere sahip model kullanılarak test verisi üzerinde tahminleme gerçekleştirilmiş ve modelin performansı  $R^2$ , RMSE, MSE ve MAE hata metrikleri ile değerlendirilmiştir.

Genel performans değerlendirmesi yapıldıktan sonra modelin karar mekanizmasında hangi değişkenlerin ne düzeyde etkili olduğunu belirlemek amacıyla permütasyon önem analizi uygulanmıştır. Bu yöntemde, her bir değişken sırayla bozulmakta ve modelin performansındaki değişim ölçülerek o değişkenin göreceli katkısı hesaplanmaktadır. Analiz sonucunda elde edilen önem skorları sıralanarak, modelin hangi değişkenlere daha fazla duyarlı olduğu ortaya konmuştur.

Tablo 6.2’de, SVM yöntemi ile yapılan kripto para fiyat tahminlerinin performansına ilişkin sonuçlar, Şekil 6.1’de ise gerçek fiyatlar ile tahmin edilen fiyatların grafiksel karşılaştırması gösterilmektedir. SVM modeli ile gerçekleştirilen fiyat tahminlerinde,

farklı kripto para birimleri için model performansı  $R^2$ , MAE, MSE ve RMSE hata metrikleri kullanılarak analiz edilmiştir. Elde edilen sonuçlar incelendiğinde, modelin Bitcoin, Ethereum ve BNB için oldukça yüksek başarı sağladığı görülmektedir. Bu varlıklar için  $R^2$  değerleri sırasıyla 0,995509, 0,995733 ve 0,995685 olup, modelin gerçek fiyatlara çok yakın tahminler yaptığını göstermektedir. Ethereum’da MAE değeri yalnızca 10,62 iken, RMSE ise 14,30 düzeyinde kalarak modelin oldukça düşük hata ile tahmin gerçekleştirdiğini ortaya koymaktadır. Benzer şekilde, BNB için 1,78 ile hem MAE, 2,78 ile hem de RMSE oldukça düşüktür.

**Tablo 6.2**

*SVM Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi*

| Kripto Para | Yöntem | Hata Metrikleri |            |               |            |
|-------------|--------|-----------------|------------|---------------|------------|
|             |        | $R^2$           | MAE        | MSE           | RMSE       |
| Bitcoin     | SVM    | 0,995509        | 256,557350 | 155985,295498 | 394,949737 |
| Ethereum    | SVM    | 0,995733        | 10,627267  | 204,569135    | 14,302766  |
| Ripple      | SVM    | 0,799939        | 0,039878   | 0,045268      | 0,002049   |
| BNB         | SVM    | 0,995685        | 1,783359   | 2,751695      | 2,751695   |
| Dogecoin    | SVM    | -15,671967      | 0,041862   | 0,001800      | 0,042433   |


Öte yandan, Ripple için modelin başarısı 0,799939  $R^2$  değeri ile nispeten daha düşüktür. Bu durum, Ripple fiyatlarındaki yapısal değişkenliklerin modele tam olarak yansıtılamadığını düşündürmektedir.

Dogecoin için ise model başarısız olmuştur;  $R^2$  değeri -15,67 olup bu değer, modelin sabit ortalamadan bile kötü tahmin yaptığına işaret etmektedir. Bu başarısızlık, Dogecoin’in spekülative doğası ve yüksek volatilitesi nedeniyle SVM modelinin bu varlığa uygun olmamasından kaynaklanabilir. Ayrıca, Dogecoin’in fiyat aralığına göre hata metrikleri düşük görünse de bu durum SVM modelinin genel başarısızlığını telafi edememektedir.

Sonuç olarak, SVM modeli Bitcoin, Ethereum ve BNB için başarılı bir performans sergilemiştir. Ripple için model performansı bir miktar düşmesine rağmen tahmin sonuçları başarılı kabul edilebilmektedir. Dogecoin için ise SVM modeli tamamen başarısız olmuştur.

**Şekil 6.1**

### SVM Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması



Tablo 6.3'te, SVM modeli ile yapılan kripto para fiyat tahminlerinde kullanılan değişkenlerin permütasyon yöntemiyle hesaplanan önem düzeyleri, Şekil 6.2'de ise önem düzeylerinin grafiksel gösterimlerine yer verilmiştir. Bitcoin, Ethereum, Ripple ve BNB için yapılan analizlerde, modelin tahmin gücüne en çok katkı sağlayan değişkenlerin genellikle fiyat seviyeleri ve teknik göstergeler olduğu anlaşılmaktadır.

Bitcoin için yapılan permütasyon önem analizi sonuçları, tahmin başarısının büyük ölçüde fiyat bileşenlerine dayandığını göstermektedir. En yüksek önem düzeyine sahip değişkenler sırasıyla High, Low ve Open olup, bu değişkenler tahminleme performansında en kritik rolü oynamaktadır. Bunun yanı sıra, MA50 ve MACD gibi teknik göstergeler de önemli katkı sağlamıştır. Bu durum, Bitcoin fiyatlarının hem geçmiş fiyat seviyelerine hem de teknik analiz sinyallerine duyarlı olduğunu göstermektedir. RSI, MA200 ve ROC50 gibi göstergeler ise ikincil düzeyde etkili olup, piyasa yönü ve momentumun tahmin sürecine katkıda bulunduğu görülmektedir. Öte yandan, EPU,


ADX, OBV ve XAU gibi bazı makroekonomik ve hacim bazlı değişkenlerin negatif ya da çok düşük önem düzeyine sahip olduğu dikkate değer bir bulgudur.

Ethereum için de en önemli üç değişken yine fiyat seviyeleri olan High, Low ve Open olmuştur. Bu durum, Bitcoin ile benzer şekilde Ethereum'un da teknik fiyat bileşenlerine oldukça duyarlı olduğunu ortaya koymaktadır. Ethereum'da MA50, MACD, RSI ve %K gibi teknik göstergeler önemli katkı sağlamıştır. Makroekonomik göstergelerin çoğu (örneğin CPI, DXY, EPU) sıfıra yakın ya da sıfır etkide bulunmuştur. Bu durum, Ethereum'un tahmininde de daha çok geçmiş fiyat hareketlerinin etkili olduğunu, piyasa duyarlılığı ve küresel ekonomik faktörlerin sınırlı rol oynadığını göstermektedir.

Ripple için yapılan önem analizi sonuçlarına göre en yüksek önem düzeyine sahip değişkenler sırasıyla Low, High ve MA50 olup, bu değişkenlerin katkısı yüksektir. Hızlı\_%D, Hızlı\_%K, RSI, Yavaş\_%D, WAD, MACD ve MA200 gibi yaygın kullanılan finansal teknik göstergelerin model üzerinde ikincil düzeyde bir etkisi bulunmaktadır. Ayrıca, makroekonomik ve yatırımcı duyarlılığı değişkenlerin (CPI, DXY, WTI) çoğu negatif önem skorlarına sahip olup, Ripple fiyatlarının küresel ekonomik göstergelere karşı duyarlılığının oldukça düşük olduğunu göstermektedir.

BNB için yapılan permütasyon önem analizi sonuçları, SVM modelinin bu kripto para üzerinde oldukça başarılı tahminlerde bulunduğunu ve değişkenlerin model üzerindeki etkisinin anlamlı olduğunu göstermektedir. En yüksek önem düzeyine sahip ilk üç değişken sırasıyla High, Low ve Open olup, fiyat seviyeleri modelin tahmin gücüne en fazla katkı sunan değişkenler olmuştur. Bu durum, BNB'nin kısa vadeli fiyat dinamiklerinin doğrudan geçmiş fiyat hareketlerine dayandığını ortaya koymaktadır. Teknik analiz göstergeleri açısından değerlendirildiğinde, MA50, MACD, Hızlı %K, Hızlı %D ve MACD\_Signal gibi göstergelerin de önemli roller üstlendiği görülmektedir. Bu göstergeler piyasa momentumu, trend yönü ve kısa vadeli değişimleri başarıyla yansıttığı için modelin doğruluğuna olumlu katkı sağlamıştır. Makroekonomik ve davranışsal değişkenlerin (örneğin FGI, VIX, EPU, CPI, GTRENDS) katkıları ise sınırlı kalmış ve bazı değişkenler (FED, ADX, ROC10) negatif skorlar alarak modelin performansına olumsuz etki göstermiştir. Bu bulgular, BNB'nin fiyatlarının büyük ölçüde teknik fiyat göstergelerine ve kısa vadeli piyasa dinamiklerine dayalı olarak şekillendiğini ve SVM modelinin bu yapıyı başarılı şekilde temsil ettiğini göstermektedir.

*SVM Yöntemi İçin Değişkenlerin Önem Düzeylerinin Grafiği*



SVM modeli ile yapılan kripto para fiyat tahminlerinde en belirleyici değişkenlerin genel olarak fiyat seviyeleri ve teknik analiz göstergeleri olduğu görülmektedir. Makroekonomik ve duyarlılık temelli değişkenlerin ise bazıları katkı sağlasa da çoğu kripto para için düşük veya negatif önem düzeyine sahip olması, bu göstergelerin fiyat hareketlerini açıklamada sınırlı kaldığını ortaya koymaktadır. Bu durum, SVM modelinin teknik ve fiyat verilerine daha duyarlı çalıştığını ve kripto paraların fiyat yapısının büyük ölçüde kendi iç piyasa dinamikleriyle şekillendiğini göstermektedir.

Tablo 6.3

Destek Vektör Makinesi Yöntemi İçin Değişkenlerin Önem Düzeyi

| Bitcoin |             |             | Ethereum |             |             | Ripple |             |             | BNB  |             |              |
|---------|-------------|-------------|----------|-------------|-------------|--------|-------------|-------------|------|-------------|--------------|
| Sıra    | Değişken    | Önem Düzeyi | Sıra     | Değişken    | Önem Düzeyi | Sıra   | Değişken    | Önem Düzeyi | Sıra | Değişken    | Önem Düzeyi  |
| 1       | High        | 7.689.580   | 1        | High        | 39.502      | 1      | Low         | 0,003561    | 1    | High        | 2.509,763303 |
| 2       | Low         | 6.255.837   | 2        | Low         | 29.847      | 2      | High        | 0,003403    | 2    | Low         | 1.695,768649 |
| 3       | Open        | 2.027.157   | 3        | Open        | 9.706       | 3      | MA50        | 0,002813    | 3    | Open        | 1.376,768691 |
| 4       | MA50        | 1.948.024   | 4        | MA50        | 1.148       | 4      | Hızlı_%D    | 0,001222    | 4    | MA50        | 20,231441    |
| 5       | MACD        | 443.323     | 5        | MACD        | 931         | 5      | Hızlı_%K    | 0,000810    | 5    | MACD        | 7,561504     |
| 6       | RSI         | 18.414      | 6        | Hızlı_%K    | 355         | 6      | RSI         | 0,000605    | 6    | Hızlı_%K    | 0,777817     |
| 7       | MA200       | 8.566       | 7        | Hızlı_%D    | 338         | 7      | Yavaş_%D    | 0,000401    | 7    | Hızlı_%D    | 0,558783     |
| 8       | WAD         | 7.838       | 8        | MACD_Signal | 107         | 8      | WAD         | 0,000254    | 8    | MACD_Signal | 0,241114     |
| 9       | ROC50       | 6.921       | 9        | FGI         | 4           | 9      | MACD        | 0,000237    | 9    | MA200       | 0,044086     |
| 10      | FGI         | 4.294       | 10       | RSI         | 2           | 10     | MA200       | 0,000229    | 10   | FGI         | 0,006737     |
| 11      | ROC10       | 2.334       | 11       | ROC50       | 1           | 11     | ROC50       | 0,000082    | 11   | ROC50       | 0,005063     |
| 12      | FED         | 2.287       | 12       | VIX         | 1           | 12     | OBV         | 0,000070    | 12   | OVX         | 0,003673     |
| 13      | CPI         | 1.601       | 13       | WAD         | 0           | 13     | FED         | 0,000068    | 13   | VIX         | 0,002825     |
| 14      | Hızlı_%D    | 1.226       | 14       | XAU         | 0           | 14     | MACD_Signal | 0,000037    | 14   | CPI         | 0,002512     |
| 15      | WTI         | 1.223       | 15       | OVX         | 0           | 15     | OVX         | 0,000029    | 15   | EPU         | 0,001600     |
| 16      | Yavaş_%D    | 1.108       | 16       | ROC10       | 0           | 16     | EPU         | 0,000018    | 16   | RSI         | 0,001338     |
| 17      | MACD_Signal | 792         | 17       | OBV         | 0           | 17     | ROC10       | 0,000016    | 17   | GTRENDS     | 0,000301     |
| 18      | GTRENDS     | 519         | 18       | EPU         | 0           | 18     | Volume      | 0,000005    | 18   | OBV         | 0,000204     |
| 19      | VIX         | 148         | 19       | GTRENDS     | 0           | 19     | GTRENDS     | 0,000003    | 19   | WAD         | 0,000000     |
| 20      | DXY         | 115         | 20       | Volume      | 0           | 20     | ADX         | -0,000009   | 20   | XAU         | -0,000217    |
| 21      | Volume      | -66         | 21       | ADX         | 0           | 21     | FGI         | -0,000079   | 21   | DXY         | -0,000536    |
| 22      | Hızlı_%K    | -75         | 22       | CPI         | 0           | 22     | VIX         | -0,000083   | 22   | Volume      | -0,002165    |
| 23      | OVX         | -112        | 23       | DXY         | 0           | 23     | XAU         | -0,000094   | 23   | ROC10       | -0,002570    |
| 24      | EPU         | -118        | 24       | FED         | -1          | 24     | WTI         | -0,000133   | 24   | WTI         | -0,004922    |
| 25      | ADX         | -316        | 25       | Yavaş_%D    | -1          | 25     | DXY         | -0,000160   | 25   | ADX         | -0,009202    |
| 26      | OBV         | -1.116      | 26       | MA200       | -1          | 26     | Open        | -0,000390   | 26   | Yavaş_%D    | -0,015115    |
| 27      | XAU         | -1.833      | 27       | WTI         | -1          | 27     | CPI         | -0,000604   | 27   | FED         | -0,020583    |

- SVM modeli Dogecoin için fiyat tahmini yapamadığı için önem analizi de yapılamamıştır.

### 6.1.2 Rastgele ormanlar yöntemi ile kripto para fiyat tahmini

Kripto para fiyatlarının tahmini amacıyla Rastgele Ormanlar regresyon modeli uygulanırken 100 karar ağacından oluşan bir topluluk modeli olarak eğitilmiş ve test verisi üzerinde tahmin gerçekleştirilmiştir. Model performansı  $R^2$ , MAE, MSE ve RMSE metrikleri ile değerlendirilmiştir. Ayrıca modelin karar mekanizmasında hangi değişkenlerin daha etkili olduğunu belirlemek amacıyla, Random Forest algoritmasının sunduğu özellik önem düzeyleri (feature importance) hesaplanmıştır. Elde edilen bu önem skorları tablo ve grafiklerle görselleştirilmiş, en belirleyici değişkenlerin hangileri olduğu analiz edilmiştir.

Tablo 6.4'te, RF yöntemi kullanılarak yapılan kripto para fiyat tahminlerinin performans değerlendirmesi, Şekil 6.3'te ise gerçek fiyatlar ile tahmin edilen fiyatların grafiksel karşılaştırması gösterilmektedir. Performans metrikleri incelendiğinde, RF modelinin genel olarak oldukça başarılı tahminler ürettiği görülmektedir. Özellikle Bitcoin, Ripple ve BNB için  $R^2$  değerleri sırasıyla 0,992618, 0,992014 ve 0,985660 düzeyinde gerçekleşmiş, bu da modelin yüksek oranda açıklayıcılığa sahip olduğunu ortaya koymuştur. Bitcoin tahminlerinde RMSE değeri 506,33, MAE değeri ise 405,25 olarak hesaplanmış ve bu değerlerin yüksekliği, fiyat düzeyinin mutlak olarak büyük olmasından kaynaklanmaktadır.

**Tablo 6.4**

*RF Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi*


| Kripto Para | Yöntem | Hata Metrikleri |            |                |            |
|-------------|--------|-----------------|------------|----------------|------------|
|             |        | $R^2$           | MAE        | MSE            | RMSE       |
| Bitcoin     | RF     | 0,992618        | 405,247122 | 256.375,685813 | 506,335546 |
| Ethereum    | RF     | 0,984681        | 21,295081  | 734,551103     | 27,102603  |
| Ripple      | RF     | 0,992014        | 0,007083   | 8,179584       | 0,009044   |
| BNB         | RF     | 0,985560        | 3,981,093  | 25,343070      | 5,034190   |
| Dogecoin    | RF     | 0,974158        | 0,001175   | 2,790934       | 0,001670   |

Öte yandan, Ethereum için  $R^2$  değeri 0,984681 olup bu varlıkta da güçlü bir tahmin başarısı elde edilmiştir. RMSE ve MAE değerleri sırasıyla 27,102603 ve 21,295081 ile kabul edilebilir düzeyde kalmıştır. Ripple için modelin 0,992014 ile hem  $R^2$  değeri oldukça yüksek 0,007083 MAE ve 0,009044 RMSE ile hem de hata metrikleri son derece düşüktür. Bu durum, RF modelinin Ripple gibi daha önce SVM ile zayıf performans gösteren bir varlıkta oldukça isabetli tahminler gerçekleştirdiğini ortaya koymaktadır.

Benzer şekilde, Dogecoin için de model yüksek  $R^2$  ve düşük hata oranlarıyla yüksek bir başarı göstermiştir. Bu bulgular, Dogecoin'in spekülative yapısına rağmen RF modelinin bu dalgalanmaları öğrenebilme kapasitesine sahip olduğunu göstermektedir. Genel olarak değerlendirildiğinde, RF algoritması, farklı kripto para birimlerinin fiyat tahmininde hem yüksek doğruluk oranı hem de düşük hata metrikleri ile güçlü bir modelleme alternatifi olarak öne çıkmaktadır.

### Şekil 6.3

*Rastgele Ormanlar Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması*



Tablo 6.5'te, RF modeli ile yapılan kripto para fiyat tahminlerinde kullanılan değişkenlerin hesaplanan önem düzeyleri, Şekil 6.4'de ise önem düzeylerinin grafiksel gösterimlerine yer verilmiştir.

RF yöntemiyle yapılan analizde, Bitcoin fiyat tahminlerinde en yüksek önem düzeyine sahip değişkenin Low (en düşük fiyat) olduğu görülmektedir. Bu değişkeni sırasıyla High ve Open değişkenleri takip etmektedir. Bu sonuçlar, Bitcoin fiyatlarının tahmininde geçmiş fiyat hareketlerinin belirleyici olduğunu ortaya koymaktadır. Teknik göstergeler

arasında görece düşük bir katkı bulunmakla birlikte, WAD, RSI ve ROC10 gibi teknik göstergelerin ikinci düzeyde etkili olduğu söylenebilir. Makroekonomik göstergeler ile duyarlılık değişkenlerinin etkisi se oldukça sınırlı düzeyde kalmıştır.

Ethereum için yapılan değişken önem analizi, fiyat tahmininde High ve Low değişkenlerinin baskın rol oynadığını ortaya koymaktadır. Bu iki değişken modelin tahmin gücünün büyük bir kısmını oluşturmaktadır. Bu bağlamda, Ethereum fiyatları üzerinde de geçmiş fiyat hareketlerinin doğrudan etkili olduğu görülmektedir. Teknik göstergeler açısından ise Hızlı\_%K, RSI, OBV gibi göstergelerin de katkısı sağladığı gözlemlenmiştir. Yatırımcı duyarlılığı değişkenlerinde VIX değişkeni fiyat yönünü belirlemede 7. sıradaki değişken olsa da diğer yatırımcı duyarlılığı değişkenleri ve makroekonomik göstergelerin etkisi oldukça sınırlı kalmıştır.

Ripple için tahmin modeli Low (0,663215) değişkenine en yüksek önem düzeyini atamış, ardından High (0,202252) ve Open (0,088692) gelmiştir. Bu, Ripple fiyatlarında özellikle günlük en düşük fiyat seviyesinin kritik rol oynadığını göstermektedir. Teknik göstergeler içerisinde ROC50, MACD ve ADX gibi faktörlerin görece daha yüksek katkı sunduğu görülmektedir. Ayrıca VIX ve RSI gibi piyasa oynaklığını temsil eden göstergeler de orta düzeyde önem taşımaktadır. Bu durum, Ripple'ın fiyat yapısının hem fiyat tabanlı hem de teknik analiz göstergelerine karşı daha karmaşık bir yapıda olduğunu göstermektedir.

BNB coin için yapılan analizde, Low High (0,228263) ve Open)değişkenleri ön plana çıkmıştır. Bunlara ek olarak, teknik göstergelerden MA200 ve MA50 gibi hareketli ortalamaların yüksek önem düzeyine sahip olması dikkat çekicidir. Bu durum, BNB fiyatlarının hem kısa hem uzun vadeli trendlere duyarlı olduğunu ortaya koymaktadır. Ayrıca OBV, MACD ve Hızlı\_%K gibi göstergeler de sıralamada üst sıralarda yer almakta olup, BNB'nin fiyat hareketlerinin hacim bazlı ve momentum göstergeleriyle açıklanabilir olduğunu göstermektedir.

Dogecoin için modelde en yüksek önem düzeyine sahip değişken High olup, onu Low ve OBV takip etmektedir. Diğer coinlere kıyasla Dogecoin modelinde OBV )değişkeni fiyat bileşenlerinin ardından en önemli teknik gösterge olarak öne çıkmaktadır. Bununla birlikte ROC50, Open ve MA200 gibi göstergeler de modele katkı sunmaktadır. Teknik göstergeler arasında MACD\_Signal, MA50 ve Hızlı\_%K gibi değişkenlerin de etkili olduğu gözlemlenmiştir. Dogecoin için fiyat ve hacim temelli değişkenlerin model tahmininde daha baskın olduğu görülmektedir.



Tablo 6.5

Rastgele Orman Yöntemi İçin Değişkenlerin Önem Düzeyi

| Bitcoin |             |             | Ethereum |             |             | Ripple |             |             | BNB  |             |             | Dogecoin |             |             |
|---------|-------------|-------------|----------|-------------|-------------|--------|-------------|-------------|------|-------------|-------------|----------|-------------|-------------|
| Sıra    | Değişken    | Önem Düzeyi | Sıra     | Değişken    | Önem Düzeyi | Sıra   | Değişken    | Önem Düzeyi | Sıra | Değişken    | Önem Düzeyi | Sıra     | Değişken    | Önem Düzeyi |
| 1       | Low         | 0,486122    | 1        | High        | 0,541757    | 1      | High        | 0,663215    | 1    | Low         | 0,338469    | 1        | High        | 0,541685    |
| 2       | High        | 0,260549    | 2        | Low         | 0,456601    | 2      | Low         | 0,202252    | 2    | High        | 0,228263    | 2        | Low         | 0,365496    |
| 3       | Open        | 0,252491    | 3        | Open        | 0,000679    | 3      | Open        | 0,086892    | 3    | Open        | 0,189609    | 3        | OBV         | 0,028943    |
| 4       | WAD         | 0,000130    | 4        | Hızlı_%K    | 0,000115    | 4      | ROC50       | 0,020640    | 4    | MA200       | 0,146793    | 4        | ROC50       | 0,025104    |
| 5       | Hızlı_%K    | 0,000118    | 5        | RSI         | 0,000092    | 5      | MACD        | 0,007022    | 5    | MA50        | 0,094763    | 5        | Open        | 0,023313    |
| 6       | RSI         | 0,000057    | 6        | OBV         | 0,000091    | 6      | ADX         | 0,007001    | 6    | OBV         | 0,000756    | 6        | MA200       | 0,009176    |
| 7       | ROC10       | 0,000053    | 7        | VIX         | 0,000067    | 7      | VIX         | 0,004547    | 7    | MACD        | 0,000532    | 7        | MA50        | 0,001974    |
| 8       | ROC50       | 0,000051    | 8        | ROC50       | 0,000063    | 8      | RSI         | 0,001958    | 8    | Hızlı_%K    | 0,000137    | 8        | MACD_Signal | 0,001340    |
| 9       | VIX         | 0,000046    | 9        | ADX         | 0,000059    | 9      | EPU         | 0,001950    | 9    | ROC10       | 0,000082    | 9        | Hızlı_%K    | 0,000544    |
| 10      | OBV         | 0,000037    | 10       | WAD         | 0,000057    | 10     | ROC10       | 0,000797    | 10   | MACD_Signal | 0,000079    | 10       | ROC10       | 0,000374    |
| 11      | Volume      | 0,000037    | 11       | Volume      | 0,000049    | 11     | XAU         | 0,000556    | 11   | RSI         | 0,000079    | 11       | RSI         | 0,000362    |
| 12      | ADX         | 0,000034    | 12       | MACD_Signal | 0,000040    | 12     | WTI         | 0,000528    | 12   | ROC50       | 0,000057    | 12       | WAD         | 0,000271    |
| 13      | Hızlı_%D    | 0,000030    | 13       | DXY         | 0,000039    | 13     | Hızlı_%D    | 0,000374    | 13   | OVX         | 0,000048    | 13       | Yavaş_%D    | 0,000229    |
| 14      | FGI         | 0,000027    | 14       | OVX         | 0,000038    | 14     | Hızlı_%K    | 0,000351    | 14   | VIX         | 0,000044    | 14       | VIX         | 0,000202    |
| 15      | Yavaş_%D    | 0,000026    | 15       | ROC10       | 0,000037    | 15     | MA50        | 0,000309    | 15   | DXY         | 0,000038    | 15       | DXY         | 0,000130    |
| 16      | MACD        | 0,000025    | 16       | XAU         | 0,000035    | 16     | Yavaş_%D    | 0,000262    | 16   | Yavaş_%D    | 0,000035    | 16       | OVX         | 0,000119    |
| 17      | OVX         | 0,000023    | 17       | Yavaş_%D    | 0,000028    | 17     | OBV         | 0,000249    | 17   | Hızlı_%D    | 0,000035    | 17       | XAU         | 0,000117    |
| 18      | MACD_Signal | 0,000023    | 18       | WTI         | 0,000026    | 18     | MACD_Signal | 0,000199    | 18   | FGI         | 0,000033    | 18       | Hızlı_%D    | 0,000116    |
| 19      | DXY         | 0,000022    | 19       | Hızlı_%D    | 0,000024    | 19     | Volume      | 0,000164    | 19   | XAU         | 0,000031    | 19       | MACD        | 0,000107    |
| 20      | MA50        | 0,000021    | 20       | MACD        | 0,000023    | 20     | WAD         | 0,000164    | 20   | ADX         | 0,000031    | 20       | Volume      | 0,000100    |
| 21      | WTI         | 0,000020    | 21       | FGI         | 0,000022    | 21     | DXY         | 0,000146    | 21   | WTI         | 0,000030    | 21       | ADX         | 0,000089    |
| 22      | XAU         | 0,000020    | 22       | MA50        | 0,000020    | 22     | OVX         | 0,000124    | 22   | Volume      | 0,000029    | 22       | FGI         | 0,000084    |
| 23      | MA200       | 0,000018    | 23       | MA200       | 0,000015    | 23     | MA200       | 0,000123    | 23   | GTRENDS     | 0,000011    | 23       | WTI         | 0,000083    |
| 24      | FED         | 0,000008    | 24       | FED         | 0,000008    | 24     | FGI         | 0,000089    | 24   | CPI         | 0,000008    | 24       | FED         | 0,000020    |
| 25      | CPI         | 0,000006    | 25       | CPI         | 0,000008    | 25     | GTRENDS     | 0,000034    | 25   | FED         | 0,000005    | 25       | GTRENDS     | 0,000011    |
| 26      | GTRENDS     | 0,000006    | 26       | GTRENDS     | 0,000007    | 26     | FED         | 0,000028    | 26   | EPU         | 0,000001    | 26       | CPI         | 0,000009    |
| 27      | EPU         | 0,000002    | 27       | EPU         | 0,000002    | 27     | CPI         | 0,000026    | 27   | WAD         | 0,000000    | 27       | EPU         | 0,000003    |

### 6.1.3 Aşırı gradyan artırma yöntemi ile kripto para fiyat tahmini

Kripto paraların fiyat tahmininde XGBoost modeli kullanılırken, modelin eğitimi için XGBRegressor sınıfı kullanılarak 100 tahmin ağacı ve 0,1 öğrenme oranı ile yapılandırılmış bir XGBoost modeli geliştirilmiştir. Eğitim sonrası model, test verisi üzerinde tahminler üretmiş ve performansı  $R^2$ , MAE, MSE ve RMSE gibi hata metrikleriyle değerlendirilmiştir. Ayrıca modelin karar sürecinde hangi değişkenlerin daha belirleyici olduğunu analiz edebilmek amacıyla özellik önem analizi gerçekleştirilmiştir. Bu analizde, XGBoost modelinin içsel `get_score()` fonksiyonu ile değişkenlerin F Score değerleri hesaplanmış ve en önemli özellikler sıralanarak görselleştirilmiştir.

Tablo 6.6'da, XGBoost yöntemi kullanılarak yapılan kripto para fiyat tahminlerinin performans değerlendirmesi, Şekil 6.5'te ise gerçek fiyatlar ile tahmin edilen fiyatların grafiksel karşılaştırması gösterilmektedir. Performans metriklerine incelendiğinde, XGBoost modeli kripto para fiyat tahminlerinde genel olarak oldukça başarılı sonuçlar vermiştir.

Bitcoin için modelin açıklama gücü yüzde 98,4059 olarak hesaplanmış, yüksek fiyat düzeyi nedeniyle ortalama mutlak hata 537,1128611, kök ortalama kare hata ise 744,09130809 olarak gerçekleşmiştir.

Ethereum'da açıklayıcılık düzeyi yüzde 95,3708 olup, hata değerleri MAE için 39,673307, RMSE için ise 47,113575 seviyesindedir. Ripple üzerinde XGBoost modeli son derece başarılı sonuçlar üretmiş olup, yüzde 99,0885 oranında açıklama gücüne ulaşırken, ortalama mutlak hata yalnızca 0,006806, RMSE ise 0,009662 gibi oldukça düşük düzeylerde kalmıştır.

**Tablo 6.6**

*XGBoost Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi*


| Kripto Para | Yöntem  | Hata Metrikleri |            |                |            |
|-------------|---------|-----------------|------------|----------------|------------|
|             |         | $R^2$           | MAE        | MSE            | RMSE       |
| Bitcoin     | XGBoost | 0,984059        | 537,128611 | 553.671,875160 | 744,091308 |
| Ethereum    | XGBoost | 0,953708        | 39,673307  | 2219,689030    | 47,113575  |
| Ripple      | XGBoost | 0,990885        | 0,006806   | 9,335673       | 0,009662   |
| BNB         | XGBoost | 0,986399        | 4,008921   | 23,871751      | 4,885872   |
| Dogecoin    | XGBoost | 0,974717        | 0,001179   | 2,730505       | 0,001652   |

Benzer şekilde, BNB için yüzde 98,6399'luk yüksek  $R^2$  değeriyle güçlü bir uyum sağlanmıştır. MAE 4,008921, RMSE ise 4,885872 düzeyinde hesaplanmıştır. Dogecoin için modelin açıklama gücü yüzde 97,4717 olarak belirlenmiş, düşük fiyat seviyeleri sayesinde hata değerleri oldukça küçük olup MAE 0,001179 ve RMSE 0,001652 seviyesindedir.

Genel olarak değerlendirildiğinde, XGBoost modeli tüm kripto paralar üzerinde yüksek doğrulukla tahmin üretmiş ve düşük hata oranlarıyla istikrarlı sonuçlar elde edilmiştir.

#### Şekil 6.5

*XGboost ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması*



Tablo 6.7’te, RF modeli ile yapılan kripto para fiyat tahminlerinde kullanılan değişkenlerin hesaplanan önem düzeyleri, Şekil 6.6’de ise önem düzeylerinin grafiksel gösterimlerine yer verilmiştir.

XGBoost modeline göre Bitcoin fiyatlarının tahmininde en önemli değişken High olurken, bunu sırasıyla Low, Volume ve Hızlı %K takip etmektedir. Bu durum, modelin fiyat seviyeleri ve işlem hacmine yüksek duyarlılık gösterdiğini ortaya koymaktadır. RSI, ROC10 ve MACD gibi teknik göstergeler de anlamlı katkı sunmuştur. FGI, VIX, WTI ve XAU gibi bazı yatırımcı duyarlılığı ve makroekonomik göstergeler orta düzeyde önem taşıırken, CPI, FED ve EPU gibi bazı makroekonomik göstergelerin de oldukça düşük önem düzeylerine sahip olduğu görülmektedir. Bu sonuç, modelin daha çok fiyat hareketlerine ve teknik sinyallere odaklandığını göstermektedir.


Ethereum için yapılan analizde en önemli değişken yine High olarak belirlenmiş, onu Volume, Hızlı %K ve Low takip etmiştir. Teknik analiz göstergelerinden RSI, Hızlı %D, Yavaş %D ve MACD modelde önemli roller üstlenmiştir. ROC10, ROC50 ve MACD\_Signal gibi değişkenler de katkı sağlarken, makroekonomik göstergeler Ethereum için de düşük düzeyde etkili olmuştur. Ethereum'un fiyat tahmininde özellikle fiyat seviyeleri ve teknik göstergelerin öne çıktığı görülmektedir.

Ripple için en yüksek önem düzeyine sahip değişkenler sırasıyla High, Hızlı %K, Volume ve Low'dur. RSI, Yavaş %D, ROC10 ve OBV gibi teknik göstergeler de modelin karar sürecine katkı sağlamaktadır. Açıklayıcı gücü daha zayıf olan göstergeler arasında ise FED, EPU, CPI gibi makroekonomik faktörler yer almaktadır. Ripple'ın teknik ve fiyat temelli veriler üzerinden güçlü bir şekilde temsil edilebildiği, ancak makroekonomik ve yatırımcı duyarlılığı verilerinin sınırlı etki gösterdiği anlaşılmaktadır.

BNB için en belirgin değişken High olurken, onu Low, Volume ve Hızlı %K izlemektedir. RSI, ROC10, Open ve FGI gibi göstergeler de model tarafından önemli bulunmuştur. MACD, ROC50 ve Yavaş %D gibi göstergeler orta düzeyde katkı sağlarken, makroekonomik göstergeler yine daha alt sıralarda yer almıştır. Bu bulgular, BNB fiyatlarının tahmininde teknik analiz temelli değişkenlerin baskın rol oynadığını, XGBoost'un da bu tür verilere yüksek duyarlılık gösterdiğini ortaya koymaktadır.

Şekil 6.6

XGBoost Yöntemi İçin Değişkenlerin Önem Düzeyi



Dogecoin için modelin en önemli gördüğü değişkenler arasında High, Low ve Hızlı %K öne çıkmaktadır. Volume, OBV, WAD ve RSI gibi göstergeler de üst sıralarda yer almakta, modelin işlem hacmi ve momentum sinyallerine duyarlılığını yansıtmaktadır. Yavaş %D, MACD ve ROC50 gibi teknik göstergeler orta düzeyde etkili olmuştur. Ancak makroekonomik değişkenlerin bazıları (FED, EPU, CPI) düşük ya da sıfıra yakın skorlar almıştır. Bu durum, Dogecoin'in fiyat hareketlerinin büyük ölçüde fiyat hareketleri ve teknik göstergeler ile şekillendiğini desteklemektedir.

Tüm kripto paralar için yapılan değişken önem analizlerine genel olarak bakıldığında, XGBoost modelinin fiyat seviyeleri ve işlem hacmi gibi temel piyasa verilerine yüksek duyarlılık gösterdiği görülmektedir. Teknik analiz göstergeleri çoğu coinde üst sıralarda yer almakta, bu da modelin teknik sinyalleri etkili bir şekilde kullandığını göstermektedir. Ancak, makroekonomik ve yatırımcı duyarlılığına ilişkin göstergeler hemen her kripto para da daha düşük önem düzeylerine sahip olmuştur.

Tablo 6.7

XGBoost Yöntemi İçin Değişkenlerin Önem Düzeyi

| Bitcoin |             |             | Ethereum |             |             | Ripple |             |             | BNB  |             |             | Dogecoin |             |             |
|---------|-------------|-------------|----------|-------------|-------------|--------|-------------|-------------|------|-------------|-------------|----------|-------------|-------------|
| Sıra    | Değişken    | Önem Düzeyi | Sıra     | Değişken    | Önem Düzeyi | Sıra   | Değişken    | Önem Düzeyi | Sıra | Değişken    | Önem Düzeyi | Sıra     | Değişken    | Önem Düzeyi |
| 1       | High        | 540,0       | 1        | High        | 586,0       | 1      | High        | 394,0       | 1    | High        | 613,0       | 1        | High        | 182,0       |
| 2       | Low         | 296,0       | 2        | Volume      | 296,0       | 2      | Hızlı_%K    | 307,0       | 2    | Low         | 297,0       | 2        | Low         | 108,0       |
| 3       | Volume      | 291,0       | 3        | Hızlı_%K    | 292,0       | 3      | Volume      | 262,0       | 3    | Volume      | 244,0       | 3        | Hızlı_%K    | 89,0        |
| 4       | Hızlı_%K    | 290,0       | 4        | Low         | 285,0       | 4      | Low         | 243,0       | 4    | Hızlı_%K    | 242,0       | 4        | Volume      | 68,0        |
| 5       | RSI         | 257,0       | 5        | RSI         | 262,0       | 5      | RSI         | 226,0       | 5    | RSI         | 202,0       | 5        | RSI         | 57,0        |
| 6       | Hızlı_%D    | 190,0       | 6        | Hızlı_%D    | 229,0       | 6      | Yavaş_%D    | 178,0       | 6    | Hızlı_%D    | 175,0       | 6        | OBV         | 56,0        |
| 7       | ROC10       | 182,0       | 7        | Yavaş_%D    | 167,0       | 7      | Hızlı_%D    | 174,0       | 7    | ROC10       | 152,0       | 7        | WAD         | 55,0        |
| 8       | Yavaş_%D    | 166,0       | 8        | ROC10       | 165,0       | 8      | ROC10       | 173,0       | 8    | Open        | 147,0       | 8        | Open        | 55,0        |
| 9       | MACD        | 147,0       | 9        | MACD        | 158,0       | 9      | OBV         | 122,0       | 9    | FGI         | 142,0       | 9        | Yavaş_%D    | 51,0        |
| 10      | FGI         | 134,0       | 10       | ROC50       | 130,0       | 10     | FGI         | 120,0       | 10   | MACD        | 141,0       | 10       | Hızlı_%D    | 44,0        |
| 11      | ROC50       | 127,0       | 11       | MACD_Signal | 127,0       | 11     | Open        | 116,0       | 11   | ROC50       | 140,0       | 11       | MACD        | 40,0        |
| 12      | OBV         | 126,0       | 12       | ADX         | 124,0       | 12     | MACD        | 115,0       | 12   | Yavaş_%D    | 135,0       | 12       | ROC50       | 36,0        |
| 13      | XAU         | 116,0       | 13       | OBV         | 118,0       | 13     | ROC50       | 114,0       | 13   | OBV         | 118,0       | 13       | MACD_Signal | 34,0        |
| 14      | ADX         | 113,0       | 14       | FGI         | 109,0       | 14     | ADX         | 114,0       | 14   | MACD_Signal | 112,0       | 14       | ROC10       | 33,0        |
| 15      | MACD_Signal | 107,0       | 15       | Open        | 107,0       | 15     | MACD_Signal | 107,0       | 15   | ADX         | 105,0       | 15       | XAU         | 27,0        |
| 16      | Open        | 103,0       | 16       | XAU         | 101,0       | 16     | VIX         | 100,0       | 16   | XAU         | 101,0       | 16       | FGI         | 25,0        |
| 17      | VIX         | 101,0       | 17       | DXY         | 101,0       | 17     | WTI         | 90,0        | 17   | OVX         | 99,0        | 17       | MA200       | 22,0        |
| 18      | WAD         | 98,0        | 18       | WAD         | 98,0        | 18     | WAD         | 87,0        | 18   | VIX         | 98,0        | 18       | ADX         | 22,0        |
| 19      | WTI         | 97,0        | 19       | VIX         | 93,0        | 19     | MA50        | 81,0        | 19   | WTI         | 87,0        | 19       | DXY         | 22,0        |
| 20      | OVX         | 89,0        | 20       | OVX         | 81,0        | 20     | OVX         | 78,0        | 20   | MA50        | 79,0        | 20       | VIX         | 19,0        |
| 21      | DXY         | 82,0        | 21       | WTI         | 74,0        | 21     | DXY         | 77,0        | 21   | DXY         | 70,0        | 21       | WTI         | 18,0        |
| 22      | MA50        | 71,0        | 22       | MA50        | 67,0        | 22     | XAU         | 75,0        | 22   | MA200       | 44,0        | 22       | MA50        | 16,0        |
| 23      | MA200       | 53,0        | 23       | MA200       | 48,0        | 23     | MA200       | 48,0        | 23   | GTRENDS     | 20,0        | 23       | OVX         | 11,0        |
| 24      | GTRENDS     | 31,0        | 24       | FED         | 32,0        | 24     | GTRENDS     | 28,0        | 24   | FED         | 20,0        | 24       | EPU         | 2,0         |
| 25      | CPI         | 19,0        | 25       | GTRENDS     | 23,0        | 25     | CPI         | 25,0        | 25   | EPU         | 19,0        | 25       | GTRENDS     | 2,0         |
| 26      | FED         | 8,0         | 26       | CPI         | 15,0        | 26     | EPU         | 22,0        | 26   | CPI         | 14,0        | 26       | FED         | 2,0         |
| 27      | EPU         | 7,0         | 27       | EPU         | 8,0         | 27     | FED         | 17,0        | 27   | WAD         | 4,0         | 27       | CPI         | 2,0         |

#### 6.1.4 Uzun kısa süreli bellek yöntemi ile kripto para fiyat tahmini

Kripto paraların fiyat tahmininde LSTM modeli kullanılırken, tüm değişkenler MinMaxScaler ile ölçeklendirilmiştir. LSTM mimarisi, 60 zaman adımı içeren 3 boyutlu girdi yapısında oluşturulmuş ve iki LSTM katmanı, Dropout katmanları ve tam bağlantılı çıkış katmanlarından oluşacak şekilde yapılandırılmıştır. Model, adam optimizasyon algoritması ve MSE kayıp fonksiyonu ile derlenmiş; erken durdurma mekanizmasıyla aşırı öğrenme riski azaltılmıştır.

Eğitim sonrası test verisi üzerinde yapılan tahminlerin performansı RMSE, MAE, MSE ve  $R^2$  metrikleri ile değerlendirilmiştir. Ayrıca, modelin değişkenlere olan duyarlılığını analiz etmek amacıyla her bir değişken rastgele karıştırılarak modelin tahmin hatasındaki artışların ölçülmesini sağlayan permütasyon önem analizi gerçekleştirilmiştir. Bu yöntemle elde edilen önem skorları, değişkenlerin modele katkı düzeyini ortaya koymuş ve sonuçlar grafiksel olarak görselleştirilmiştir.

Tablo 6.8’de, LSTM yöntemi ile yapılan kripto para fiyat tahminlerinin performansına ilişkin sonuçlara, Şekil 6.7’de ise tahmin edilen ile gerçek değerlerin grafiksel karşılaştırılmasına yer verilmiştir.

Sunulan performans sonuçlara göre, LSTM modeli Bitcoin için oldukça güçlü bir tahmin performansı sergilemiş ve kapanış fiyatlarının yüzde 90,9544’ünü açıklayabilmiştir. Ancak Bitcoin’in yüksek fiyat seviyeleri nedeniyle MAE 1239,143834, RMSE 80,205624 düzeyinde kalmıştır. Ethereum’da modelin açıklama gücü yüzde 83,30087 olarak hesaplanmış ve MAE 61,148925 ve RMSE 81,432750 seviyesinde gerçekleşmiştir.

**Tablo 6.8**

*LSTM Yöntemi ile Kripto Para Fiyat Tahmini Performans Değerlendirmesi*

| Kripto Para | Yöntem | Hata Metrikleri |              |                  |           |
|-------------|--------|-----------------|--------------|------------------|-----------|
|             |        | $R^2$           | MAE          | MSE              | RMSE      |
| Bitcoin     | LSTM   | 0,909544        | 1.239,143834 | 2.566.413,863513 | 80,205624 |
| Ethereum    | LSTM   | 0,833087        | 61,148925    | 6432,942162      | 81,432750 |
| Ripple      | LSTM   | 0,697342        | 0,039751     | 0,002536         | 0,050358  |
| BNB         | LSTM   | 0,862361        | 12,582522    | 240,518902       | 15,508671 |
| Dogecoin    | LSTM   | 0,796686        | 0,003508     | 2,092764         | 0,004574  |

Ripple ve Dogecoin gibi görece düşük fiyatlı kripto paralarda LSTM modeli oldukça düşük hata değerleri üretmiştir. Ripple’da MAE 0,39751 ve RMSE 0,050358 olarak ölçülürken, Dogecoin’de bu değerler sırasıyla 0,003508 ve 0,004574 olmuştur. Ancak bu varlıklarda açıklayıcılık düzeyi Ripple için yüzde 69,7342, Dogecoin için ise yüzde

79,6686 ile diğer varlıklara göre daha düşüktür. BNB özelinde ise model başarılı sonuçlar üretmiş, yüzde 86,2361 oranında açıklama gücüne ulaşırken ortalama MAE 12,582522, RMSE ise 15,508671 olarak kaydedilmiştir. Genel olarak değerlendirildiğinde, LSTM modeli yüksek fiyatlı ve düzenli trende sahip varlıklarda başarılı performans sergilerken, daha dalgalı yapıya sahip kripto paralarda tahmin gücü görece zayıflamaktadır.

#### Şekil 6.7

*LSTM Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması*



Tablo 6.9’da, LSTM modeli ile yapılan kripto para fiyat tahminlerinde kullanılan değişkenlerin permütasyon yöntemi ile hesaplanan önem düzeyleri, Şekil 6.8’de ise önem düzeylerinin grafiksel gösterimlerine yer verilmiştir.

Bitcoin için yapılan permütasyon önem analizi sonuçları, LSTM modelinin en çok etkilendiği değişkenlerin sırasıyla Open, High ve Low olduğunu göstermektedir. Bu üç temel fiyat bileşeni, modelin fiyat tahminlerini şekillendirmede belirleyici rol oynamaktadır. RSI, FGI, MA50 ve ROC10 gibi teknik ve yatırımcı duyarlılığı göstergeleri de önemli katkı sunmuştur. Öte yandan, MA200, DXY, WTI, CPI, MACD,

GTRENDS, DXY ve ADX gibi deęiřkenlerin negatif skorlar aldıęı g r lmektedir. Bu durum, Bitcoin fiyatlarının daha  ok kısa vadeli fiyat seviyelerine ve momentuma duyarlı olduęunu, makroekonomik ve yatırımcı duyarlılıęı g stergelerinin modelde sınırlı etkiye sahip olduęunu ortaya koymaktadır.

Ethereum i in en y ksek  neme sahip deęiřken Yavaş %D olurken, onu sırasıyla High, Low ve Hızlı %K takip etmektedir. Bu sonu lar, Ethereum fiyatlarının teknik osilat r g stergelerine ve ge miř fiyat seviyelerine duyarlı olduęunu g stermektedir. FGI, MA50, Open ve MACD\_Signal gibi deęiřkenler de orta d zeyde  nem tařıtmaktadır. RSI, ADX, XAU ve CPI gibi deęiřkenlerin ise negatif skorlarla en alt sıralarda yer alması, Ethereum fiyatlarının bu g stergelerden olumsuz ya da anlamsız etkilendięini g stermektedir.


Ripple i in LSTM modelinde en etkili deęiřken MA50 olurken, ardından RSI, Hızlı %K, Yavaş %D ve Open gelmektedir. Low, MA200 ve ROC10 gibi ge miř fiyat ve trend g stergeleri de modelde anlamlı katkı saęlamıřtır. Ancak ADX, MACD, OBV ve DXY gibi deęiřkenlerin katkısı  ok d ř k kalmıřtır. Bazı makroekonomik g stergeler (FED, EPU, XAU, WTI, FED ve CPI) ise negatif etkiler g stermiřtir. Odelin daha  ok basit teknik g stergelere dayalı olarak  ęrenme ger ekleřtirdięi anlařılmaktadır.

BNB i in en y ksek  nem d zeyine sahip deęiřkenler sırasıyla High, Low, Open ve MA50 olup, modelin fiyat seviyelerine dayalı g  l  bir  ęrenme ger ekleřtirdięi g r lmektedir. Hızlı %D, Yavaş %D, FGI ve MACD gibi teknik ve duyarlılık g stergeleri de modelin karar s recine katkı saęlamaktadır. ROC10, RSI, XAU ve DXY gibi deęiřkenlerin g reli etkisi daha d ř kt r. GTRENDS, ADX ve FED gibi bazı deęiřkenlerin ise negatif skorlar alması, bu g stergelerin BNB fiyatlarını a ıklamada yetersiz kaldıęını g stermektedir.

Dogecoin i in LSTM modelinde en  nemli deęiřken Hızlı %K olarak belirlenmiř, onu Yavaş %D, RSI ve Low takip etmiřtir. Dięer coinlerden farklı olarak Dogecoin’de deęiřken  nem d zeyleri  ok d ř k seviyelerde kalmıřtır.  zellikle yatırımcı duyarlılıęı, makroekonomik g stergeler ve teknik analiz verilerinin  oęunun (GTRENDS, CPI, MACD, FED vb.) sıfıra yakın veya negatif  nem skorları aldıęı g r lmektedir.

Şekil 6.8

LSTM Yöntemi İçin Değişkenlerin Önem Düzeyi



Genel olarak değerlendirildiğinde, LSTM modelinin en çok önem verdiği değişkenlerin başında fiyat seviyeleri (Open, High, Low) ve bazı teknik göstergeler (RSI, MA50, Hızlı %K, Yavaş %D) gelmektedir. Fiyatların geçmiş hareketlerine dayanan bu göstergeler, modelin zaman serisi temelli öğrenme sürecinde belirleyici rol oynamaktadır. Buna karşın, ADX, CPI, FED ve GTRENDS gibi bazı makroekonomik ve duyarlılık göstergelerinin çoğu kripto para için düşük veya negatif önem skorları aldığı görülmektedir. Bu durum, LSTM modelinin özellikle kısa vadeli piyasa dinamiklerine duyarlı olduğunu, ancak daha karmaşık, ekonomik içerikli göstergelerin model tarafından yeterince öğrenilemediğini göstermektedir.

Tablo 6.9

LSTM Yöntemi İçin Değişkenlerin Önem Düzeyi

| Bitcoin |             |                 | Ethereum |             |             | Ripple |             |             | BNB  |             |             | Dogecoin |             |             |
|---------|-------------|-----------------|----------|-------------|-------------|--------|-------------|-------------|------|-------------|-------------|----------|-------------|-------------|
| Sıra    | Değişken    | Önem Düzeyi     | Sıra     | Değişken    | Önem Düzeyi | Sıra   | Değişken    | Önem Düzeyi | Sıra | Değişken    | Önem Düzeyi | Sıra     | Değişken    | Önem Düzeyi |
| 1       | Open        | 4.873.575,86020 | 1        | Yavaş_%D    | 9.320,72940 | 1      | MA50        | 0,00181     | 1    | High        | 272,43826   | 1        | Hızlı_%K    | 0,00010     |
| 2       | High        | 3.754.888,11797 | 2        | High        | 6.330,60190 | 2      | RSI         | 0,00168     | 2    | Low         | 247,42273   | 2        | Yavaş_%D    | 0,00005     |
| 3       | Low         | 3.584.021,11355 | 3        | Low         | 4.770,00606 | 3      | Hızlı_%K    | 0,00160     | 3    | Open        | 204,27413   | 3        | RSI         | 0,00003     |
| 4       | RSI         | 2.268.700,29459 | 4        | Hızlı_%K    | 4.458,96847 | 4      | Yavaş_%D    | 0,00124     | 4    | MA50        | 146,11107   | 4        | Low         | 0,00001     |
| 5       | FGI         | 1.062.611,66705 | 5        | FGI         | 1.835,19708 | 5      | Open        | 0,00105     | 5    | Yavaş_%D    | 139,74877   | 5        | High        | 0,00001     |
| 6       | MA50        | 841.460,67920   | 6        | Hızlı_%D    | 1.690,38214 | 6      | Low         | 0,00047     | 6    | Hızlı_%K    | 83,85170    | 6        | MA50        | 0,00001     |
| 7       | ROC10       | 524.471,28264   | 7        | Open        | 1.283,33887 | 7      | MA200       | 0,00047     | 7    | Hızlı_%D    | 29,83660    | 7        | MACD_Signal | 0,00000     |
| 8       | ROC50       | 503.227,51354   | 8        | MACD_Signal | 1.271,36048 | 8      | High        | 0,00027     | 8    | FGI         | 22,14861    | 8        | WTI         | 0,00000     |
| 9       | WAD         | 168.451,48700   | 9        | ROC50       | 1.138,29915 | 9      | ROC10       | 0,00017     | 9    | MACD        | 15,97976    | 9        | GTRENDS     | 0,00000     |
| 10      | OBV         | 103.435,63326   | 10       | OBV         | 892,34052   | 10     | Hızlı_%D    | 0,00013     | 10   | ROC50       | 12,14226    | 10       | Open        | 0,00000     |
| 11      | OVX         | 84.185,02029    | 11       | ROC10       | 660,86994   | 11     | Volume      | 0,00013     | 11   | MACD_Signal | 10,63658    | 11       | Hızlı_%D    | 0,00000     |
| 12      | Hızlı_%D    | 63.243,35951    | 12       | WTI         | 602,41656   | 12     | ADX         | 0,00009     | 12   | ROC10       | 9,53006     | 12       | MACD        | 0,00000     |
| 13      | VIX         | 3.567,42348     | 13       | MA200       | 551,57151   | 13     | VIX         | 0,00007     | 13   | FED         | 7,37363     | 13       | OBV         | 0,00000     |
| 14      | Yavaş_%D    | 979,78895       | 14       | MA50        | 449,59718   | 14     | MACD        | 0,00006     | 14   | RSI         | 7,13802     | 14       | Volume      | 0,00000     |
| 15      | EPU         | 0,22694         | 15       | WAD         | 168,26374   | 15     | OBV         | 0,00006     | 15   | XAU         | 2,76493     | 15       | VIX         | 0,00000     |
| 16      | Hızlı_%K    | -2.698,57437    | 16       | CPI         | 77,99932    | 16     | DXY         | 0,00006     | 16   | DXY         | 2,22540     | 16       | ADX         | 0,00000     |
| 17      | WTI         | -7.340,54156    | 17       | VIX         | 27,08417    | 17     | OVX         | 0,00003     | 17   | WTI         | 2,13107     | 17       | FED         | 0,00000     |
| 18      | MACD_Signal | -32.698,37094   | 18       | EPU         | -0,02106    | 18     | MACD_Signal | 0,00002     | 18   | MA200       | 0,65765     | 18       | ROC10       | 0,00000     |
| 19      | XAU         | -64.085,71776   | 19       | DXY         | -21,18818   | 19     | GTRENDS     | 0,00001     | 19   | OBV         | 0,03980     | 19       | EPU         | -0,00000    |
| 20      | MA200       | -65.131,35335   | 20       | GTRENDS     | -42,00916   | 20     | ROC50       | 0,00001     | 20   | Volume      | 0,00067     | 20       | XAU         | -0,00000    |
| 21      | DXY         | -83.022,91051   | 21       | Volume      | -105,64256  | 21     | EPU         | 0,00000     | 21   | WAD         | 0,00000     | 21       | ROC50       | -0,00000    |
| 22      | FED         | -94.754,29642   | 22       | OVX         | -132,15046  | 22     | FGI         | -0,00000    | 22   | EPU         | -0,00006    | 22       | MA200       | -0,00000    |
| 23      | Volume      | -113.190,33457  | 23       | FED         | -132,82190  | 23     | XAU         | -0,00002    | 23   | OVX         | -1,74463    | 23       | FGI         | -0,00000    |
| 24      | CPI         | -135.519,41437  | 24       | MACD        | -225,95207  | 24     | WTI         | -0,00005    | 24   | CPI         | -3,11922    | 24       | CPI         | -0,00000    |
| 25      | MACD        | -138.787,81544  | 25       | XAU         | -474,55578  | 25     | WAD         | -0,00007    | 25   | ADX         | -3,16182    | 25       | DXY         | -0,00000    |
| 26      | GTRENDS     | -194.661,66668  | 26       | ADX         | -656,91918  | 26     | FED         | -0,00016    | 26   | VIX         | -7,11611    | 26       | OVX         | -0,00000    |
| 27      | ADX         | -248.771,11098  | 27       | RSI         | -854,82000  | 27     | CPI         | -0,00036    | 27   | GTRENDS     | -15,98472   | 27       | WAD         | -0,00000    |

### 6.1.5 ML Yöntemlerinin Hata Metriklerine Göre Karşılaştırılması

ML yöntemlerinin için kripto varlıklara ilişkin tahmin sonuçları dikkate alınarak, hata metrikleri bazında genel bir sıralama yapılmıştır. Tablo 6.10’da yer verildiği üzere, her bir hata metriği için kripto varlık özelinde yöntemlerin sıralamaları belirlenmiş ve bu sıralamalar üzerinden her yöntemin genel başarı düzeyi ortaya konmuştur. Böylece model seçimine yönelik daha objektif ve karşılaştırmalı bir değerlendirme yapılması mümkün hale gelmiştir.

**Tablo 6.10**

*ML Yöntemlerinin Hata Metriklerine Göre Sıralaması*

| Kripto Varlık | Yöntem  | Hata Metrikleri |          |                  |          |                   |          |                  |          |
|---------------|---------|-----------------|----------|------------------|----------|-------------------|----------|------------------|----------|
|               |         | $R^2$           | Sıra     | MAE              | Sıra     | MSE               | Sıra     | RMSE             | Sıra     |
| Bitcoin       | SVM     | <b>0,995509</b> | <b>1</b> | <b>256,55735</b> | <b>1</b> | <b>155.985,30</b> | <b>1</b> | 394,949737       | 2        |
|               | RF      | 0,992618        | 2        | 405,247122       | 2        | 256.375,685813    | 2        | 506,335546       | 3        |
|               | XGBoost | 0,984059        | 3        | 537,128611       | 3        | 553.671,875160    | 3        | 744,091308       | 4        |
|               | LSTM    | 0,909544        | 4        | 1.239,14         | 4        | 2.566.413,86      | 4        | <b>80,205624</b> | <b>1</b> |
| Ethereum      | SVM     | <b>0,995733</b> | <b>1</b> | <b>10,627267</b> | <b>1</b> | <b>204,569135</b> | <b>1</b> | <b>14,302766</b> | <b>1</b> |
|               | RF      | 0,984681        | 2        | 21,295081        | 2        | 734,551103        | 2        | 27,102603        | 2        |
|               | XGBoost | 0,953708        | 3        | 39,673307        | 3        | 2219,68903        | 3        | 47,113575        | 3        |
|               | LSTM    | 0,833087        | 4        | 61,148925        | 4        | 6432,942162       | 4        | 81,432750        | 4        |
| Ripple        | SVM     | 0,799939        | 3        | 0,039878         | 4        | 0,045268          | 2        | <b>0,002049</b>  | <b>1</b> |
|               | RF      | <b>0,992014</b> | <b>1</b> | 0,007083         | 2        | 8,179584          | 3        | 0,009044         | 2        |
|               | XGBoost | 0,990885        | 2        | <b>0,006806</b>  | <b>1</b> | 9,335673          | 4        | 0,009662         | 3        |
|               | LSTM    | 0,697342        | 4        | 0,039751         | 3        | <b>0,002536</b>   | <b>1</b> | 0,050358         | 4        |
| BNB           | SVM     | <b>0,995685</b> | <b>1</b> | <b>1,783359</b>  | <b>1</b> | <b>2,751695</b>   | <b>1</b> | <b>2,751695</b>  | <b>1</b> |
|               | RF      | 0,985560        | 3        | 3,981,093        | 2        | 25,343070         | 3        | 5,034190         | 3        |
|               | XGBoost | 0,986399        | 2        | 4,008921         | 3        | 23,871751         | 2        | 4,885872         | 2        |
|               | LSTM    | 0,862361        | 4        | 12,582522        | 4        | 240,518902        | 4        | 15,508671        | 4        |
| Dogecoin      | SVM     | -15,67197       | 4        | 0,041862         | 4        | <b>0,0018</b>     | <b>1</b> | 0,042433         | 4        |
|               | RF      | 0,974158        | 2        | <b>0,001175</b>  | <b>1</b> | 2,790934          | 4        | 0,001670         | 2        |
|               | XGBoost | <b>0,974717</b> | <b>1</b> | 0,001179         | 2        | 2,730505          | 3        | <b>0,001652</b>  | <b>1</b> |
|               | LSTM    | 0,796686        | 3        | 0,003508         | 3        | 2,092764          | 2        | 0,004574         | 3        |

Bitcoin tahmininde en yüksek  $R^2$  değeri ve en düşük MAE ile SVM yöntemi öne çıkmıştır. RMSE açısından ise en düşük değeri LSTM sağlamış olsa da diğer metriklerdeki yüksek hata değerleri nedeniyle genel başarı düzeyi düşüktür. RF, SVM’ye yakın sonuçlar verirken, XGBoost bu üçüncü düzeyde bir başarı elde etmiştir. Bu bağlamda, Bitcoin için SVM yöntemi genel olarak en başarılı yöntem olarak değerlendirilmektedir.

Ethereum tahmininde de SVM yöntemi tüm hata metriklerinde en düşük değerlere sahip olarak en başarılı sonuçları vermiştir. RF ikinci sırada yer alırken, XGBoost ve LSTM

daha yüksek hata değerleriyle sıralamanın sonlarında kalmıştır. Bu sonuçlar, Ethereum fiyat tahmini için SVM'nin tutarlı ve güçlü performansını göstermektedir.

Ripple özelinde RF yöntemi, en yüksek  $R^2$  ile en başarılı yöntem olarak değerlendirirken, MAE'ye göre XGBoost, MSE'ye göre LSTM, RMSE'ye göre ise SVM en başarılı yöntem olarak değerlendirilmektedir.

BNB fiyat tahmininde SVM yöntemi, tüm hata metrikleri açısından en başarılı yöntem olarak öne çıkmıştır. XGBoost ve RF benzer hata seviyelerinde sıralanırken, LSTM yine yüksek hata değerlerine sahip yöntem olmuştur.

Dogecoin tahmininde ise en yüksek  $R^2$  ve en düşük RMSE değeri ile en başarılı yöntem XGBoost olarak öne çıkmıştır. En düşük MSE değeri ile SVM yöntemine ait olsa da eksi  $R^2$  değeri ile fiyat tahmininde tamamen başarısız olmuştur.

Bu sonuçlar dikkate alındığında, her bir hata metriği farklı bir ML yöntemini en başarılı olarak göstermektedir. Bu durumda, en başarılı yöntemi belirlemek ve sıralama yapmak zorlaşmaktadır. Her metriğin farklı yönleri ölçmesi nedeniyle, yöntemler arasında objektif ve bütüncül bir sıralama yapabilmek ancak bu kriterlerin birlikte değerlendirilmesiyle mümkündür. İşte bu noktada, ÇKKV teknikleri devreye girerek, tüm hata metriklerini eş zamanlı olarak dikkate alan dengeli ve tutarlı bir karşılaştırma imkânı sunmakta ve en başarılı yöntemin çok boyutlu olarak belirlenmesine katkı sağlamaktadır.

## **6.2 ML Yöntemlerinin ÇKKV Tekniklerine Göre Değerlendirilmesi**

Kripto paraların fiyat tahmininde kullanılan makine öğrenmesi yöntemlerinin istatistiki performans metriklerini kullanarak çok kriterli karar verme teknikleriyle en iyi yöntemin seçildiği bu bölümde, kriterlerin ağırlıkları CRITIC yöntemiyle hesaplanarak TOPSIS, ARAS ve CODAS yöntemleriyle yöntemlerin sıralaması elde edilmiştir. Yöntemler arasında farklı sıralamalar olduğundan, genel sıralama için Copeland birleştirme yöntemi kullanılmıştır.

### **6.2.1 İstatistiki performans metriklerinin ağırlıklarının hesaplanması**

Bu çalışmada kullanılan performans metriklerinin karar verme sürecine katkı düzeylerini objektif olarak belirlemek amacıyla literatürde yaygın kullanıma sahip olan, hesaplaması zor olmayan ve alternatif sıralama yöntemlerine kolaylıkla entegre edilebilen CRITIC yöntemi uygulanmıştır. CRITIC yöntemi, her bir kriterin varyansı ile diğer kriterlerle olan korelasyonlarını dikkate alarak kriter ağırlıklarını hesaplamaktadır. Bu yöntem sayesinde, sadece kriterlerin kendi içindeki bilgi miktarı değil, aynı zamanda diğer kriterlerle olan

ilişkileri de dikkate alınmaktadır. Tablo 6.11'de  $R^2$ , MAE, MSE ve RMSE performans metriklerinin CRITIC yöntemiyle elde edilen ağırlıkları sunulmaktadır.

**Tablo 6.11**

*Performans Metriklerinin CRITIC Yöntemi ile Ağırlıklarının Hesaplanması*

| Kriterler               | $R^2$ | MAE  | MSE  | RMSE |
|-------------------------|-------|------|------|------|
| Kriterlerin Ağırlıkları | 0,28  | 0,18 | 0,19 | 0,35 |

Buna göre en yüksek ağırlık değeri %35 ile RMSE metriğine aittir. Bu durum, RMSE'nin hem varyansının yüksek olduğunu hem de diğer metriklerle olan korelasyonlarının görece düşük olduğunu göstermektedir. Dolayısıyla RMSE, model değerlendirmesinde en fazla bilgi katkısı sağlayan kriter olarak öne çıkmaktadır.

İkinci en yüksek ağırlık ise %28 ile  $R^2$  metriğine aittir. Bu metrik, modelin bağımlı değişken üzerindeki açıklayıcı gücünü ifade ettiği için, karar sürecinde önemli bir rol oynamaktadır. MSE ve MAE metriklerinin ağırlıkları ise sırasıyla %19 ve %18 olarak hesaplanmıştır. Bu değerler, bu metriklerin bilgi katkısının görece daha az olduğunu, ancak yine de çok değişkenli performans analizlerinde dikkate alınması gerektiğini göstermektedir.

Bu sonuçlar doğrultusunda, çok kriterli karar verme aşamalarında, performans metriklerine eşit ağırlık verilmesi yerine CRITIC gibi objektif ağırlıklandırma yöntemlerinin kullanılması, daha sağlıklı ve veri odaklı sonuçların elde edilmesini sağlamaktadır.

### 6.2.2 İstatistiki performans metriklerimin çkkv ile sıralanması

Makine öğrenmesi yöntemlerinin tahmin performanslarının çok boyutlu olarak değerlendirilmesi, tek bir metrikle karar verilmesinin ötesine geçerek daha objektif ve kapsamlı bir karşılaştırma imkanı sunar. Bu kapsamda, çalışmada kullanılan yöntemlerin performansları, TOPSIS, ARAS ve CODAS olmak üzere üç farklı ÇKKV tekniğiyle değerlendirilmiştir. Bu yöntemler, her modelin istatistiki metriklerine dayalı olarak puanlamalar yapmakta ve bu puanlara göre sıralamalar oluşturmaktadır. Bu yöntemlerin seçilme nedenleri literatürde yaygın kullanım alanı bulması, anlaşılmasının kolay olması, hesaplama karmaşıklığı olmaması ve paket program gerektirmemesi nedeniyle karar problemlerinde kolaylıkla uygulanabilir olmasıdır. TOPSIS yöntemi, alternatifleri pozitif ideal ve negatif ideal çözüme olan göreceli uzaklıkları Öklid mesafesi yaklaşımını dikkate alarak sıralarken; ARAS yöntemi ise oransal derecelendirme amacı kapsamında her

alternatifin ideal alternatife göre oransal benzerliğini ortaya koymaktadır. CODAS yöntemi ise alternatiflerin sıralanmasında ele alınan negatif ideal çözüme uzaklık kapsamında TOPSIS yönteminde kullanılan Öklidyen uzaklığa ek olarak Taxicab uzaklığını da dikkate almaktadır.

Tablo 6.12’de yöntemlerin her bir ÇKKV tekniği açısından aldıkları puanlar ve bu puanlara göre elde ettikleri sıralamalar, Şekil 6.9’da ise bu sıralamaların grafiksel gösterimi yer almaktadır.

**Tablo 6.12**


*ÇKKV Teknikleri ile ML Yöntemlerinin İstatistikî Performans Göstergelerine Göre Sıralanması*

| Yöntem         | TOPSIS |          | ARAS |           | CODAS |        |
|----------------|--------|----------|------|-----------|-------|--------|
|                | Sıra   | Puan     | Sıra | Puan      | Sıra  | Puan   |
| <b>LSTM</b>    | 1      | 0,660059 | 3    | 0,298264  | 2     | 0,3700 |
| <b>XGBoost</b> | 2      | 0,607004 | 2    | 0,399135  | 1     | 0,3797 |
| <b>RF</b>      | 3      | 0,518230 | 1    | 0,401288  | 3     | 0,3468 |
| <b>SVM</b>     | 4      | 0,466939 | 4    | -0,567570 | 4     | 0,2722 |

TOPSIS yöntemi, en yüksek puanı 0,660059 ile LSTM yöntemine atayarak onu birinci sıraya yerleştirmiştir. 0,607004 puan ile XGBoost ikinci sırada, RF ise üçüncü sıradadır. SVM ise en düşük TOPSIS puanını alarak son sırada yer almıştır. Benzer şekilde ARAS yöntemi, RF yöntemine en yüksek puanı (0,401288) verirken, XGBoost ikinci sırada ve LSTM üçüncü sıradadır. CODAS yöntemi ise 0,3797 puan ile XGBoost’u en üst sıraya koymuş, ardından LSTM, RF ve SVM gelmiştir.

**Şekil 6.9**

*ÇKKV Tekniklerine Göre Yöntemlerin Sıralanması*



TOPSIS, ARAS ve CODAS yöntemlerinden elde edilen sıralamalar temel alınarak yöntemler arasında ikili karşılaştırmalar yapılmış ve bu doğrultuda Tablo 6.13’de verilen Copeland ikili karşılaştırma matrisi oluşturulmuştur.

**Tablo 6.13**

*Copeland İkili Karşılaştırma Matrisi*

| Yöntem         | LSTM   |      |       | XGBoost |      |       | RF     |      |       | SVM    |      |       |
|----------------|--------|------|-------|---------|------|-------|--------|------|-------|--------|------|-------|
| CKVV<br>Yöntem | TOPSIS | ARAS | CODAS | TOPSIS  | ARAS | CODAS | TOPSIS | ARAS | CODAS | TOPSIS | ARAS | CODAS |
| <b>LSTM</b>    |        | -    |       | 1       | -1   | -1    | 1      | -1   | 1     | 1      | 1    | 1     |
| <b>XGBoost</b> | -1     | 1    | 1     |         | -    |       | 1      | -1   | 1     | 1      | 1    | 1     |
| <b>RF</b>      | -1     | 1    | -1    | -1      | 1    | -1    |        | -    |       | 1      | 1    | 1     |
| <b>SVM</b>     | -1     | -1   | -1    | -1      | -1   | -1    | -1     | -1   | -1    |        | -    |       |

Matrisin satırlarında yer alan yöntemler, sütunlardaki yöntemlerle karşılaştırıldığında; kazanılan karşılaştırmalar için +1, kaybedilenler için -1 puan verilmiştir. Elde edilen bu değerler doğrultusunda her yöntemin toplam galibiyet ve yenilgi puanları hesaplanarak Tablo 6.14’te yer verilen Copeland puanları belirlenmiştir

**Tablo 6.14**

*Galibiyet, Yenilgi ve Copeland Puanları ile Genel Sıra*

| Yöntemler      | Galibiyet Puanı | Yenilgi Puanı | Copeland Puanı | Genel Sıra |
|----------------|-----------------|---------------|----------------|------------|
| <b>XGBoost</b> | 7               | -2            | 5              | 1          |
| <b>LSTM</b>    | 6               | -3            | 3              | 2          |
| <b>RF</b>      | 5               | 4             | 1              | 3          |
| <b>SVM</b>     | 0               | -9            | -9             | 4          |


Tablo 6.14’e göre; en yüksek galibiyet puanı olan XGBoost yöntemi, 7 galibiyet ve 2 yenilgi ile en yüksek 5 puan ile Copeland puanına ulaşmış ve birinci sırada yer almıştır. LSTM yöntemi 6 galibiyet ve 3 yenilgi ile ikinci sırada, RF yöntemi ise 5 galibiyet ve 4 yenilgi ile üçüncü sırada yer almıştır. En düşük performansı gösteren yöntem ise karşılaşmaların tamamında yenilgi yaşayan SVM olmuştur. Bu durum, SVM'nin değerlendirme kriterleri açısından diğer yöntemlere kıyasla daha zayıf kaldığını göstermektedir.

### 6.2.3 Duyarlılık Analizi

Duyarlılık analizi bağlamında CRITIC-TOPSIS, CRITIC-ARAS ve CRITIC-CODAS modelleri açısından alternatif olan makine öğrenmesi yöntemlerinin sıralama sonuçları üzerinde kriter ağırlıklarının etkisi ele alınmıştır. Bu amaçla 20 farklı ağırlık senaryosu oluşturulmuş olup bunların grafiksel gösterimi Şekil 6.10'da verilmiştir.

Şekil 6.10

*Oluşturulan Senaryolara Göre Kriter Ağırlıklarında Gözlenen Değişimler*




Şekil 6.10'da kriter olarak ele alınan hata metriklerinden  $R^2$ , K1 ile gösterilirken MAE K2, MSE K3 ve RMSE ise K4 ile ifade edilmiştir. İlk senaryo olan S0'da önerilen model kullanılarak bulunan mevcut sıralama sonuçları ortaya konulmaktadır. Diğer senaryolar olan (S1-S20) ise ilgili kriter ağırlıklarının %10, %30, %50, %70 ve %90 oranında azaltılmasıyla oluşturulmuştur. Yeni kriter ağırlıklarının elde edildiği senaryoların oluşturulmasında Ecer (2022) tarafından ortaya konulan aşağıdaki eşitlikten yararlanılmıştır.

$$w_{yad} = (1 - w_{ad}) \left( \frac{w_{od}}{1 - w_{aod}} \right)$$

Burada  $w_{yad}$  kriter için yeni hesaplanan ağırlık değerlerini gösterirken,  $w_{ad}$  ise kriterin azaltılmış (indirgenmiş) değerini ifade etmektedir. Buna ek olarak kriterin orijinal değeri  $w_{od}$  ile gösterilirken, azaltılmış (indirgenmiş) değere sahip kriterin orijinal değeri ise  $w_{aod}$  ile belirtilmektedir. Duyarlılık analizi sonuçları CRITIC-TOPSIS için Şekil 6.11'de, CRITIC-ARAS için Şekil 6.12'de ve CRITIC-CODAS için ise Şekil 6.13'de sırasıyla verilmiştir.

**Şekil 6.11**


*Oluşturulan Senaryolara Göre ML Yöntemlerinin Sıralanması (CRITIC-TOPSIS)*



Şekil 6.11'e göre CRITIC-TOPSIS modeli bağlamında kriter ağırlıklarındaki değişimlere karşılık oluşturulan tüm senaryolarda makine öğrenmesi yöntemlerinin sıralamasında değişiklik gözlenmemektedir. Başka bir deyişle oluşturulan tüm senaryolarda LSTM birinci, XGBoost ikinci, RF üçüncü ve SVM ise dördüncü sırada yer almaktadır. Bu açıdan bakıldığında CRITIC-TOPSIS modeli kriter ağırlıklarındaki değişimlere karşı geçerli, dayanıklı ve sağlamdır.

**Şekil 6.12**

*Oluşturulan Senaryolara Göre ML Yöntemlerinin Sıralanması (CRITIC-ARAS)*




Şekil 6.12'e göre CRITIC-ARAS modeli bağlamında kriter ağırlıklarındaki değişimlere karşılık oluşturulan tüm senaryolarda alternatif olan makine öğrenmesi yöntemlerinin

sıralamasında deęişiklik görülmemektedir. Yani oluşturulan tüm senaryolarda RF birinci, XGBoost ikinci, LSTM üçüncü ve SVM ise dördüncü sırada yer almaktadır. Bu açıdan bakıldığında CRITIC-ARAS modeli kriter ağırlıklarındaki deęişimlere karşı geçerli, dayanıklı ve sağlamdır.

**Şekil 6.13**

*Oluşturulan Senaryolara Göre ML Yöntemlerinin Sıralanması (CRITIC-CODAS)*



Şekil 6.13'e göre CRITIC-CODAS modeli bağlamında kriter ağırlıklarındaki deęişimlere karşılık oluşturulan tüm senaryolarda alternatif olan makine öğrenmesi yöntemlerinin sıralamasında küçük deęişiklikler görülmektedir. Elde edilen tüm senaryolarda SVM dördüncü sırada yer alırken, senaryo 17-20 haricinde XGBoost birinci, 10,14,15,17-20 senaryoları dışında LSTM ikinci ve 10,14 ile 15. senaryoların haricinde ise RF üçüncü sıradaki yerini korumaktadır. Bu açıdan bakıldığında ise CRITIC-CODAS modeli kriter ağırlıklarındaki deęişimlere karşı daha az duyarlıdır.

Ecer vd. (2019) ve Ecer (2021)'in ifade ettięi gibi önerilen CRITIC-TOPSIS, CRITIC-ARAS ve CRITIC-CODAS modelleri açısından sıralama sonuçları ile oluşturulan tüm senaryoların sıralama sonuçları Spearman sıra korelasyon katsayısı (SSKK) ile incelenmiştir. Tüm korelasyon katsayıları en az 0,8'den büyük olup önerilen modellerin sıralama sonuçları ile elde edilen farklı senaryoların sıralama sonuçları arasında yüksek bir korelasyonu göstermektedir. SSKK'dan elde edilen sonuçlar ise farklı senaryolar açısından ağırlıklarda yaşanan deęişimlerin önerilen modellerin final sıralamasını anlamlı şekilde etkilemediğini ortaya koymaktadır.

## 7 SONUÇ VE ÖNERİLER

### 7.1 Sonuç

Bu tez çalışmasında, kripto para piyasalarının volatil ve karmaşık doğasından kaynaklanan fiyat tahmin zorluklarına yönelik olarak, dört farklı makine öğrenmesi algoritması olan Destek Vektör Makineleri (SVM), Rastgele Ormanlar (RF), Aşırı Gradyan Artırma (XGBoost) ve Uzun Kısa Süreli Bellek (LSTM) yöntemleri karşılaştırmalı olarak analiz edilmiştir. Tahmin modelleri, 2018-2023 dönemine ait günlük kripto para verileri üzerinden teknik analiz göstergeleri, makroekonomik değişkenler ve yatırımcı duyarlılığına ilişkin göstergeler dahil edilerek oluşturulmuş ve modellerin performansları  $R^2$ , MAE, MSE ve RMSE gibi istatistiksel hata metrikleri ile değerlendirilmiştir. Ayrıca, değişkenlerin tahmin doğruluğuna katkısı, algoritmaların türlerine uygun şekilde belirlenmiş; SVM ve LSTM için permütasyon önem analizi, RF ve XGBoost için ise gömülü önem hesaplama yöntemleri kullanılmıştır.

Modellerin performansları yalnızca hata oranlarıyla değil, aynı zamanda Çok Kriterli Karar Verme (ÇKKV) teknikleri ile çok boyutlu değerlendirmeye tabi tutulmuştur. Bu kapsamda, CRITIC yöntemi ile her bir performans metriği için kriter ağırlığı belirlenmiş, ardından TOPSIS, ARAS ve CODAS yöntemleriyle algoritmalar sıralanmış ve genel sıralama Copeland yöntemiyle elde edilmiştir.

Çalışmada kullanılan modellerin performansları, hata metrikleri çerçevesinde incelendiğinde farklı kripto varlıklar için değişken düzeylerde başarı elde edildiği görülmüştür.  $R^2$  değerlerine göre, SVR yöntemi eksi  $R^2$  değeriyle Dogecoin için fiyat tahmininde başarısız olmuştur. Bunun dışında dört yöntem de tüm varlıkların fiyatlarını başarılı şekilde tahmin etmiştir. Ayrıca  $R^2$  değerlerine göre, Bitcoin, Ethereum ve Ripple için en başarılı sonucu SVR yöntemi verirken, Ripple için RF yöntemi, Dogecoin için ise XGBoost yöntemi en başarılı tahmini yapmıştır. Ancak MAE, MSE ve RMSE metrikleriyle karşılaştırıldığında her bir hata metriği farklı bir ML yöntemini en başarılı olarak gösterebilmektedir. Örneğin, Bitcoin tahmini için LSTM yöntemi  $R^2$  değerine göre dördüncü sırada yer alırken, RMSE metriğine bakıldığında en düşük hata oranını vermektedir. Bulgulara göre, farklı yöntemlerin farklı varlıklarda farklı sonuçlar verdiği görülmektedir. Hitam ve İsmail (2018), Hitam vd. (2019) ve Salb vd., (2021) gibi çalışmalarda da yöntemlerin başarı düzeylerinin varlık türüne göre değişebildiği vurgulanmakta ve bu durum literatür tarafından da desteklenmektedir. Bu durumda, en

başarılı yöntemi belirlemek ve sıralama yapmak zorlaşmaktadır. Her metriğin farklı yönleri ölçmesi nedeniyle, yöntemler arasında objektif ve bütüncül bir sıralama yapabilmek ve bu kriterleri birlikte değerlendirilmek amacıyla, ÇKKV teknikleriyle sıralama yapılmıştır.

Ayrıca, ÇKKV teknikleri ile sıralama yapmadan önce, araştırmada kullanılan değişkenlerin fiyat tahminine ne düzeyde katkı sağladığını belirlemek amacıyla değişken önem düzeyi analizleri gerçekleştirilmiştir. Yapılan analizlere göre, geçmiş fiyat hareketleri ile göreceli güç endeksi (RSI), hareketli ortalama yakınsama ıraksama (MACD), 50 günlük basit hareketli ortalama (MA50) ve 200 günlük basit hareketli ortalama (MA200) gibi teknik göstergeler tahmin performansına belirgin katkı sağlamaktadır. Bu bulgular, Liu vd. (2021), Basher ve Sadorsky (2022), Gradojevic vd. (2023), Labbaf Khaniki ve Manthouri (2024), Hafid vd. (2024), Lee ve Xu (2024) ve Islam vd. (2025) gibi çalışmalarda da desteklenmektedir.

Teknik göstergelerin önemli katkılarına rağmen, makroekonomik ve yatırımcı duyarlılığı göstergelerinin sınırlı katkısı tespit edilmiştir. Bulgular literatürle karşılaştırıldığında hem benzerlikler hem de farklılıklar göze çarpmaktadır. Örneğin Aggarwal vd. (2019), altın fiyatı ile Bitcoin fiyatı arasında pozitif bir ilişki bulmamış, bu çalışmada da benzer biçimde altın göstergesi anlamlı bir etki göstermemiştir. Basher ve Sadorsky (2022) enflasyon oranının Bitcoin fiyat yönünün güçlü bir göstergesi olmadığını belirtmiş, bu bulgu da bu çalışma tarafından teyit edilmiştir. Buna karşılık aynı çalışmada petrol piyasası belirsizliği (OVX) önemli bir tahmin edici olduğu ifade edilirken, bu çalışmada böyle bir ilişki saptanamamıştır. Ayrıca Gradojevic vd. (2023), Bitcoin piyasasının korku ve açgözlülük endeksi (FGI), hacim ve Google arama eğilimleri (GTRENDS) gibi yatırımcı duyarlılığı göstergeleri tarafından yönlendirildiğini ortaya koyarken, bu araştırmada söz konusu göstergelerle yalnızca sınırlı bir ilişki belirlenmiştir. Ben Hamadou vd. (2025) çalışmalarında da GTRENDS ve altın göstergeleri güçlü öngörü gücünü korurken, bu çalışmada bu değişkenlerin anlamlı bir katkısı bulunmamıştır. Ayrıca aynı araştırmada ekonomi politikası belirsizliği (EPU) göstergesinin öneminin azalması bu çalışmayla benzerlik göstermektedir. Bu benzerlikler ve farklılıklar, piyasa koşullarına, döneme ve veri setinin kapsamına bağlı olarak değişkenlerin etkisinin farklılaşabileceğini göstermektedir.

ÇKKV teknikleriyle sıralama aşamasında, CRITIC yöntemiyle belirlenen kriter ağırlıklarıyla yapılan TOPSIS, ARAS ve CODAS sıralamalarının Copeland yöntemiyle

birleştirilmesi sonucunda XGBoost algoritması en başarılı yöntem olarak öne çıkmıştır. Çalışmaya dahil edilen tüm yöntemler başarılı kabul edilebilecek düzeyde tahmin performansı sergilemiş olsa da en iyi sonuçlar XGBoost algoritmasıyla elde edilmiştir. Bu durum, yatırım kararları, portföy optimizasyonu ve algoritmik işlem stratejilerinin oluşturulmasında XGBoost gibi gradyan artırma tabanlı yöntemlerin öncelikli tercih edilebileceğini göstermektedir.

Yöntemsel açıdan, XGBoost algoritmasının öne çıkması Karğın vd. (2022), Ranjan vd. (2022) ve Hafid vd. (2024) gibi çalışmalarda elde edilen bulgularla da örtüşmektedir. Söz konusu araştırmalar, XGBoost'un gradyan artırma mantığı sayesinde hızlı öğrenme ve yüksek genelleme kabiliyeti sunduğunu ve diğer ML modellerine göre daha düşük hata metrikleri sağladığını göstermiştir. Ayrıca Karasu vd. (2018), Hitam ve İsmail (2018), Phaladisailoed ve Numnonda (2018), Atsalakis vd. (2019), Aggarwal vd. (2020), Zhao vd. (2019), Erfanian vd. (2022) ve Gradojevic vd. (2023), RF, LSTM ve SVR tabanlı modellerin de bazı durumlarda yüksek doğruluk sunduğunu belirtmiş, bu da çalışmamızda RF, LSTM ve SVR'nin özellikle belirli varlıklarda güçlü sonuçlar vermesiyle paralellik göstermektedir.

Çalışmada performans açısından en başarılı yöntem olarak seçilen XGBoost modeli için elde edilen hata metriklerinin yatırımcı açısından ifade ettiği anlam değerlendirildiğinde, sonuçların kripto para piyasalarında oldukça yüksek bir tahmin doğruluğuna işaret ettiği görülmektedir.  $R^2$  değerlerinin tümünde 0,95'in üzerinde olması, fiyat hareketlerinin büyük bölümünün model tarafından açıklandığı anlamına gelir ve bu da yatırımcı için tahminlerin güvenilirliğini artırır. MAE ve RMSE değerleri ise yatırımcının karşılaşılabileceği tahmin sapmasını ifade eder. Örneğin Ethereum için MAE'nin 39 olması, modelin ortalama olarak gerçek fiyattan 39 dolar sapmayla tahmin yaptığını, Bitcoin'de ise RMSE'nin 744 olması tahminlerin 744 dolar civarında bir hata payına sahip olduğunu gösterir. Genel olarak sonuçlar, XGBoost'un kripto paralarda yüksek doğrulukla çalışan bir model olduğunu ve yatırımcıya karar verme sürecinde anlamlı bir öngörü avantajı sunduğunu göstermektedir.

Bu bağlamda, çalışmanın hem yöntemsel katkısı hem de çok değişkenli yapıyı bir araya getiren kapsamlı yaklaşımıyla literatüre özgün bir katkı sunduğu değerlendirilmektedir. Özellikle yatırımcı duyarlılığı ve makroekonomik göstergelerin modele entegrasyonu, klasik teknik analiz modellerine göre daha geniş perspektifli bir tahmin süreci geliştirilmesine imkân tanımıştır. Ancak bu tür değişkenlerin etkisinin sınırlı kalması,

daha etkili duyarlılık ve temel veri kaynaklarının geliştirilmesi gerektiğini ortaya koymaktadır.

Sonuç olarak elde edilen bulgular, yalnızca akademik alana değil, aynı zamanda uygulayıcılar açısından da anlamlı ve kullanılabilir sonuçlar sunmaktadır. Özellikle güçlü tahmin performansı sergileyen algoritmaların öne çıkması hem kurumsal hem de bireysel yatırım kararlarının veri temelli ve sistematik şekilde desteklenmesine olanak tanımaktadır. Büyük ölçekli portföy yöneticileri, bu modelleri portföy optimizasyonu, risk yönetimi ve algoritmik işlem stratejilerinin geliştirilmesi süreçlerinde karar destek aracı olarak kullanabilirken, küçük yatırımcılar açısından ise daha sadeleştirilmiş ve yorumlanabilir modellerin sağladığı çıktılar, piyasa trendlerini anlamada ve alım ile satım zamanlamalarını belirlemede yol gösterici olabileceği değerlendirilmektedir. Ayrıca çalışmada kullanılan değişken önem düzeyi analizleri, yatırımcılara hangi tür göstergelerin süreçlerinde daha belirleyici olduğunu ortaya koyarak, yatırım stratejilerinin oluşturulmasında değişken seçimine ilişkin önemli ipuçları sunmaktadır. Bu kapsamda, bulgular sadece akademik bir katkı sağlamamakta, aynı zamanda pratikte veri odaklı yatırım anlayışını benimseyen tüm paydaşlar için somut bir referans noktası oluşturmaktadır.

## 7.2 Öneriler

Çalışma sonucunda elde edilen bulgular doğrultusunda, gelecek çalışmalara ve uygulamalara yönelik çeşitli öneriler sunulabilir.

Araştırmanın sınırlılıkları arasında, teknik analiz göstergeleri, makroekonomik faktörler ve yatırımcı duyarlılığına ilişkin seçilmiş göstergeler yer almaktadır. Bu yapı, ML algoritmalarının kripto varlık fiyatlarını çok boyutlu bir bakış açısıyla modellemesine olanak tanımaktadır. Ancak analiz kapsamında yer almayan, kripto varlık fiyatlarını etkileyebilecek potansiyel veri türlerinin de bulunduğu düşünülmektedir. Örneğin, gelecekte yapılacak çalışmalarda, zincir verileri (işlem hacmi, aktif cüzdan sayısı, hash rate vb.), haber metinleri, sosyal medya içerikleri (X, Reddit, Ekşi Sözlük vb.), forum analizleri, blog yorumları ve YouTube kullanıcı tepkileri gibi alternatif veri türlerinin de modele entegre edilmesi, yatırımcı davranışlarının daha doğru temsil edilmesini sağlayabilir. Aynı zamanda, işlem derinliği, emir defteri verileri, kripto varlık arz hareketleri gibi göstergelerinin dahil edilerek veri setlerinin zenginleştirilmesi, algoritmaların özellikle yüksek volatilité içeren dönemlerde daha kararlı ve duyarlı

tahminler üretmesine olanak tanıyabilir. Ayrıca, sadece spot piyasalar değil, vadeli işlem verileri, opsiyon piyasaları ya da zincir üstü (on-chain) veriler gibi alternatif veri kaynaklarının da tahmin süreçlerine dâhil edilmesi model performansını artırabilir.

Gerçek zamanlı fiyat tahmini ve otomatik alım-satım sistemlerine entegrasyon da bu modellerin uygulanabilirliğini artıracaktır. Bu bağlamda, geliştirilen modellerin canlı veri akışı ile beslenmesi ve dinamik karar destek sistemlerine dönüştürülmesi yatırımcılar açısından büyük avantaj sağlayabilir.

Bununla birlikte, çalışmada yalnızca beş büyük kripto para birimi analiz edilmiştir. Modelin daha az bilinen altcoinlerde ya da farklı dönemsel kriz senaryolarında test edilmesi, yöntemlerin genellenebilirliği ve dayanıklılığı açısından değerli olacaktır.

Son olarak, bu çalışmada kullanılan dört makine öğrenmesi yöntemi dışında, hibrit modellemeler (örneğin LSTM + XGBoost ya da CNN + LSTM gibi) gelecekteki çalışmalarda test edilerek daha güçlü tahmin performansları elde edilebilir. Kripto paraların spekülatif yapısı göz önünde bulundurulduğunda hem açıklayıcı gücü yüksek hem de genellenebilirliği yüksek modellerin geliştirilmesi, finansal karar alma süreçlerinde güvenilir öngörüler sunacaktır.

## KAYNAKÇA

- Aggarwal, A., Gupta, I., Garg, N., & Goel, A. (2019, August). Deep learning approach to determine the impact of socio economic factors on bitcoin price prediction. In *2019 twelfth international conference on contemporary computing (IC3)* (pp. 1-5). IEEE. <https://doi.org/10.1109/IC3.2019.8844928>
- Aggarwal, D., Chandrasekaran, S. and Annamalai, B. (2020). A complete empirical ensemble mode decomposition and support vector machine-based approach to predict Bitcoin prices. *Journal of behavioral and experimental finance*, 27, 100335. <https://doi.org/10.1016/j.jbef.2020.100335>
- Agrawal, M., Shukla, P. K., Nair, R., Nayyar, A. and Masud, M. (2022). Stock prediction based on technical indicators using deep learning model. *Computers, Materials and Continua*, 70(1), 287-304. <https://doi.org/10.32604/cmc.2022.014637>
- Ahmadova, S., & Ereğ, M. (2022). A review on Ripple, a financial intermediary Coin. *Akademik İzdüşüm Dergisi*, 7(2), 117-130.
- Akleyek, S., Yıldırım, H. M. ve Tok, Z. Y. (2011). Kriptoloji ve uygulama alanları: açık anahtar altyapısı ve kayıtlı elektronik posta. *Akademik Bilişim*, 11, 2-4.
- Almeida, J. and Gonçalves, T. C. (2023). A decade of cryptocurrency investment literature: a cluster-based systematic analysis. *International Journal of Financial Studies* 11: 71. <https://doi.org/10.3390/ijfs11020071>
- An, M., Fan, Q., Yu, H. and Zhao, H. (2023). Blockchain technology research and application: a systematic literature review and future trends. *Journal of Data Science and Intelligent Systems* 2023, 00(00). 1–12 <https://doi.org/10.47852/bonviewJDSIS32021403>
- Arıcı, T., Kitapçı, H. ve Fidan, E. (2022). Değişim çağında yeni nesil para: Kripto paraların avantaj ve dezavantajlarına yönelik inceleme. *Holistic Economics*, 1(1), 11-19.
- Aspris, A., Foley, S., Svec, J. and Wang, L. (2021). Decentralized exchanges: The “wild west” of cryptocurrency trading. *International Review of Financial Analysis*, 77, 101845. <https://doi.org/10.1016/j.irfa.2021.101845>
- Atlan, F., Pençe, I. ve Çeşmeli, M. Ş. (2020, October). Online price forecasting model using artificial intelligence for cryptocurrencies as bitcoin, ethereum and ripple. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE. <https://doi.org/10.1109/SIU49456.2020.9302082>
- Atlan, F., Pençe, I., Çeşmeli, M. S. ve Kalkan, A. (2018). Bitcoin'in Türkiye Piyasasındaki Değerinin Yapay Zeka Teknikleri ile Tahmini. *5th International Management Information Systems Conference*. (pp. 1–5).
- Atsalakis, G. S., Atsalaki, I. G., Pasiouras, F. and Zopounidis, C. (2019). Bitcoin price forecasting with neuro-fuzzy techniques. *European journal of operational research*, 276(2), 770-780. <https://doi.org/10.1016/j.ejor.2019.01.040>
- Avaroğlu, E. (2017). Bilgi güvenliğinin temel yapı taşı: kriptoloji. *Düşünce Dünyasında Türkiz*, 8(43), 53-65.

- Avunduk, H. ve Aşan, H. (2018). Blok zinciri (blockchain) teknolojisi ve işletme uygulamaları: genel bir değerlendirme. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 33(1), 369-384. <https://doi.org/10.24988/deuiibf.2018331746>
- Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F. and Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225. <https://doi.org/10.1016/j.knosys.2021.107119>
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Bai, Y. (2023). Investor Sentiment Measurement and Time Series Analysis. In *SHS Web of Conferences*, 163, 01002. <https://doi.org/10.1051/shsconf/202316301002>
- Bardak, S., Ersen, N., Polat, K. ve Akyüz, K. C. (2024). Makine öğrenmesi yöntemleri ile hisse senedi fiyat tahmini: Kâğıt firması örneği. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 25(2), 47-58. <https://doi.org/10.17474/artvinofd.1500569>
- Barsky, R., Epstein, C., Lafont-Mueller, A. and Yoo, Y. (2021). What drives gold prices?. *Chicago Fed Letter*, 464, 1-6.
- Basher, S. A. and Sadorsky, P. (2022). Forecasting Bitcoin price direction with random forests: How important are interest rates, inflation, and market volatility? *Machine Learning with Applications*, 9, 100355. <https://doi.org/10.1016/j.mlwa.2022.100355>
- Başbuğ, B. ve Lokmanoglu, E. (2021). İnternet mem efsanesinden kripto paraya evriliş: postmodern dönemde popüler bir meme coin örneği olarak Dogecoin”, *International Social Mentality and Researcher Thinkers Journal*, (Issn:2630-631X) 7(52). 3131-3139.
- Ben Hamadou, F., Mezghani, T., Zouari, R. and Boujelbene-Abbes, M. (2025). Forecasting Bitcoin returns using machine learning algorithms: Impact of investor sentiment. *EuroMed Journal of Business*, 20(1), 179-200. <https://doi.org/10.1108/EMJB-03-2023-0086>
- Betül, Ü. (2017). Sanal para birimleri. *Uzmanlık Yeterlik Tezi, Türkiye Cumhuriyet Merkez Bankası Ödeme Sistemleri Genel Müdürlüğü Ankara, Eylül*.
- Bouteska, A., Abedin, M. Z., Hajek, P. ve Yuan, K. (2024). Cryptocurrency price forecasting—a comparative analysis of ensemble learning and deep learning methods. *International Review of Financial Analysis*, 92, 103055.
- Budak, M. Y. ve Aytekin, S. (2022). Kripto varlık fiyatlarının makine öğrenmesi kullanılarak tahmin edilmesi. *Geçmişten Günümüze Para, Banka ve Finans Tartışmaları* (ss. 159-175). Ekin Yayınevi.
- Chaum, D. (1983). Blind signatures for untraceable payments. In *Advances in Cryptology: Proceedings of Crypto 82* (pp. 199-203). Boston, MA: Springer US.
- Chen, H., Liu, L. and Li, X. (2018). The predictive content of CBOE crude oil volatility index. *Physica A: Statistical Mechanics and its Applications*, 492, 837-850. <https://doi.org/10.1016/j.physa.2017.11.014>

- Chen, Z., Li, C. and Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395. <https://doi.org/10.1016/j.cam.2019.112395>
- Cheng, K. Y. (2024). *China's crackdown on crypto mining from a climate perspective: unified efforts from administrative authorities and the judiciary*. *International Journal of Digital Law and Governance*, 1(1), 91-11 <https://doi.org/10.1515/ijdlg-2023-0004>
- Chiu, J. And Koepl, T. (2017). The Economics of Cryptocurrencies Bitcoin and Beyond, *Queen's Economics Department Working Paper, No. 1389*, Queen's University, Department of Economics, Kingston (Ontario).
- Chohan, U. W. (2021). A history of Dogecoin. *Discussion Series: Notes on the 21st Century*, <http://dx.doi.org/10.2139/ssrn.3091219>
- Choi, H. and Varian, H. (2012). Predicting the present with Google Trends. *Economic record*, 88, 2-9. <https://doi.org/10.1111/j.1475-4932.2012.00809.x>
- Chowdhury, R., Rahman, M. A., Rahman, M. S. and Mahdy, M. R. C. (2020). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning. *Physica A: Statistical Mechanics and Its Applications*, 551, 124569. <https://doi.org/10.1016/j.physa.2020.124569>
- Crosby, M., Pattanayak, P., Verma, S. and Kalyanaraman, V. (2016). Blockchain technology: Beyond bitcoin. *Applied innovation*, 2(6-10), 71.
- Crumbley, D. L., Ariail, D. L. and Khayati, A. (2024). How should cryptocurrencies be defined and reported? an exploratory study of accounting professor opinions. *Journal of Risk and Financial Management*, 17(1), 3. <https://doi.org/10.3390/jrfm17010003>
- Çağlar, B. ve Yavuz, U. (2021). Finansal haberlerin Bitcoin fiyatlarına etkisinin yapay sinir ağları ile analizi. *Bilişim Teknolojileri Dergisi*, 14(1), 65–78. <https://doi.org/10.17671/gazibtd.703688>
- Çakır, E. (2017). Kriter ağırlıklarının SWARA–Copeland yöntemi ile belirlenmesi: Bir üretim işletmesinde uygulama. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 4(1), 42-56.
- Çetinyokuş, T. Ve Gökçen, H. (2002). Borsada göstergelerle teknik analiz için bir karar destek sistemi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 17(1), 43-58.
- Daniels, P. S. (2022). Machine Learning Techniques for Pricing, Hedging and Statistical Arbitrage in Finance. *University of Technology Sydney (Australia)*. <http://hdl.handle.net/10453/172004>
- Demiroğlu, S. (2020). bitcoin ve ethereum arasındaki ilişki: toda-yamamoto nedensellik testi. *Journal Of Social, Humanities And Administrative Sciences (Joshas)*, 6(33), 1903-1911. : <http://doi.org/10.31589/JOSHAS.447>
- Doğan, Z. ve Evlimoğlu, U. (2022). Bireysel yatırımcıların yatırım kararlarında davranışsal finansın rolü: Aydın ili örneği. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 11(4), 1983-2010. <https://doi.org/10.15869/itobiad.1079129>

- Duchow, M. (2025). Crypto crime and punishment: the case for stronger international regulations. *Denver Journal of International Law & Policy (Online)*, April 25, 2025
- Dumanoğlu, S. (2010). İMKB'de işlem gören çimento şirketlerinin mali performansının topsıs yöntemi ile değerlendirilmesi. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 29(2), 323-339.
- Ecer, F. (2021). Sustainability assessment of existing onshore wind plants in the context of triple bottom line: a best-worst method (BWM) based MCDM framework. *Environmental Science and Pollution Research*, 28(16), 19677-19693. <https://doi.org/10.1007/s11356-020-11940-4>
- Ecer, F. (2022). An extended MAIRCA method using intuitionistic fuzzy sets for coronavirus vaccine selection in the age of COVID-19. *Neural Computing and Applications*, 34, 5603-5623. <https://doi.org/10.1007/s00521-021-06728-7>
- Ecer, F., Pamucar, D., Zolfani, S. H. and Eshkalag, M. K. (2019). Sustainability assessment of OPEC countries: Application of a multiple attribute decision making tool. *Journal of Cleaner Production*, 241, 118324. <https://doi.org/10.1016/j.jclepro.2019.118324>
- Ercan, S., ve Demirbaş, B. (2020). ABD doları endeksi ile vix korku endeksi arasındaki ilişki: ardl sınır testi yaklaşımı. *Bilgi Ekonomisi Ve Yönetimi Dergisi*, 15(2), 115-129.
- Erek, M. (2009). Examining us dollar index (DXY) movements by monte carlo simulation. *Bitlis Eren Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 191-199.
- Erfanian, S., Zhou, Y., Razzaq, A., Abbas, A., Safeer, A. A. and Li, T. (2022). Predicting Bitcoin (BTC) price in the context of economic theories: A machine learning approach. *Entropy*, 24(10), 1487. <https://doi.org/10.3390/e24101487>
- Ersoy, N. (2022). Kriter ağırlıklandırma yöntemlerinin ÇKKV sonuçları üzerindeki etkisine yönelik gerçek bir hayat uygulaması. *MANAS Sosyal Araştırmalar Dergisi*, 11(4), 1449-1463.
- Fatih, Y. B. (2015). Çok Kriterli Karar Verme Problemlerinde ARAS Yöntemi. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi*, 6(9).
- Federal Reserve Board. (2021, Temmuz 29). *Monetary policy: What are its goals? How does it work?* <https://www.federalreserve.gov/monetarypolicy/monetary-policy-what-are-its-goals-how-does-it-work.htm>
- Galasso, J. (2023). The Crypto Revolution: A Comparative Analysis of Crypto Regulation in the United States and the European Union. *Touro Law Review*, 39(4), 1183-1218
- Gan, H. L. (2023). Centralized crypto exchanges (CEX) website. *Doctoral dissertation*, Lee Kong Chian Faculty of Engineering and Science University Tunku Abdul Rahman.
- Gemici, E. (2020). ekonomi politikası belirsizliği ile g7 ülke borsaları arasındaki ilişki. *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi (BUSBED)*, 10(20), 353-372.

- Gold, S. (2015). The viability of six popular technical analysis trading rules in determining effective buy and sell signals: MACD, AROON, RSI, SO, OBV, and ADL. *Journal of Applied Financial Research*, 2.
- Gradojevic, N., Kukolj, D., Adcock, R. and Djakovic, V. (2023). Forecasting Bitcoin with technical analysis: A not-so-random forest? *International Journal of Forecasting*, 39(1), 1–17. <https://doi.org/10.1016/j.ijforecast.2021.08.001>
- Guo, H., Zhang, D., Liu, S., Wang, L. and Ding, Y. (2021). Bitcoin price forecasting: A perspective of underlying blockchain transactions. *Decision Support Systems*, 151, 113650. <https://doi.org/10.1016/j.dss.2021.113650>
- Hafid, A., Ebrahim, M., Rahouti, M. and Oliveira, D. (2024). Cryptocurrency price forecasting using XGBoost regressor and technical indicators. *2024 IEEE International Performance, Computing, and Communications Conference (IPCCC)*, 1–7. <https://doi.org/10.1109/IPCCC59868.2024.10850357>
- Härdle, W. K., Harvey, C. R., & Reule, R. C. (2020). Understanding cryptocurrencies. *Journal of Financial Econometrics*, 18(2), 181-208. <http://dx.doi.org/10.2139/ssrn.3360304>
- He, X., Li, Y. and Li, H. (2024). Revolutionizing Bitcoin price forecasts: A comparative study of advanced hybrid deep learning architectures. *Finance Research Letters*, 69, 106136.
- Hitam, N. A. and Ismail, A. R. (2018). Comparative performance of machine learning algorithms for cryptocurrency forecasting. *Ind. J. Electr. Eng. Comput. Sci*, 11(3), 1121-1128. <https://doi.org/10.11591/ijeecs.v11.i3.pp1121-1128>
- Hitam, N. A., Ismail, A. R. and Saeed, F. (2019). An optimized support vector machine (SVM) based on particle swarm optimization (PSO) for cryptocurrency forecasting. *Procedia Computer Science*, 163, 427–433. <https://doi.org/10.1016/j.procs.2019.12.125>
- Hsu, C. W., Chang, C. C., and Lin, C. J. (2003). A practical guide to support vector classification. *Department of Computer Science National Taiwan University*, Taipei 106, Taiwan
- http-1: (2023, April, 3). What is cryptocurrency and how does it work? *Binance Academy*. <https://academy.binance.com/en/articles/what-is-a-cryptocurrency> (Erişim tarihi: 03.05.2024)
- http-2: Advantages and disadvantages of blockchain. Bit Shes. <https://bitshes.com/toolbox/learning-center/advantages-and-disadvantages-of-blockchain> (Erişim tarihi: 03.05.2024)
- http-3: Tamplin, T. (2023, September, 7). *Blockchain Advantages and Disadvantages*. Finance Strategists. <https://www.financestrategists.com/wealth-management/blockchain/blockchain-advantages-and-disadvantages/> (Erişim tarihi: 03.05.2024)
- http-4: (2022, April, 26). Advantages and disadvantages of different types of blockchain. *Zeb Pay*. <https://zebpay.com/blog/advantages-and-disadvantages-of-blockchains> (Erişim tarihi: 03.05.2024)

- http-5: (2018, December, 12). Blockchain advantages and disadvantages. *Binance Academy*. <https://academy.binance.com/en/articles/positives-and-negatives-of-blockchain> (Erişim tarihi: 03.05.2024)
- http-6: Hamacher, A. (2022, April, 6). How David Chaum went from inventing digital cash to pioneering digital privacy. *Decrypt*. <https://decrypt.co/95109/david-chaum-from-inventing-digital-cash-to-pioneering-digital-privacy> (Erişim tarihi: 05.05.2024)
- http-7: Grabata, A. (2024, April, 30). DigiCash: Exploring its Origins, Innovations, and Impact on Digital Currency, *Super Money*. <https://www.supermoney.com/encyclopedia/digicash> (Erişim tarihi: 05.05.2024)
- http-8: How David Chaum's ecash spawned a cypherpunk dream. *Saylor Academy*. <https://learn.saylor.org/mod/book/view.php?id=30735> (Erişim tarihi: 05.05.2024)
- http-9: Bruehl, E. (2022, September, 12). Five differences between ethereum and Bitcoin. *Current*. [current.com/blog/five-differences-between-ethereum-and-bitcoin/](https://current.com/blog/five-differences-between-ethereum-and-bitcoin/) (Erişim tarihi: 26.05.2024)
- http-10: (2022, January, 12). What is BNB auto-burn. *Binance Academy*. <https://academy.binance.com/en/articles/what-is-bnb-auto-burn> (Erişim tarihi: 27.05.2024)
- http-11: Schwartz, D. (2020, October, 29). Beyond proof of work: the RPL consensus solution. *Ripple*. <https://ripple.com/insights/beyond-proof-of-work-the-xrpl-consensus-solution/> (Erişim tarihi: 27.05.2024)
- http-12: <https://coinmarketcap.com/currencies/bitcoin/> (Erişim tarihi: 26.05.2024)
- http-13: <https://coinmarketcap.com/currencies/ethereum/> (Erişim tarihi: 26.05.2024)
- http-14: <https://coinmarketcap.com/currencies/bnb/> (Erişim tarihi: 27.05.2024)
- http-15: <https://coinmarketcap.com/currencies/xrp/> (Erişim tarihi: 27.05.2024)
- http-16: <https://coinmarketcap.com/currencies/dogecoin/> (Erişim tarihi: 27.05.2024)
- http-17: About Binance. <https://coinmarketcap.com/exchanges/binance/> (Erişim tarihi: 30.05.2024)
- http-18: About Coinbase Exchange. <https://coinmarketcap.com/exchanges/coinbase-exchange/> (Erişim tarihi: 30.05.2024)
- http-19: About Bybit. <https://coinmarketcap.com/exchanges/bybit/> (Erişim tarihi: 30.05.2024)
- http-20: About Uniswap. <https://coinmarketcap.com/exchanges/uniswap/> (Erişim tarihi: 30.05.2024)
- http-21: About Raydium. <https://coinmarketcap.com/exchanges/raydium/> (Erişim tarihi: 30.05.2024)
- http-22: About PancakeSwap. <https://coinmarketcap.com/exchanges/pancakeswap-v2/> (Erişim tarihi: 30.05.2024)
- http-23: Solidus Labs (2023, October, 31). *Cryptocurrency Regulation in Germany: An Overview*. [https://www.soliduslabs.com/post/germany-cryptocurrency-regulation#:~:text=Germany%20has%20clear%20AML%20regulations,BaFin%](https://www.soliduslabs.com/post/germany-cryptocurrency-regulation#:~:text=Germany%20has%20clear%20AML%20regulations,BaFin%20)

- E2%80%99s%20Suspicious%20Transaction%20Reporting%20System (Eriřim tarihi: 01.05.2025)
- http-24: Alternative.me. (n.d.). *Crypto fear & greed index*. <https://alternative.me/crypto/fear-and-greed-index/> (Eriřim tarihi: 01.05.2025)
- http-25: Scikit-learn. StandardScaler. <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html> (Eriřim tarihi: 24.05.2025)
- http-26: Geeks for Geeks (2025, April, 21). StandardScaler, MinMaxScaler and RobustScaler techniques – ML. <https://www.geeksforgeeks.org/standardscaler-minmaxscaler-and-robustscaler-techniques-ml/> (Eriřim tarihi: 24.05.2025)
- http-27: Scikit-learn. MinMaxScaler. <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html#sklearn.preprocessing.MinMaxScaler> (Eriřim tarihi: 24.05.2025)
- http-28: Paghdal, S. (2025, January, 22). Feature Scaling in Machine Learning: Why It Matters. <https://medium.com/@paghadalsneh/feature-scaling-in-machine-learning-why-it-matters-39a866f56d0d> (Eriřim tarihi: 24.05.2025)
- http-29: Thenraj, P. (2020, June, 22). Do Decision Trees need Feature Scaling? <https://medium.com/data-science/do-decision-trees-need-feature-scaling-97809eaa60c6> (Eriřim tarihi: 24.05.2025)
- http-30: Scikit-learn. Permutation feature importance. [https://scikit-learn.org/stable/modules/permutation\\_importance.html](https://scikit-learn.org/stable/modules/permutation_importance.html) (Eriřim tarihi: 24.05.2025)
- Hu, J. (2024). *The regulation of cryptocurrency in China*. International Journal of Digital Law and Governance, 1(1), 53-79 <https://doi.org/10.1515/ijdlg-2024-0007>
- Hua, Y. (2020). Bitcoin price prediction using ARIMA and LSTM. *In E3s Web Of Conferences*, 218, 01050. <https://doi.org/10.1051/e3sconf/202021801050>
- Islam, M. S., Bashir, M., Rahman, S., Al Montaser, M. A., Bortty, J. C., Nishan, A. and Haque, M. R. (2025). Machine learning-based cryptocurrency prediction: Enhancing market forecasting with advanced predictive models. *Journal of Ecohumanism*, 4(2), 2498–2519. <https://doi.org/10.62754/joe.v4i2.6663>
- Karamitsos, I., Papadaki, M. and Al Barghuthi, N.B. (2018) Design of the blockchain smart contract: a use case for real estate. *Journal of Information Security*, 9, 177-190. <https://doi.org/10.4236/jis.2018.93013>
- Karasu, S., Altan, A., Saraç, Z. ve Hacıoğlu, R. (2018). Prediction of Bitcoin prices with machine learning methods using time series data. *2018 26th Signal Processing and Communications Applications Conference (SIU)* (ss. 1–4). IEEE. <https://doi.org/10.1109/SIU.2018.8404760>
- Karğın, M., Yıldız, S. B. ve Gözkonan, Ü. H. (2022). Kripto para piyasasında fiyat tahminlemesi: Bitcoin üzerine bir uygulama. *Geçmişten Günümüze Para, Banka ve Finans Tartışmaları* (ss. 132–143). Ekin Yayınevi.
- Kayalı, M. M. ve Ünal, S. (2015). Piyasa mikro yapısı, finansal varlıkların likitidesi ve fiyatların oluşumu. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi* (12).

- Kılıç, E.(2022). Petrol riski, petrol spot ve petrol vadeli işlemler arasındaki dinamik stokastik volatilité yayılımı. *Equinox, Journal of Economics, Business & Political Studies*, 9 (2), 158-171 <https://doi.org/10.48064/equinox.1116434>
- Koç Ustalı, N., Tosun, N. ve Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 1-16. <https://doi.org/10.17153/Oguiibf.636017>
- Labbař Khaniki, M. A. and Manthouri, M. (2024). Enhancing price prediction in cryptocurrency using transformer neural network and technical indicators. *arXiv*. <https://doi.org/10.48550/arXiv.2403.03606>
- Latif, N., Selvam, J. D., Kapse, M., Sharma, V. and Mahajan, V. (2023). Comparative performance of LSTM and ARIMA for the short-term prediction of Bitcoin prices. *Australasian Accounting, Business and Finance Journal*, 17(1), 256–276. <https://doi.org/10.14453/aabfj.v17i1.1>
- Lee, M. C. and Xu, R. J. (2025). Cryptocurrency price forecasting using deep learning model with technical indicators. *2025 International Conference on Electronics, Information, and Communication (ICEIC)* (pp. 1–4). IEEE. <https://doi.org/10.1109/ICEIC64972.2025.10879755>
- Lee, S. S., and Wang, M. (2024). Variance Decomposition and Cryptocurrency Return Prediction. *Journal of Financial and Quantitative Analysis*, 1-32.
- Liu, M., Zhang, D., Yang, X. and Wang, Y. (2021). Forecasting the price of Bitcoin using deep learning. *Finance Research Letters*, 40, 101728. <https://doi.org/10.1016/j.frl.2020.101755>
- Lyu, H. (2022). Cryptocurrency price forecasting: A comparative study of machine learning models in short-term trading. *2022 Asia Conference on Algorithms, Computing and Machine Learning (CACML)* (ss. 280–288). IEEE. <https://doi.org/10.1109/CACML55074.2022.00054>
- M'ng, J. C. P. and Jean, A. H. J. (2014). The usefulness of a new technical indicator, rate of change–alpha (ROC- $\alpha$ ) on stock markets: a study of Malaysian top capitalization stocks. *Journal of Emerging Issues in Economics, Finance and Banking (JEIEFB) An Online International Research Journal (ISSN: 2306-367X) 2014 Vol: 3 Issue 3*.
- Mali Suçları Arařtırma Kurulu (MASAK). (2021, Mayıs, 4). *Kripto Varlık Hizmet Sağlayıcılar Rehberi*. <https://ms.hmb.gov.tr/uploads/sites/12/2021/05/Kripto-Varlik-Hizmet-Saglayicilar-Rehberi.pdf>
- Malik, S., Dedeoglu, V., Kanhere, S. S. And Jurdak, R. (2019). Trustchain: Trust management in blockchain and iot supported supply chains. *EEE International Conference on Blockchain (Blockchain)*, Atlanta, GA, USA, 2019, pp. 184-193, <https://doi.org/10.1109/Blockchain.2019.00032>
- Mallick, S. K. (2020). Causal relationship between Crypto currencies: An analytical study between bitcoin and binance Coin. *Journal of Contemporary Issues in Business and Government*, 2172.
- Mallqui, D. C. A. and Fernandes, R. A. S. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine

- learning techniques. *Applied Soft Computing*, 75, 596–606. <https://doi.org/10.1016/j.asoc.2018.11.038>
- Massey, J. L. (1988). "An introduction to contemporary cryptology," in *Proceedings of the IEEE*, vol. 76, no. 5, pp. 533-549, doi: 10.1109/5.4440.
- Mbedzi, T. A. (2022). Share Price Prediction for Increasing Market Efficiency using Random Forest (Doktora Tezi). University of Venda.
- Menéndez-García, L. A., García-Nieto, P. J., García-Gonzalo, E. and Sánchez Lasheras, F. (2024). Time series analysis for COMEX platinum spot price forecasting using SVM, MARS, MLP, VARMA and ARIMA models: A case study. *Resources Policy*, 95. <https://doi.org/10.1016/j.resourpol.2024.105148>
- Mittal, M. and Geetha, G. (2022). Predicting Bitcoin price using machine learning. *2022 International Conference on Computer Communication and Informatics (ICCCI)* (ss. 1–6). IEEE. <https://doi.org/10.1109/ICCCI54379.2022.9740772>
- Murugappan, M., Nair, R. and Krishnan, S. (2023). Global market perceptions of cryptocurrency and the use of cryptocurrency by consumers: a pilot study. *J. Theor. Appl. Electron. Commer. Res.* 2023, 18, 1955–1970. <https://doi.org/10.3390/jtaer18040098>
- Münyas, T. Ve Atasoy, F. (2021). *Sermaye piyasası temel ve teknik analiz yöntemleri*. Ekin Yayınevi.
- Nagula, P. K. and Alexakis, C. (2022). A new hybrid machine learning model for predicting the Bitcoin (BTC-USD) price. *Journal of Behavioral and Experimental Finance*, 36, 100741. <https://doi.org/10.1016/j.jbef.2022.100741>
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. <https://bitcoin.org/bitcoin.pdf>
- Nazlıoğlu, E. H. (2024). Ekonomik politika belirsizliği, turizm gelirleri ve döviz kuru arasındaki ilişki: türkiye örneği. *Yönetim Ve Ekonomi Dergisi*, 31(3), 477-490. <https://doi.org/10.18657/yonveek.1441935>
- Nyoni, T., 2019. ARIMA modeling and forecasting of consumer price index (CPI) in Germany. *MPRA Paper 92442, University Library of Munich, Germany*.
- Oğuz, R. F., Uygun, Y., Aktaş, M. S., and Aykurt, İ. (2019, April). On the use of technical analysis indicators for stock market price movement direction prediction. In *2019 27th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Omelchuk, O., Iliopol, I. and Alina, S. (2021). Features of inheritance of cryptocurrency assets. *Ius Humani, Revista de Derecho*, Vol. 10 (I), pp. 103-122. 10, 103. <https://doi.org/10.31207/ih.v10i1.233>
- Omole, O. and Enke, D. (2024). Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared. *Financial Innovation*, 10, 117. <https://doi.org/10.1186/s40854-024-00643-1>
- Özgür, A. S., Tarhan, Ç., Komesli, M. ve Tecim, V. (2023). Yapay Zeka Teknikleri Kullanılarak Proje Üretim Sistemlerinin Tasarımı ve Geliştirilmesi. *Journal of Information Systems and Management Research*, 5(1), 1-12.

- Penmetsa, S. and Vemula, M. (2023). Cryptocurrency price prediction with LSTM and transformer models leveraging momentum and volatility technical indicators. *2023 IEEE 3rd International Conference on Data Science and Computer Application (ICDSCA)*, 411–418. <https://doi.org/10.1109/ICDSCA59871.2023.10393319>
- Phaladisailoed, T. and Numnonda, T. (2018). Machine learning models comparison for Bitcoin price prediction. *2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE)* (ss. 1–6). IEEE. <https://doi.org/10.1109/ICITEED.2018.8534911>
- Polat, M. (2013). Altın fiyatını etkileyen faktörlerin zaman serisi analiziyle tespiti. *Yüksek Lisans Tezi, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü*.
- Poynton, A. (2022). Cryptocurrency Regulation: a slowly evolving state of affairs. Available at SSRN: <https://ssrn.com/abstract=4204063> or <http://dx.doi.org/10.2139/ssrn.4204063>
- Quirk, C. (2021). El Salvador's Bitcoin Law: Contemporary Implications of Forced Tender Legislation. *Princeton Legal Journal*, 1(3), 48-57
- Ranjan, S., Kayal, P. and Saraf, M. (2023). Bitcoin price prediction: A machine learning sample dimension approach. *Computational Economics*, 61(4), 1617–1636. <https://doi.org/10.1007/s10614-022-10262-6>
- Rathan, R., Reddy, M. V. and Reddy, S. K. (2019). Crypto-currency price prediction using decision tree and regression techniques. *2019 Third International Conference on Trends in Electronics and Informatics (ICOEI)* (ss. 938–942). IEEE. <https://doi.org/10.1109/ICOEI.2019.8862585>
- Sakız, B. ve Kutlugün, E. (2018). Bitcoin price forecast via blockchain technology and artificial intelligence algorithms. *2018 26th Signal Processing and Communications Applications Conference (SIU)* (ss. 1–4). IEEE. <https://doi.org/10.1109/SIU.2018.8404719>
- Salb, M., Elsadai, A., Živković, M. and Bačanin Džakula, N. (2021). Cryptocurrency forecasting using optimized support vector machine with sine cosine metaheuristics algorithm. In *Singidunum University International Scientific Conference*. (pp. 315-321). <https://doi.org/10.15308/Sinteza-2021-315-321>
- Schär, F. (2021). Decentralized finance: on blockchain and smart contract-based financial markets. *Review of the Federal Reserve Bank of St Louis*, 103(2), 153-174.
- Sermaye Piyasası Kanununda Değişiklik Yapılmasına Dair Kanun*. (Kanun No. 7518). Resmî Gazete No. 32590. 02 Temmuz 2024.
- Shahzad, M. F., Xu, S., Lim, W. M., Hasnain, M. F., & Nusrat, S. (2024). Cryptocurrency awareness, acceptance, and adoption: the role of trust as a cornerstone. *Humanities and Social Sciences Communications*, 11(1), 1-14. <https://doi.org/10.1057/s41599-023-02528-7>
- Somayajulu, M. V. N. S. S. R. K., Ahmed, M. ve Kotaiah, B. (2025). Bitcoin price prediction using LSTM and CNN. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.5190840>
- Subhani, M. I. 2009. Relationship between consumer price index (CPI) and government bonds. *MPRA Paper 36161, University Library of Munich, Germany*.

- Swan, M. (2015). Blockchain: Blueprint for a new economy. *O'Reilly Media, Inc. Sebastopol*.
- Şahin, E. E. (2020). Kripto para fiyatlarında balon varlığının tespiti: Bitcoin, IOTA ve Ripple örneği. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (43), 62-69.
- Taş, O. ve Kiani, F. (2018). Blok zinciri teknolojisine yapılan saldırılar üzerine bir inceleme. *Bilişim Teknolojileri Dergisi*, 11(4), 369-382. <https://doi.org/10.17671/gazibtd.451695>
- Tevetoğlu, M. (2021). Ethereum ve akıllı sözleşmeler. *İnönü Üniversitesi Hukuk Fakültesi Dergisi*, 12(1), 193-208. <https://doi.org/10.21492/inuhfd.852860>
- Tilborg, H. C. (2002). Fundamentals of cryptology: a professional reference and interactive tutorial. *Springer US*.
- Tuş, A., ve Adalı, E. A. (2018). CODAS ve PSI yöntemleri ile personel değerlendirmesi. *Alphanumeric Journal*, 6(2), 243-256.
- Türkiye Cumhuriyet Merkez Bankası (TCMB). (2021, Nisan, 16). *Ödemelerde kripto varlıkların kullanılmamasına dair yönetmelik*. Resmî Gazete No. 31456.
- Türkiye Cumhuriyet Merkez Bankası (TCMB). (2021, Nisan, 16). *Ödemeler alanına ilişkin basın duyurusu*. <http://bit.ly/44Icbts>
- Vejačka, M. (2014). Basic aspects of cryptocurrencies. *Journal of Economy, Business and Financing*, 2(2), 75-83.
- Wang, J., Wang, Y., Zhang, X., Jin, Z., Zhu, C., Li, L., ... and Lv, S. (2023). LearningChain: A highly scalable and applicable learning-based blockchain performance optimization framework. *IEEE Transactions on Network and Service Management*, 21(2), 1817-1831. <https://doi.org/10.1109/TNSM.2023.3347789>
- Xu, W., Hu, D., Lang, K. R. and Zhao, J. L. (2022). Blockchain and digital finance. *Financial Innovation*, 8(1), 97 (2022). <https://doi.org/10.1186/s40854-022-00420-y>
- Yaslıdağ, B. (2024). *Finansal yatırımlarda teknik analiz*. Seçkin Yayıncılık.
- Yavuz, U., Özen, Ü., Taş, K. ve Çağlar, B. (2020). Yapay sinir ağları ile blockchain verilerine dayalı bitcoin fiyat tahmini. *Journal of information systems and management research*, 2(1), 1-9.
- Yazdi, S. H. M. and Lashkari, Z. H. (2013). Technical analysis of Forex by MACD Indicator. *International Journal of Humanities and Management Sciences (IJHMS)*, 1(2), 159-165.
- Zhang, Y. J., & Yan, X. X. (2020). The impact of US economic policy uncertainty on WTI crude oil returns in different time and frequency domains. *International Review of Economics & Finance*, 69, 750-768. <https://doi.org/10.1016/j.iref.2020.04.001>
- Zhao, D., Rinaldo, A. And Brookins, C. (2019). Cryptocurrency price prediction and trading strategies using support vector machines. *1911.11819*, *arXiv.org*, <https://doi.org/10.48550/arXiv.1911.11819>

## ÖZ GEÇMİŞ

**Adı Soyadı** : Yunus Emre KORKMAZ  
**Yabancı Dil** : İngilizce  
**ORCID Numarası** :

### **Eğitim Bilgileri:**

- 2025, Anadolu Üniversitesi/Lisansüstü Eğitim Enstitüsü, İşletme ABD, Finansman Bilim Dalı Doktora Programı
- 2019, Kütahya Dumlupınar Üniversitesi/Sosyal Bilimler Enstitüsü, İşletme ABD, Pazarlama Bilim Dalı Tezli Yüksek Lisans Programı
- 2015, Manisa Celal Bayar Üniversitesi/UBYO, Bankacılık ve Finans Lisans Programı

### **Mesleki Deneyimi:**

- 2024 (devam eden), Şef, Posta ve Telgraf Teşkilatı Anonim Şirketi, Eskişehir PTT Başmüdürlüğü, 2 Eylül PTT Müdürlüğü
- 2019-2024, Gişe ve Büro Görevlisi, Posta ve Telgraf Teşkilatı Anonim Şirketi, Eskişehir PTT Başmüdürlüğü, 2 Eylül PTT Müdürlüğü