



T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

**KRİPTO PARA FİYATLARININ LSTM VE GRU MODELLERİ
İLE TAHMİNİ**

HAZIRLAYAN
Esranur DEMİRCİ
1930201009

YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Meltem KARAATLI

ISPARTA- 2021

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “**Kripto Para Fiyatlarının LSTM ve GRU Modelleri İle Tahmini**” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadar olan bütün süreçlerde bilimsel ahlâk ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim.

Esratur DEMİRCİ

01/04/2021



(DEMİRCİ, Esranur, *Kripto Para Fiyatlarının LSTM ve GRU Modelleri İle Tahmini*, Yüksek Lisans Tezi, Isparta, 2021)

ÖZET

Yakın geçmişte hayatımıza giren ve kısa zamanda finansal piyasalarda kendisine yer bulan kripto paralar, hem bir değişim aracı hem de bir yatırım aracı olarak kullanılmaktadır. Kripto para ticareti, artan bir işlem hacmine sahiptir. Piyasadaki yatırımcılar da kripto paraların kar potansiyeline inanmış olmalı ki her geçen gün işlemci sayısı da artmaktadır. Mart 2021 itibarıyla 35 binden fazla borsada 8 binden fazla kripto para işlem görmektedir. Gerçekleşen işlemlerin yaklaşık %60'ı piyasasının en popüler parası Bitcoin'de gerçekleşmektedir. Kripto paraların merkezi bir otoritenin kontrolünde olmaması bu araçların fiyatlarında dalgalanmaları beraberinde getirmiştir. Kripto para fiyatlarında gerçekleşen yüksek oynaklık bu araçların fiyatları ile ilgili gelecek tahmini yapmayı zorlaştırmaktadır. Bu nedenle, akıllı bir tahmin modelinin geliştirilmesi, yatırım yapılacak finansal varlıkların seçimi ve yatırım kararlarının hayata geçirilmesi açısından oldukça önemlidir. Böylelikle yatırımcıların potansiyel kârlarını arttırmalarına imkân sağlanacaktır.

Derin öğrenme ve yapay zeka, yatırım yapılacak olan kripto para birimi ve diğer yatırım araçlarının seçiminde kullanılmaktadır. Tekrarlayan Sinir Ağı (RNN), Uzun-Kısa Süreli Bellek (LSTM) ve Geçitli Yinelenen Birim (GRU) modeli gibi derin öğrenme modellerinin, kripto para birimi fiyat tahmininde geleneksel zaman serisi modellerinden daha iyi performans gösterdiği araştırmacılar tarafından kanıtlanmıştır. Bundan dolayı bu çalışmada, özel bir RNN yöntemi olan LSTM ve GRU'dan yararlanılarak, günümüzde piyasa değeri ve işlem hacmi en yüksek olan kripto paralardan Bitcoin, Ethereum ve Ripple'ın 30 günlük fiyat tahmininde bulunulmuştur. Araştırmanın sonucunda her iki modelde de en iyi tahmin sonucunu Bitcoin vermiştir. İkinci en iyi tahmin sonucu Ripple, sonrasında ise Ethereum için bulunmuştur. Kullanılan yöntemler karşılaştırıldığında ise MAPE performans ölçütüne göre en iyi tahmin sonucuna Bitcoin ve Ripple için GRU, Ethereum için ise LSTM modeli ile ulaşılmıştır.

Anahtar kelimeler: Kripto Para, Bitcoin, Ethereum, Ripple, Derin Öğrenme, RNN, LSTM, GRU, Tahmin.

ABSTRACT

Cryptocurrencies, which entered our lives in the recent past and soon found a place in financial markets, are used both as an exchange tool and an investment tool. Cryptocurrency trading has an increasing transaction volume. Investors in the market must have believed in the profit potential of crypto money, as the number of processors is increasing day by day. As of March 2021, more than 8 thousand cryptocurrencies are traded in more than 35 thousand exchanges. Approximately 60% of the transactions are carried out in Bitcoin, the most popular currency in the market. The fact that cryptocurrencies are not under the control of a central authority has brought fluctuations in the prices of these instruments. High volatility in crypto currency prices makes it difficult to predict the prices of these instruments. Therefore, developing a smart prediction model is very important in terms of choosing the financial assets to be invested and realizing investment decisions. This will enable investors to increase their potential profits.

Deep learning and artificial intelligence are used in the selection of cryptocurrency and other investment instruments to be invested. Deep learning models such as the Recurrent Neural Network (RNN), Long-Short Term Memory (LSTM) and the Gated Repeating Unit (GRU) model have been proven by researchers to outperform traditional time series models in cryptocurrency price prediction. For this reason, in this study, a 30-day price estimate of Bitcoin, Ethereum and Ripple, which are the crypto currencies with the highest market value and transaction volume, has been made using LSTM and GRU, a special RNN method. As a result of the research, Bitcoin gave the best prediction result in both models. The second best prediction result was found for Ripple, then Ethereum. When the methods used were compared, the best estimation result was reached with the GRU model for Bitcoin and Ripple, and the LSTM model for Ethereum, according to the MAPE performance criterion.

Keywords: Crypto-Currency, Bitcoin, Ethereum, Ripple, Deep Learning, RNN, LSTM, GRU, Predict.

ÖNSÖZ

Yüksek lisans eğitimim de ve tez çalışmam boyunca düşünceleri, yardımları ve sözleri ile her daim yanımda olan ve araştırma sürecim boyunca bana destek olup bilimsel görüş ve önerilerini benimle paylaşan sayın danışman hocam Doç. Dr. Meltem KARAATLI'ya çok teşekkür ederim.

Araştırmada, analizleri seçmemde öneride bulunan, analizleri yaparken her zaman yanımda olup yardım eden ve bilimsel desteğini hiçbir zaman esirgemeyen sayın Prof. Dr. Ecir Uğur KÜÇÜKSİLLE hocama; konuyu seçmem de yardımcı olan, araştırma süresince her fırsatta bana vakit ayıran, yardım ve önerilerini hiçbir zaman esirgemeyen sayın Doç. Dr. Turan KOCABIYIK hocama çok teşekkür ederim.

Ayrıca eğitim hayatım süresince her zaman yanımda olup bana yardım eden ve manevi desteğini hiçbir zaman esirgemeyen başta değerli aileme ve bu süreçte bizzat yanımda olup motive edici tüm duygularını bana aktaran sevgili arkadaşım Mehmet ÇELİK'e, Nermin SALÇIN'a ve Hatice Tuğba YILDIRIM'a en içten duygularıyla teşekkür ederim.

Esranur DEMİRCİ
ISPARTA, 2021

İÇİNDEKİLER

YEMİN METNİ	i
ÖZET.....	ii
ABSTRACT	iii
ÖNSÖZ.....	iv
TABLO DİZİNİ.....	ix
ŞEKİLLER DİZİNİ	xi
GRAFİKLER	xiii
KISALTMALAR DİZİNİ	xv
GİRİŞ	1

BİRİNCİ BÖLÜM KRİPTO PARALAR

1.1. KRİPTO PARA KAVRAMI	4
1.2. KRİPTO PARANIN DOĞUŞU VE GELİŞİMİ.....	5
1.3. KRİPTO PARALAR NASIL ÇALIŞIR	7
1.4. KRİPTO PARA YAPILARI	8
1.5. KRİPTO PARANIN TEKNOLOJİK ARKA PLANI	10
1.5.1. Kriptolojik Özet Fonksiyonu (Hash Function).....	11
1.5.2. Dijital İmza.....	12
1.5.3. Bitcoin Adresi.....	15
1.5.4. İş İspatı (Proof of Works).....	15
1.6. KRİPTO PARA MADENCİLİĞİ	16
1.7. SANAL PARANIN SINIFLANDIRILMASI.....	17
1.8. BAŞLICA KRİPTO PARALAR VE ÖZELLİKLERİ.....	19
1.8.1. Bitcoin (BTC).....	20
1.8.2. Ethereum (ETH)	21
1.8.3. Ripple (XRP).....	23
1.8.4. Tether (USDT)	24
1.8.5. Bitcoin Cash (BCH)	26
1.9. BLOK ZİNCİRİ (BLOCKCHAIN).....	27
1.9.1. Blok Zincirinin Kullanım Alanları (Uses Cases for Blockchain Technology) 31	

1.9.2. Blok Zinciri Teknolojisinin Geleceği (Future of Blockchain Technology)	34
1.10. KRİPTO PARALAR VE FİNANSAL PİYASALAR ARASINDAKİ İLİŞKİ.....	35
1.10.1. Kripto Paraların Avantajları ve Dezavantajları	36
1.10.2. Kripto Paraların Geleceği.....	38
1.10.2.1. Geçmişten Bugüne Bitcoin'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları	40
1.10.2.2. Geçmişten Bugüne Ethereum'un Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları	41
1.10.2.3. Geçmişten Bugüne Ripple (XRP'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları	42
1.10.2.4. Geçmişten Bugüne Tether (USDT)'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları.....	43
1.10.2.5. Geçmişten Bugüne Bitcoin Cash (BCH)'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları	44

İKİNCİ BÖLÜM

YAPAY ZEKA VE DERİN ÖĞRENME

2.1 YAPAY ZEKA (ARTIFICIAL INTELLIGENCE).....	46
2.1.1. Yapay Zekanın Amacı ve Avantajları	47
2.1.2. Yapay Zeka Türleri	48
2.2. DERİN ÖĞRENME (DEEP LEARNING).....	49
2.3. DERİN ÖĞRENMENİN TEMEL KAVRAMLARI	51
2.3.1. Nöron.....	52
2.3.2. Ağırlıklar	53
2.3.3. Sapma (BIAS)	53
2.3.4. Aktivasyon Fonksiyonları	54
2.3.5. Sinir Ağı	55
2.3.6. Sinir Ağı Katmanları	56
2.4. DERİN ÖĞRENMENİN TEMELLERİ	56
2.4.1. Makine Öğrenmesi	57
2.4.2. Makine Öğrenmesi Türleri	57
2.5. DERİN ÖĞRENME KÜTÜPHANELERİ VE YAZILIMLARI.....	58

2.6. DERİN ÖĞRENME MİMARİLERİ.....	61
2.6.1. Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN)	62
2.6.2. Uzun-Kısa Süreli Hafıza (Long-Short Term Memory-LSTM) Ağları.....	65
2.6.3. Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU).....	67
2.7. LİTERATÜR TARAMASI	70

ÜÇÜNCÜ BÖLÜM

UYGULAMA

3.1. ARAŞTIRMANIN AMACI.....	77
3.2. ARAŞTIRMADA KULLANILAN DEĞİŞKENLER VE VERİ SETİ	77
3.2.1. Euro/Dolar Paritesi	78
3.2.2. Altın Spot Amerikan Doları (Altının USD Bazında Ons Fiyatı)	79
3.2.3. 12 Aylık Londra Bankalararası Faiz Oranı (LIBOR).....	80
3.2.4. Ham Petrol WTI Vadeli İşlem Fiyatı	81
3.2.5. S&P 500 Endeksi.....	82
3.2.6. Twitter Tabanlı Ekonomik Belirsizlik Endeksi.....	83
3.2.7. Jeopolitik Risk Endeksi	85
3.2.8. Ekonomik Politika Belirsizliği Endeksi	86
3.2.9. ABD Finansal Krizler Endeksi	87
3.2.10. Kripto Para Piyasasında Gerçekleşen İşlem Hacimleri (24h Volume)	89
3.2.11. Kripto Paraların Para Arzı (Supply, Free Float).....	90
3.2.12. Kripto Paraların Günlük Kapanış Fiyatları (Price/USD)	91
3.3. ARAŞTIRMA İÇİN YAPILAN HAZIRLIKLAR.....	92
3.4. EĞİTİMDE KULLANILAN ARAÇLAR.....	94
3.5. ARAŞTIRMADA KULLANILAN PERFORMANS ÖLÇÜTLERİ.....	96
3.6. ANALİZ VE BULGULAR.....	98
3.6.1. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Modelinin Eğitimi ve Testi... 98	
3.6.2. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Modeli ile Tahmin Sonuçlarının Elde Edilmesi	99
3.6.2.1. Bitcoin Günlük Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Model Tahmini.....	99

3.6.2.2. Ethereum Günlük Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Model Tahmini.....	102
3.6.2.3. Ripple Günlük Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Model Tahmini.....	106
3.6.3. Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Modeli ile Tahmin Sonuçlarının Elde Edilmesi.....	109
3.6.3.1. Bitcoin Günlük Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Model Tahmini.....	109
3.6.3.2. Ethereum Günlük Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Model Tahmini.....	113
3.6.3.3. Ripple Günlük Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Model Tahmini.....	116
3.6.4. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Modellerinin Tahmin Sonuçlarının Karşılaştırılması	119
SONUÇ VE DEĞERLENDİRME	121
KAYNAKÇA	124
ÖZGEÇMİŞ.....	138

TABLO DİZİNİ

Tablo 1. 04.11.2020'de Piyasada En Çok İşlem Gören 10 Kripto Para	19
Tablo 2. 2017 Yılı En Büyük 10 ICO Projesi (Top 10 ICO Projects of 2017)	31
Tablo 3. Aktivasyon Fonksiyonlarının Başarı Oranları	54
Tablo 4. Aktivasyon Fonksiyonlarının Matematiksel İfadeleri.....	55
Tablo 5. Derin Öğrenme Kütüphaneleri	60
Tablo 6. Kütüphanelerin Çalışma Zamanı Performansının Karşılaştırılması	61
Tablo 7. Kripto Paraların Tahmininde Kullanılan Derin Öğrenme Yöntemlerinin İncelendiği Çalışmalar	71
Tablo 8. Çalışmada Kullanılan Değişkenlerin İncelendiği Çalışmalar	73
Tablo 9. Çalışmada Kullanılan Değişkenler ve Veri Tabanları	78
Tablo 10. Araştırmada Kullanılan Kripto Paralar İçin Ayrılan Eğitim ve Test Sayıları	99
Tablo 11. LSTM Modelinde Bitcoin Eğitim ve Test Verilerinin Performans Ölçüt Değerleri	100
Tablo 12. LSTM En İyi Modeli İçin Bitcoin Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri	100
Tablo 13. LSTM Modelinde Ethereum Eğitim ve Test Verilerinin Performans Ölçüt Değerleri	103
Tablo 14. LSTM En İyi Modeli için Ethereum Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri.....	104
Tablo 15. LSTM Modelinde Ripple Eğitim ve Test Verilerinin Performans Ölçüt Değerleri	106
Tablo 16. LSTM En İyi Modeli için Ripple Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri	107
Tablo 17. GRU Modelinde Bitcoin Eğitim ve Test Verilerinin Performans Ölçüt Değerleri	110
Tablo 18. GRU En İyi Modeli İçin Bitcoin Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri	111
Tablo 19. GRU Modelinde Ethereum Eğitim ve Test Verilerinin Performans Ölçüt Değerleri	113

Tablo 20. GRU En İyi Modeli İçin Ethereum Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri.....	114
Tablo 21. GRU Modelinde Ripple Eğitim ve Test Verilerinin Performans Ölçüt Değerleri	116
Tablo 22. GRU En İyi Modeli İçin Ripple Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri	117
Tablo 23. LSTM ve GRU Modellerinin Performans Ölçüt Değerlerinin Karşılaştırılması.....	120



ŞEKİLLER DİZİNİ

Şekil 1. Kripto Paraların Çalışma Şekli (Rosic, 2016)	8
Şekil 2. Merkezi Ağ (Centralized), Merkezi Olmayan Ağ (Decentralized) ve Dağıtılmış Ağ (Distributed) Yapıları (Pisa ve Juden, 2017, s. 7)	9
Şekil 3. Geleneksel Veri Tabanı Örneği (UBS, 2017).....	10
Şekil 4. Blok Zincir Veri Tabanı Örneği (UBS, 2017).....	10
Şekil 5. Örnek SHA_256 Sistemi (Coinkazanma, 2018).....	12
Şekil 6. Dijital İmzalama Örneği (Ömrüuzun, 2019, s. 32).....	14
Şekil 7. İmza Doğrulama Örneği (Ömrüuzun, 2019, s. 33).....	14
Şekil 8. Sanal Para Birimi Türleri Şeması (European Central Bank, 2012, s. 15)	19
Şekil 9. Blok Zinciri Çalışma Mantığı (Crosby vd., 2016).....	28
Şekil 10. Sunucu Tabanlı Ağ ve Eşten Eşe Ağ Yapısı (CIS 3347 Cruz Guzman, 2020)	29
Şekil 11. Hype Cycle for Emerging Technologies, 2016 (Gartner, 2016)	35
Şekil 12. Yapay Zeka Tanımlamaları ve Sınıflandırılması (Russell ve Norvig, 1995)	47
Şekil 13. Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi (IEEE, 2020)	49
Şekil 14. Derin Öğrenme Yöntemlerinin Sınıflandırılması (Aminanto ve Kim, 2016, s. 4).....	51
Şekil 15. Bir Sinir Hücresinin Biyolojik Yapısı (Kızrak, 2018).....	52
Şekil 16. İnsandaki Bir Sinir Hücresinin Matematiksel Modeli (Kızrak, 2018)	52
Şekil 17. Yapay Sinir Ağının Temel Öğeleri (Zafari vd., 2013, s. 2).....	53
Şekil 18. Tek Gizli Katmanlı ve Çok Katmanlı Sinir Ağı Yapısı (Kızrak, 2018)	56
Şekil 19. Tekrarlayan Sinir Ağlarının Döngüleri (Colah's Blog, 2015).....	62
Şekil 20. RNN'e Ait Çoklu Döngüler Yapısı (Colah's Blog, 2015)	63
Şekil 21. Tekrarlayan Sinir Ağları (Recurrent Neural Networks) (RNN) Mimarisi (Spirina, 2018)	63
Şekil 22. Bir Gecikme Hattına Sahip Normal Tek Yönlü bir RNN'nin Genel Yapısı (Schuster ve Paliwal, 1997, s. 2674)	64
Şekil 23. RNN'de Tek Katmanlı Tekrarlayan Ağ Yapısı (Colah's Blog, 2015)	65

Şekil 24. Tek Modül İçerisinde 4 Katmana Sahip Bir LSTM Nöral Ağı (Colah's Blog, 2015).....	66
Şekil 25. Diyagramın Üstünden Yatay Çizgi Şeklinde Geçen LSTM Anahtarı (Colah's Blog, 2015)	67
Şekil 26. LSTM'de Bulunan Sigmoid Katmanı (Colah's Blog, 2015).....	67
Şekil 27. GRU ve LSTM'a Ait Kapılar (Gates) (Phi, 2018)	68
Şekil 28. Geçitli Tekrarlayan Birim (GRU) ile Tekrarlayan Sinir Ağı (RNN) (Kostadinov, 2017)	69
Şekil 29. Geçitli Tekrarlayan Birim (GRU) in Ayrıntılı Yapısı (Kostadinov, 2017)	70
Şekil 30. Geçitli Tekrarlayan Birim (GRU) e Ait Notasyonlar (Kostadinov, 2017) .	70



GRAFİKLER

Grafik 1. Ekim 2020 İtibari ile Dünya Genelinde Seçili Ülkelerdeki Bitcoin ATM Sayısı (Statista, 2020).....	6
Grafik 2. 2010-2020 Yılları Arası Madencilerin Toplam İşlem Ücretleri (USD) (Blockchain, 2020)	17
Grafik 3. 29.04.2013-12.11.2020 Dönemi Günlük Bitcoin (BTC) Değişimi (CoinMarketCap, 2020).....	41
Grafik 4. 08.08.2015-12.11.2020 Dönemi Günlük Ethereum (ETH) Değişimi (CoinMarketCap, 2020).....	42
Grafik 5. 05.08.2015-12.11.2020 Dönemi Günlük Pipple (XRP) Değişimi (CoinMarketCap, 2020).....	43
Grafik 6. 07.08.2015-12.11.2020 Dönemi Günlük Tether (USDT) Değişimi (CoinMarketCap, 2020).....	44
Grafik 7. 24.07.2017-12.11.2020 Dönemi Günlük Bitcoin Cash (BCH) Değişimi (CoinMarketCap, 2020).....	45
Grafik 8. 27.12.2013-15.09.2020 Dönemi Euro/Dolar Paritesi Grafiği	79
Grafik 9. 27.12.2013-15.09.2020 Dönemi Altın Spot Amerikan Doları (Altının USD Bazında Ons Fiyatı) Grafiği	80
Grafik 10. 27.12.2013-15.09.2020 Dönemi 12 Aylık LIBOR Grafiği	81
Grafik 11. 27.12.2013-15.09.2020 Dönemi Ham Petrol WTI Vadeli İşlem Fiyatları Grafiği.....	82
Grafik 12. 27.12.2013-15.09.2020 Dönemi S&P 500 Endeksi İşlemleri Grafiği.....	83
Grafik 13. 27.12.2013-15.09.2020 Dönemi Twitter Tabanlı Ekonomik Belirsizlik Endeksi Grafiği.....	84
Grafik 14. 12.2013-09.2020 Dönemi Jeopolitik Risk Endeksi Grafiği	86
Grafik 15. 12.2013-09.2020 Dönemi Ekonomik Politika Belirsizliği Endeksi Grafiği	87
Grafik 16. 12.2013-09.2020 Dönemi ABD Finansal Krizler Endeksi Grafiği	88
Grafik 17. 01.08.2017-15.09.2020 Dönemi Kripto Para Piyasasında Gerçekleşen İşlem Hacim (24h Volume) Grafikleri	90
Grafik 18. 01.08.2017-15.09.2020 Dönemi Kripto Paraların Para Arzı (Supply, Free Float) Grafikleri.....	91

Grafik 19. 01.08.2017-15.09.2020 Dönemi Kripto Paraların Günlük Kapanış Fiyatı (Price/USD) Grafikleri	92
Grafik 20. LSTM En İyi Modeli İçin Bitcoin Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	101
Grafik 21. LSTM En İyi Modeli İçin Bitcoin Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	102
Grafik 22. LSTM En İyi Modeli İçin Ethereum Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması	105
Grafik 23. LSTM En İyi Modeli İçin Ethereum Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	105
Grafik 24. LSTM En İyi Modeli için Ripple Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	108
Grafik 25. LSTM En İyi Modeli için Ripple Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	108
Grafik 26. GRU En İyi Modeli için Bitcoin Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	112
Grafik 27. GRU En İyi Modeli için Bitcoin Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	112
Grafik 28. GRU En İyi Modeli için Ethereum Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	115
Grafik 29. GRU En İyi Modeli için Ethereum Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	115
Grafik 30. GRU En İyi Modeli için Ripple Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	118
Grafik 31. GRU En İyi Modeli için Ripple Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması.....	118

KISALTMALAR DİZİNİ

- ABD:** Amerika Birleşik Devletleri
- ADA:** Cardano
- ANFIS:** Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi
- ASIC:** Uygulamaya Özel Tümüleşik Devre (Application-Specific Integrated Circuit)
- BCH:** Bitcoin Cash
- BEKK:** Yarı Maksimum Olabilirlik
- BNB:** Binance Coin
- BTC:** Bitcoin
- CPU:** Merkezi İşlem Birimi (Central Processing Unit)
- DNN:** Derin Sinir Ağları
- DOT:** Polkadot
- ECB:** Avrupa Merkez Bankası
- EMV:** Equity Market Volatility
- ETH:** Ethereum
- FAVAR:** Faktör Arttırımlı Vektör Otoregresyon (Factor-Augmented Vector Autoregression Model)
- FED:** Merkez Bankaları Sistemi (Federal Reserve System)
- GJR:** Glosten-Jagannathan-Runkle
- GPU:** Grafik İşleme Birimi (Graphics Processing Unit)
- GRNN:** Generalized Regression Neural Networks
- GRU:** Geçitli Tekrarlayan Birim (Gated Recurrent Unit)
- LIBOR:** Londra Bankalararası Faiz Oranı (London Interbank Offered Rate)
- LINK:** Chainlink
- LSTM:** Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory)
- LTC:** Litecoin
- MAE:** Ortalama Mutlak Hata (Mean Absolute Error)
- MAPE:** Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
- MGARCH:** Çok Değişkenli (Multivariate) GARCH
- MLP:** Çok katmanlı algılayıcılar (Multi-Layer Perceptron)
- MSE:** Ortalama Hata Kareleri (Mean Square Error)
- OLS:** En Küçük Kareler Yöntemi
- PBFT:** Practical Byzantine Fault Tolerance
- P2P:** Peer-to-Peer

ResNet: Derin Artık Ağları
RMSE: Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error)
RNN: Tekrarlayan Sinir Ağı (Recurrent Neural Networks)
RTGS: Gerçek Zamanlı Bir Brüt Ödeme Sistemi
SHA-256: Secure Hash Algorithm
S&P 500: Standard & Poor's 500
SWIFT: Dünya Bankalar Arası Finansal Telekomünikasyon Derneği Transferi (Society for Worldwide Interbank Financial Telecommunication)
TDNN: Zaman Gecikmeli Sinir Ağı (Time Delay Neural Network)
TEU: Twitter Tabanlı Ekonomik Belirsizlik
TMU: Twitter Tabanlı Yeni Bir Pazar Belirsizliği
TPU: Tensor İşleme Birimi (Tensor Processing Unit)
USD: United States Dollar (Birleşik Devletler (Amerika) Doları)
USDT: Tether
WTI: Western Texas Intermediate
XRP: Ripple
VAR: Vektör Otoregresyon Model (Vector Autoregression Model)
YSA: Yapay Sinir Ağları

GİRİŞ

Gün geçtikçe insan ihtiyaçları artmakta buna bağılı olarak da artan insan ihtiyacını karşılamak ve yaşamı daha kolay bir hale getirmek amacıyla yeni teknolojik gelişmelere ihtiyaç duyulmaktadır. Teknolojide gerçekleşen bu hızlı deęişim hayatın her alanında kendini göstermeye devam etmektedir. Finansal sistemde yapılan teknolojik gelişmeler de bunlardan biridir. Bu küreselleşme çağında, modern bir yatırım aracı ve alternatif bir ödeme yöntemi olarak ise kripto para birimleri yaratılmıştır.

Birçok yatırımcı şu anda kripto para birimlerini, yeni ortaya çıkan bir varlık sınıfı yani deęeri depolamak için bir araç olarak görmektedir (Indera vd., 2017, s. 792). Bu, büyük ölçüde deęişen kripto para birimlerinin piyasa deęerlerinde de görülmektedir. 6 Mart 2021 tarihi itibarıyla piyasa deęeri en yüksek olan ilk beş kripto para birimi Bitcoin (BTC, 904,38B USD), Ethereum (ETH, 180,93B USD), Tether (USDT, 36,43B USD), Cardano (ADA, 36,15B USD) ve Binance Coin (BNB, 35,09B USD)'dir (Investing.com, 2021). Yatırımcı sayısı arttıkça bu liste sürekli olarak deęişmektedir. Kripto para biriminin şu anki lideri ise, ilk kez toplu kullanım için tanıtılmış orijinal kripto para birimi olan Bitcoin'dir (Indera, vd., 2017, s. 792).

Ulusal Ekonomik Araştırma Bürosu'na göre, 2007-2009 küresel mali krizi son birkaç on yıldaki en şiddetli krizdir. Sonuçları ise, ekonomik (yatırım, üretkenlik, işler ve gerçek gelir) ve sosyal (eşitsizlik, yoksulluk ve sosyal gerilimler) olmak üzere hayatın çoęu alanında şiddetini göstermiş ve uzun vadede siyasi istikrarsızlığa ve daha fazla ekonomik reform ihtiyacına yol açmıştır. Hükümetleri ve finansal kurumların manipölasyonunu ve kontrolünü atlamak için 2008 yılında Satoshi Nakamoto (asıl ismi bilinmeyen kişi ya da grup) tarafından yayınlanan "Bitcoin: A Peer-to-Peer Electronic Cash System (P2P, uçtan uca)" başlıklı bir makale ile kripto para olan Bitcoin ortaya çıkmıştır (Nakamoto, 2008, Livieris vd., 2020, s. 1).

Çetinkaya (2018, s. 16) yaptığı çalışmada Bitcoin ve dięer kripto para birimlerinin, geleneksel finansal sistemleri için yıkıcı bir teknoloji olma potansiyeline sahip olabileceğini belirtmiştir. Çünkü blok zinciri teknolojisi, bankacılık sektörünün ve para otoritelerinin finansal işlemlere katılımını etkin bir şekilde ortadan kaldırmaktadır. Buna ek olarak, düşük işlem maliyeti, sınırlı arzı, ulusal para birimlerinde meydana gelen dalgalanmalara karşı korunacak bir alan

olarak görülmesi ve eyalet sınırlarının ötesine kolayca değer aktarabilme yeteneği Bitcoin'in son yıllarda başarısının hızla artmasını ve daha fazla kullanılmasını sağlamıştır. 2015 yılında, Bitcoin'in piyasa değerinin yaklaşık 7 milyar ABD doları olduğu ve günlük 60 milyon ABD doları değerinde değiştiği tahmin ediliyordu (Hayes, 2017, s. 1309). Günümüzde ise şimdiye kadar üretilen Bitcoin'lerin toplam değeri günlük 11 milyar dolar artış ile 1 trilyon dolara kadar yükselmiştir (Güven, 2020).

Kripto paraların doğasında var olan bir değeri yoktur. Bu değeri belirleyen insan, piyasadaki arz ve talep koşullarıdır. Dolayısıyla piyasada dolaşan sınırlı sayıda kripto para bulunmaktadır. Kripto paraların prosedürü ve limiti öncesinde belirlendiği için, talep arza göre daha yüksek bir artış gösterirse kripto paraların değerinde de artış olmaktadır (Melih Güney, 2020). Bununla birlikte kripto paraları etkileyen birçok faktör bulunmaktadır. Bunlardan biri de sosyal medyanın kripto paralar üzerindeki etkisidir. Bilgiye ulaşılmasını ve bilginin oluşturulmasını sağlayan her türlü görsel, işitsel basılı ve yazılı araçlar "Bilgi ve İletişim Teknolojileri" adı altında yer almaktadır. Günümüzde bu teknolojinin yatay hiyerarşisi her kesimden insanı bir platform altında toplayan uluslararası bir kripto para borsasını oluşturmuştur. Bu borsalar uzun süredir hizmet vermekte olan çok daha büyük borsalarla yarışabilecek milyarlar dolarlık işlem hacmine gelmiştir. Kripto para fiyatlarının düşmesi ve yükselmesini takip etmek isteyen kurum ve kişiler sosyal medyanın her türlü mecrasından yararlanabilmekte, bu da küçük veya büyük çaplı her türlü yatırım ve yatırımcıya büyük bir bilgi kaynağı olarak yol göstermektedir (Polat ve Akbıyık, 2019, s. 446). Kripto paraların sosyal medyada daha sık yer alması ise, bu dijital paraların çok daha fazla tanınmasını sağlamaktadır. Dolayısıyla bu durumda kripto paraların daha fazla talep almasına yol açmıştır (Sistemkoin, 2020).

Kripto paraların çıktığı ilk yıllarda, sahip olduğu endüstri dış etkenlere bağlı hareket etmiyor, yani küresel piyasada meydana gelen gelişmeler kripto paralar üzerinde çok fazla bir etkiye sahip olmuyordu. Fakat son yıllarda merkez bankaları tarafından basılan ve devletlerin kullandıkları geleneksel paranın kripto para ile uyum içine girmeye başlaması bu durumu değiştirmiştir. Günümüze yaklaştıkça geleneksel piyasa yapısına etki eden siyasi ve ekonomik gelişmeler aynı zamanda

kripto para sektörünü de etkilenmeye başlamıştır. Herhangi bir ülkenin ekonomisine bağlı olmayan kripto paraların, özellikle piyasa değeri en yüksek olan Bitcoin'in, Çin ve ABD gibi ülkelerde meydana gelen siyasi ve ekonomik olaylarından fazlasıyla etkilendiği, fiyat değişiminde geleneksel varlıklar gibi davrandığı gözlemlenebilmektedir (Sistemkoin, 2020).

Bu çalışmanın amacı, günümüzde giderek popülaritesi artan ve insanlar tarafından alternatif bir yatırım aracı ve ödeme yöntemi olarak görülen kripto paraların bir derin öğrenme modeli olan Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) ile fiyat tahmininde bulunmaktır.

Bu tez çalışması üç bölümden oluşmaktadır. Birinci bölümde, günümüzde önemli bir yatırım aracı olan kripto paraların temel yapısı ve özellikleri üzerinde durularak işleyişi anlatılmıştır. Ayrıca Ekim 2020 itibarıyla işlem hacmi ve piyasa hacmi en yüksek olan beş kripto para birimi ayrıntılı bir şekilde detaylandırılmış, kripto paraların geleceğine, avantaj ve dezavantajlarına değinilmiştir.

Çalışmanın ikinci bölümünde yapay zekayı oluşturan makine öğrenmesi ve derin öğrenme yöntemlerine değinilmiş ve çalışmada kullanılan “Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM)” ve “Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU)” modelleri üzerinde durulmuştur.

Çalışmanın üçüncü bölümü olan uygulama kısmında ise Ekim 2020 itibarıyla günümüzde işlem ve piyasa hacmi en yüksek olan kripto paralardan, Bitcoin, Ethereum ve Ripple dijital para birimlerinin günlük fiyat tahmininde bulunulmuştur. Uygulamada kullanılan analizler kıyaslanarak hangi analizin daha sağlıklı sonuçlar verdiği tespit edilmiştir.

BİRİNCİ BÖLÜM

KRİPTO PARALAR

1.1. KRİPTO PARA KAVRAMI

21. yüzyılda meydana gelen bilgi teknolojilerindeki hızlı gelişim güncel finansal yapıların da oluşmasına neden olmuştur. Bu finansal yeniliklerden en dikkat çekicisi ve en popülerleri şüphesiz ki bir sanal para birimi olan kripto paralardır. Bunun en büyük nedeni ise geleneksel para birimlerine göre işlem hızının daha yüksek oluşu ve herhangi bir kuruma ya da merkeze bağlı olmayışıdır. Son yıllarda kripto paranın kullanımını ve kullanım alanları giderek artış göstermiştir (Inshyn vd, 2018, s. 170).

Kripto paranın temeli “crypto” ve “currency” kelimelerinin birleşmesi ile oluşturulmuş olan “cryptocurrency” kelimesine dayanmaktadır. Kripto “şifreli” anlamına gelmektedir. Kripto para, internet aracılığı ile kullanılabilen, herhangi bir merkezi otoriteye ya da kuruma bağlı olmayan bir sanal para birimi olarak ifade edilmektedir. Kripto paraların temeli adının da temelini oluşturan “şifreli” kelimesine dayanmaktadır. Kripto paralar belirli şifrelerden faydalanılarak yerleştirildiği sanal cüzdanlardan sadece o şifreler aracılığıyla çıkarılabilmektedir (Kahya, 2020). Şu an piyasada 7 binden fazla kripto çeşidi bulunmaktadır (CoinMarketCap, 2020).

Kripto paraların oluşum amacı diğer para birimlerinden farklı olarak dijital bilgi alışverişini sağlamaktır. Fung vd., (2014) yaptıkları bir çalışmaya göre kripto paraları herhangi bir merkeze bağlı olmayan elektronik paralar olarak tanımlamışlardır. Ancak bu tanımı daha net bir şekilde açıklamak gerekirse; elektronik ortamda üretilebilen, merkezi bir otoriteye bağlı olmayan, kimin tarafından ihraç edildiği bilinmeyen ve herhangi bir seyre karşı duyarlı olmayan dijital paralar olarak nitelendirilmektedir (Fung vd., 2014).

Kripto paraların temeli kendine özgün ve resmi bir dayanağı olan işlemleri gerçekleştirmek amacıyla kriptografik algoritmaları kullanarak dijital bilgilerin iletilmesine dayanmaktadır. Kripto paraların bu özelliği, geleneksel para birimlerinden üstünlük sağlayarak merkeziyetçilikten uzaklaşmasını sağlamaktadır. Kripto paralar özellikle 2011 yılından sonra fazlasıyla ilgi görmeye başlamış ve ilk

kripto para olan Bitcoin'in ardından birçok kripto para da ortaya çıkmıştır (Farell, 2015).

1.2. KRİPTO PARANIN DOĞUŞU VE GELİŞİMİ


İlk kripto para olan Bitcoin, 31 Ekim 2008 tarihinde Satoshi Nakamoto (asıl ismi bilinmeyen kişi ya da grup) tarafından yayınlanan "Bitcoin: A Peer-to-Peer Electronic Cash System (P2P, uçtan uca)" başlıklı bir makale ile ortaya çıkmıştır (Nakamoto, 2008). Yazılan bu makalede Bitcoin özelliklerini şu şekilde aktarmıştır;

- ✓ Güvenilir bir üçüncü şahıs olmadan işlem yapabilme,
- ✓ Geri alınamayan işlemleri sağlama
- ✓ Yapılan küçük işlemlerde maliyeti ve işlem masraflarını azaltma
- ✓ Çift harcama sorununun önüne geçme (Aynı parayla iki veya daha fazla işlem yapılması).

Yayınlanan bu makaleden sonra gündeme gelen tartışmaların ardından 2009 ocak ayında ilk blok oluşturulmuş böylece blok zinciri sistemi ile Bitcoin işlemlerine başlanmıştır.

Grafik 1'de, 6 Ekim 2020 itibarıyla dünya çapında seçilen ülkelerdeki Bitcoin ATM sayısını göstermektedir. O gün itibarıyla, Amerika Birleşik Devletleri'nde 8279 Bitcoin ATM'si bulunmaktadır (Statista, 2020).

Grafik 1. Ekim 2020 İtibari ile Dünya Geneline Seçili Ülkelerdeki Bitcoin ATM Sayısı (Statista, 2020)



Şubat 2017'de dünya çapında 986 Bitcoin ATM'si bulunmaktaydı. Şubat 2020'de sayıları 6674'e çıkmıştır. En fazla Bitcoin ATM sayısı 2020'de Amerika Birleşik Devletleri'nde kaydedilmiş olup onu Kanada, İngiltere ve Avusturya izlemiştir. Toplamda, küresel ATM'lerin yüzde 74'ünden fazlası Kuzey Amerika'da yoğunlaşmaktadır (Statista, 2020).

İki ana Bitcoin ATM türü vardır: Temel olanlar, kullanıcıların yalnızca Bitcoin satın almalarına izin vermektedir. Daha karmaşık olanlar ise, kullanıcıların sanal parayı hem alıp hem satmalarına olanak sağlamaktadır. Karmaşık ATM'ler olması durumunda, ATM'yi yalnızca belirli bir ATM üreticisinin üyeleri kullanabilmektedir. Haziran 2019 itibarıyla General Bytes, dünya çapında lider

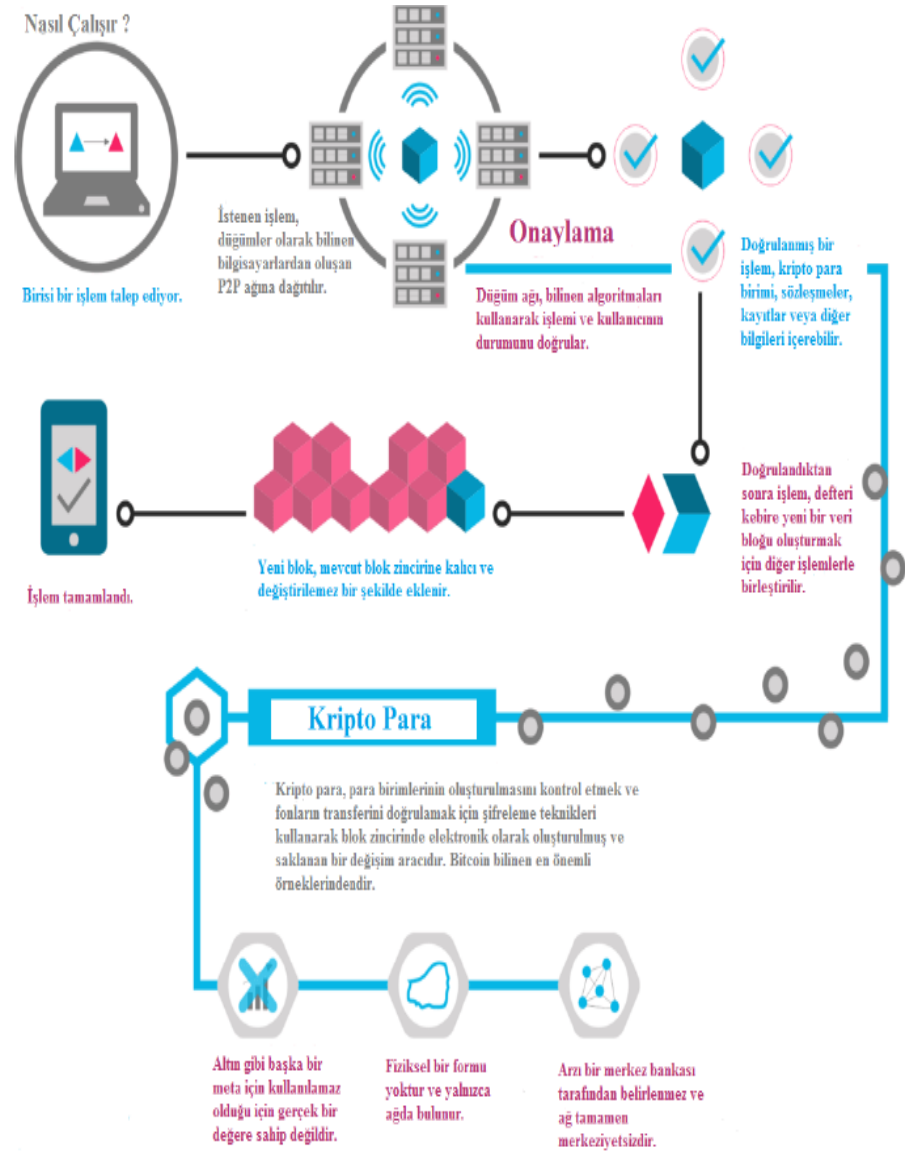
Bitcoin ATM üreticisi olup küresel pazar payının yaklaşık yüzde 32'sine sahiptir (Statista, 2020).

Kripto paraların günümüzde birçok kullanım alanları bulunmaktadır. Bunlardan bazıları (CoinTürk, 2020);

- ✓ Kripto paraların kullanım alanlarından en çok bilinen ve çıkış noktası olan işlevi bir para transfer etme aracı olmasıdır. Daha açık bir şekilde ifade etmek gerekirse, bir alıcıya kripto para gönderilirken banka veya aracı kurumların koymuş olduğu yüksek komisyon ya da gönderim ücretlerine maruz kalmadan masrafsız bir şekilde para transferinde bulunulabilmektedir.
- ✓ Kripto paralar geleneksel paralar gibi kripto para borsalarında alım-satım yapılarak bir yatırım aracı gibi değerlendirilebilmektedir.
- ✓ İnternette ya da mağazalardan kripto para karşılığında alışveriş yapılabilmektedir.
- ✓ Bitcoin ve diğer kripto paralarında altyapısı olan blok zincirinin finans dışı birçok alanda da kullanılması düşünülmektedir. Blok zinciri teknolojisi ile bilim, sanat, sağlık ve kültür gibi birçok alanda katma değer oluşturabilecek ve aynı zamanda hayatı kolaylaştırabilecek uygulamaların geliştirilmesi de planlanmaktadır.

1.3. KRİPTO PARALAR NASIL ÇALIŞIR

Bir kullanıcı kripto paralarla ilgili herhangi bir işlem yapmak istediği zaman geleneksel para işlemlerinden farklı olarak arka planında bazı işlem süreçleri gerçekleşmektedir. Bu işlemlerin Şekil 1'de de gösterildiği gibi bir döngüsü vardır. İlk olarak, istenilen işlemler düğümlerden oluşan "Eşler Arası Ağ (Peer to Peer Network-P2P)" ağına bildirilir. Sonrasında bu düğümler daha önceden sisteme tanıtilen algoritmaları kullanarak kullanıcıyı ve işlemi doğrular. İşlem onaylandıktan sonra diğer işlemlerin tutulduğu defteri keşif işlemi yapılır. Her yeni işlem yeni bir blok anlamına geldiği için defteri keşif işlemi diğer işlem bloklarıyla birleştirilmek suretiyle dahil edilir. Blok zincire kalıcı olarak kaydedilen bu işlem değiştirilemez.




Şekil 1. Kripto Paraların Çalışma Şekli (Rosic, 2016)

1.4. KRİPTO PARA YAPILARI

Sayısal değerlerden meydana gelen ve birbirlerine zincirler ile bağlı bulunan blokların değiştirilmesi mümkün değildir. Bu bloklar üst üste kayıt yaparak işlemcide saklanır. Blok zinciri, kullanıcılar arasında yapılan işlemleri bütün bir şekilde herkese ulaşmasını sağlar ve bulunduğu yerden yönetilmesine izin verir (Swan, 2015, s. 5).

Verinin depolanma şeklini gösteren birçok farklı yöntem bulunmaktadır. Bunlar sırasıyla Merkezi Ağ (centralized), Merkezi Olmayan Ağ (Decentralized) ve Dağıtılmış Ağ (Distributed) yapılarıdır.



Şekil 2. Merkezi Ağ (Centralized), Merkezi Olmayan Ağ (Decentralized) ve Dağıtılmış Ağ (Distributed) Yapıları (Pisa ve Juden, 2017, s. 7)

Merkezi Ağ (Centralized) yapısı geleneksel ağ yapısı olarak da adlandırılmaktadır. Merkezi Ağ yapısında düğümler kendi aralarında iletişim kuramaz sadece merkez ile iletişim kurabilirler. Bu sistemlerde veriyi merkez kaydeder ve ödül-ceza gibi konularda tam yetkilidir. *Merkezi Olmayan Ağ (Decentralized) yapısında* ise merkezi ağ yapısının tam tersine tüm düğümler eşittir. Ağa dahil olan herkes veriyi kaydedebilir, herkesin yetki gücü eşittir. Bu özellikler bir yandan sistemin şeffaf ve adil olmasını sağlarken bir yandan da güvensiz bir ortam oluşmasına neden olabilmektedir. *Dağıtılmış Ağ (Distributed) yapısında* da merkezi olmayan ağda olduğu gibi ana bir merkez yoktur. İşlemlerin başı itibarıyla tüm düğümlerde veriler tutulur, kayıtlardaki en ufak değişim bile fark edilir böylece güvenilir bir ortam elde edilir ve merkezi bir sisteme gerek duyulmaz. Dağıtık ağ yapısı teknik olarak verimlilik ve performans sağlar.

Geleneksel veri tabanları ile dağıtılmış veri tabanları arasında bazı farklılıklar bulunmaktadır. Şekil 3'te gösterilen geleneksel veri tabanlarının çalışma sistemi kopya çoğaltma mantığına dayanmaktadır. Ayrıca ana kopyayı güvenilir taraf tek başına güncelleyebilmektedir. İşlem kontrolü ve çalışması daha zordur. Şekil 4'te gösterilen dağıtılmış veri tabanlarında ise sistemde yapılan tüm işlemlerin ve kullanıcı veri tabanının blok zinciri altında bir kopyası bulunmaktadır. Daha güvenli olmakla birlikte daha az maliyetlidir. Daha kolay kontrol edilmektedir. Kullanıcıların işlemlerini gerçekleştirebilmesi için üçüncü bir aracıya ihtiyaçları yoktur. Her işlemin blok zinciri gibi dağıtılmış veri tabanlarındaki tüm kullanıcılar tarafından

doğrulanması gerekmektedir. Bu sistemin kırılmaz bir yapıya dönüşmesini sağlar (UBS, 2017). Blok zinciri yapısı ilerleyen bölümlerde ayrıntılı bir şekilde anlatılmıştır.



Şekil 3. Geleneksel Veri Tabanı Örneği (UBS, 2017)




Şekil 4. Blok Zincir Veri Tabanı Örneği (UBS, 2017)

1.5. KRİPTO PARANIN TEKNOLOJİK ARKA PLANI

Dijital bir para birimi olan kripto paraların arka planında ise daha teknolojik bir yapı bulunmaktadır. Bunlara kriptolojik özet fonksiyonu, dijital imza, Bitcoin adresi ve iş ispatı örnek olarak verilebilir.

Security Agency-NSA)” in geliřtirdiđi bir algoritmadır. SHA-256, Bitcoin madenciliđinde kullanılan proof of work hesaplamalarında kullanılmasının yanı sıra Bitcoin adresi üretirken de kullanılmaktadır. Bu algoritma bilinmekte olan kriptolama fonksiyonları içerisinde en güvenilir olanlarındandır. SHA_256 algoritması her zaman 32 baytlık özet oluşturduğundan dolayı girilen mesaj uzunluđunun herhangi bir önemi yoktur. Őekil 5’de örnek bir SHA_256 fonksiyonu gösterilmektedir (Seyhan, 2018).



Őekil 5. Örnek SHA_256 Sistemi (Coinkazanma, 2018)

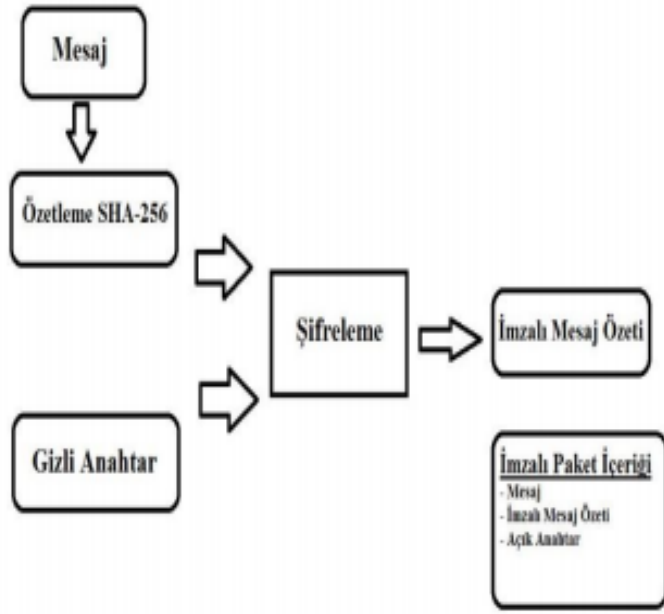
SHA-256 sisteminde mesajın içeriđi ve uzunluđu fark edilmeksizin 0 ya da 1’den oluřan 256 karakter bulunacaktır. Mesajların okunması zor olduđu için, mesajlar önce 4’e bölünerek her grup on altılık sistemde kodlanmaktadır. Dolayısıyla özet mesajı 64 tane birbirini takip eden karakterden meydana gelmiř olacaktır. Teorik açıdan ise, 256 tane ardıřık 0 ya da 1 sayılarıyla, $2^{256} \approx 1.15 \times 10^{77}$ adet özet fonksiyonu oluşturulabilmektedir. Sistemin ne kadar güvenli olduđu buradan da anlaşılabilir. Mesajda meydana gelecek küçük bir deđiřiklik özet mesajının tamamen deđiřmesine ve bambařka bir hal almasına neden olacaktır. Eđer böyle olmasaydı özet mesajından, mesajın orjinaline ulařılabilirdi.

1.5.2. Dijital İmza

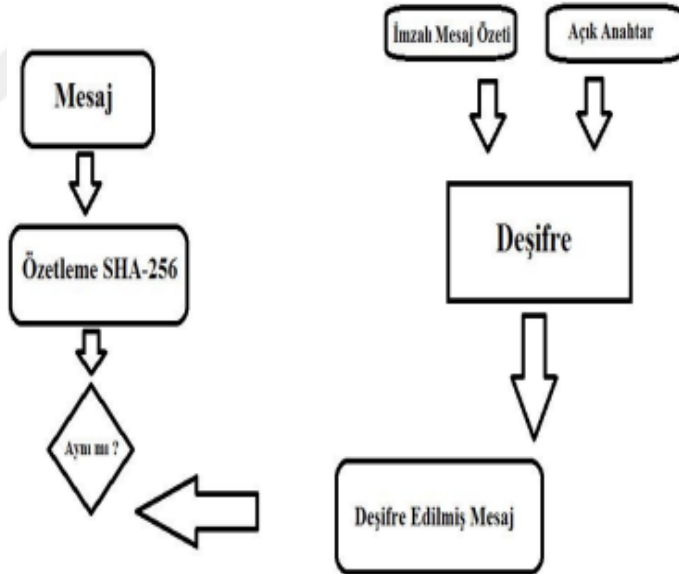
Günlük hayatta belli bařlı resmi iřlemlerin gerçekleřtiđi kurumlarda kiřinin kendini ispatlaması ya da belli hizmetlerden yararlanabilmesi için çođu zaman birçođ belgeye imza atması gerekmektedir. Bir belgede yer alan imza, yapılan iřlemin hangi řahıs tarafından yapıldıđını kanıtlamaktadır. Elektronik ortamda ise ıslak imza yerine dijital imza kullanılmaktadır. Dijital imza fikrini ilk olarak Whitfield Diffie ve

Martin Hellman (1976) yayınladıkları makale ile ortaya atmışlardır. Böylelikle dijital imzanın temeli ve asimetrik bir şifreleme algoritması olan RSA algoritması oluşturulmuştur. Asimetrik şifrelemede gizli ve açık olmak üzere iki tür anahtar bulunmaktadır.

Kripto para işlemleri gerçekleştirilen işlemlerde de buna benzer bir kontrol sistemi bulunmakta ve dijital imza kullanılarak kimlik doğrulması yapılmaktadır. Dijital imzanın en büyük avantajı işlemleri gerçekleştirmek için yer, gün ve saat sabitlemeleri olmaması yani istenildiği zaman yapılabilmesidir. Gizli ve açık anahtarla birlikte çalışan dijital imza, matematiksel testlerden güç almaktadır. Ancak bir kullanıcı bir mesajı gizli anahtar ile gizlediyse, bu mesajı yalnızca açık anahtarla açabilmesi mümkündür. Gizli imza ve açık imza aynı kişide bulunmakta olup, gizli imzanın kişinin kendine özel kalması gerekmektedir. Açık imza için ise böyle bir şart yoktur. Ayrıca gizli anahtardan açık anahtar üretimi yapılabilen fakat açık anahtardan gizli anahtar üretimi yapılamamaktadır (Antonopoulos, 2014, s. 330). Tüm bu durumlara bakılacak olursa güvenilirlik seviyesinin ne kadar yüksek olduğu görülebilmektedir. Dijital imza yöntemi genelde 3 adımdan oluşmaktadır. Bunlar; hash işlemi, imzalama ve doğrulamadır. Şekil 6'de dijital ortamda yapılan imzalama örneği gösterilmektedir.



Şekil 6. Dijital İmzalama Örneği (Ömrüuzun, 2019, s. 32)



Şekil 7. İmza Doğrulama Örneği (Ömrüuzun, 2019, s. 33)

Şekil 7’de yer alan imza doğrulama örneğinde de görüldüğü gibi, transfer işlemi yapmak isteyen şahıs ilk olarak mesajı ve açık imzalı mesaj özetini karşı tarafa gönderir sonrasında alıcı kişi gönderici kişinin açık anahtarını kullanarak imzalı olan

mesaj özetini deşifre eder. Bu mesaj özeti ile gönderilen mesaj özeti aynı ise mesajın gönderici tarafından gönderildiği doğrulanarak işlem tamamlanır.

1.5.3. Bitcoin Adresi

Bitcoin adresi, Bitcoin'lerin saklandığı Bitcoin cüzdanına tanımlanan 26-35 arası alfanümerik karakterden meydana gelen bir dizedir. Bitcoin adresleri 1 ya da 3 sayıları ile başlamakta olup büyük ve küçük harf duyarlılığına sahiptir. Tüm kullanıcıların işlemleri bu adreslerden gerçekleşmektedir. Uzun ve karışık olduğundan dolayı unutulma ihtimaline karşı QR kodu ile de kullanımı gerçekleştirilmektedir (Bitcoin Gündem, 2020).

Örnek Bitcoin Adresi: 1Bno39AF8RyxXer1wFoTk2DqKavnRP278V

1.5.4. İş İspatı (Proof of Works)

Siber saldırılar veya ağda yer alan spamlar gibi problemler, platformaların kullanıcılara sağladıkları hizmetlere zarar verebilmektedir. Bu amaçla oluşturulan “iş ispatı” kavramının başlangıcı 1993 senesine kadar dayanmaktadır. Kullanıcıların yararlanabileceği birtakım işlemler için kullanıcının desteğine ihtiyaç duyulmaktadır. Bu tarz durumlar ise çoğunlukla kullanıcının bilgisayar başında geçirdiği işlem süresinden kaynaklanmaktadır. Zaman ilerledikçe bu yenilikçi algoritma yayılmaya başlamış ve bazı kripto paralar tarafından da kullanılır hale gelmiştir (Kaya, 2020).

Kripto paralar yapısı gereği sadece verilerden oluşmaktadır. Bundan dolayı bu dijital paralar kopyalanmaya ve aynı parayla birden fazla işlem yapılmaya müsaittir. Kripto paralar ortaya çıktığında çift harcama sorununu ortadan kaldırmak için iş ispatı kullanılmıştır. Kısacası iş ispatı çift harcamanın önüne geçmek için oluşturulmuş bir fikir birliği algoritmasıdır (Tekeli, 2021).

Kripto paraların genelinde veri madenciliği yapılmaktadır. Veri madenciliğindeki amaç en çok işlem ile uygun blok oluşturmaktır. Bu işlemin gerçekleşmesi için önceden belirlenmiş kurallar vardır. Belirlenen kurallara uyarak blok üreten kişilere kripto para verilerek ödüllendirilir. Uygun bloğu bulmak için yapılan işleme ise “iş ispatı” denilmektedir (Tekeli, 2021).

1.6. KRİPTO PARA MADENCİLİĞİ


Kripto para üretimi, yapılan transferlerin onaylanması ve işlemlerin sürekli olarak tüm kişilerin erişimine açık olan blok zincirine yazılması amacıyla yapılan matematiksel doğrulama işlemine “kripto para madenciliği” denilmektedir. Daha kısa tanımı ile kripto para madenciliği kripto para üretme işlemine verilen addır. Bu işlemi gerçekleştirebilmek için yararlanılan donanımlara (bilgisayarların işlemci gücü) ise “madencilik” adı verilmektedir. Teorik olarak, bir bilgisayarı ve interneti olan tüm kullanıcılar madencilik yapabilmektedirler. Kripto para transferlerinin geçerliliğinin olması için madencilerin onay vermesi gerekmektedir. Kripto para madencilerinin kullandıkları teknoloji ve madencilik türü onay sürecinde etkilidir (BtcTurk, 2020).

Madenciler, kullanıcıların birbirine transfer ettikleri Bitcoin işlemlerini takip eder ve bu takibi “blok” denilen listelerde kayıt altına alırlar. Sonrasında ise onay vererek ana deftere geçirirler. Blok zinciri işlemlerinin takibinden bulunmak, onaylamak, kayıt altına almak ve gizliliğini sağlamak madencilerin görevidir. Madenciler bu işlemleri ayrıntılı bir şekilde inceleyip blok oluşturabilmek için yüksek derece efor ve güç sarf etmeleri gerekmektedir. Madenciler blok zinciri işlemlerini ve blok içerisindeki bilgileri matematiksel formüllerden geçirip özet (hash) haline getirirler. Sonrasında ise bu özeti diğer bloklara ekleyerek blok zincir yapısının oluşumunu sağlarlar. Örnek olarak SHA-256 gibi özel algoritmalarından yararlanarak yapılan işlemler için yüksek performans ve elektrik gücü gerekmektedir (Nakamoto, 2008, s. 3-4).

Madenci olarak adlandırılan kullanıcılar Bitcoin ya da diğer kripto paraları bulabilmek amacıyla kazı çalışmasında bulunurlar. Madenciler elde edilen kripto paraları dolaşıma sürebilmeleri için 16 haneden oluşan şifreyi çözmeleri gerekmektedir. Ancak bu şifre çözümü kolay değildir. Bunun için uzmanlığa yani profesyonel bilgi ve teknik donanıma ihtiyaç vardır. Madenciler tüm bu emek sürecinden sonra kripto para kazanabilirler (Twentify, 2018, s. 9). Bu işlemlerin matematiksel problemlerini çözmek için yüksek donanıma ihtiyaç olmasının en büyük nedeni ise çoğu kişinin madencilik yapmak için daha çok işlemci gücünden faydalanmasıdır. Bu Bitcoin bazında düşünülecek olursa, sistem piyasaya aşırı

Bitcoin sürülmesinin önüne geçmek için kendi içerisindeki zorluk seviyesinin ayarını otomatik olarak yapmaktadır. Eğer problem süresi 10 dakikanın altında ise problem otomatik bir şekilde zorlaşmakta, 10 dakikadan fazla ise kolaylaşmaktadır (Ankalkoti ve Santhosh, 2017, s. 1757). Bitcoin üretimi 21 milyona ulaştığı zaman ise süre duracak ve madenciler sadece yapılan işlem onayı karşılığı çok az bir işlem ücreti alabileceklerdir (Ankalkoti ve Santhosh, 2017, s. 1758). 2020 senesinde Bitcoin üretimi için kullanılan en elverişli cihazlar “Uygulamaya Özel Tümlleşik Devreler (Application-Specific Integrated Circuit-ASIC)” dir. ASIC’ler minimal donanımdan oluşmakta olup diğer işlemcilerden daha hızlı ve daha verimlidirler (Bfmedia, 2019).

Grafik 2. 2010-2020 Yılları Arası Madencilerin Toplam İşlem Ücretleri (USD)
(Blockchain, 2020)



Grafik 2’de 2010-2020 yılları arası madencilere ödenen tüm işlem ücretlerinin USD cinsinden toplam değeri gösterilmektedir. Coinbase blok ödülleri buna dahil değildir. İşlem ücretlerinin en yüksek seviyeye ulaştığı zaman 2017 aralık ayı olup 21 milyon doların üzerine çıkmıştır. 03.11.2020 tarihinde madencilere ödenen işlem ücretlerinin toplam değeri ise 3.938 milyon dolardır.

1.7. SANAL PARANIN SINIFLANDIRILMASI

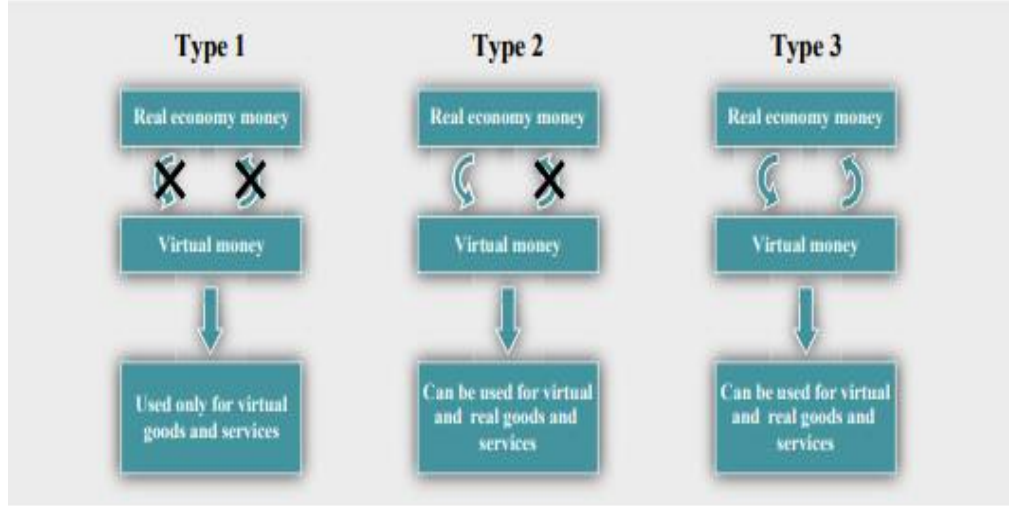
Günümüz piyasasında birçok sanal para çeşidi bulunmaktadır. Bu paralarının genel yapısının daha anlaşılır olması için sınıflandırılması son derece önemlidir. Bu

konu ile ilgili ilk resmi ve detaylı araştırma Avrupa Merkez Bankası (European Central Bank-ECB) na aittir. ECB'nin 2012 yılına ait raporunda, literatürde yer alan 15 farklı yaklaşım arasından en yaygın olan "reel ekonomi ile bağlantı" yaklaşımı esas alınmış ve sanal paralar üç sınıfa ayrılmıştır (European Central Bank, 2012, s. 13-14). Bunlar sırasıyla kapalı sanal para planları, tek yönlü akışa sahip sanal para planları ve çift yönlü akışlı sanal para şemalarıdır. Şekil 8'de sanal para birimi türleri şeması gösterilmektedir.

Kapalı Sanal Para Planları: Bu planların reel ekonomiyle neredeyse hiçbir bağlantısı yoktur ve bazen "yalnızca oyun içi" planlar olarak adlandırılmaktadır (Strauss, 2010). Kullanıcılar genellikle bir abonelik ücreti öder ve ardından çevrimiçi performanslarına göre sanal para kazanır. Sanal para yalnızca sanal topluluk içinde sunulan sanal mal ve hizmetleri satın alarak harcanabilir ve en azından teoride sanal topluluk dışında alınıp satılamaz (European Central Bank, 2012, s. 13).

Tek Yönlü Akışa Sahip Sanal Para Planları: Bu tür sanal para planları, belirli bir döviz kuru üzerinden doğrudan gerçek para birimi kullanılarak satın alınabilir, ancak orijinal para birimine geri çevrilemez. Dönüştürme koşulları, plan sahibi tarafından belirlenmektedir. Tek yönlü akışa sahip sanal para planları para biriminin sanal mal ve hizmetlerin satın alınmasında kullanılmasına izin verir, ancak bazıları para birimlerinin gerçek mal ve hizmetleri satın almak için kullanılmasına da izin verebilir (European Central Bank, 2012, s. 14).

Çift Yönlü Akışlı Sanal Para Şemaları: Bu tür sanal para birimlerinde kullanıcılar kendi para birimleri ile döviz kurlarına göre sanal para alıp satabilirler. Sanal para birimi, gerçek dünya ile birlikte çalışabilirliği açısından diğer dönüştürülebilir para birimlerine benzemektedir. Bu planlar hem sanal hem de gerçek mal ve hizmetlerin satın alınmasına izin verir (European Central Bank, 2012, s. 14).



Şekil 8. Sanal Para Birimi Türleri Şeması (European Central Bank, 2012, s. 15)

1.8. BAŞLICA KRİPTO PARALAR VE ÖZELLİKLERİ

CoinMarketCap (2020) verilerine göre günümüzde 7 binden fazla kripto para birimi bulunmaktadır. Piyasa da en çok işlem gören 10 kripto para birimi Tablo 1’de yer almaktadır.

Tablo 1. 04.11.2020'de Piyasada En Çok İşlem Gören 10 Kripto Para (CoinMarketCap, 2020)

	Kripto Para Birimleri	Kapanış Fiyatları (USD)	İşlem Hacimleri	Piyasa Değerleri
1	Bitcoin (BTC)	14.133,71	35.116.364.962	261.954.213.176
2	Ethereum (ETH)	402,14	15.126.077.675	45.559.668.259
3	Tether (USDT)	1,00	51.351.488.942	16.772.875.580
4	Ripple (XRP)	0,237793	3.335.786.074	10.768.360.115
5	Bitcoin Cash (BCH)	241,13	2.602.972.773	4.476.173.288
6	Chainlink (LINK)	10,47	1.678.488.769	4.089.645.472
7	Binance Coin (BNB)	26,93	383.972.480	3.889.087.338
8	Litecoin (LTC)	54,50	3.050.534.139	3.586.579.398
9	Polkadot (DOT)	4,10	836.536.272	3.494.221.350
10	Cardano (ADA)	0,095369	1.041.738.046	2.967.168.445

Bu bölümde işlem hacmi ve piyasa değeri en fazla olan 5 kripto para ele alınmıştır. Bunlar sırasıyla; Bitcoin, Ethereum, Tether, Ripple ve Bitcoin Cash’dır.

1.8.1. Bitcoin (BTC)

İlk kripto para olan Bitcoin, 31 Ekim 2008 yılında Satoshi Nakamoto (asıl ismi bilinmeyen kişi ya da grup) tarafından yayınlanan “Bitcoin: A Peer-to-Peer Electronic Cash System (P2P, uçtan uca)” başlıklı bir makale ile ortaya çıkmıştır (Nakamoto, 2008). İlk açık kaynaklı sanal para birimi olan Bitcoin’i üretmek için açık kaynak kodlu bir yazılım algoritması ve Merkezi İşlem Birimi (Central Processing Unit-CPU) kullanılmıştır (BtcTurk, 2020).

Bitcoin “eşler arası” bir çevrimiçi para birimidir, yani tüm işlemlerin, herhangi bir aracıya izin vermeden veya bunları kolaylaştırmak için herhangi bir aracıya ihtiyaç duymayan, doğrudan eşit, bağımsız ağ katılımcıları arasında gerçekleştirilmektedir. Bitcoin, Nakamoto'nun kendi sözlerine göre, "çevrimiçi ödemelerin bir finansal kurumdan geçmeden doğrudan bir taraftan diğerine gönderilmesine izin vermek” için yaratılmıştır (CoinMarketCap, 2020; Nakamoto, 2008, s. 1).

Bitcoin’in bir sunucusu ya da kontrol noktası yoktur. Bitcoin ekosistemi, internet aracılığıyla Bitcoin protokolünden yararlanarak karşılıklı iletişim kurulabilen bir kullanıcı ağından oluşmaktadır. Bitcoin protokolünün açık kaynak kodlu bir yazılım uygulaması olması, mal alım-satımı yapmak isteyen kullanıcıların Bitcoin transferi yapabilmesinin yanı sıra diğer para birimleri içinde Bitcoin takası yapabilmesini mümkün kılmaktadır (Vranken, 2017, s. 2). Bitcoin bir şifreleme para birimi olmasıyla birlikte Bitcoin oluşumunu ve değişimini kontrol etmek amacıyla şifreleme ilkelerini kullanmaktadır. Bitcoinler, açık kaynaklı bir kod kullanarak kişisel bilgisayar veya akıllı telefon gibi kişiye ait yerel ya da çevrimiçi cüzdanlarda saklanmaktadır (Ciaian ve Rajcaniova, 2016, s. 888).

Geleneksel paralar gibi fiziksel bir yapıda olmayan Bitcoin’i benzersiz kılan en önemli özelliği ise kullanıcıların işlem yapabildiği ilk kripto para birimi olması ve küresel bir topluluk oluşturmayı başarmasıdır. Bitcoin üreticileri günlük yaşamda Bitcoin ve diğer kripto para birimlerini yaratan, kullanan, yatırım ve ticaret yapan milyonlarca kullanıcıdan oluşan yepyeni bir endüstriyi doğurmayı başarmışlardır. İlk kripto para biriminin ortaya çıkışı, daha sonra binlerce rakip projenin geliştirilmesine ilham veren kavramsal ve teknolojik bir temelin oluşmasına neden olmuştur (CoinMarketCap, 2020).

Dolaşımda Bulunan Bitcoin (BTC):

Günümüzde “300 milyar doları aşan” tüm kripto para piyasasında olan işlemlerin çoğunluğunun, Bitcoin tarafından gerçekleştirildiği fikri hakimdir. Bankalar ve finansal hizmet şirketleri gibi güvenilir araçlara güvenmeksizin dünyanın herhangi bir yerindeki herhangi biri tarafından gönderilip alınabilmektedir.

Bitcoin'in toplam arzı yazılımıyla sınırlıdır ve asla 21.000.000 coin'i geçmeyecektir. "Madencilik" olarak bilinen süreç sırasında yeni madeni paralar yaratılır. İşlemler ağ üzerinden aktarılırken, madenciler tarafından alınır ve bloklar halinde paketlenir ve karmaşık kriptografik hesaplamalarla korunur. Hesaplama kaynaklarını harcamanın telafisi olarak, madenciler başarıyla blok zincirine ekledikleri her blok için ödül alırlar. Bitcoin'in piyasaya sürüldüğü anda ödül, blok başına 50 Bitcoin'di. Bu sayı, her 210.000 yeni blok çıkarıldığında yarıya inmektedir bu da ağı kabaca dört yıllık bir süre almaktadır. 2020 itibarıyla blok ödülü üç kez yarıya indirilmiştir ve 6.25 bitcoin içermektedir.

Bitcoin halka açılmadan önce kurucular arasında herhangi bir madeni para çıkarılmamış veya dağıtılmamıştır. Bununla birlikte, Bitcoin'in varlığının ilk birkaç yılında, madenciler arasındaki rekabet nispeten düşüktür ve ilk ağ katılımcılarının düzenli madencilik yoluyla önemli miktarlarda madeni para biriktirmesine izin verilmiştir. Satoshi Nakamoto'nun tek başına bir milyonun üzerinde Bitcoin'e sahip olduğuna inanılmaktadır (CoinMarketCap, 2020).

1.8.2. Ethereum (ETH)

Bitcoin dışında kalan tüm paralar altcoin olarak adlandırılmaktadır. Fakat Ethereum birçok özelliği nedeniyle bu kavramın dışında kalabilecek niteliklere sahiptir. Ethereum ilk kez 2015 senesinde Kuzey Amerika'da olan bir Bitcoin konferansında Buterin (2014, s. 3) tarafından tanıtılmış ve büyük talep almıştır. Buterin, diğer ortak kurucularla birlikte, 2014 yazında bir çevrimiçi halka açık kitle satışında proje için fon sağlamış ve 30 Temmuz 2015'te resmi olarak blok zincirini başlatmıştır.

Bitcoin gibi Ethereum'da merkezi bir otoriteye bağlı olmayan ve kendi kripto para birimi olan Ether'i içeren blok zincir tabanlı bir dijital para birimidir (Coin

Medya, 2018). Ethereum, merkezi olmayan akıllı sözleşmelerin yürütülmesinin yanı sıra diğer birçok kripto para birimi için de bir platform olarak çalışmaktadır.

Ethereum'da temel amaç aracıya ihtiyaç duymadan bir mal ya da hizmet satın alımını sağlamaktır. Ethereum madenciliği Grafik İşleme Birimi (Graphics Processing Unit-GPU) ile yapılmaktadır. Ethereum'da yapılan herhangi bir işlem ücretinin maliyeti, işlemin kapladığı alan ve işlemin ağda kullandığı band genişliğine bağlıdır (Odabaş, 2017). Bu işlem ücreti maliyeti durumu Ethereum için çok büyük bir dezavantajdır.

Ethereum'u diğer para birimlerinden farklı kılan en büyük yanı Ethereum, bir blok zinciri akıllı sözleşme platformu konseptine öncülük etmesidir. Akıllı sözleşmeler, internette birkaç taraf arasında bir anlaşmanın yerine getirilmesi için gerekli eylemleri otomatik olarak gerçekleştiren bilgisayar programlarıdır. Kullanıcılar arasında güvenilir ara ürün ihtiyacını azaltmak, böylece işlem maliyetlerini düşürürken aynı zamanda işlem güvenilirliğini artırmak için tasarlanmıştır. Ethereum'un temel yeniliği, akıllı sözleşme teknolojisinin halihazırda var olan faydalarını daha da güçlendiren ve blok zinciri kullanarak akıllı sözleşmeler yapmasına izin veren bir platform tasarlamaktır. Kurucu ortak Gavin Wood'a göre, Ethereum'un blok zinciri bir tür "tüm gezegen için tek bir bilgisayar" olarak tasarlanmıştır. Teorik olarak Ethereum, herhangi bir programı küresel olarak dağıtılmış bir genel düğüm ağında çalıştırarak, daha sağlam, otorite müdahalelerine karşı korumalı ve sahtekarlığa daha az eğilimli hale getirebilmektedir (CoinMarketCap, 2020).

Ethereum'un gelecekteki hedefi ise, merkezi olmayan uygulamalar için küresel bir platform haline gelmek ve dünyanın her yerinden kullanıcıların müdahalelere, kesinti süresine ve dolandırıcılığa maruz kalmadan işlemler yapmasına olanak sağlamaktır (CoinMarketCap, 2020).

Dolaşımda Bulunan Ethereum (ETH):

Ağustos 2020'de dolaşımda yaklaşık 112 milyon Ethereum bulunmaktaydı. Bunun 72 milyonu Ethereum'un blok zincirindeki ilk blok olan "genesis bloğu" nda yayınlanmıştır. Bu 72 milyonun 60 milyonu, 2014 yılında projeyi finanse eden ve kitle satışına ilk katkıda bulunanlara, 12 milyonu ise geliştirme (kalkınma) fonuna

verilmiştir. Kalan miktar, Ethereum ağındaki madencilere blok ödülleri şeklinde dağıtılmıştır. 2015'teki orijinal ödül, blok başına 5 Ethereum iken 2017'nin sonlarında 3 Ethereum'a ve ardından 2019'un başlarında 2 Ethereum'a düşmüştür. Bir Ethereum bloğunu çıkarmak için geçen ortalama süre ise yaklaşık 13-15 saniyedir (CoinMarketCap, 2020).

1.8.3. Ripple (XRP)

Ryan Fugger tarafında fikirsel temeli atılan XRP kısa sürede birçok talep almış ve üne kavuşmuştur. 2012 senesinde Ryan Fugger bu fikri Jed McCaleb ve Chris Larsen'a devretmiş ve şirket kurulmuştur. XRP günümüzde ise en popüler ve en değerli ilk üç coin arasında yer almaktadır (Paribulog, 2019).

İlk olarak XRP, Ripple ve RippleNet arasındaki farkı anlamak önemlidir. "XRP", XRP Ledger adlı dağıtılmış bir defter veritabanının üstünde bulunan RippleNet adlı dijital bir ödeme platformunda çalışan para birimidir. "RippleNet", Ripple adlı bir şirket tarafından çalıştırılırken, XRP Ledger açık kaynaklıdır ve blok zincirine değil, daha önce bahsedilmiş olan dağıtılmış defter veritabanına dayanmaktadır. RippleNet ödeme platformu, küresel olarak anlık parasal işlemleri etkinleştirmeyi amaçlayan gerçek zamanlı bir brüt ödeme (RTGS) sistemidir. "XRP" ise, XRP Ledger'e özgü kripto para birimi olsa da, aslında platformda işlem yapmak için herhangi bir para birimini de kullanılabilir.

XRP, Ripple tarafından hem diğer dijital varlıklara hem de Dünya Bankalar Arası Finansal Telekomünikasyon Derneği Transferi (Society for Worldwide Interbank Financial Telecommunication-SWIFT) gibi mevcut parasal ödeme platformlarına hızlı, daha az maliyetli ve daha ölçeklenebilir bir alternatif olarak oluşturulmuştur.

RippleNet'in defteri, şirketin aktif bir üyesi olduğu Ripple ile küresel XRP Topluluğu tarafından tutulmaktadır. XRP işlemlerinin hem sırası hem de geçerliliği konusunda bir fikir birliğine varıldığında işlem geçerli sayılmaktadır. Herkes Ripple doğrulayıcısı olabilmektedir. XRP Topluluğu listesinde şu anda üniversiteler ve finansal kurumlar yanı sıra Ripple'da yer almaktadır (CoinMarketCap, 2020).

Ripple büyük bankalar ve finansal hizmet sunan kurumlar tarafından tercih edilmekte olup çok az işlemde bulunan para birimleri arasında köprü görevini

üstlenmektedir (Aslan, 2018, s. 10). XRP köprü görevini Ripple Network üzerinde yapılan transfer işlemleri sayesinde gerçekleştirmektedir. XRP kullanılarak geleneksel para birimleri arasında transfer yapabilmekte ve geleneksel para birimleri birbirlerine çevirilebilmektedir. İşlem ücreti ise sadece 0.00001 ABD dolarıdır. XRP'nin bu özelliğinden ötürü XRP “joker” olarak da adlandırılmaktadır. Bu platformda yapılan her işlemden sonra tahsil edilen işlem ücreti yok olur bunun sebebi ise spam amaçlı saldırıları engellemektir (Cointelegraph, 2019).

Dolaşımda Bulunan Ripple (XRP):

Toplamda 100 milyar adet Ripple üretimi yapılmıştır. Bu miktarın %20'si Ripple'in kurucularına, %25'i ise Ripple Laboratuvarına aittir. Kalan %55'lik kısım ise, ağına dağıtımı için ayrılmıştır. Ripple madenciliği yapılamamaktadır. Ripple transfer işlemlerinde komisyon ücreti kadar piyasadan Ripple silinmektedir. Ripple'in temel amacı, bankacılık sektörüne girerek işlem kolaylığı sağlamak ve bunu olabildiğince daha hızlı ve daha düşük maliyetlerle gerçekleştirmektir. Saniyede yapılan Ripple işlemi yaklaşık 1500 adettir ve ödemeler 4 saniye gibi çok yüksek bir hızda gerçekleşebilmektedir (Ripple, 2020).

1.8.4. Tether (USDT)

RealCoin olarak bilinen Tether 2014 senesinde Brock Pierce, Reeve Collins ve Craig Sellars tarafından piyasaya sürülmüştür. 2015 senesinde ise yeniden markalanmaya giderek Tether adını almıştır. Omni protokoli yoluyla Ethereum blok zinciri üzerinden oluşturulmuş ERC20 tabanlı bu dijital para “ABD Doları'na endekli bir kripto para” olarak da tanımlanmaktadır. Tether'in 1 USD'ye sabitlenmesi için dolaşımdaki Tether sayısı kadar rezervlerde de eşit miktarda dolar tutulması gerekmektedir (BtcTurk, 2020).

Tether ilk olarak Temmuz 2014'te Omni platformu kullanılarak Bitcoin'in blok zincirinin üzerine inşa edilen ikinci katman bir kripto para belirteci olan Realcoin olarak piyasaya sürülmüştür. Sonrasında USTether olarak yeniden adlandırılmış ve son olarak Tether (USDT) olarak değiştirilmiştir. Bitcoin'in yanı sıra Tether daha sonra Ethereum, EOS, Tron, Algorand, SLP ve OMG blok zincirlerinde çalışacak şekilde güncellenmiştir (CoinMarketCap, 2020).

Tether'ı diğer para birimlerinden farklı kılan yanı ise değerinin ABD dolarına sabit kalması için Tether yaratıcıları tarafından garanti edilmesidir. Tether üreticilerine göre, yeni Tether coinleri yayınladığında, rezervlerine aynı miktarda USD tahsis ediyor ve böylece Tether'in nakit ve nakit benzerleriyle tamamen desteklenmesini sağlıyor. Fiyatının 1 USD olarak sabitlenmesinden dolayı Tether en istikrarlı kripto para birimi olarak tanımlanabilmektedir. Ayrıca Tether fiyat dalgalanmalarının yaşanmadığı kripto para olarak da bilinmektedir (Tan vd., 2018).

Kripto piyasalarının yüksek volatilitesi, kripto para birimlerinin tek bir gün içinde %10-20 oranında yükselip düşebileceği anlamına gelmektedir ve bu da onları bir değer deposu olarak güvenilir hale getirmektedir. Tether ise bu dalgalanmalardan korunmaktadır. Bu özellik, Tether'ı kripto yatırımcıları için güvenli bir liman haline getirmektedir. Yüksek volatilité dönemlerinde, portföylerini tamamen USD'ye çevirmek zorunda kalmadan Tether'a yatırım yapılabilir. Ek olarak, Tether kullanıcılarına, bir banka veya finansal hizmetler sağlayıcısı gibi yavaş ve pahalı bir aracıya güvenmek zorunda kalmadan, blok zinciri aracılığıyla bölgeler, ülkeler ve hatta kıtalar arasında ABD doları eşdeğerinde işlem yapmanın basit bir yolunu sağlamaktadır. Bununla birlikte, yıllar içinde Tether'in USD rezervleriyle ilgili iddialarının geçerliliğine ilişkin bir dizi tartışmalar olmuştur. Bu da zaman zaman Tether'in fiyatında bozulmalara yol açmış, fiyatını 0,88 \$ 'a kadar düşürmüştür. Birçoğu, Tether'in rezervlerinin hiçbir zaman bağımsız bir üçüncü şahıs tarafından tam olarak denetlenmediği konusunda endişelerini dile getirmişlerdir (CoinMarketCap, 2020).

Tether'in temel amacı, güvenilir bir üçüncü taraf aracı olmadan, kullanıcılar arasında gönderilebilen kripto para birimlerinin sınırsız doğasını ABD dolarının sabit değeriyle birleştirmektir (CoinMarketCap, 2020).

Dolaşımda Bulunan Tether (USDT):

Tether'ın toplam arzında sabit kodlanmış bir sınır yoktur. Özel bir şirkete ait olduğu gerçeği göz önüne alındığında, teorik olarak ihracı yalnızca Tether'in kendi politikalarıyla sınırlıdır. Bununla birlikte Tether üreticileri, üretilen her bir Tether'ın bir ABD doları tarafından desteklenmesini beklediğini iddia ettikleri için, coin miktarı şirketin gerçek nakit rezervleriyle sınırlı tutulmuştur. Ayrıca, Tether üreticileri ihraç programlarını vaktinden önce açıklamaz, bunun yerine varlık

rezervlerinin ve yükümlülüklerinin toplam tutarını listeleyen günlük şeffaflık raporları sunarlar. Tether üreticilerine göre, Eylül 2020 itibarıyla dolaşımda 14,6 milyar dolarlık varlıkla desteklenen 14,4 milyar Tether bulunmaktadır (CoinMarketCap, 2020).

1.8.5. Bitcoin Cash (BCH)

Bitcoin'in standart blok boyutu 1MB belirlenerek spam ataklarına karşı sistemi korumak amaçlanmıştır. Fakat blok boyutundaki bu sınır işlem ve transfer hızında gecikmeler oluşmasına neden olmuştur. Bitcoin'in artan yayılım ve yükselişinin ardından blok boyutu sınırı ölçülenebilirlik problemini ortaya çıkmıştır. 1 Ağustos 2017 tarihinde Bitcoin'de gerçekleşen Hard Fork (Mecburi Çatallaşma) problemini çözmek için Bitcoin'de çatallanmaya gidilerek 2017 yılında Bitcoin Cash üretilmiştir. Böylelikle blok boyutu 8 MB'a yükseltilmiştir. Böylelikle transfer işlemleri Bitcoin Cash daha verimli ve daha hızlı bir şekilde gerçekleştirecektir (Frankenfield, 2017).

Bitcoin Cash, hızlı ödemeler, mikro ücretler, gizlilik ve yüksek işlem kapasitesi (büyük bloklar) ile güvenilir küresel para olmayı hedefleyen, eşler arası bir elektronik nakit sistemidir. Fiziksel paranın doğrudan ödenen kişiye verilmesi gibi, Bitcoin Cash ödemeleri de doğrudan bir kişiden diğerine gönderilmektedir.

Bitcoin Cash'in çeşitli kullanım alanları bulunmaktadır. Bireyler arasındaki eşler arası ödemelere ek olarak, Bitcoin Cash, katılımcı tüccarlar tarafından mağaza içi ve çevrimiçi mal ve hizmetler için ödeme yapmak için de kullanılabilir. Çok düşük ücretler, içerik oluşturuculara bahşış vermek ve uygulama kullanıcılarını birkaç sent ödüllendirmek gibi yeni mikro işlem ekonomilerini mümkün kılmaktadır. Bunlara ek olarak Bitcoin Cash, para havaleleri ve sınır ötesi ticaret için ücretleri ve ödeme sürelerini de azaltmaktadır. Basit akıllı sözleşmeler ve CashShuffle, CashFusion gibi özel ödeme araçları kullanılarak Bitcoin Cash ile geleneksel paralar gibi işlem yapılabilir (CoinMarketCap, 2020).

Dolaşımda Bulunan Bitcoin Cash (BCH):

Bitcoin Cash, altın gibi kıtlığa sahip olduğu için nakit harcanabilirliği sınırlıdır. 21 milyon jetonluk sınırlı toplam arzı ile Bitcoin Cash oldukça azdır ve fiziksel paralar gibi kolayca harcanabilir. İşlemler hızlıdır ve işlem ücretleri genellikle bir

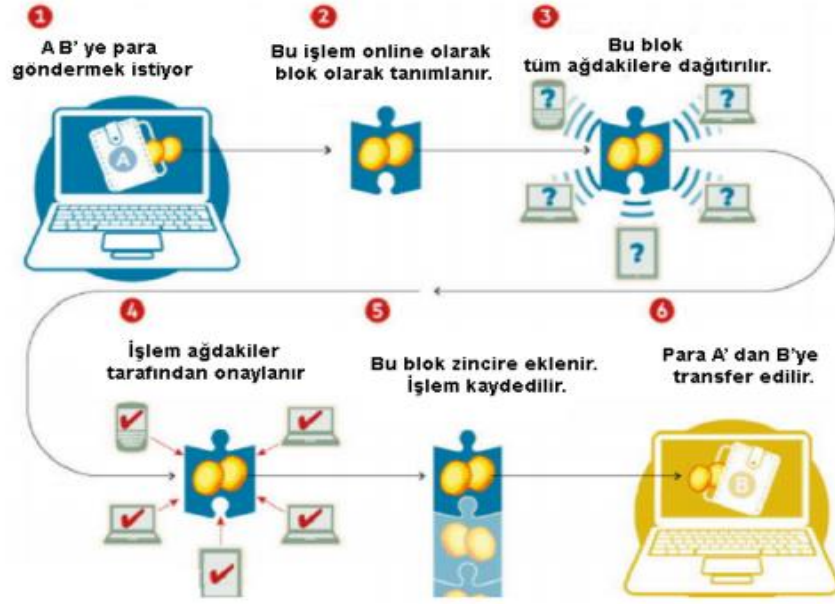
sentin onda birinden azdır. Akıllı telefon veya bilgisayar ile herkes Bitcoin Cash ödemesi gerçekleştirebilir (CoinMarketCap, 2020).

1.9. BLOK ZİNCİRİ (BLOCKCHAIN)

Elektronik bir para çeşidi olan kripto paralara herhangi bir finansal kuruluş, hükümet ya da şirket aracılığıyla müdahalede bulunulamamaktadır. Bu elektronik paraları oluşturmak ve aktarmak için ihtiyaç duyulan şey ise, güven yerine kriptografik kanıta dayalı bir elektronik ödeme sistemidir. Bu sistem, işlem yapacak herhangi iki istekli tarafın güvenilir bir üçüncü tarafa ihtiyaç duymadan birbirleriyle doğrudan işlem yapmasına izin vermektedir (Nakamoto, 2008, s. 1).

Blok zinciri teknolojisinin geliştirmesinin temel amacı dijital paralarda bulunan “çift harcama (peer-to-peer)” probleminin önüne geçmektir. Çift harcama (peer-to-peer) eşten eşe veya eşler arası olarak bilinen, herhangi bir merkezi olmayan, uçtan uca işlem sağlayan bir ağ yapısıdır. Blok zincirini daha basit bir şekilde ifade etmek gerekirse; herhangi bir güvenlik açığı ihtimaline karşı koruyucu ve erişimi kolay olan bir ağdaki şifrelenen verilerin idaresini sağlayabilen dağıtık veri tabanıdır. Blok zincir teknolojisini günümüzde var olan ağlardan farklı olmasının nedeni ise eşler arası ağ (peer to peer network), dağıtılmış defter (distributed ledger), mutabakat mekanizması (consensus mechanism) ve kriptografi (cryptografy) teknolojisine sahip olmasıdır (Krause vd, 2016, s. 6; Pisa ve Juden, 2017, s. 5-7; Hewlett Packard Enterprise (HPE), 2016, s. 1-4; Price waterhouse Cooper (PwC), 2017, s. 1-3).


Blok zinciri teknolojisinin çalışma mantığı Şekil 9’da gösterilmektedir. Blok zincirinde yeni bir katılımcı sisteme dahil olduğunda ve işlem yapmak istediğinde düğümlerin tümü sistemde yeni olan bu işlemi bir blok içinde toplar. Bu blok hareketinden tüm düğümlere yayın yapılır. Sonrasında “proof of work” denilen blok doğrulama işlemi gerçekleşir. Düğümler doğrulanmış bloğu bulduktan sonra onay verir ve önceki düğümün bloğundan zincir oluşturularak işlem son bulur.



Şekil 9. Blok Zinciri Çalışma Mantığı (Crosby vd., 2016)

Eşler Arası Ağ-Eşten Eşe Ağ (Peer to Peer Network-P2P): İki ya da daha fazla bilgisayar arasındaki veri paylaşım ve dağıtımını sağlayan P2P bir çeşit ağ mimarisidir. 1999 senesinde “Napster” isimli dosya paylaşım programının ortaya çıkması ile birlikte popülerliğide fazlasıyla artmıştır (Sabahlatan, 2020). Eşler arası ağda yer alan bilgisayarların her birine “düğüm (node)” de denilmektedir. Düğümlerin her biri, ağda hem sunucu hem de istemci olarak bulunabilmektedir (Karthikeyan vd., 2017, s. 14394). Blok zinciri teknolojisinde ağda yer alan tüm katılımcıların kendilerine özel senkronize edilmiş bir kopyası bulunmaktadır. Bu sayede katılımcılar ağda yapılan işlemleri takip edebilir ve onay verebilirler. Böylece kullanıcıları birbirine bağlayarak üçüncü şahıs ve otoriteleri ortadan kaldırır. Eş kullanıcılar içerisinde herhangi birinde hata oluştuğunda yalnız hata veren kullanıcının bağlantısı kesilir, ancak kesilse bile ağ çalışmasını sürdürmeye devam eder. Bu özellik ise P2P ağ mimarisini sadece bir noktaya bağlı kalmadığından dolayı güçlü kılmaktadır. Kısacası P2P, alıcı ve satıcı arasında bir aracı bulunmadan ticaret yapmalarına olanak sağlayan bir iletişim platformudur. Günümüzde P2P ağ mimarisi kripto para temelini oluşturan blok zincir teknolojisinde önemli bir yer kaplamakta, web arama motorları ve online pazaryeri platformları gibi birçok farklı bilgisayar uygulamasında da kullanılmaktadır.

Birçok avantajı bulunan P2P iletişim modelinin kullanıcılar açısından bazı dezavantajları da bulunmaktadır. P2P de sınırsız dosya paylaşımı gerçekleşmektedir. Bu ise telif hakları ile korunan ve para karşılığı satılan içeriklere ulaşımı olanaklı hale getirmektedir. Paylaşımı gerçekleştiren veri ve bilgilerde kriptografik gizlemenin bulunmaması sıkıntılı durumlara neden olabilmektedir. Buradan da P2P modelinin kriptoloji ile birlikte kullanımı sağlandığında daha güvenilir bir ortam yaratacağı sonucuna varılabilir (Erözel Durbilmez ve Yılmaz Türkmen, 2019, s. 32; Yavuz, 2019, s. 17). Şekil 10’da sunucu tabanlı ağ ve eşten eşe ağ yapısına yer verilmektedir.



Şekil 10. Sunucu Tabanlı Ağ ve Eşten Eşe Ağ Yapısı (CIS 3347 Cruz Guzman, 2020)

Dağıtılmış Defter (Distributed Ledger): Blok zinciri teknolojisi aynı bilgileri farklı düğümlerde (blok zinciri ağında olan işlemlerin kaydını depolayan, internete bağlı olan herhangi bir akıllı cihaz) saklar ve bilgiler yalnızca düğümler fikir birliğine vardığında eklenebilir. Yeni işlemler eklense bile tüm düğümlerin geçmişi izlemesini sağlayan önceki bilgiler kaldırılamaz. İşlem bilgilerinin farklı düğümlerde depolanmasına “dağıtılmış defter” adı verilmektedir. Bu, merkezi bir aktöre bağımlılığı ve tüm düğümler tam bilgiye sahip olduğundan, manipülasyon veya sistem arızası riskini azaltır. Blok zinciri, herhangi bir mülkiyet değişikliği ve sertifikalar, lisanslar, hükümet kararları ve mevzuat gibi önemli bilgi ve belgelerin saklanması için kullanılabilir. Tipik olarak, bir blok zincirinde depolanan bilgiler, tapu sicilinin mülkiyeti, doğum ve evlilik sertifikaları, araç kayıtları, (işletme) lisansları, eğitim sertifikaları, öğrenci kredileri, sosyal yardımlar ve oylar gibi işlem verileridir (Ølnes vd., 2017, s. 355). Blok zinciri ayrıca “Distributed Ledger Technology (DLT)” adı altında da kullanılmaktadır. Dağıtılmış defter, her

katılımcının paylaşılan bir erişime sahip olduğu fikrine dayanmaktadır. Açık, evrensel olarak erişilebilir bir deftere sahip olma fikri Bitcoin ile doğmuş ve bu sistem, güvensiz bir ortamda üçüncü bir tarafa güvenmeksizin güven oluşturma sorununa ilk çözümü sağlamıştır (Lamport, 1982, s. 382).

Mutabakat Mekanizması (Consensus Mechanism): Blok zinciri ağının büyümesi avantajlarının yanında birçok sorunu da beraberinde getirmiştir. Ağın büyümesi güvenilirliği artırırken diğer taraftan ağda bulunan veri tabanlarının aynı anda güncellenmesi problemini ortaya çıkarmıştır. Blok zincirinde işlemler hızlı bir şekilde gerçekleşirken, işlemlere ait olan bloklarında aynı anda bütün veri tabanlarına ulaşması gerekmektedir. Fakat bazen, oluşan yeni blokların aynı zamanda iletimi sağlanamayabilir. Bu durum ise değişik veriler barındıran veri tabanlarının ortaya çıkmasına neden olur. Bu problemi aşabilmek amacıyla çeşitli “mutabakat mekanizmaları” üretilmiştir (Doğan ve Ertugay, 2019, s. 1659).

Kullanım olarak en yaygın olan mutabakat mekanizması “iş ispatı (proof of work)” mekanizmasıdır. Blok zinciri ağındaki katılımcıların birbirlerine güven duymadıkları zamanlarda tercih edilmektedir. Proof of work mekanizmasında üretimi yapılacak yeni blokta bulunacak veriler hazır hale getirilir, yeni veri bloğunun özet değerleri bir öncesindeki blokta yer alan özet değerlerinden yararlanılarak kriptografik özet fonksiyonları ile hesaplaması yapılır. Hesaplamalar sonucunda bulunan yeni özet değerinin belirli bir nizamda olması beklenir. Özet değerinin düzeni ise hesaplamada kullanılan fonksiyonun “zorluk derecesi” olarak isimlendirilmektedir. Zorluk derecesi ile özet değerinin üretim süresi doğru orantılı bir şekilde artış göstermektedir. Mutabakat sürecinde bulunan bütün bilgisayarlar, geçerli olabilecek bir özet değeri üretimi yapabilmek amacıyla çalışırlar. Bu çalışmaya “blok zinciri madenciliği” adı verilmektedir. Özet değerinin belirlenen niteliklere en uygun zamanda yapan bilgisayara karşılığı ödenir (Narayanan vd., 2016, s. 65). Bitcoin başta olmak üzere birçok kripto para sistemi mekanizması “iş ispatı (proof of work)” olarak kullanılmaktadır (Nakamoto, 2008, s. 3). Kullanımı yaygın olan diğer mutabakat mekanizmaları ise “paydaşlığın ispatı – proof of stake” ve Pratik Bizans Hata Toleransı (Practical Byzantine Fault Tolerance – PBFT)’dir.

Kriptografi (Cryptografy): Günümüzde enformasyon ve iletişim teknolojileri insan hayatında büyük bir yer kaplamaktadır. Bu teknolojiler birçok avantaj ve kolaylığı beraberinde getirmiş olsa da birçok probleme de yol açmıştır. Bunlardan en önemlileri elektronik işlemlerde meydana gelen kimlik hırsızlıkları ve dolandırıcılıklarıdır. Teknolojinin kullanımının giderek artmasıyla beraber güven ortamının azalması “kriptoloji” biliminin ön plana çıkmasına neden olmuştur. Geçmişten günümüze kadar bilginin korunabilmesi için birçok çözüm üretilmiştir. Bunlar arasında en kabul gören çözüm yolu ise kriptolojidir. Kriptolojinin en büyük ve en önemli özelliği ise bir kişinin bilgisine onun dışındakilerin erişimini engelliyor olmasıdır (Yılmaz, 2007, s. 137).

1.9.1. Blok Zincirinin Kullanım Alanları (Uses Cases for Blockchain Technology)

Blok zinciri teknolojisinin en büyük ve en bilinen kullanım alanı kripto paralar olsa da birçok farklı alanda da kullanılmaktadır. Blok zincir teknolojisinin, güven probleminin yaşandığı ve aşılmaya çalışıldığı birçok iş alanında kullanılabilmesi düşünülmektedir. Fakat bu teknolojiden yararlanan birçok kavram kanıtama ve prototip ürün çalışmaları olsa da henüz günlük hayata geçirilememiştir. Üretilen fikirlerin günlük hayatta yer alabilmesi ve uygulanabilmesi için zaman ve yatırım bütçesi gerekmektedir. Blok zinciri temelli yeni iş görüşlerine fon bulmak amacıyla yararlanmaya başlanan yenilikçi fon toplama mekanizması “ICO (Initial Coin Offering)” 2013 yılında kullanılmaya başlanmıştır. Bu yöntemin başarı elde ettiği ilk projelerden biri ise 2013 yılının en büyük ICO’su olarak 18 milyon USD yakın fon toplayan Ethereum projesi olmuştur (CoinMarketCap, 2020).

ICO 2017 senesinin gündem maddeleri içerisinde en önemlisi olarak yer almıştır. Bunun iki önemli nedeni bulunmaktadır. Birinci ve en önemli nedeni ICO adını taşıyan birçok dolandırıcılık örneğinin baş göstermesi, ikincisi nedeni ise başarılı ICO projelerinin üretilmesidir. 2017 senesinde üretilen bu projeler 3,5 milyar USD’de fazla para toplamayı başarmışlardır. 2017 senesinin en başarılı 10 ICO projesi Tablo 2’de yer almaktadır.

Tablo 2. 2017 Yılı En Büyük 10 ICO Projesi (Top 10 ICO Projects of 2017)
(Business Insider, 2018)

Sıralama	Proje Adı	Projenin Amacı	Şirket Yeri	Toplanan Tutar
1	Filecoin	Blockchain tabanlı veri depolama projesi.	ABD	257.000.000 \$
2	Tezos	Bitcoin ve Ethereum'dan daha güvenli olduğu iddiası ile geliştirilen yeni bir blok zinciri.	ABD	232.000.000 \$
3	The Bancor Protocol	Ethereum için hazırlanan bu protokol ile herhangi bir karşı alıcı olmadan, sistem üzerinden Ethereum alım-satımı yapabilmektedir. Merkezi olmayan bir sistem üzerinden parayı nakite olarak dönüştürebilen bir sistem de denilebilmektedir.	İsrail	153.000.000 \$
4	Polkadot	Birçok blok zinciri teknolojisini aynı anda kullanılmasına olanak sağlayan inovatif bir teknoloji.	İsviçre	145.000.000 \$
5	Status	İnsanlara Ethereum kullanım kolaylığı sağlayan arayüz.	İsviçre	107.000.000 \$
6	Qash	Finansal hizmet amacıyla bir ödeme sistemi.	Tokyo	106.000.000 \$
7	Kin	Video mesajlaşma uygulaması olan Kik'in yatırım toplamak için geliştirdiği yeni bir kripto	Kanada	98.000.000 \$
8	TenX	Kripto paraların harcanabilmesi için bir debit kart.	Singapur	80.000.000 \$
9	WAX	Kullanıcılara güvenlik, altyapı, ödeme sistemi gibi konuları ücretsiz sunan bir pazaryeri kurma aracı.	ABD	68.000.000 \$
10	SALT	Blok zinciri tabanlı, kripto paralarımızı satmadan önce nakit borç veren bir sistem.	ABD	48.000.000 \$

Finans Endüstrisi (Finance Industry): Blok zinciri teknolojisinin birçok avantajı bulunmasından dolayı banka ve kurumların birçoğu olası kullanım alanlarını araştırmaya devam etmektedir. Yapılan araştırmalar sonucunda farklı kaynaklarda yayımlanan olası birkaç finansal kullanım alanları; ödeme işlemleri, para transferleri, alış/satış platformları, takas yönetimi, yetkilendirme, doğrulama, dijital kimlik yönetimi, doküman yönetimi ve islami bankacılık uygulamaları olarak geçmektedir (Deloitte, 2015; Cognizant, 2016; Everis Next, 2016; Evans, 2015).

Kamu Sektörü (Public Sector): Blok zinciri teknolojisinin kamusal alanlarda da kullanımı mümkün olmakla beraber yenilik sahibi bazı uygulamalar da üretilmeye başlanmıştır. Kamu sektöründe blok zincirinden yararlanabilecek bazı alanlar ise; oylama, doküman yönetimi, enerji dağıtımı, akıllı kontratlar, dijital kimlik, dijital pasaport, sosyal güvenlik sistemi ve vergi sistemidir (Cognizant, 2016).

Bazı ülkelerde, kamu sektöründe blok zinciri kullanımı için yatırımlara başlandığı bilinmektedir. Dubai, İsviçre, İngiltere, Estonya, Singapur ve Kıbrıs blok zinciri alanın yapılan yeniliklere öncülük yapan ülkeler arasındadır.

Kamusal bir alan olan savunma alanı da blok zinciri teknolojisine ilgi duyan alanlar arasında yer almaktadır. Amerikan Savunma Bakanlığı (Pendagon) ve NATO yakın zamanda blok zinciri teknolojisi ile ilgilenmeye başlamışlardır. Amerikan Savunma Bakanlığı (Pendagon) blok zinciri teknolojisinden daha çok blok zinciri tabanlı güvenli bir mesajlaşma uygulaması olarak yararlanmak isterken, NATO ise lojistik ve tedarik gibi alanlarda kullanmak istemektedir (Kar, 2016).

Akıllı Kontratlar (Smart Contracts): Blok zinciri teknolojisinin işlevi, katılımcıların arasında gerçekleşen dijital sözleşmelerin blok zinciri üzerinden tanımlanmasına yardımcı olmaktır.


Blok zinciri 2.0 teknolojisiyle beraber en popüler çözüm olan akıllı sözleşmelerdir. Kripto paraları kullanmak isteyen paydaşların arasında imzalanan akıllı sözleşmelerin koşullarının oluşturulması ve takibi kolaydır. Akıllı sözleşmelerin basit yapısına rağmen hedeflenen aksiyonların otomatik olarak oluşturulması bu sistemin popüler olmasını sağlamıştır (Ünsal ve Kocaoğlu, 2018, s. 59).

Nesnelerin İnterneti ve Finansal Dönüşüm (Internet of Things and Financial Transformation): Teknolojinin ve internetin gelişmesiyle birlikte kullanılan cihazlar da akıllanmaya başlamıştır. Günümüzde cihazlar kendi aralarında kolayca iletişime geçebilmektedir. İnternetin yaygınlaşmasıyla beraber akıllı olarak adlandırılan her cihazdan kripto paralara erişim sağlanabilmektedir. Bunlardan biri de kripto para cüzdanlarıdır. Kripto para cüzdanları blok zinciriyle iletişime geçmek için gerekli araçları bulunduran cihazlardır. Kripto para cüzdanları sayesinde kripto paralar taşınabilmekte ve internetin olduğu her yerde kullanılabilir.

Teknolojinin gelişmesinden en çok etkilenen ve değişen sektörlerden biri de finans sektörüdür. Mobil bankacılığın gelişmesiyle birlikte online alışveriş hızla artmış bu da finans sektörünü bir dönüşümle karşı karşıya bırakmıştır. Bu dönüşüm kripto paralar ile beraber daha da hızlanmaya, finansal sektörün tamamen sanallaşmasına yol açmaktadır.

1.9.2. Blok Zinciri Teknolojisinin Geleceği (Future of Blockchain Technology)

İnovasyon sahibi teknolojilerin gelişmelerini izlemek ve öngörülerde bulunabilmek amacıyla başvuru yapılan araçlardan en önemlisi firmalar tarafından yayınlanan araştırma raporlarıdır. Gartner firmasının geliştirdiği “Hype Cycle Metodolojisi”, inovatif teknoloji takibinde kullanılan önemli araçlar arasında yer almaktadır. Mike J. Walker (Gartner'da araştırma direktörü) “Gelişen Teknolojiler için Gartner Hype Döngüsü, çoğu Hype Döngüsü arasında benzersizdir. Çünkü 2.000'den fazla teknolojiden elde edilen içgörüler, bir kuruluşun stratejik planlamasında tek başına en büyük etkiye sahip olacak, bilinmesi gereken yeni teknolojiler ve trendlerden oluşan kısa ve öz bir kümeye dönüştürecektir” demiştir. Hype Döngüsü, özellikle önümüzdeki beş ile 10 yıl içerisinde yüksek derecede rekabet avantajı sağlama konusunda umut vaat eden teknolojilere odaklanmakta olup bunların içine blok zincirini de dahil etmektedir (Gartner, 2016). Şekil 11'de 2016 yılı Hype Cycle for Emerging Technologies grafiğine yer verilmektedir.



Şekil 11. Hype Cycle for Emerging Technologies, 2016 (Gartner, 2016)

1.10. KRİPTO PARALAR VE FİNANSAL PİYASALAR ARASINDAKİ İLİŞKİ

Kripto para birimlerini, değeri banka mevduatları, tahvil ve hisse senetleri gibi sözleşmelerden türeyen varlıklarla mukayese ederek ya da bağdaştırarak somut sonuçların ortaya çıkması beklenemez. Dijital olan bu para birimlerinin parasal otorite üzerindeki etkisi hala bir tartışma konusudur. Fakat, kripto paraların çoğunluğunun yüksek hacimlere ve miktarlara varması olanaklı olabilmektedir. Bu dijital paraların finansal varlıklarla arasındaki en belirgin fark ise “verginin olmaması ya da çok az bir vergiye tabi tutulmasıdır”. Bu ise ülkelerin yönetim kuruluşlarını zor durumda bırakan etkenlerin başında gelmektedir. Finansal piyasalarda bulunan enstrümanların birçoğunda belirli bir zaman aralığında büyük değer değişimleri (volatilité) gözlenmektedir. Kripto paralarda ise bu değişimlerin diğer finansal enstrümanlara bakılarak çok daha az olması bu para birimlerini güvenli bir alan haline getirmektedir. Fakat herhangi bir medya kuruluşlarından yayınlanan bir haberin veya sistemde oluşan teknik bir problemin kripto para fiyatı üzerinde etkisi bu güven ortamında kırılmalara da neden olabilmektedir (Ömrüuzun, 2019, s. 49).

1.10.1. Kripto Paraların Avantajları ve Dezavantajları

Dijital bir para birimi olan kripto paralar, kullanıcılarına birçok avantaj sunarken bu avantajların yanında dezavantajları da bulunmaktadır. Genel anlamda değerlendirilecek olursa, gün geçtikçe kripto paraların çeşitliliğinde ve işlem hacimlerinde büyük artışlar görülmesi avantajlarının ağır basmasına neden olsa da dezavantajlarını da yanında getirmektedir.

Kripto Paraların Avantajları:

Kripto para birimleri doğuşundan bu yana kullanıcılarına birçok avantaj sağlamıştır. Kripto paraların bu avantajları genel olarak aşağıdaki gibi özetlenmektedir (Hendrickson vd. 2016, s. 928).

- Kripto paraların en büyük avantajlarında biri blok zinciri teknolojisidir. Blok zinciri teknolojisinde herhangi bir aracıya gerek duymadan işlem yapılmaktadır. Kripto paralarının blok zinciri sistemine sahip olması bu para birimlerinin güvenilirliğini arttırmakta ve bu dijital paraları saklamak için somut bir finansal kuruma gerek duyulmamaktadır. Yine blok zincirinin yapısı gereği aracı barındırmaması ve merkezi bir otoriteye bağlı olmamasının yarattığı güven ortamında yapılan işlemler anlık olarak takip edilebilmektedir.
- Kripto para sisteminde merkezi bir varlık mevcut değildir. Bir kullanıcının ya da katılımcının ne kadar önem arz ettiği, sisteme temin ettiği bilgi işlem gücü ile ölçülmektedir.
- Kripto paralar çoğunlukla finansal kuruluşlardan ve uluslardan bağımsız olarak hareket etmektedir. Bundan dolayı, çoğu kullanıcı mevcut düzeyci çerçeve dışında hareket etmekte onlara bağımlı kalmamaktadır.
- Kripto para birimleri ile işlemde bulunurken herhangi bir açıklama, raporlama ve büyük çaplı işlemler ile ilgili soruşturma yapılmaz. Kaynağı ne olursa olsun bir yerden iki farklı ülkeye fon gönderme arasında herhangi bir fark yoktur.
- Kripto paralar geleneksel paraların aksine somut bir yapıya sahip değildir. Bu dijital para kullanıcılarının reel hayatta kazançlarını ya da yatırımlarını kullanılabilmesi için geleneksel paraya çevirmesi gerekmektedir. Bu nedenlerden dolayı geleneksel bankacılık sistemlerinde kullanıcıların hesap açıp sanal adresten öteye geçerek bu para birimlerini dönüştürmeleri gerekmektedir.

- Kullanıcılar gerçek hayatta herhangi bir kripto para birimini alabilmek veya transfer edebilmek için kendilerini tanımlamak zorunda değillerdir. Her üretilen kripto para kendine ait bir dijital imzaya sahip olduğu ve bu imza taklit edilemediği için kripto para takas işlemlerinde sahtekarlık yapılamaz.
- İşlem ücreti çok düşük olan bu dijital paralar özellikle uluslararası para transferleri yapılırken kullanıcılarına büyük bir kolaylık ve avantaj sağlamaktadır.

Bu avantajlara ek olarak, kripto paralarda geleneksel paraların aksine enflasyon riski düşüktür. Dolaşımda bulunan gerçek para arzındaki yükseliş enflasyona yol açarken kripto paralarda böyle bir durum söz konusu değildir. Kripto para birimleri ile geleneksel para birimleri karşılaştırıldığında aralarındaki en büyük fark kripto para birimlerinin çöküş riskinin geleneksel paralara bakılarak oldukça az olmasıdır. Geleneksel yani gerçek para birimlerinde meydana gelen çöktümlere hükümet kaynaklı yüksek enflasyon sebep olurken, kripto para birimlerinin herhangi bir merkezi otoriteye bağılı olmaması bu risk ihtimalini oldukça düşürür hatta ortadan kaldırır. Blok zincirinde kriptografi (şifreleme) bulunması gizlilik ve veri bütünlüğü korumasında meydana gelebilecek güvenlik sorunlarını ortadan kaldırır. Kripto paraların dijital bir para birimi olması paraya fiziksel erişimi engeller ve uzaktan ödemeler kolay bir şekilde gerçekleşir (Kenger ve Tokmak, 2018, s. 4700).

Kripto Paraların Dezavantajları:

Bazı ülke yönetimleri kripto para kullanımını engellemek ve önüne geçmek amacıyla önlemler almak istemektedir. Bunun nedeni ise bu dijital paraların birçok avantajının yanında bazı dezavantajlarının da bulunmasıdır. Kripto paraların bu dezavantajları genel olarak aşağıdaki gibi özetlenmektedir (Hendrickson vd. 2016, s. 930-932).

- Kripto paraların en büyük dezavantajlarından biri sistemin kabulüdür, özel işletmelerin birçoğu kripto para birimlerini tanımaktadır. Kripto paralar ile işlem yaparken, bu para birimine güvenmeyen ve bu yüzden kullanmak istemeyen birçok kurum bulunmaktadır.
- Geleneksel para birimleri genellikle devlet merkez bankaları tarafından basılmakta ve devletlerin nezdinde takas durumunda karşılığı bulunmaktadır. Geleneksel para birimlerinin bu özelliğinden dolayı devletler ya da hükümetler bu

para birimleriyle para politikaları oluşturabilmektedir. Fakat kripto paralarda ise merkezi bir yapı olmadığı için hiçbir devlet ya da kurum kripto paralarla para politikası belirleyemez.

- Kripto paralar bağımsız bir para birimi olmasından dolayı, bir ülkenin yönetim kuruluşlarının para politikası oluşturma ya da gelir yükseltme gibi benzeri özelliklerine sahip değildir.
- Geleneksel işlemlerde eğer bir taraf illegal bir işlemde bulunursa finansal hesaplar dondurulabilmekte ve ödemeler tersine çevrilebilmektedir. Hesap sahibi gerçek yani fiziksel dünyada kolayca tanımlanabilmekte kısa süre içerisinde işleme müdahale edilebilmektedir. Kripto paralarda ise bunun tam tersidir. Hesaplar dondurulamaz, işlemler ters çevrilemez ve hesap sahiplerinin tanımlanması çok zordur. Yani sisteme müdahale edilmesi oldukça düşük bir ihtimaldir. Bu da kripto paraların yasadışı işlem için kullanılabilme riskini arttırmaktadır. Meydana gelen problemlerde yasal bir muhatap bulmak oldukça zor hatta imkansıza yakındır çünkü kripto paraların çıkış noktasını tam olarak tanıyıp bilen hiçbir hükümet yoktur.
- Kripto para birimleriyle ödeme yapılabilen ve bu ödemeleri kabul eden yaklaşık 50 adet kumar sitesi mevcuttur. Bu sitelerden en bilineninde ise, kullanıcıların 1-64.000 arasında bir sayıya ulaştığı benzersiz bir bahis adresidir.
- Uyuşturucu ve kumar gibi illegal işlemlere ek olarak, bazı araştırmacılar kripto paraların terör için etkili bir finansman sağlayacağını da düşünmektedir.

Bunlara ek olarak, kripto para birimlerinin işlendiği elektronik platformlarda devamlı olarak güncellemeler yapılmaktadır. Bu da kullanıcıların platformları ve sistemi düzenli bir şekilde yakından takip etmesine engel olacak durumlar yaratabilmektedir. Ayrıca kripto para sistemlerinde bulunan parolalı şifrelemenin en büyük tehlikesi, bu sistemde bulunan paranın devlet nezdince yasaklanma olasılığıdır. Çünkü bu dijital para birimleri para işlemlerine açıktır. Bu tür bir durumla karşılaşılması kullanıcıları, paranın kaybolması ve değersizleşmesi sorunları ile karşı karşıya bırakabilmektedir. Ayrıca kripto para sistemi kullanıcılar hakkında bilgi alımına da izin vermemektedir (Kenger ve Tokmak, 2018, s. 4700-4701).

1.10.2. Kripto Paraların Geleceği

Teknolojinin giderek gelişmesi ve birçok inovasyonun gerçekleşmesi ile birlikte günümüzde her şey dijital bir hal alamaya başladı. Finans dünyasını derinden

sarsan ve dijital bir para birimi olan kripto paralar yeni bir buluş olsa da yüksek potansiyelinden dolayı finans dünyasında büyük değişikliklere yok açmıştır. İlk çıkan kripto para birimi olan Bitcoin oluşturulduğunda geleceği belirsizliklerle doluydu. Bu belirsizlikler alıcıları korkutmakta ve kafa karışıklıklarına sebep olmaktaydı. Ayrıca önünde birçok engel bulunmaktaydı. Günümüzde ise bütün kafa karışıklıkları ve olumsuzluklara rağmen çoğu uzman kripto paraların gelecekte çok daha iyi bir yerde olacağını hatta tüm dünyayı kaplayacağını düşünmektedir. Mevcut durumdaki belirsizlik ise nasıl ve ne şekilde gerçekleşeceği konusundadır.

Bazı ülkelerin yönetim kuruluşları kripto paraların regülasyonu (devletin finansal araçlarla ilgili yaptığı düzenlemeler) ile ilgilenmekteyken bazı ülkeler ise kendi kripto paralarını üretmeyi amaçlamaktadır. Buna en büyük örnek ise bu sanal para teknolojisini kullanmaya ve üretmeye çalışan İngiltere'dir. İngiltere dışında bunu deneyen ve test eden birçok ülke bulunmaktadır. Birçok finans uzmanı ve yatırımcısının görüşüne göre 2030 senesinde dünyada yer alan paraların %25'lik kısmını kripto paralar oluşturacaktır. Uzmanların ve yatırımcılarının düşüncelerinin bu yönde olması ve kripto paralarının geleceğini bu kadar parlak görmesinin ise birçok nedeni bulunmaktadır. Bu nedenlerin en başında kripto paraların "merkezinin olmaması" durumu gelmektedir. Bu yönü ile kripto paralar altına benzetilmektedir. Daha ayrıntılı bir şekilde anlatmak gerekirse tüm dünya da ortak bir değer olan altının doğrudan kontrol edilen bir merkezi yoktur. Fakat merkezinin olmaması manipülasyonlara tamamen kapalı olduğu anlamına da gelmemektedir. Bunun nedeni ise üretiminin sınırlı olmamasıdır. Ancak kripto para birimlerinde bu durum altına bakılarak daha net ve daha katıdır. Gelecek dönemlerde de bu durumun daha da artması beklenmektedir.

Gün geçtikçe kripto paraların yatırımcısı artmaktadır. Bu duruma en büyük etken ise hükümetlerin kripto paraya ilgisinin giderek artmasıdır. İlgi arttıkça daha çok kurumsal firma ve sermaye sahipleri kripto para yatırımını arttırmaktadır. Günümüzde borsa veya forex gibi yatırım platformlarında, yatırımcılar tarafından kripto tabanlı birçok alım satım yapılmaktadır. Hem kredi alınabilmekte hem de kazanç karşılığında bu sanal paralar mevduat şeklinde yatırılabilir. Bu durum ise özellikle finans sektörünün iskeleti olan bankalar için büyük avantaj sağlamaktadır.

Grafik 3'te yer alan kripto para grafiklerinde de görüldüğü gibi kripto para fiyatları zaman içinde ciddi değişimler göstermiştir. Sermaye de veya fiyatta en ufak bir hareketlilik derinlik olmadığından ötürü büyük hareketliklere yol açmıştır. Ancak Bitcoin ne kadar düşüş gösterirse göstereceği her zaman bir öncesinden yer alan fiyatın üzerine çıkmayı başarmıştır. Bu duruma bakılacak olursa önemli yatırımcıların 2022 senesi için bekledikleri 250.000 USD beklentisinin çokta anlamsız olmadığı görülmektedir. Bitcoin'in 1,5 yıl içerisinde 1000 USD'den 20.000 USD'ye yükselmesi de bu potansiyelin bir göstergesidir (Investing.com, 2018).

Ekim 2020 itibarıyla piyasada en yüksek işlem hacmine sahip olan ilk beş kripto paranın geçmişten bugüne kadar geçirdiği gelişim ve önemli fiyat dalgalanmaları Grafik 3,4,5,6 ve 7 de görülmektedir.

1.10.2.1. Geçmişten Bugüne Bitcoin'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları

İlk kripto para birimi olan Bitcoin Grafik 3'de görüldüğü gibi en büyük fiyat ve hacim artışını 2017 Aralık ve 2018 Ocak aylarında yaşamıştır. 2018 Ocak ayından sonra Bitcoin fiyatları düşüşe geçse de 2019 Haziran ayında tekrar bir yükseliş göstermiştir. 2020 Mart ayında tekrar bir düşüş yaşayan Bitcoin mart ayı itibarı ile yükselişini devam ettirmektedir.

Bitcoin'in fiyatı bugün (12.11.2020) 15.772,52 USD ve 24 saatlik işlem hacmi 33.577.347.110 USD dir. Bitcoin, son 24 saatte %92 düşmüştür. Mevcut CoinMarketCap sıralamasına göre Bitcoin, 292.396.775.926 USD piyasa değeri ile 1. sırada yer almaktadır. Dolaşımdaki Bitcoin 18.538.368 coin arzına ve maksimum 21.000.000 BTC coin arzına sahiptir. Bitcoin ticareti için en iyi borsalar şu anda Binance, Huobi Global, CITEEX, Binance.KR ve ZG.com'dur (CoinMarketCap, 2020).

Grafik 3. 29.04.2013-12.11.2020 Dönemi Günlük Bitcoin (BTC) Değişimi
(CoinMarketCap, 2020)



1.10.2.2. Geçmişten Bugüne Ethereum'un Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları

Bitcoin'den sonra en çok işlem hacmine sahip olan Ethereum Grafik 4'de görüldüğü gibi en yüksek işlem hacmi ve fiyat artışını 2017 Temmuz ve 2018 Ocak tarihlerinde yaşamıştır. 2018 Ocak ayından sonra Ethereum fiyatlarında bir düşüş gerçekleşmiş olsa da 2020 Mart ayı itibarı ile fiyatlardaki yükseliş devam etmektedir.

Ethereum'un fiyatı bugün (12.11.2020) 459,39 USD ve 24 saatlik işlem hacmi 14.379.516.723 USD'dir. Ethereum son 24 saatte %0,26 düşmüştür. Mevcut CoinMarketCap sıralamasına göre Ethereum, 52.091.745.576 USD piyasa değeri ile ikinci sırada yer almaktadır. Ethereum 113.396.144 madeni para dolaşım arzına sahiptir ancak maksimum arz mevcut değildir. Ethereum ticareti için en iyi borsalar şu anda Binance, Huobi Global, CITEEX, ZG.com ve Binance.KR'dir. Değişimi (CoinMarketCap, 2020).

Grafik 4. 08.08.2015-12.11.2020 Dönemi Günlük Ethereum (ETH) Değişimi (CoinMarketCap, 2020)




1.10.2.3. Geçmişten Bugüne Ripple (XRP'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları

Ethereum'dan sonra en yüksek işlem hacmine sahip olan Ripple (XRP) Grafik 5'te görüldüğü gibi en büyük fiyat ve işlem hacmi artışını 2017 Temmuz ve 2018 Ocak tarihlerinde yaşamıştır. 2018 Ocak ayından sonra Ripple fiyatlarında bir düşüş gerçekleşmiş olsa da 2018 Aralık ayında tekrar yükseliş göstermiştir. 2018 Aralık ayında yaşadığı düşüşten sonra 2018 Temmuz ayında fiyatlar sabitlenmiş ve günümüze kadar ciddi bir fiyat dalgalanması yaşamamıştır.

XRP fiyatı bugün (12.11.2020) 0,255551 USD ve 24 saatlik işlem hacmi 2.446.233.739 USD'dir. XRP, son 24 saatte %0,58 düşüş göstermiştir. Mevcut CoinMarketCap sıralamasına göre XRP, 11.579.641.371 USD piyasa değeri ile dördüncü sırada yer almaktadır. XRP 45.312.488.850 coin dolaşım arzına ve maksimum 100.000.000.000 XRP coin arzına sahiptir. XRP ticareti için en iyi borsalar şu anda Binance, Huobi Global, ZG.com, Binance.KR ve Bybit'dir (CoinMarketCap, 2020).


Grafik 5. 05.08.2015-12.11.2020 Dönemi Günlük Pipple (XRP) Değişimi (CoinMarketCap, 2020)



1.10.2.4. Geçmişten Bugüne Tether (USDT)'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları

Ripple (XRP)'dan sonra en yüksek işlem hacmine sahip olan Tether Grafik 6'da görüldüğü gibi, fiyatının 1 USD olarak sabitlenmesinden dolayı en istikrarlı kripto para birimi olarak tanımlanabilmektedir. Tether'ın fiyatı bugün (12.11.2020) 1,00 USD ve 24 saatlik işlem hacmi 44.453.283.188 USD'dir. Tether, son 24 saatte %0,03 düşmüştür. Mevcut CoinMarketCap sıralaması, 17.566.480.205 USD piyasa değeri ile üçüncü sırada yer almaktadır. Tether 17.551.209.235 coin dolaşım arzına sahiptir ancak maksimum arz mevcut değildir. Tether'de ticaret için en iyi borsalar şu anda Binance, Huobi Global, Binance.KR, OKEEx ve HBTC'dir (CoinMarketCap, 2020).

Grafik 6. 07.08.2015-12.11.2020 Dönemi Günlük Tether (USDT) Değişimi (CoinMarketCap, 2020)



1.10.2.5. Geçmişten Bugüne Bitcoin Cash (BCH)'in Geçirdiği Gelişim ve Önemli Fiyat Dalgalanmaları

Bugün Bitcoin Cash'in fiyatı 257,76 USD ve 24 saatlik işlem hacmi 1.592.363.248 USD'dir. Bitcoin Cash, son 24 saatte %0,09 düşmüştür. Mevcut CoinMarketCap sıralamasına göre Bitcoin Cash, 4.786.564.917 USD piyasa değeri ile altınca sırada yer almaktadır. Dolaşımdaki Bitcoin Cash 18.570.106 coin arzına ve maksimum 21.000.000 BCH coin arzına sahiptir. Bitcoin Cash ticareti için en iyi borsalar şu anda Binance, Huobi Global, CITEEX, ZG.com ve Binance.KR'dir (CoinMarketCap, 2020).

Tether'dan sonra en yüksek işlem hacmine sahip olan Bitcoin Cash Grafik 7'de görüldüğü gibi en büyük fiyat ve işlem hacmi artışını 2017 Kasım ve 2017 Aralık aylarında yaşamıştır. 2018 Nisan ayında ciddi bir düşüş yaşayan Bitcoin Cash 2018 Mayıs ayına doğru tekrar yükselişe geçmiştir. Bitcoin Cash 2019 Ocak ayından günümüze kadar birçok fiyat dalgalanması yaşasada ciddi bir fiyat dalgalanması meydana gelmemiştir.

Grafik 7. 24.07.2017-12.11.2020 Dönemi Günlük Bitcoin Cash (BCH) Değişimi
(CoinMarketCap, 2020)



İKİNCİ BÖLÜM

YAPAY ZEKA VE DERİN ÖĞRENME

2.1 YAPAY ZEKA (ARTIFICIAL INTELLIGENCE)

İnsanoğlunun hayatına devam edebilmesi için yeni gelişmelere adapte olması gerekmektedir. Bu adaptasyonu sağlayabilmek içinse araç gereçler geliştirmekte ve birçok farklı alanda üretim yapılmaktadır. Sanayi devrimine kadar bu gelişmenin yavaş ilerlemesine rağmen sanayi devriminden sonra gelişim hızı artmıştır. 20. yüzyılda üretilen araç gereçlerin gelişimi insanoğlunun hayatını kolaylaştırmaktan öteye geçerek, insanların yerini alma konusunu gündeme gelmiştir. Günümüzde ise internet ve bilgisayar teknolojilerinin gelişmesi ile birlikte makinelerin işlem kapasitesi de giderek artmaya başlamıştır. İşlem kapasitesinde meydana gelen bu artış makinelerin, insanların düşünce yapısını taklit edip edemeyeceği fikrini gündeme getirmiş ve yapay zeka kavramını ortaya çıkmasına neden olmuştur. İnsan beyin yapısından esinlenerek oluşturulan birçok sinir ağı algoritması üretilmiştir. Günümüzde bu doğrultuda yapılan birçok çalışma ve teknolojik ilerlemelere rağmen, yapay zeka algoritmaları belirli insan davranışlarını kopyalayabilme yeteneğine sahip olsa da mevcut bilgisayar teknolojisiyle insan davranışlarını tamamen simüle etme becerisine sahip olamayacağı açıkça görülmektedir. Ancak günümüzde internet ve veri depolama kapasitesinin oldukça gelişmesi, bir makinenin ihtiyaç duyulan çözümü elde edebilmesini sağlamaktadır.

Yapay zeka kavramını ilk kez, en eski ve en güçlü yapay zeka programlama dilleri arasında yer alan Lisp'i icat eden ve yapay zeka alanının öncülerinden biri olan John McCarthy tarafından 1956 yılında ortaya atılmıştır (Russell ve Norvig, 1995, s. 17-18). Fakat bilindiği üzere yapay zekanın sınırları ve geleceği üzerinde yapılan tahminler doğrudan bilgisayar teknolojisinin gelişimine bağlıdır. Bu yüzden yapay zeka kavramı 20. yüzyılın ortalarında gündeme gelmiş olsa da o dönemde teknolojinin yetersiz kalması gelişimini engellemiştir. Teknolojinin ilerlemesi ile birlikte birçok yapay zeka tekniği üretilmiştir. En popüler olduğu alanlar ise; veri işleme, tıbbi teşhis, görüntü ve ses tanıma gibi alanlardır. Yapay zeka tekniklerinin birçok alanda kullanılması yönünde önemli gelişmeler gerçekleşse de halen birçok

alanda da fikir aşamasında olup günlük hayata geçirilememiştir (Haenlein ve Kaplan, 2019, s. 1-2)

Russell ve Norvig (1995) yapay zekayı, sekiz farklı tanımdan yola çıkarak iki temel boyuta göre Şekil 12’de yer aldığı gibi sınıflandırmışlardır.



Şekil 12. Yapay Zeka Tanımlamaları ve Sınıflandırılması (Russell ve Norvig, 1995)

Sırasıyla birinci boyutta düşünce aşamaları ve mantıkları, ikinci boyutta ise şahıslar ve davranışlar ele alınmıştır. Daha ayrıntılı bir şekilde incelendiği zaman; Turing test yaklaşımı ile insan gibi davranma, bilişsel modelleme yaklaşımı ile insan gibi düşünme, düşünce kanunlarının yasaları ile akılcı düşünce ve akılcı ajan yaklaşımı ile ise akılcı davranış yapıları açıklanmaktadır (Russell ve Norvig, 1995, s. 17-18).

2.1.1. Yapay Zekanın Amacı ve Avantajları

Yapay zekanın ortaya çıktığı ilk andan itibaren temel amacı, zeka kavramının ve insan beyninin biyolojik yapısından yola çıkarak makinelerin zeka yapısını ve düşünme kapasitesini geliştirip insan hayatını kolaylaştırmaktır. Yapay zekanın gelecekteki amacı ise makinelerin "akıllı davranış" sergileyebilir duruma gelmesidir. Akıllı davranış sayesinde, karşılaşılabilecek herhangi bir karmaşık problemde insan zekasının hata yapma olasılığı ortadan kaldırılmaktadır. Bu sayede akıllı davranış yapay zekayı insan zekası karşısında daha avantajlı kılmaktadır.

İnsan zekasının işlem kapasite gücünün çok fazla olmasına karşın duygularla kolay manipüle olması, yapay zekanın insan zekasına büyük avantaj sağlamasına neden olmaktadır. Yapay zekanın diğer bir önemli avantajı ise problem çözümünde büyük kolaylık sağlaması ve oluşturulan bilginin kolayca kopyalanabilmesidir (Yılmaz, 2019, s. 7) Bu avantajlara rağmen yapay zeka insan zekasıyla kıyaslandığı zaman elbette çok daha ilkel yeteneklere sahiptir. İnsan zekasının en büyük avantajı olan duyuları kullanma ve bu duyularla sayesinde yaratıcı çözümler üretme yeteneği yapay zekada bulunmamaktadır.

2.1.2. Yapay Zeka Türleri

Araştırmacılar yapay zekayı, sahip oldukları yeteneklere göre üç gruba ayırmışlardır. Bunlar:

➤ Yapay Dar Zeka

Yapay dar zeka insan zekasının temel özelliklerinin biri ya da daha fazlasının bir makine tarafından taklit edilmesidir. Dar yapay zekanın yetenekleri kısıtlı ve diğer yapay zeka türlerine göre çalışma alanları daha dardır. Günümüzde karşımıza çıkan yapay zeka temelli dijital asistanlar yapay dar zekaya örnektir (Reece, 2020).

➤ Yapay Genel Zeka

Yapay genel zeka güçlü yapay zeka olarak da bilinmektedir. Yapay genel zeka, karşısına çıkan problemi çözerken insan zekasını taklit edebileceği bir makine öğrenme konseptine sahiptir. Bu öğrenme konsepti insan zekasının öğrenme ve problem çözmedeki uygulama yeteneğini kullanacak düzeyde yetenekli bir sistemdir. Yapay genel zeka bir problemi çözerken insan gibi davranarak, sistem denetleyici modellerin insanlardan ayırt edilememesini sağlar (Tunalı, 2020).

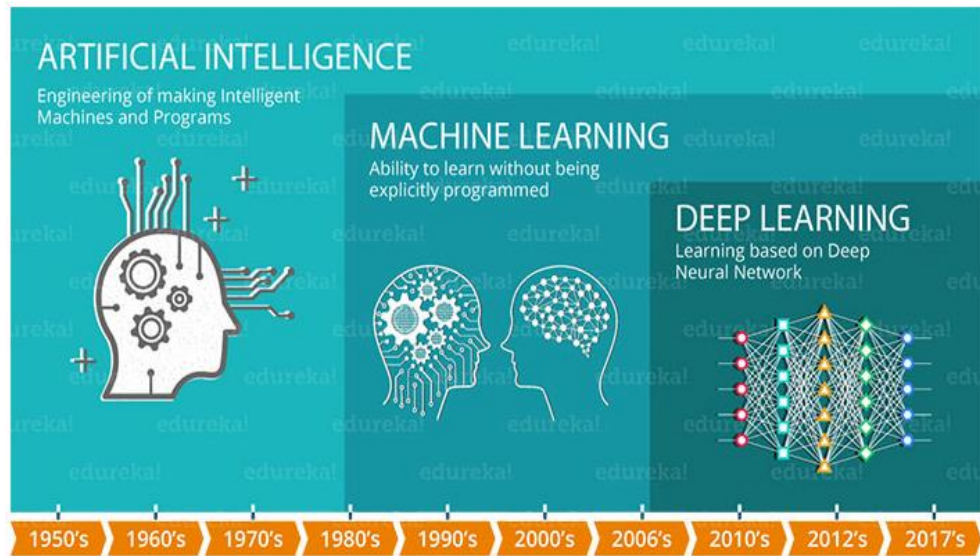
İnsan zekasının bilinç yapısı insanın bir problem karşısındaki davranışlarını içermektedir. Yapay genel zekada amaç insan zekasının bilinç yapısını taklit etmektir. Fakat bu durumun gerçekleşebilmesi için insan zekasının bilinç yapısının tüm detayları ile bilinmesi ve bu bilgileri yapay zekaya aktarmak için programlanabilir olması gerekmektedir. Bu yüzden yapay genel zekanın günümüzde bir örneği bulunmamaktadır. Yapay genel zekanın oluşturulması tekil görevlerde başarıyı artıracaktır ve daha karmaşık problemlerin çözülmesini yardımcı olacaktır (Reece, 2020).

➤ Yapay Süper Zeka

Yapay süper zeka ise yapay genel zekanın daha gelişmiş halidir. Yapay süper zeka, insan zekasını ve insan davranışları taklit etmekle kalmayıp problem çözerken çevreyle etkileşimde bulunarak zeka gelişimini sürdürmeye devam etmesi beklenen sistemlerdir (Yampolskiy, 2015, s. 6).

2.2. DERİN ÖĞRENME (DEEP LEARNING)

Derin öğrenme insan beyninden ve yapay sinir ağlarından esinlenen algoritmaların veriden öğrendiği bir makine öğrenmesi alt dalıdır. Makine öğrenmesi modelleri veriler ile eğitilerek elde ettiği bilgiler sonucunda tahminlerde bulunabilmektedir. Derin öğrenme ise daha karmaşık problemlere ait büyük veri yapılarına çözüm üretebilmektedir. Bu büyük veri yapıları, birden fazla algoritma ve yapay sinir ağından yararlanılarak eğitilmekte ve eğitim sonucunda tahminler elde edilmektedir (Alpaydın, 2011). Örneğin; bir kedi ile köpek ayrımı makine öğrenmesiyle yapılmak istediğinde kedi ve köpeğe ait tüm parametreler makineye tanıtılır. Daha sonra gösterilecek olan resmin kedi mi köpek mi olduğunu makinenin ayırt etmesi ve tanınması beklenir. Derin öğrenme de ise binlerce kedi ve köpek resmi gösterilerek makinenin herhangi bir parametreye ihtiyacı olmadan resimleri ayırt etmesi beklenir. Şekil 13'te yapay zeka, makine öğrenmesi ve derin öğrenmenin kronolojisine yer verilmektedir.



Şekil 13. Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi (IEEE, 2020)

Derin öğrenmedeki asıl amaç, insan beyninden esinlenerek oluşturulan algoritmalarla, daha iyi bir sonuç elde etmek için her seferinde yapılan hataları azaltıp gerekli olan değişiklikleri yaparak daha iyi bir sonuç elde etmektir (Marr, 2018). Derin öğrenme, nitelik çıkarma ve dönüştürme amacıyla birden çok doğrusal olmayan işlemci katmanı kullanılmaktadır. Ardışık olan her katman, önceki katmanda yer alan çıktıyı girdi olarak işleme dahil etmektedir (Deng ve Yu, 2014).

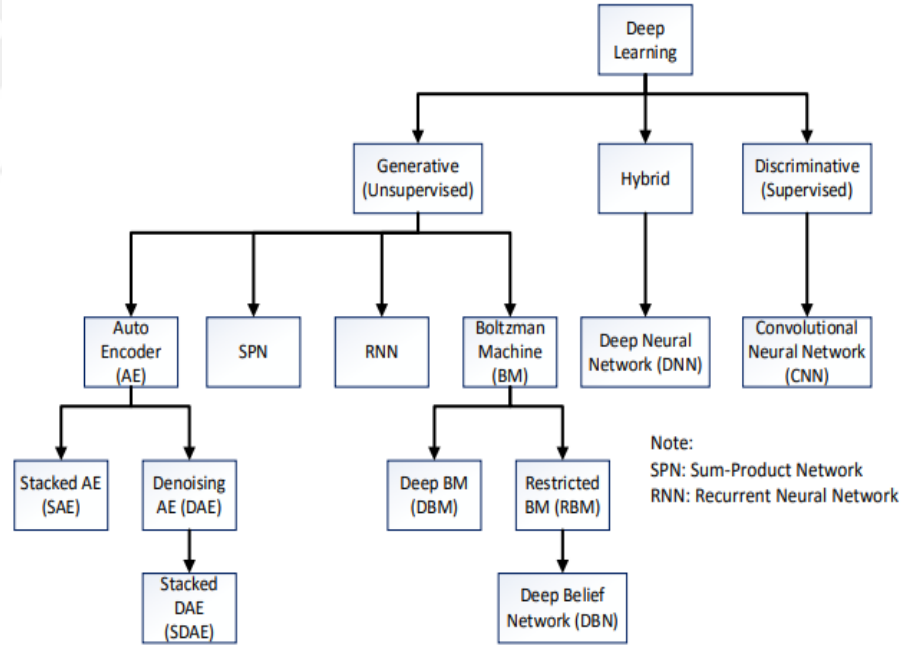
Derin öğrenmenin yapısı, elde bulunan verilerin birçok nitelik seviyesine ya da bu nitelik seviyelerini etkileyen ikincil nitelikleri öğrenmesine dayanmaktadır. Derin öğrenme yapı olarak yüksek nitelik seviyesine sahip veriler ve düşük nitelik seviyesine sahip verilerden bir kompozisyon oluşturur. Oluşturulan bu ortak veri kümesi insan beyin yapısından farklı olarak modelde elde edilen verileri de girdi olarak kullanarak derin bir öğrenme sağlar. Makine öğrenmesini devamı ve gelişmiş hali olan derin öğrenmenin başarı oranının artması ise veri miktarının fazlalığına bağlıdır (Bengio, 2009, s. 6). Ancak derin öğrenmede başarı oranı verilerin miktarına bağlı olsa da çalışılan modelde ana değişkene ait örnek uzaydaki tüm veriler elde edilemeyebilir. Bu tarz durumlarda modelin eğitiminde kullanılan verilere temsil verileri denilmektedir. Model eğitiminde temsil verilerinden yararlanırken hiyerarşik özellik çıkarımını ortaya koyan mimariler kullanılmaktadır (Song ve Lee, 2013, s. 466).

Derin öğrenme sistemlerinde, öğrenme ve karar verme aşamasında elde edilen niteliklerden benzer olanların birleştirilmesine alt küme (Pooling) oluşumu denilmektedir. Çok sayıda farklı verinin bütün nitelikleri tamamen aynı olamayacağından dolayı bu aşama çok önemlidir. Elde edilen alt kümelerin stokastik (rastlantısal) olarak elenmesine ise silme (drop out) adı verilmektedir. Bu işlem ile birlikte ilişkisi zayıf olan bağlar koparılır (Zocca vd., 2017). Derin öğrenme sistemlerinde bulunan öğrenme ve karar verme aşamalarına bakıldığında zaman aşığıda yer alan bileşenlerin öğrenme ağlarının tümünde bulunduğu sonucuna varılabilmektedir (Patterson vd., 2017).

- ✓ Parametreler
- ✓ Katmanlar
- ✓ Aktivasyon fonksiyonları
- ✓ Zarar fonksiyonları

- ✓ Optimizasyon yöntemleri
- ✓ Hiper parametreler

Derin öğrenme ilk olarak ham veriyi etiketlendirmek için gözetimsiz eğitimden yararlanmaktadır. Sonrasında ise modelin eğitimi tamamlanırken gözetimli eğitim sürecine geçmektedir (Alpaydın, 2011). Gizli katmaların sınırlarını aşmak için çeşitli derin öğrenme metotları uygulanmaktadır. Temel olarak bu metotlar ardışık gizli katmanları hiyerarşik bir yapıya dahil etmektedir. Birçok derin öğrenme metodunda asıl amaç sınıflandırmadır. Deng (2014, s. 1) sınıflandırma için bazı özellikler belirlemiştir. Bu özelliklere göre derin öğrenmeyi üç gruba ayırmıştır. Bunlar; *üretici* (verilerden bir şeyler üretenlere), *ayırıcı* (verileri sınıflandıran ya da kümeleyenlere) ve *hibrit sistemler* (her ikisini de kullanan) dir. Derin öğrenme yöntemlerinin sınıflandırılması Şekil 14’te yer almaktadır (Aminanto ve Kim, 2016, s. 4).



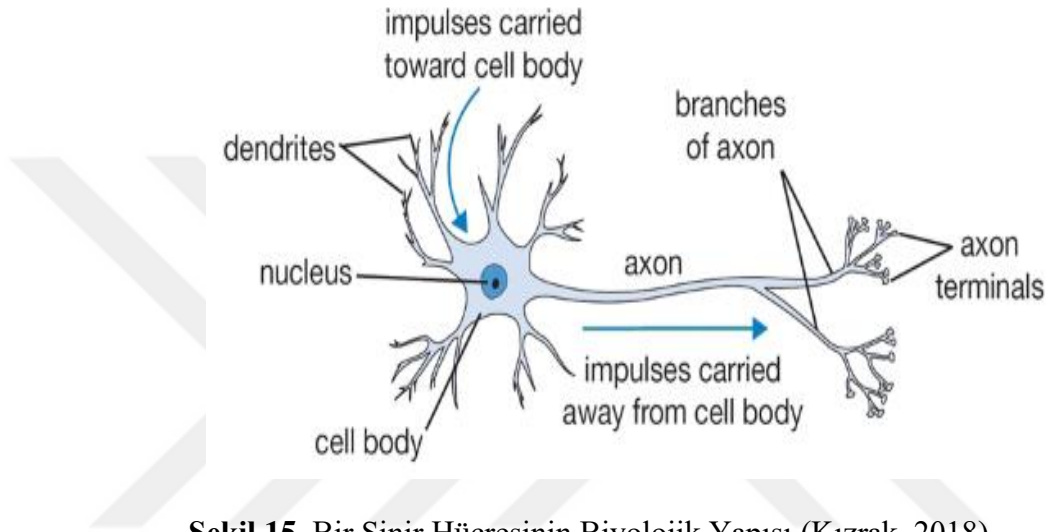
Şekil 14. Derin Öğrenme Yöntemlerinin Sınıflandırılması (Aminanto ve Kim, 2016, s. 4)

2.3. DERİN ÖĞRENMENİN TEMEL KAVRAMLARI

Bir derin öğrenme modelinde kullanılan sinir ağlarını oluşturan birden fazla faktör bulunmaktadır. Bu bölümde ise bu faktörlere yer verilmektedir.


2.3.1. Nöron

Sinir ağları temel yapısını oluşturan nöronlar insan beyninin biyolojik yapısından esinlenerek oluşturulmuştur. İnsan beyni güncel bir bilgi aldığı zaman bu bilgiyi işleyerek çıktıya dönüştürür. Nöron ağlarında ise yeni bilgi girdi olarak alınır ve işlenir. Ardından sıradaki işlemler için diğer nöronlara aktarılan bir çıktı veya sonuç çıktısı üretir. Şekil 15’de insanlarda yer alan bir sinir hücresinin biyolojik yapısı gösterilmektedir.



Şekil 15. Bir Sinir Hücresinin Biyolojik Yapısı (Kızırak, 2018)

Yapay sinir ağlarının en küçük parçasını perseptron (perceptron) lar oluşturmaktadır. İlk olarak 1957 senesinde Frank Rosenblatt’ın tanımladığı lineer fonksiyon Şekil 16’da ki gibi ifade edilmektedir.



Şekil 16. İnsandaki Bir Sinir Hücresinin Matematiksel Modeli (Kızırak, 2018)

Şekil 16’de gösterilen matematiksel modelde yer alan y değeri Eşitlik 1’deki formülle hesaplanmaktadır.

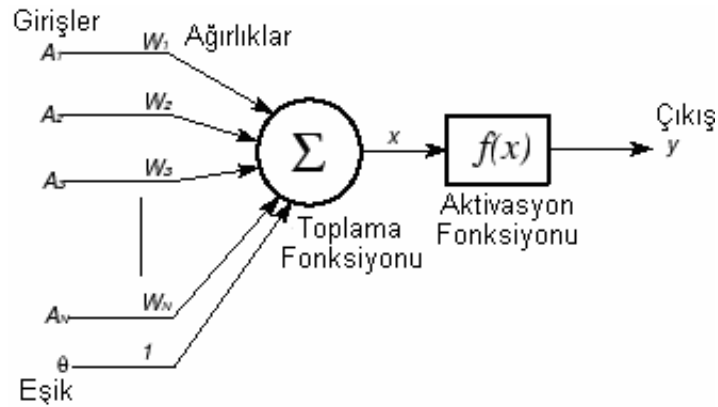
$$y = w * x + b \quad (1)$$

Eşitlik 1’de bağımlı değişken olan y girdiye ait skorunu, x bağımsız değişkeni, w ağırlık parametresini ve b ise bias değerini ifade etmektedir.

Yapay sinir ağları ve derin öğrenme mimarilerindeki temel amaç; oluşturulan modeldeki en iyi sonucu verecek olan w (ağırlık parametresi) ve b (bias değeri) değerlerini elde etmektir.

2.3.2. Ağırlıklar

Bir sinir ağında modelin eğitimi başlatıldığında her giriş için rastgele ağırlıklar atanmaktadır. Modelin eğitiminde kullanılan her girdi nörona ulaştığında bu ağırlıklarla çarpılmaktadır. Her bir girdiye verilen ağırlık katsayısı onun model için önem derecesini göstermekte ve bu ağırlıklar eğitim sürecince güncellenmektedir. Modelin eğitimi bittiğinde model başarı oranı gözden geçirilerek önem derecesine göre ağırlıkları arttırılmakta ya da azaltılmaktadır. Eğer önemsiz olduğu düşünülen girdi var ise bu girdinin ağırlığı sıfır olarak tanımlanmaktadır. Bir A_i girdisine atanan ağırlık değeri w_i ise düğümden sonra girdi $A_i * w_i$ olarak işleme dahil olmaktadır (Yılmaz ve Kaya, 2019, s. 6). Şekil 17’de yer alan şekilde bir yapay sinir ağının temel öğeleri gösterilmektedir.



Şekil 17. Yapay Sinir Ağının Temel Öğeleri (Zafari vd., 2013, s. 2)

2.3.3. Sapma (BIAS)

Modelin eğitim aşamasında girdinin ağırlıkla çarpılmasına doğrusal bileşen olarak sapma (bias) değeri eklenmektedir. Sapma değerinin eklenmesi aktivasyon

fonksiyonunun belirtilen aralıklar arasında hareket etmesine olanak sağlamaktadır. Sapma değeri girdi değerini etkilememektedir. Bu yüzden modelin eğitilmesinde hiçbir etkisi yoktur. Fakat sapma değeri modelin eğitim sonucunda verdiği çıktı değerini etkilemektedir. Bu değer eklendiği zaman giriş “ $A_i * w_i + \text{sapma (bias)}$ ” şeklinde tanımlanmaktadır. Bu girdi ise döngünün “son doğrusal bileşeni” dir. Sapma değerinin kullanılma amacı eğitim sonucunu daha iyi hale getirmektir (Çarkacı, 2017).

2.3.4. Aktivasyon Fonksiyonları

Derin öğrenme modelinin doğrusal olmayan problemleri çözmesi için aktivasyon fonksiyonları kullanılmaktadır. Yapay sinir ağının eğitilmesinde x değişkeni girdi, w değişkeni de ağırlık olarak tanımlanmaktadır. Ağın eğitimi için ağın çıkışına aktarılan değere, $f(x)$ olarak ifade edilen aktivasyon işlemi uygulanır. Aktivasyon işleminin ardından elde edilen çıkış değerleri ise başka bir katmanda girdi olarak tanımlanır. Bu işlem uygulanmaz ise çıkış olarak öğrenim gücü kısıtlı olan basit bir doğrusal fonksiyon elde edilir. Doğrusal fonksiyonlar tek dereceli polinom olduğu için görüntü, video, yazı ve ses işleme gibi gerçek dünyaya ait karmaşık problemlerin çözümünde yetersiz kalırlar. Bundan dolayı doğrusal olmayan karmaşık problemlerin çözümünde aktivasyon fonksiyonları kullanılmaktadır (Kızrak, 2018). Tablo 3’de aktivasyon fonksiyonlarının başarı oranları, Tablo 4’te ise aktivasyon fonksiyonlarının matematiksel ifadeleri verilmiştir.

Tablo 3. Aktivasyon Fonksiyonlarının Başarı Oranları (Kızrak, 2018)

Aktivasyon Fonksiyonu	Test Başarımı	Test Yitimi
Sigmoid Fonksiyon	0.9866	0.0567
Hiperbolik Tanjant Fonksiyonu	0.9905	0.0474
ReLU	0.9929	0.0401
Leaky (Sızıntı) ReLU	0.9925	0.0403
Swish Fonksiyonu	0.9922	0.0412

Tablo 4. Aktivasyon Fonksiyonlarının Matematiksel İfadeleri (Kızrak, 2018)

Aktivasyon Fonksiyonu	Denklem	Aralık
Doğrusal Fonksiyon	$f(x) = x$	$(-\infty, \infty)$
Basamak Fonksiyonu	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ 1 & \text{için } x \geq 0 \end{cases}$	$\{0,1\}$
Sigmoid Fonksiyon	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0,1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	$(-1,1)$
ReLU	$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$[0, \infty]$
Leaky (Sızıntı) ReLU	$f(x) = \begin{cases} 0.01 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Swish Fonksiyonu	$f(x) = 2x\sigma(\beta x) \begin{cases} \beta = 0 & \text{için } f(x) = x \\ \beta \rightarrow \infty & \text{için } f(x) = 2\max(0, x) \end{cases}$	$(-\infty, \infty)$

Aktivasyon fonksiyonlarının kullanımlarında kesin bir doğru bulunmamaktadır. Her fonksiyonun kendine ait avantaj ve dezavantajları vardır. Aktivasyon fonksiyonu seçerken yapay öğrenme modeline göre karar verilmektedir. Örneğin; hiperbolik tanjant fonksiyonu daha geniş aralıklarda aktive olurken sigmoid fonksiyonu ise daha yavaş öğrenme hızına sahiptir. Eğitilecek ağ derin, veri boyutu büyük ve bunlardan dolayı işlem yükü fazla ise ReLU tercih edilmektedir. Aktivasyon fonksiyonlarını seçmek eğitilecek yapay öğrenme modelinin optimizasyonu için kritik bir işlemdir. Bundan dolayı yapay öğrenme modelinin eğitimi için modelinin ihtiyaç duyduğu gereksinimleri iyi bilmek gerekmektedir (Kızrak, 2018).


2.3.5. Sinir Ağı

Derin öğrenmenin temeli nöral ağlara dayanmaktadır. Nöral ağların temel amacı, tespit edilemeyen bir problemin çözümünü bulmak için çözüm fonksiyonu üretmektir. Sinir ağlarında bulunan katmanlar aynı doğrultuda birbirleri ile bağlantılı olan nöronlardan meydana gelmektedir. Nöronların her biri ise eğitim esnasında hata değerlerine bağlı bulunarak yenilenen b (sapma-bias) ve w (ağırlık) değerlerine sahiptir. Aktivasyon fonksiyonunun görevi ise, çıktının oluşumunu sağlayan doğrusal kombinasyonun, doğrusal olmayan problemleri tanıtmaya yardımcı olmaktadır.

Modelde kullanılan tüm nöronlar birlikte çalışarak ağı girilen veriyi eğitip doğru çıktıyı vermektedir (Yılmaz ve Kaya, 2019, s. 10).

2.3.6. Sinir Ağı Katmanları

Bir sinir ağı üç temel katmandan oluşmaktadır. Bunlar sırasıyla; girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı katmanı (output layer)'dir. Ağın girişi (ilk katman) olan katman *girdi katmanıdır*. Girdi katmanı modele girilen verileri ağırlıklandırarak *gizli katmana* ulaşmasına aracılık etmektedir. Girdi katmanı probleme etki eden parametrelerden oluşmakta ve bu katmanda bulunan nöron sayısı değişken sayısına göre tayin edilmektedir (İslamoğlu, 2015, s. 181). Bir sinir ağının son aşamasında ise gizli katmanda bulunan veriler çıktı katmanına iletilir. Veriler bu katmanda işlenerek nihai sonuç verileri elde edilir (Erdoğan ve Özyürek, 2012, s. 88). Şekil 18'de tek gizli katmanlı ve çok katmanlı sinir ağı yapısına bir örnek gösterilmiştir.



Şekil 18. Tek Gizli Katmanlı ve Çok Katmanlı Sinir Ağı Yapısı (Kızrak, 2018)

Basit bir yapay sinir ağı modelinde x girdi değerlerini, w ağırlıkları ve $f(x)$ çıktı değerlerini ifade etmektedir. Ağın çıktı değerine uygun görülen aktivasyon işlemi uygulandıktan sonra çıkan sonuca göre işlem sonlandırılmakta veya farklı bir katmanın girişi yapılmaktadır (Kızrak, 2018).

2.4. DERİN ÖĞRENMENİN TEMELLERİ

Yapay zeka alt dallarından biri olan derin öğrenmeyi tam anlamıyla kavramak için daha kapsayıcı olan ve derin öğrenmenin temelini oluşturan makine

öğrenmesinin bilinmesi gerekmektedir. Bundan dolayı aşağıda makine öğrenmesine ve türlerine yer verilmektedir.

2.4.1. Makine Öğrenmesi

Makine öğrenmesi kavramı ilk olarak 1959 senesinde Arthur Samuel tarafında ortaya atılmıştır. Makine öğrenmesi genel olarak akıllı ve başarılı çıkarımlarda bulunabilen, kendisine verilen problemleri kapsamlı bir şekilde ele alarak sonuca gitme becerisine sahip olan bir yapay zeka sınıfıdır. Arthur Samuel'in yazmış olduğu dama oyunu algoritması, yaptığı hatalardan ders çıkaran bir algoritmadır. Bu algoritmanın çoğunlukla kullanıldığı alan ise resim tanımlama alanıdır. Resim tanımlama alanı; makine öğrenmesinde yer alan algoritmaya çok sayıda nesne resmi ya da canlı resmi parametreleri tanımlanır. Parametrelerin eğitimi sağlandıktan sonra daha önce görmediği bir resim sunulduğunda makinenin hangi resme ait olduğunu tanımlayabilmesi beklenir. Bunun temelinde ise makinelerin kendi kendilerine karar verebilir hale getirilmesi düşüncesi yatmaktadır. Başka bir şekilde ifade edilecek olursa, makine ve bilgisayarda bulunan komutların, sadece modelleri veya verilen görevleri yerine getiren bir mekanizma değil, insanlar gibi geçmişten çıkarımlarda bulunarak karar verebilen bir mekanizma olması beklenmektedir (Boyras, 2019, s. 14).

Bunları teknik bir şekilde ifade etmek gerekirse, makine öğrenmesi karşılaştığı bir problemde, çözümüne dair çeşitli kuramlar ve teknikler geliştirerek bunun üzerine mantıksal işlemler gerçekleştirebilen, bilgisayar veya makinelerin çeşitli yöntemlerle elde ettiği verileri öğrenerek ve bunlardan yararlanarak çeşitli matematiksel algoritma ve modeller ile anlamlı çıkarımlarda bulunabilen bir yapay zeka türüdür. Kısacası makine öğrenmesi bir problemi çözmek için insanlara benzer bir şekilde geçmiş deneyimlerden yardım almaktadır. Sonrasında ise öğrenme algoritmalarından yararlanarak veriler arasında bağlantı kurup çözülmesi gereken probleme uygun bir model üreterek nihai sonuca ulaşmaktadır (Gezer ve Saylan, 2017, s. 55).

2.4.2. Makine Öğrenmesi Türleri

Makine öğrenmesi türleri gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üçe ayrılmaktadır:

➤ Gözetimli Öğrenme

Modelin eğitilmesi için yeterli verinin olduğu durumlarda gözetimli öğrenme kullanılmaktadır. Gözetimli öğrenmedeki amaç hazır olarak bulunan verilerle belirli problemleri çözmek için model ya da fonksiyon üretmektir. Bu öğrenme tekniğinde daha önceden girdi olarak tanımlanmış veriler ile ulaşılmak istenen çıktı değerleri arasında bir eşleşme fonksiyonu üretilir. Bu süreçte hem girdide hem de çıktıda elde edilen verilerle modelin eğitimi sağlanır (Mitchell, 1997, s. 367).

➤ Gözetimsiz Öğrenme

Modelin eğitimi için hâlihazırda yeterli veri bulunmuyorsa gözetimsiz öğrenme kullanılmaktadır. Gözetimsiz öğrenmedeki amaç ise, daha önce hiçbir veri ön işleme işlemine tabi tutulmamış ham verileri model eğitiminde kullanarak problemlerdeki bilinmeyen yapıları çözmek için fonksiyonlar üretmektir. Gözetimsiz öğrenmede ham verilerde hiçbir sınıflandırma işlemi yapılmadığı için girdi ve çıktılarının hangi sınıfa ait olduğu belirsizdir (Mitchell, 1997, s. 368).

➤ Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, davranışçılığı (bir eğitim sürecinde en iyi sonuca ulaşana kadar eğitimin devam etmesi) temel almaktadır. Pekiştirmeli öğrenme problem çözmek için oluşturulan modellerde en doğru sonuç ve en büyük başarıya ulaşmayı amaçlar. Bu öğrenmede model bulunduğu ortam ile etkileşime geçebilmektedir. Ayrıca sistem sonuçlara göre karar verebilme yeteneğine sahiptir. Pekiştirmeli öğrenme modelinde fazla veri kullanılmaz fakat eğitim sürecinde model doğru işliyorsa veri eklenebilir. Bu yönden modelin eğitimine dışarıdan müdahale edilebilmektedir. Pekiştirmeli öğrenmeyi gözetimli öğrenmeden ayıran en önemli özellik ise tüm verilerin birden verilmeyip uzman tarafından bölünerek başarı oranına göre sırayla verilmesidir (François-Lavet vd., 2018, s. 94-96)

2.5. DERİN ÖĞRENME KÜTÜPHANELERİ VE YAZILIMLARI

Derin öğrenme temelde problemlerin çözümü için programlama dillerini kullanarak yapay sinir ağlarının tasarlanmasına ve eğitilmesine olanak sağlamaktadır. Derin öğrenme yöntemlerinde kullanılması amacıyla oluşturulan birçok kütüphane ve yazılım vardır. Genellikle tercih edilen derin öğrenme yapılarından birkaçı;

Caffe2, Bilişsel (algısal) Araç Setleri (CTNK), PyTorch, TensorFlow'dur. Bu yapılar çoklu Grafik İşlemci Birimleri (GPU)'nden yararlanarak yüksek performans sağlamaktadır. Ayrıca cuDNN ve NCCL gibi grafik işlemci birimini hızlandıran kütüphaneleri kullanarak daha hızlı bir eğitim olanağı sunmaktadırlar. Tablo 5'de sıklıkla kullanılan kütüphanelerden birkaçının temel bilgilerine yer verilmiştir.



Tablo 5. Derin Öğrenme Kütüphaneleri (Cireşan vd., 2011)

Kütüphane	Programlandığı Dil	Geliştirici	Öne Çıkan Özellikleri
Theano	Phyton	MILA Lab	<ul style="list-style-type: none">• Öğreticileri (tutorial) çok etkilidir.• Keras Blocks gibi API sayesinde matematiksel hesapları kolaylaştırır.• GPU desteği içerir.
Caffe	Phyton	Berkeley Vision and Learning Center (BVLC)	<ul style="list-style-type: none">• Caffe Model Zoo üzerinden indirilebilecek ve hemen kullanılacak önceden eğitilmiş ağırları bulundurmaktadır.• İleri beslemeli ağırlar ve görüntü işleme konularında oldukça hızlıdır.• GPU desteği içerir.
Caffe2	Phyton	Facebook	<ul style="list-style-type: none">• Phyton API ile C++ desteği sağlar.• Berkeley yazılım dağıtım lisansı bulunmaktadır.• GPU desteği içerir.
Torch/PyTorch	Lua/Phyton	Ronan Collobert, Clement Farabet	<ul style="list-style-type: none">• Algoritmaları oluşturma konusunda maksimum esnekliğe ve hıza sahiptir.• GPU desteği içermektedir.• (CUDA) kullanıcı dostu arayüze sahiptir.• Birçok modül parçayı birleştirmek ve yeni katmanları yazıp GPU üzerinde çalıştırması kolaydır.• Çokça önceden eğitilmiş model bulunmaktadır.
Digits	C++	NVIDIA	<ul style="list-style-type: none">• Çoklu GPU sistemleri üzerinde sinir ağı tasarımı ve eğitimi yapabilmektedir.• Gelişmiş görselleştirmelerle performansı gerçek zamanlı olarak izleme olanağı sağlar.• Tamamen etkileşimlidir.
TensorFlow	Phyton	Google	<ul style="list-style-type: none">• Tek bir API ile bir masaüstü, sunucu veya mobil cihazdaki bir veya daha fazla CPU'ya veya GPU'ya dağıtım olanağı sağlamaktadır.

			<ul style="list-style-type: none"> • Hızlı derleme yapabilmektedir. • Tensorboard ile görselleştirme yapabilmektedir. • Veri ve model paralelliği sağlamaktadır.
DeepLearning	Java	Adam Gibson	<ul style="list-style-type: none"> • JVM tabanlıdır.
KNET	Julia	Deniz Yuret	<ul style="list-style-type: none"> • Kolay anlaşılırdır. • Kısa kodlama yeteneğine ve ifade gücüne sahiptir. GPU desteği içerir.
Keras	Phyton	Francois Chollet-Google	<ul style="list-style-type: none"> • Torch kütüphanesinden esinlenilmiş sezgisel bir API'dır. • Theano, TensorFlowi Deeplearning4j ve CNTK arkaplanında kullanılmaktadır. • Hızlı büyüyen bir yapıya sahiptir. • GPU veya CPU'da paralel çalışabilmektedir.

Tablo 5'de ele alınan kütüphanelerden TensorFlow, Torch, Knet, Caffe ve Theano için çalışma zamanı performansının karşılaştırılmasına Tablo 6'da yer verilmiştir.

Tablo 6. Kütüphanelerin Çalışma Zamanı Performansının Karşılaştırılması (Cireşan vd., 2011)

Model	Veri Kümesi	Knet	Theano	Torch	Caffe	TensorFlow
LinReg	Housing	2.84	1.88	2.66	2.35	5.92
Softmax	MNIST	2.35	1.40	2.88	2.45	5.57
MLP	MNIST	3.68	2.31	4.03	3.69	6.94
LeNet	MNIST	3.59	3.03	1.69	3.54	8.77
CharLM	Hiawatha	2.25	2.42	2.23	1.43	2.86

Tablo 6'da verilen kütüphanelerin çalışma zamanı performansları incelendiğinde en yavaş çalışan kütüphanenin TensorFlow, en hızlı çalışan kütüphanenin ise Theano olduğu sonucuna varılmaktadır.


2.6. DERİN ÖĞRENME MİMARİLERİ

Birçok derin öğrenme mimarisi bulunmaktadır. Bunlardan bazıları; Evrişimli Sinir Ağları olarak da bilinen Konvolüsyonel Sinir Ağları (Convolutional Neural

Networks-CNN), Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN), Uzun Kısa Dönemli Bellek (Long / Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU)'dir. Bu çalışmanın analiz kısmında geleneksel sinir ağlarından farklı olan ve onların eksikliklerini tamamlayan RNN'in özel bir türü olan LSTM ve daha küçük ve daha seyrek veri kümelerinde başarı oranı yüksek olan GRU modellerinden yararlanılmıştır.

2.6.1. Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN)


Tekrarlayan sinir ağları 1980 senelerinde Basit Tekrarlayan Ağ (Simple Recurrent Network) olarak ortaya çıkmıştır. 1990 senelerinde ise Jeff Elman Tekrarlayan sinir ağları (RNN) nı önermiştir. RNN'in temel yapısı sıralı bilgileri kullanmaya dayanmaktadır. Elman 1990 yılında geliştirdiği cümle simülasyonunda kelimeleri isim ve fiil şeklinde sınıflandırmıştır (Elman, 1990). Bu sistemi kısaca anlatmak gerekirse; bir insan bir kitabı veya bir yazıyı okurken mevcut yazıda yer alan bir cümleyi ondan önceki cümlelerle bağdaştırıp anlamlandırabilmektedir. Daha önce okuduğu bilgiler silinip, her seferinde okuma işlemini başa sarmaz. Kısacası insan beyni anlama ve öğrenme işlevini bu şekilde gerçekleştirmektedir. Geleneksel sinir ağları ise bu şekilde çalışmaz. Bu yüzden bu soruna çözüm yolu olarak RNN geliştirilmiştir. RNN, bilginin kalıcı olmasını sağlayan, içlerinde döngüler bulunduran bir ağıdır (Colah's Blog, 2015). Şekil 19'da bir girişi ve bir çıkışı bulunan RNN yapısı gösterilmektedir.



Şekil 19. Tekrarlayan Sinir Ağlarının Döngüleri (Colah's Blog, 2015)

Şekil 19'da yer alan diyagramda, bir sinir ağı parçası olan A, bazı x_t girişlerine bakarak bir h_t değeri oluşturur. Döngü, bilgilerin ağı bir adımından diğerine aktarılmasına izin verir. RNN, her biri bir sonrakine mesaj ileten aynı ağı


birden fazla kopyası olarak da düşünülebilir. Şekil 20’de yer alan döngünün açılmış hali gösterilmektedir.



Şekil 20. RNN’e Ait Çoklu Döngüler Yapısı (Colah’s Blog, 2015)

Bu zincir benzeri RNN yapısı, tekrarlayan sinir ağlarının diziler ve listelerle yakından ilişkili olduğunu ortaya koymaktadır. Bu tür veriler için kullanılacak sinir ağının doğal mimarisidir (Colah’s Blog, 2015).

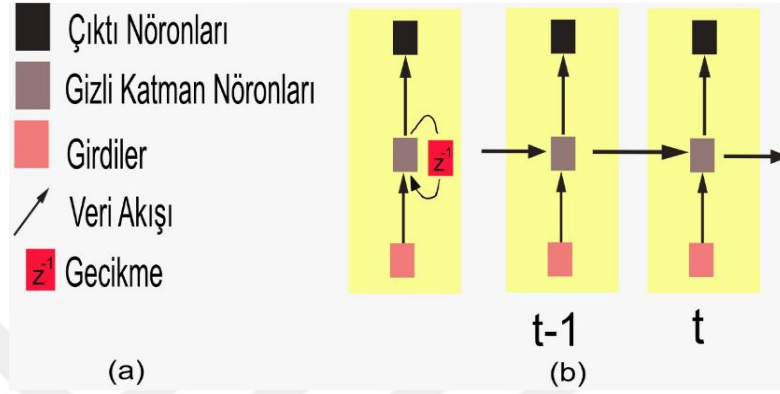
Geleneksel bir sinir ağında yer alan bütün girdi ve çıktıların ise birbirinden bağımsızlığı söz konusudur. RNN mimarisinin yinelenen sinir ağı olarak tanımlanmasının nedeni ise, bir dizide yer alan her öge için aynı görevi önceki çıktılara bağlı gerçekleştirmesidir. RNN mimarisinin çalışma prensibi Şekil 21’de gösterilmektedir (Gürbüz, 2018).



Şekil 21. Tekrarlayan Sinir Ağları (Recurrent Neural Networks) (RNN) Mimarisi (Spirina, 2018)

Tekrarlayan Sinir Ağları mimarisinin bir giriş katmanı, iki gizli katmanı ve bir çıkış katmanı bulunmaktadır. Bu katmanlar hepsinin kendine özgü bir çalışma prensibi vardır ve her birinin işlevi farklıdır. Yani birbirinden bağımsız bir şekilde çalışmaktadırlar. Daha detaylı bir şekilde anlatmak gerekirse her katmandaki

yapıların kendine özgü bir ağırlığı vardır ve her birine ait bir eşik değeri tayin edilir. Bu yapı sayesinde sistemin daha iyi sonuçlar vermesi beklenir. Tekrarlanan adımlar neticesinde bir öncesinde yer alan giriş durumu depolanır ve bulunan yeni giriş değerleri ile birleştirilir. Bunun sonucunda yeni bulunan girişin bir öncesinde yer alan giriş ile ilişkisi sağlanmış olur (Spirina, 2018).



Şekil 22. Bir Gecikme Hattına Sahip Normal Tek Yönlü bir RNN'nin Genel Yapısı (Schuster ve Paliwal, 1997, s. 2674)


Şekil 22’de ise (a) bir gecikme hattına sahip ve (b) iki zaman adımı için zaman içinde açılmış temel bir RNN mimarisi gösterilmektedir. Bu yapıda, girdi vektörleri RNN’de birer birer beslenir. Çok Katmanlı Algılayıcılar (Multi-Layer Perceptron) (MLP) ve Zaman Gecikmeli Sinir Ağı (Time Delay Neural Network) (TDNN) yapılarında yapıldığı gibi sabit sayıda giriş vektörü kullanmak yerine, bu mimari y_{t_c} tahmin etmek için mevcut zaman çerçevesine kadar t_c (i.e., $\{x_t, t=1, 2, \dots, t_c\}$) mevcut tüm giriş bilgilerinden yararlanabilmektedir. Bu bilgilerin ne kadarının belirli bir RNN tarafından yakalandığı, yapısına ve eğitim algoritmasına bağlıdır (Schuster ve Paliwal, 1997, s. 2674).

Son birkaç yıldır RNN’ler çeşitli sorunlara uygulayarak yüksek derece başarı elde edilmiştir. Bunlardan bazıları: konuşma tanıma, dil modelleme, çeviri ve resim yazılarıdır. Andrej Karpathy 2015 senesinde blog sayfasında yazdığı yazısında da RNN’le elde edilebilecek yüksek başarılarından söz etmiştir. Bu başarılar için gerekli olan, birçok görev için standart versiyondan çok daha iyi çalışan ve tekrarlayan sinir ağlarının özel bir türü olan “LSTM’lerin” kullanılmasıdır. Tekrarlayan sinir ağlarına dayanan neredeyse tüm başarılı sonuçlar LSTM’lerle elde edilmektedir (Colah’s Blog, 2015).

2.6.2. Uzun-Kısa Süreli Hafıza (Long-Short Term Memory-LSTM) Ağları

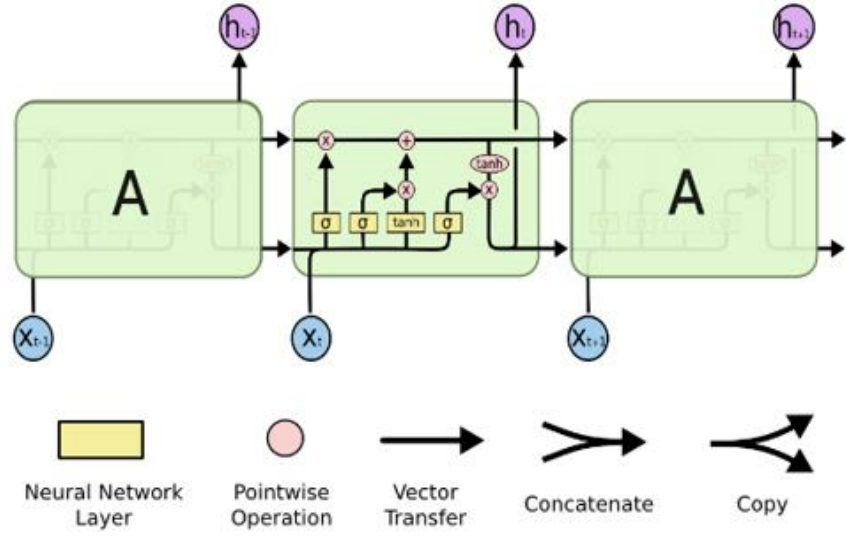
Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) bağımlılık probleminde çözüm üretmek için Hochreiter ve Schmidhuber (1997) tarafından geliştirilmiş uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türüdür.

Tüm tekrarlayan sinir ağları, sinir ağının yinelenen modüllerinden meydana gelen bir zincir biçimine sahiptir. Standart RNN'lerde, bu tekrar eden modül, aktivasyon fonksiyonlarından biri olan "tanh" katmanına benzer çok basit bir yapıya sahip olacaktır. Şekil 23'te RNN'de bulunan tek katmanlı tekrarlayan ağ yapısı gösterilmektedir.



Şekil 23. RNN'de Tek Katmanlı Tekrarlayan Ağ Yapısı (Colah's Blog, 2015)


LSTM'lerin de bu zincir benzeri bir yapısı bulunmakta olup, tekrarlayan modülün ise farklı bir yapısı bulunmaktadır. Standart RNN modülünün aksine bir değil çok özel bir şekilde etkileşime giren dört katmanı bulunmaktadır. Şekil 24'de dört katmana sahip tekrarlayan bir modül yapısı gösterilmektedir.



Şekil 24. Tek Modül İçerisinde 4 Katmana Sahip Bir LSTM Nöral Ağı (Colah's Blog, 2015)


Şekil 24'de yer alan diyagramda, her ileri yönlü tek çizgi, bir düğümün çıktısından diğerlerinin girişlerine kadar bütün bir vektörü taşımaktadır. Pembe renkli daireler, vektör toplama gibi noktasal işlemleri temsil ederken, sarı renkli dikdörtgenler ise öğrenilmiş sinir ağı katmanlarıdır. Birleşen çizgiler birleştirmeyi belirtirken, çatallanan çizgi ise içeriğinin kopyalanmakta olduğunu ve kopyaların farklı konumlara gittiğini göstermektedir (Colah's Blog, 2015).

LSTM'lerin anahtarı, diyagramın üstünden geçen yatay çizgi olan hücre durumudur. Hücre durumu bir tür taşıma bandına benzemektedir. Sadece bazı küçük doğrusal etkileşimler ile tüm zincir boyunca düz bir şekilde ilerlemektedir. Bu sayede bilginin değişmeden akması çok daha kolaydır. Şekil 25'de bir diyagramın üstünden yatay çizgi şeklinde geçen LSTM anahtarı gösterilmektedir (Colah's Blog, 2015).



Şekil 25. Diyagramın Üstünden Yatay Çizgi Şeklinde Geçen LSTM Anahtarı (Colah's Blog, 2015)

LSTM, kapı (gate) olarak adlandırılan yapılar tarafından dikkatlice düzenlenen hücrelere bilgileri ekleme ya da kaldırma yeteneğine sahiptir. Kapılar, kullanıcının isteğine bağlı olarak bilginin iletilmesi görevini yerine getirmektedir. Bir sigmoid sinir ağı katmanından ve puanlama işleminden (noktasal çarpma) oluşmaktadır. LSTM'de bulunan sigmoid katmanı Şekil 26'da gösterilmektedir.




Şekil 26. LSTM'de Bulunan Sigmoid Katmanı (Colah's Blog, 2015)

Sigmoid katmanı, her bir bileşenin kaçının geçmesine izin verilmesi gerektiğine karar veren ve bunu 0 ile 1 arasındaki sayılarla sağlayan katmandır. 0 değeri "hiçbir şeyin geçmesine izin vermeyin" anlamına gelirken, 1 değeri "her şeyin geçmesine izin verin" anlamına gelmektedir. Bir LSTM, hücre durumunu korumak ve kontrol etmek için bu kapılardan üçüne sahiptir (Colah's Blog, 2015).

2.6.3. Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU)

Cho, vd. (2014) tarafından geliştirilen GRU (Geçitli Tekrarlayan Birim), standart bir tekrarlayan sinir ağıyla birlikte gelen, kaybolan gradyan problemini çözmek amacıyla geliştirilmiştir. GRU, LSTM'in bir varyasyonu olarak da

düşünülebilir çünkü her ikisi de benzer şekilde tasarlanmış ve bazı durumlarda eşit derecede başarılı sonuçlar verebilen ağ yapılarıdır. İkisinde de temel amaç aynıdır. LSTM'ler ve GRU'lar kısa süreli belleğe çözüm olarak oluşturulmuşlardır. Bilgi akışını düzenleyebilen “kapı (gate)” adı verilen iç mekanizmalara sahiptirler (Kostadinov, 2017; Phi, 2018). Ancak GRU'lar da bir çıkış kapısı mevcut olmadığı için LSTM'den daha az parametresi bulunmaktadır. Şekil 27'de GRU ve LSTM'a ait kapılar (gates) gösterilmektedir.

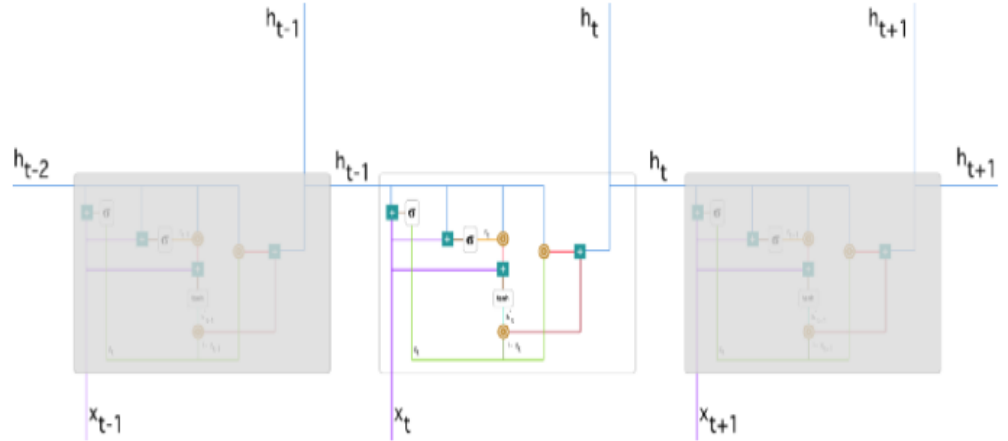


Şekil 27. GRU ve LSTM'a Ait Kapılar (Gates) (Phi, 2018)

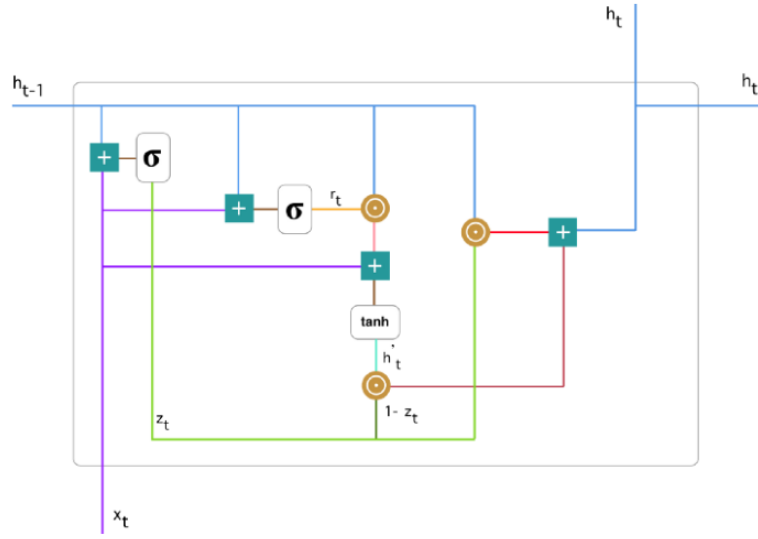
Bu kapılar, eğitimde yer alan verilerden hangilerinin saklanması veya atılmasının önemli olduğunu öğrenebilirler. Bunu yaparak, tahminlerde bulunmak için ilgili bilgileri uzun dizi zincirinden geçirebilirler. RNN'lere dayalı hemen hemen tüm son teknoloji sonuçlar bu iki ağ ile elde edilmektedir. LSTM'ler ve GRU'lar ayrıca konuşma tanıma, konuşma sentezi ve metin oluşturmada bulunabilir ve videolar için altyazı oluşturmak amacıyla bile kullanılabilirler (Phi, 2018). Ancak Weiss vd. (2018) yaptıkları çalışmada LSTM'in GRU'dan daha iyi sonuçlar verdiğini göstermişlerdir. Bunun nedenini ise LSTM'ler kolayca sınırsız sayma yapabilirken GRU'nun bunu yapamamasıdır. Bundan dolayı GRU, LSTM tarafından öğrenilebilen basit dilleri öğrenmekte başarısız olmaktadır. Gruber ve Jockisch

(2020) yaptıkları çalışma da ise GRU'ların daha küçük ve daha seyrek veri kümelerinde daha iyi performans sergilediğini göstermişlerdir.

GRU'lar standart tekrarlayan sinir ağının geliştirilmiş bir versiyonudur. Standart bir RNN'nin kaybolan gradyan problemini çözmek için GRU kullanılmaktadır. Bunu “kapıyı güncelle (update gate)” ve “kapıyı sıfırla (reset gate)” vektörleri ile gerçekleştirmektedir. Temel olarak bu iki vektör, hangi bilgilerin çıktıya aktarılması gerektiğine karar vermektedir. Bu iki vektörü özel kılan şey ise, tahminle ilgili verileri temizlemeden eğitim için hafıza da uzun süre tutması ve modelin eğitiminde kullanmasıdır. Şekil 28’de bu sürecin arkasındaki matematiği açıklamak amacıyla tekrarlayan sinir ağından bir birim ve Şekil 29’da GRU 'nun daha ayrıntılı bir yapısı gösterilmektedir. Şekil 30’da ise notasyonlar tanıtılmaktadır (Kostadinov, 2017).



Şekil 28. Geçitli Tekrarlayan Birim (GRU) ile Tekrarlayan Sinir Ağı (RNN)
(Kostadinov, 2017)



Şekil 29. Geçitli Tekrarlayan Birim (GRU) in Ayrıntılı Yapısı (Kostadinov, 2017)



Şekil 30. Geçitli Tekrarlayan Birim (GRU) e Ait Notasyonlar (Kostadinov, 2017)

2.7. LİTERATÜR TARAMASI

Dünya ekonomisine hızlı bir şekilde giriş yapan ve kısa bir süre içinde piyasaları etkisi altına alan kripto paraların fiyatlarını nicel veya nitel birçok değişken etkilemektedir. Bu değişkenlerden yararlanarak kripto para fiyatlarının tahmininde bulunurken birçok farklı yöntem kullanılmaktadır. Çalışmanın bu bölümünde yer alan literatür taraması iki farklı açıdan ele alınmıştır. Tablo 7’de kripto paraların tahmininde kullanılan derin öğrenme yöntemlerinin incelendiği çalışmalara, Tablo 8’de ise çalışmada kullanılan değişkenleri inceleyen çalışmalara yer verilmiştir.

Tablo 7. Kripto Paraların Tahmininde Kullanılan Derin Öğrenme Yöntemlerinin İncelendiği Çalışmalar

Yıl	Yazar	Veri ve Yöntem	Sonuç
2018	Gullapalli, S	Bitcoin'in en yüksek ve kapanış fiyatını bir gün önceden tahmin etmek amacıyla bir Yapay Sinir Ağları (YSA) uygulaması yapmıştır. Gecikmeli Sinir Ağı (TDNN) ve Tekrarlayan Sinir Ağı (RNN) olarak iki geçici sinir ağı mimarisi kullanarak model karşılaştırması yapmıştır. Eylül 2011-2018 dönemi Bitcoin fiyat veri setinden yararlanmıştır.	TDNN modelinin Bitcoin verilerini RNN'e göre daha kısa sürede eğittiği ve gerçek fiyata daha yakın öngörü değerleri verdiği tespit edilmiştir. Ayrıca, Pearson'ın korelasyon katsayısı (r), TDNN modeli için neredeyse tüm durumlarda RNN'den daha yüksek çıkmıştır. Bu ise, önerilen TDNN modelinin Bitcoin fiyatını RNN'e göre daha doğru tahmin ettiğini göstermektedir.
2018	Hirano, Y. Pichl, L. Eom, C. Kaizoji, T.	RNN, GRU ve LSTM yöntemlerinden yararlanarak Bitcoin'in fiyat tahmininde bulunmuşlardır. Veri seti 01.01.2015-16.02.2018 dönemi AUD, CAD, CNY, EUR, GBP, JPY ve USD para birimleri için 822 kapanış Bitcoin fiyatının tamamını içermektedir. USD tipi üçgen arbitrajı analiz etmek için XBT-CRC-USD, USDAUD, USDCAD, USDCNY, USDEUR, USDGBP ve USDJPY döviz kurlarının kapanış değerlerinden yararlanmış ve buna bağlı olarak her bir döviz piyasasının tatil günlerine kadar veri noktalarını veri setine dâhil etmemişlerdir.	Derin öğrenme algoritmalarının, %67 ile %73 aralığında F-ölçüsü ile geçmiş verilere dayanarak bir sonraki gün için fiyat değişiminin yönünü tahmin edebildiği tespit edilmiştir. Analizler sonucunda Etkin Pazar Hipotezine göre Bitcoin piyasasının USD/EUR piyasasından daha verimsiz olduğu kanısına varılmıştır.
2018	Nakano, M. Takahashi, A. Takahashi, S.	Bitcoin'in gün içi teknik ticaretini kapanış fiyatlarını, en yüksek ve en düşük fiyat değişkenlerinden yararlanarak yeni birçok katmanlı sinir ağı mimarisi oluşturarak tahmin etmişlerdir. Zaman aralığı, 2016/07/31 15:00 (GTM)'den 2018/01/24 07:30'a kadar alınmıştır. Kapanış, yüksek ve düşük fiyatlar, sırasıyla her 15 dakikada son, maksimum ve minimum (işlem gören) fiyatları ifade etmektedir.	Derin öğrenme yöntemi ile her 15 dakikada bir geçmiş zaman serisi verileri kullanılarak hesaplanan teknik göstergelerin belirli giriş verileri için yedi katmanlı bir sinir ağı yapısı oluşturulmuş ve ticaret sinyalleri başarıyla tahmin edilmiştir.

2018	McNally, S. Roche, J. Caton, S.	Bayesian Optimizasyonlu RNN ve LSTM ağını kullanarak Bitcoin fiyatlarının tahmininde bulunmuşlardır. 08.2013-06.2016 dönemi günlük Bitcoin fiyat, twitter ve goggle trend verilerinden yararlanmışlardır.	%52 doğruluk oranı ile en iyi sınıflandırma doğruluğu LSTM modeli ile elde edilmiştir. Klasik doğrusal yöntem olan ARIMA kötü sonuçlar verirken doğrusal olmayan derin öğrenme modelleri daha iyi sonuçlar vermiştir.
2019	Atlan, F.	YSA, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS), Eğri Uydurma ve Uzun Kısa Süreli Bellek (LSTM) yöntemlerinden yararlanarak Bitcoin/TL fiyatının Dolar/TL kuru ve tarih öznitelikleri ile değer tahmininde bulunmuştur. 08.12.2016-08.12.2018 dönemi veri setinden yararlanmıştır.	Eğri Uydurma ve ANFIS yöntemlerinin diğer yöntemlere bakılarak çok daha iyi sonuçlar verdiği görülmüştür.
2019	Dutta, A. Kumar, S. Basu, M.	Basit Sinir Ağı, LSTM ve GRU yöntemleri kullanılarak Bitcoin'in fiyat tahmininde bulunmuşlardır. Veri seti 01.01.2010-06.30.2019 dönemi günlük Bitcoin kapanış fiyatlarından ve Bitcoin fiyatını etkileyen iç ve dış faktörlerden oluşturulmuştur.	Yapılan çalışmada LSTM ve GRU'nun klasik yöntem olarak adlandırılan SARIMA'dan daha iyi tahminleme yaptığı sonucuna varılmıştır.
2019	Ji, S. Kim, J. Im, H.	Derin Sinir Ağları (DNN), Derin Artık Ağları (ResNet), Konvesyonel Derin Ağları ve LSTM'den yararlanarak Bitcoin fiyat tahmininde bulunmuşlardır. 29.11.2011-31.12.2018 dönemi Bitcoin (USD) fiyatlarına ek olarak Bitcoin blok zincirine ait 29 özellik kullanılmış ve her bir özelliğin değerleri bu çalışma için her gün ölçülmüş veya günlük ortalama değerlere dönüştürülmüştür.	LSTM tabanlı tahmin modellerinin Bitcoin fiyat tahmini (regresyon) için diğer tahmin modellerinden biraz daha iyi performans göstermesine rağmen, DNN tabanlı modellerin fiyat artışlarının ve düşüşlerinin tahmininde (sınıflandırma) daha iyi performans gösterdiği tespit edilmiştir. Bunlara ek olarak, basit bir kârlılık analizinin, algoritmik ticaret için sınıflandırma modellerinin regresyon modellerinden daha etkili olduğu gösterilmiştir.
2019	Lahmiri, S. Bekiros, S.	Bitcoin, Dijital Cash ve Ripple'ın günlük fiyatlarını LSTM ve Generalized Regression Neural Networks (GRNN) yöntemleri kullanılarak tahmin etmişlerdir. Bitcoin için 16.07.2010-	LSTM ve GRNN için hesaplanan RMSE'ler sırasıyla Bitcoin için 2.75×10^3 ve 8.80×10^3 , Dijital Para Birimi için 19.2923 ve 50.2418 ve Ripple için 0.0499 ve

		01.10.2018, Dijital Cash için 08.02.2010-01.10.2018 ve Ripple için ise 21.01.2015-01.10.2018 dönemi günlük verilerden yararlanmışlardır.	0.3115'tir. En başarılı sonucu GRNN modeli vermiştir.
2019	Tandon, S. Tripathi, S. Saraswat, P. Dabas, C.	Canlı akış verilerinden yararlanarak, 10 kat çapraz doğrulama ile birlikte RNN, Doğrusal Regresyon, Rastgele Karar Ormanı ve LSTM modellerini kullanarak Bitcoin'in günlük fiyat tahmininde bulunmuşlardır. Veri setini CoinMarketCap sitesinden aldıkları; açılış, en yüksek, en düşük, kapanış, hacim ve piyasa değerlerinden oluşturmuşlardır.	Sürekliliği ve verimliliği artırmak için RNN ve LSTM ile 10 kat çapraz doğrulama uygulanmış ve bu da 0.0043s MAE değerinin düşmesine neden olmuştur. Çapraz doğrulama kullanan LSTM ile birlikte RNN modelinin MAE açısından daha iyi sonuçlar verdiği tespit edilmiştir.
2020	Zoumpakas, T. Houstis, E. Vavalis, M.	Ethereum'un 08.08.2015-28.05.2018 dönemi günlük açılış, en yüksek, en düşük, kapanış ve günlük ortalama fiyat verilerinin her biri bir test verisi olarak kullanarak belirledikleri 6 zaman dilimi için öngörude bulunmuşlardır. CNN, LSTM, GRU, sLSTM ve BiLSTM yöntemlerinden yararlanmışlardır.	RMSE, nRMSE, MAE, nMAE ve MDA performans ölçütlerine bakılarak en başarılı sonuçları LSTM ve GRU modelleri vermiştir. Ancak LSTM, GRU'dan biraz daha iyi performans göstermiştir.

Tablo 8. Çalışmada Kullanılan Değişkenlerin İncelendiği Çalışmalar

Yıl	Yazar	Veri ve Yöntem	Sonuç
2015	Kristoufek, L.	14.09.2011-28.02.2014 dönemi Bitcoin sirkülasyonu, Bitcoin arzı, Bitcoin tahmini işlem hacmi, hacim rasyosu, hash oranı ve zorluk değerlerinden yararlanarak Wavelet Coherence analizi ile Bitcoin fiyatı ile aralarındaki ilişkiyi bakmıştır.	Bitcoin fiyatı ile Bitcoin sirkülasyonu ve zorluk arasında ilişki bulunamamıştır. Fakat Bitcoin fiyatı ile Bitcoin arzı, hash oranı ve Bitcoin tahmini işlem hacmi arasında pozitif yönlü bir ilişki bulunmuştur.
2017	Nunes, B. S. R.	01.01.2013-28.08.2017 dönemi günlük ham petrol ve altın fiyatları, 6 aylık ve 1 yıllık Amerikan tahvil getirileri, S&P 500 endekslerini kullanılarak Bitcoin ile aralarındaki ilişkiyi incelemiştir. VAR Analizi yöntemi kullanılmıştır.	Tüm değişkenlerin Bitcoin fiyatına etkisi görülmüş fakat özellikle 6 aylık Amerikan devlet tahvil getirilerinin daha yüksek bir etkisi olduğu tespit edilmiştir.

2017	Stenqvist, E Lönnö, J.	Yakın gelecekte bir fiyat değişikliğine işaret edebilecek duygu dalgalanmaları için Bitcoin ile ilgili 2,27 milyon tweet'i incelemişlerdir. 11.05.2017-11.06.2017 dönemi, 31 günlük ardışık Bitcoin ile ilgili tweet'leri ve USD/BTC değişim oranı verilerini toplamışlardır. Duyarlılık analizi ile önceden belirlenen parametrelere uygun tweet verilerinin USD/BTC paritesinin düşüş ve yükseliş hareketine etkisi incelenmişlerdir.	Duyarlılık analizi ile önceden belirlenen parametrelere uygun tweet verilerinin USD/BTC paritesinin düşüş ve yükseliş hareketini etkilediği sonucuna varılmıştır.
2018	Corbet, S., Meegan, A., Larkin, C. Lucey, B. Yarovaya, L.	2013-2017 dönemi Bitcoin, Ripple ve Litecoin kapanış fiyatları ile S&P 500 endeksi, VIX volatilité endeksi, COMEX altın future opsiyon piyasası ve imalat sektörü endeksi arasındaki ilişkiyi incelemişlerdir. Diebold ve Yılmaz'ın geliştirmiş olduğu genelleştirilmiş varyans ayrıştırma analizinden yararlanmışlardır. İkinci analiz olarak durum bazlı analiz yaparak değişkenlerin birbirleri ile kısa ve uzun durum ilişkisini incelenişlerdir.	İncelenen kripto paraların arasındaki ilişkinin yüksek, diğer değişkenlerle aralarındaki ilişkinin zayıf olduğu kanısına varılmıştır.
2018	Demir, E. Gozgora, G. Lau, C.K.M. Vigne, S.A.	Bayesian nedensellik analizini kullanarak ekonomik politika belirsizlik endeksi ve günlük Bitcoin getirisi arasında ilişki olup olmadığına bakmışlardır. Daha sonra sıradan En Küçük Kareler Yöntemi (OLS) ve Kuantil Regresyon Analizi yaparak ekonomik politika belirsizlik endeksinin Bitcoin getirisi üzerindeki etkisini incelemişlerdir.	Ekonomik politika belirsizlik endeksi ile günlük Bitcoin getirisinin arasında pozitif ilişki olduğu saptanmış ve önem değerinin bazen yüksek bazen ise düşük olduğu gözlenmiştir.

2018	Yıldırım, H.	ADF birim kök testleri, Johansen eşbütünleşme testi, hata düzeltme modeli ve düzeltilmiş en küçük kareler modeli ile Bitcoin ve altın fiyatları arasındaki ilişkiyi incelemiştir. 02.02.2012-31.12.2013 dönemi Bitcoin'in günlük fiyat ve ons cinsinden altın fiyat verilerinden yararlanmıştır.	Analiz sonucunda Bitcoin ve altın fiyatları arasında kısa vadeli bir ilişkinin olmadığı ve Bitcoin fiyat hareketlerinin altın fiyatlarını etkilemediği tespit edilmiştir. Fakat altın fiyat hareketlerinin Bitcoin fiyatlarını uzun vadede etkilediği sonucuna varılmıştır.
2019	Erdoğan, S. Dayan, V.	Korelasyon, Vektör Otoregresyon, Nedensellik ve ARDL analizlerinden yararlanarak Bitcoin ve LIBOR arasındaki ilişkiyi incelemiştir. Veri seti olarak 21.10.2013-21.09.2018 dönemi haftalık Bitcoin kapanış fiyatları kullanılmış, LIBOR oranları ise yıllık olarak alınmıştır.	Yapılan analizler sonucunda Bitcoin'in LIBOR'a etkisi görülmesede LIBOR'un uzun vadede Bitcoin'e etkisi saptanmıştır.
2019	Gemici, E. Polat, M.	Toda-Yamamoto ve Hatemi-J testlerini kullanılarak 01.2012-04.2018 dönemi Bitcoin fiyatı ve hacmi arasında nedensellik ilişkisi olup olmadığına bakmışlardır.	Bitcoin fiyatı ve hacmi arasında çift yönlü bir nedensellik ilişkisi olduğu tespit edilmiştir.
2019	Panagiotidis, T. Stengos, T. Vravorinos, O.	Hisse senedi getirisi, döviz kuru, altın ve petrol getirisi, FED ve ECB oranları, internet trendleri, S&P 500 endeksi ve Amerika politika belirsizliği endeksi gibi değişkenlerde oluşacak olan dalgalanmaların Bitcoin'e etkisi VAR ve FAVAR analizi ile incelemiştir.	Geleneksel hisse piyasaları ile Bitcoin piyasaları arasında güçlü bir ilişki saptanmış fakat döviz piyasaları ve diğer makroekonomik değişkenler ile aralarında daha zayıf bir ilişki olduğu tespit edilmiştir.
2020	Okorie, D.I. Lin, B.	29.04.2013-17.09.2019 dönemi en fazla işlem gören 10 kripto paranın VAR, MGARCH, GJR ve BEKK modellerini kullanarak ham petrol fiyatı ile ilişkisine bakmışlardır.	Ham petrol fiyatındaki dalgalanmaların bazı kripto paraları doğrudan etkilediği, bazılarını ise dolaylı yoldan etkilediği tespit edilmiştir.

2020	Şahin, E.E.	01.2012-10.2019 dönemi Bitcoin kapanış fiyatları ile finansal baskı endeksi, altın, ABD dolar ve jeopolitik risk endeksi arasındaki ilişkiyi Mars metodu ile incelemiştir.	Ele alınan bağımsız değişkenlerin Bitcoin fiyatına etkisi olduğu sonucuna ulaşılmıştır.
-------------	-------------	--	---

Bu çalışmada ise literatürde incelenen çalışmalardan farklı olarak kripto para fiyatlarını etkileyen Euro/Dolar paritesi, altın spot Amerikan Doları (altının USD bazında ons fiyatı), 12 aylık Londra bankalararası faiz oranı (LIBOR), ham petrol WTI vadeli işlem fiyatı, S&P 500 endeksi, Twitter tabanlı ekonomik belirsizlik endeksi, jeopolitik risk endeksi, ekonomik politika belirsizliği endeksi, Amerika finansal krizler endeksi, kripto para piyasasında gerçekleşen işlem hacimleri ve para arzı değişkenlerinden yararlanarak bir derin öğrenme metodu olan LSTM ve GRU modelleri ile kripto paraların fiyat tahmininde bulunulacaktır.

ÜÇÜNCÜ BÖLÜM

UYGULAMA

3.1. ARAŞTIRMANIN AMACI

Kripto para piyasaları geleneksel para piyasalarından çok daha farklı bir yapıya sahiptir. Kripto para piyasalarında oluşan dalgalanmalar geleneksel para piyasalarına göre çok daha fazla ve belirsizdir. Kripto paralar üretildiği yıllardan günümüze kadar ciddi fiyat sıçramaları ve düşüşleri yaşamıştır. Kripto para endekslerini bu yapısından ötürü klasik istatistiksel tahmin yöntemleri ile tahmin etmek oldukça zordur. Bundan dolayı kripto para tahminleri makine öğrenmesi ve derin öğrenme yöntemleri ile daha kolay yapılabilmektedir. Bu çalışmada derin öğrenme modelinin seçilmesindeki temel amaç; derin öğrenme modellerinin büyük veri, eksik veri ve kırılmaların fazla olduğu verilerle de sağlıklı sonuçlar elde edebiliyor olmasıdır.

Bu çalışmanın amacı, günümüzde giderek popüleritesi artan, insanlar tarafından alternatif bir yatırım aracı ve ödeme yöntemi olarak görülen kripto paraların bir derin öğrenme modeli olan LSTM ve GRU ile fiyat tahmininde bulunmaktır.

3.2. ARAŞTIRMADA KULLANILAN DEĞİŞKENLER VE VERİ SETİ

Bu çalışmada, işlem hacmi ve piyasa değeri en yüksek olan 5 kripto paradan 3'ü ele alınmıştır. Bunlar sırasıyla; Bitcoin, Ethereum ve Ripple'dır. Bağımlı değişken olarak ele alınan kripto paraların günlük kapanış fiyatları seçilmiştir. Kripto paralar için alınan dönemler sırasıyla; Bitcoin 31.12.2013-15.09.2020, Ethereum 10.08.2015-15.09.2020 ve XRP (Ripple) 15.08.2014-15.09.2020'dir. Bağımsız değişken olarak ise Euro/Dolar paritesi, altın spot Amerikan Doları (altının USD bazında ons fiyatı), 12 aylık Londra bankalararası faiz oranı (LIBOR), ham petrol WTI vadeli işlem fiyatı, S&P 500 endeksi, Twitter tabanlı ekonomik belirsizlik endeksi, jeopolitik risk endeksi, ekonomik politika belirsizliği endeksi, ABD finansal krizler endeksi, kripto para piyasasında gerçekleşen işlem hacimleri (24h volume) ve para arzı (supply, free float) verileri kullanılmıştır. Çalışmada kullanılan değişkenler ve veri tabanları Tablo 9'da gösterilmektedir. Veriler Ek 1, 2 ve 3'te yer almaktadır.

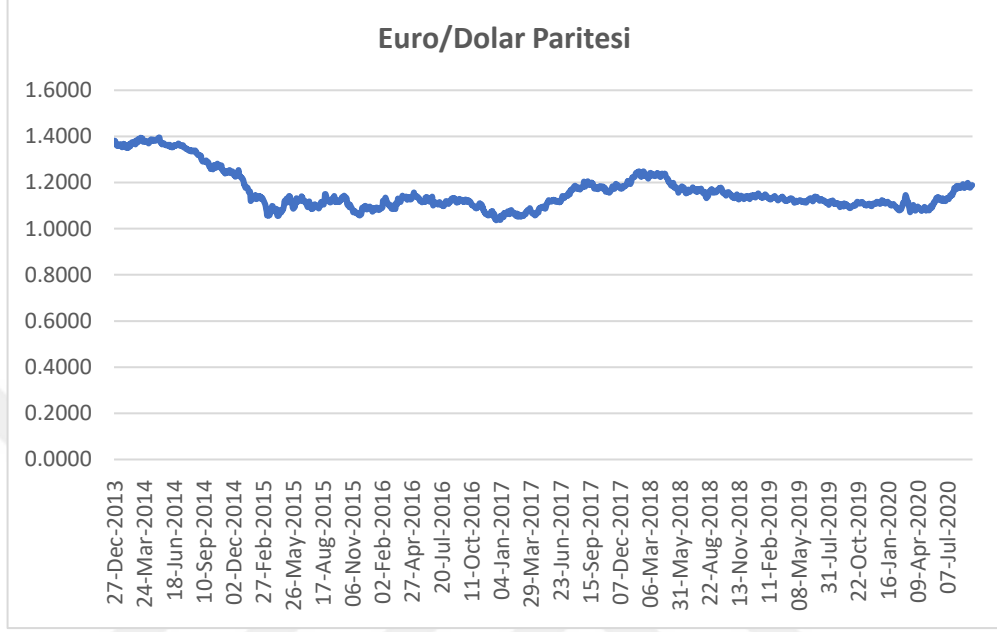
Tablo 9. Çalışmada Kullanılan Değişkenler ve Veri Tabanları

Değişkenler	Veri Tabanı
Euro/Dolar Paritesi	https://www.avrupa.info.tr/tr/avrupa-merkez-bankasi-106
12 Aylık LIBOR (USD)	https://fred.stlouisfed.org/series/USD12MD156N
Altın Spot Amerikan Doları (Altının USD Bazında Ons Fiyatı)	https://tr.investing.com/currencies/xau-usd-historical-data
Ham Petrol WTI Vadeli İşlem Fiyatı	https://tr.investing.com/commodities/crude-oil-historical-data
S&P 500 Endeksi	https://tr.investing.com/indices/us-spx-500-historical-data
Jeopolitik Risk Endeksi	https://www.policyuncertainty.com/
Ekonomik Politika Belirsizliği Endeksi	https://www.policyuncertainty.com/
ABD Finansal Krizler Endeksi	https://www.policyuncertainty.com/
Twitter Tabanlı Ekonomik Belirsizlik Endeksi	https://www.policyuncertainty.com/
Kripto Para Piyasasında Gerçekleşen İşlem Hacimleri (24h Volume)	https://coinmarketcap.com/
Kripto Paraların Para Arzı (Supply, Free Float)	https://coinmetrics.io/community-network-data/
Günlük Kapanış Fiyatları (Price, USD)	https://coinmetrics.io/community-network-data/

3.2.1. Euro/Dolar Paritesi

Parite temel anlamda iki para biriminin birbirine olan oranı demektir. Parite hesaplanırken, ilk para birimine baz para birimi, ikinci para birimine ise karşıt para birimi denilmektedir. Euro/Dolar paritesinde ise Euro baz para birimi, dolar ise karşıt para birimidir. Bu paritedeki oran bir Euro'nun Dolar cinsinden değerini vermektedir. Grafik 8'de 7.12.2013-15.09.2020 dönemi Euro/Dolar paritesi yer almaktadır.

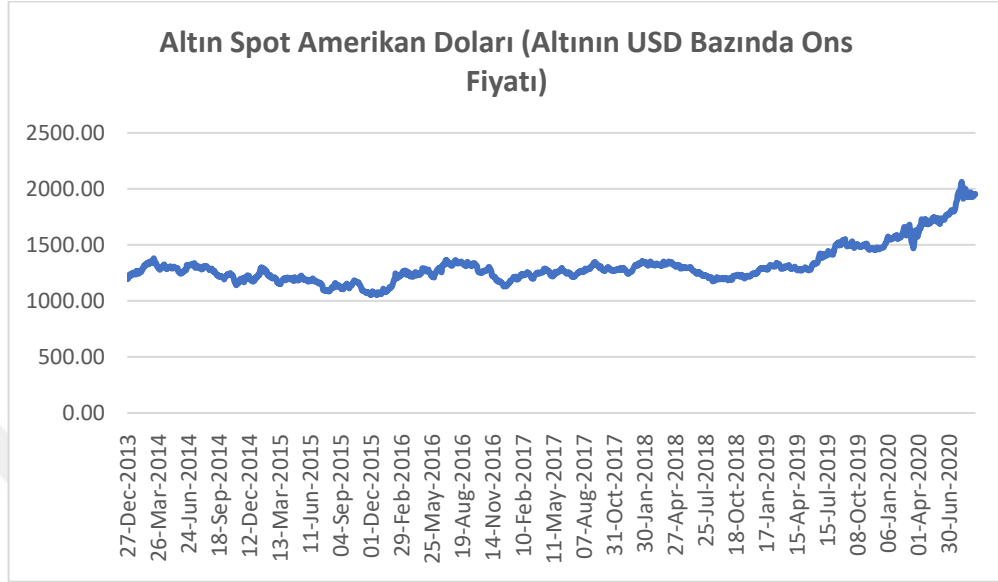
Grafik 8. 27.12.2013-15.09.2020 Dönemi Euro/Dolar Paritesi Grafiği



3.2.2. Altın Spot Amerikan Doları (Altının USD Bazında Ons Fiyatı)

Altın geçmişten günümüze kadar değerini koruyan ve en fazla işlem gören emtiadır. Bunun sebebi ise altının tüm zamanlar için değer saklama özelliğine sahip olmasıdır. Altın sadece yatırım aracı olarak değil takı ve ziynet eşyası olarak da kullanılmaktadır. Dolayısıyla dünyada altına olan talebin her geçen gün artması ve sınırlı bir değer olması altın fiyatının da her geçen gün artmasına sebep olmaktadır. Altının bir yatırım aracı olarak fiyatlanması Ons üzerinden yapılmaktadır. 1 Ons altın, dolar üzerinden fiyatlandırılmakta olup XAU/USD olarak adlandırılmaktadır. 1 Ons altın yaklaşık olarak 31.10 grama karşılık gelmektedir. Grafik 9’da 27.12.2013-15.09.2020 dönemi altın spot Amerikan Doları (altının USD bazında ons fiyatı) yer almaktadır.

Grafik 9. 27.12.2013-15.09.2020 Dönemi Altın Spot Amerikan Doları (Altının USD Bazında Ons Bazında Ons Fiyatı) Grafiği




3.2.3. 12 Aylık Londra Bankalararası Faiz Oranı (LIBOR)

LIBOR, dünyanın en büyük ve en güvenilir bankalarının kısa vadeli borçlanmada bulunurken aralarında kullandıkları faiz oranıdır. LIBOR'un en önemli özelliği ise bankaların borçlanma faiz oranları tespit edilirken LIBOR'da belirlenen faiz oranının referans olarak kabul edilmesidir.

LIBOR faiz oranı hesaplanırken beş para birimi (Dolar, Euro, Yen, Frank ve Pound) ve gecelik-yıllık arasındaki yedi farklı zaman dilimi seçilmektedir. İngiliz Bankalar Birliği (British Bankers' Association) her sabah referans faiz oranını günlük olarak belirlemektedir (Bloomberght, 2016). Grafik 10'da 27.12.2013-15.09.2020 dönemi 12 aylık LIBOR yer almaktadır.


Grafik 10. 27.12.2013-15.09.2020 Dönemi 12 Aylık LIBOR Grafiği



3.2.4. Ham Petrol WTI Vadeli İşlem Fiyatı

West Texas Intermediate (WTI) ham petrolü bir petrol sınıflandırma derecesidir. Brent ve Dubai ham petroleri ile birlikte üç petrol fiyatını belirleyen ana kriterlerden biridir. Bu üç petrol sınıflandırma derecesi petrolün fiyatının belirlenmesinde ana kriterdir. WTI %0,24 kükürt içerdiği için daha düşük yoğunluğa sahiptir ve bu yüzden daha hafiftir. Bu özellikleri WTI petrolünü daha kolay rafine edilebilen yüksek kaliteli bir petrol olmasını sağlamaktadır (Chen, 2020). Grafik 11'de 27.12.2013-15.09.2020 dönemi ham petrol WTI vadeli işlemleri grafiği yer almaktadır.

Grafik 11. 27.12.2013-15.09.2020 Dönemi Ham Petrol WTI Vadeli İşlem Fiyatları Grafiği




3.2.5. S&P 500 Endeksi

Standard & Poor's 500 endeksini ABD'nin halka açık en büyük 500 şirketi oluşturmaktadır. Bu endeks 1,25 trilyon ABD Doları büyüklüğündeki "Standar Poors Endeksi" ailesine aittir. Bu endeks Amerikan hisse senedi piyasasının yaklaşık olarak %75'ini oluşturmaktadır. S&P 500 endeksi bu özellikleri sayesinde ABD hisse senetleri endeksleri arasında en iyi gösterge endeksi olarak kabul edilmektedir.

S&P 500 endeksi değişken ağırlıklı bir endekstir. Bu endekste yapılan işlemler hisselerin gelecekteki fiyatları üzerinden yapılmakta, yani yatırım yapılırken hisseleri satın almak yerine gelecekteki fiyatı satın alınmaktadır. Bu endekste her işlemin belli bir kontrat vadesi vardır. Kontrat vadesi bittiğinde ise yatırımcıların yeni vade süresinde işlem yapmaları gerekmektedir (IKON Menkul, 2020). Grafik 12'de 27.12.2013-15.09.2020 dönemi S&P 500 endeksi işlemleri grafiği yer almaktadır.

Grafik 12. 27.12.2013-15.09.2020 Dönemi S&P 500 Endeksi İşlemleri Grafiği



3.2.6. Twitter Tabanlı Ekonomik Belirsizlik Endeksi

Bu veri seti, Ocak 2010'dan günümüze kadar devam eden Twitter tabanlı yeni bir ekonomik belirsizlik (TEU) endeksi ve Twitter tabanlı yeni bir pazar belirsizliği (TMU) endeksi verilerine dayanmaktadır. Bu endeks Thomas Renault (Paris Üniversitesi 1 Panthéon-Sorbonne) tarafından, Scott R. Baker (Kuzeybatı), Nicholas Bloom (Stanford) ve Steve Davis (Chicago Üniversitesi) ile birlikte geliştirilmiştir. Araştırmacılar 1 Ocak 2010'dan günümüze kadar, Twitter'da gönderilmiş olan ekonomi veya hisse senedi piyasaları ile ilgili anahtar kelimelerin yanı sıra belirsizlikle de ilgili anahtar kelimeleri de içeren tüm mesajları (tweetleri) tespit ederek çıkarmışlardır.


Araştırmada kullanılan belirsizlik terimleri (anahtar kelimeler) şu şekildedir: “belirsiz (uncertain)”, “belirsiz olarak (uncertainly)”, “belirsizlikler (uncertainties)”, “belirsizlik (uncertainty)”. Ekonomiyle ilgili anahtar kelimeler ise şunlardır: “ekonomik (economic)”, “ekonomik (economical)”, “ekonomik olarak (economically)”, “ekonomi bilimi (economics)”, “ekonomiler (economies)”, “ekonomist (economist)”, “ekonomistler (economists)”, “ekonomi (economy)”. Son olarak, finans veya hisse senedi piyasalarıyla ilgili anahtar kelimeler şu setten oluşturulmuştur: “hisse senetleri (equities)”, “hisse senedi (equity)”, “hisse sahibi (equityholder)”, “hisse sahipleri (equityholders)”, “finans etmek (finance)”, “finanse edilebilir (financeable)”, “finanse edilen (financed)”, “finans (finances)”, “finansal

(financial)", "finansal olarak (financially)", "finansallar (financials)", "finansçı (financier)", "finansörler (financiers)", "finansman (financing)", "finansmanlar (financings)", "yatırım (investment)", "yatırımlar (investments)", "yatırımcı (investor)", "yatırımcılar (investors)", "yatırımlar (invests)", "market (pazar)", "markets (pazarlar)", "tüccar (trader)", "tüccarlar (traders)", "ticaretler (trades)", "ticaret (trading)", "ticaretler (tradings)".

TEU ve TMU endeksini oluşturmak için, her seriyi 2010-2015 arasında ortalama 100 olacak şekilde yeniden ölçeklendirmişlerdir. Veritabanları, Amerika Birleşik Devletleri dışında bulunan kullanıcılar da dahil olmak üzere tüm İngilizce Tweet'leri kapsamıştır. Bununla birlikte, Statista'ya göre, Amerika Birleşik Devletleri'ndeki kullanıcılar, İngilizce konuşulan ülkelerde bulunan Twitter kullanıcılarının üçte ikisini temsil etmektedir (geri kalan üçte biri çoğunlukla Birleşik Krallık, Kanada ve Avustralya'dadır). Bu yoğunlaşma nedeniyle, göstergeler çoğunlukla ABD kaynaklı belirsizliği yakalamaktadır (Economic Policy Uncertainty, 2012).

Bu çalışmada ise, daha önceki çalışmalarda kripto para fiyatları üzerinde etkisi olduğu tespit edilen "Twitter Tabanlı Ekonomik Belirsizlik (TEU) Endeksinden" yararlanılmıştır. Grafik 13'te 27.12.2013-15.09.2020 dönemi Twitter tabanlı ekonomik belirsizlik endeksi grafiği yer almaktadır.

Grafik 13. 27.12.2013-15.09.2020 Dönemi Twitter Tabanlı Ekonomik Belirsizlik Endeksi Grafiği




3.2.7. Jeopolitik Risk Endeksi

Jeopolitik Risk Endeksi Federal Rezerv Kurulu'nda bulunan Dario Caldara ve Matteo Iacoviello tarafından geliştirilmiştir. Caldara ve Iacoviello, önde gelen 11 uluslararası gazetede jeopolitik gerilimlerle ilgili kelimelerin oluşumunu sayan aylık bir jeopolitik risk endeksi oluşturmuştur. Jeopolitik risk endeksi, 11 Eylül'den sonra, 2003 Irak işgali ve 2014 Rusya-Ukrayna krizi sırasında, Paris terörist saldırılarının ardından Körfez Savaşı etrafında yükselmektedir.

Jeopolitik risk endeksi, 11 ulusal ve uluslararası gazetenin elektronik arşivlerinin otomatik metin arama sonuçlarını yansıtmaktadır. Bunlar; The Boston Globe, Chicago Tribune, The Daily Telegraph, Financial Times, The Globe and Mail, The Guardian, Los Angeles Times, The New York Times, The Times, The Wall Street Journal ve The Washington Post'dur. Caldara ve Iacoviello, jeopolitik riskle ilgili makalelerin sayısını her ay için her bir gazetede (toplam haber makalesi sayısının bir payı olarak) sayarak endeks hesaplaması yapmaktadır. Bu endeks 2000-2009 yılları arasındaki on yıllık verilerin normalize edilmesi ile oluşturulmuştur (Economic Policy Uncertainty, 2012). Grafik 14'de 12.2013-09.2020 dönemi jeopolitik risk endeksi grafiği yer almaktadır.

Grafik 14. 12.2013-09.2020 Dönemi Jeopolitik Risk Endeksi Grafiği



3.2.8. Ekonomik Politika Belirsizliği Endeksi

Kategorik veriler, yalnızca haber verilerine dayanan bir dizi alt dizin içermektedir. Bunlar, 2000'den fazla ABD gazetesinin “Access World News” veri tabanından elde edilen sonuçlar kullanılarak elde edilmiştir. Her bir alt endeks, ekonomik, belirsizlik ve politika terimlerinin yanı sıra bir dizi kategorik politika şartı da gerektirmektedir. Örneğin; EPU (Economic Policy Uncertainty) olarak belirlenen anahtar kelimelerin yanı sıra Federal Rezerv terimini içeren makaleler para politikası belirsizlik alt endeksine dahil edilmiştir. Her kategorik seri, 1985-2010 arasında ortalama 100 olacak şekilde çarpımsal olarak normalleştirilmiştir.

EPU verileri toplanırken kullanılan terimler; para politikası, vergiler, maliye politikası ve hükümet harcamaları, sağlık hizmetleri, ulusal güvenlik, halk kazanma programları, yönetmelik, finansal düzenleme, ticaret politikası, devlet borçları ve döviz krizleri terimlerinin alt terimleridir (Economic Policy Uncertainty, 2012).

Bu çalışmada ise “ABD Kategorik EPU Endeksleri” içerisinde yer alan 12 endeksten “Economic Policy Uncertainty (Ekonomik Politika Belirsizliği) Endeksi” analize dahil edilmiştir. Grafik 15’te 12.2013-09.2020 dönemi ekonomik politika belirsizliği endeksi grafiği yer almaktadır.

Grafik 15. 12.2013-09.2020 Dönemi Ekonomik Politika Belirsizliği Endeksi Grafiği



3.2.9. ABD Finansal Krizler Endeksi

Equity Market Volatility (EMV), ABD Hisse Senedi Piyasasında oynaklığa neden olan 30'dan fazla spesifik kategori baz alınarak oluşturulmuştur. Her kategori 1985'den günümüze kadar olan aylık verileri içermektedir.

Genel EMV izleyicisini oluşturmak için aşağıdaki yol izlenmektedir. İlk olarak, aşağıdaki gibi üç küme halinde terimler belirlenir:

- E: {ekonomik, ekonomi, finans}
- M: {"borsa", hisse senedi, hisse senetleri, "Standart ve Yetersiz" (ve varyantlar)}
- V: {volatilite, volatile, belirsiz, belirsizlik, risk, riskli}

İkinci adımda, on bir büyük ABD gazetesi için E, M ve V terimlerinden en az birini içinde barındıran aylık gazete makaleleri aranır. Bu gazeteler: Boston Globe, Chicago Tribune, Dallas Morning News, Houston Chronicle, Los Angeles Times, Miami Herald, New York Times, San Francisco Chronicle, USA Today, Wall Street Journal ve Washington Post'tur. Üçüncü adımda, tüm ham EMV verilerini bulmak için aynı aydaki ve aynı sayfadaki terimler sayılarak ölçeklendirilir. Dördüncü adımda, 1990'dan 2015'e kadar olan verilerin standart sapması alınarak EMV verileri

standart hale getirilir. Beşinci adımda, standartlaştırılmış sayıların aylık gazetelere göre ortalaması alınır. Son adımda ise, ortaya çıkan ortalama veri seti, 1985'ten 2015'e kadar olan VIX'in ortalama değeriyle eşleşecek şekilde çarpımsal olarak yeniden ölçeklendirilir.


Kategoriye özgü EMV izleyicilerini oluşturmak için, her kategorideki EMV makalelerinin payı hesaplanıp eşzamanlı EMV izleyici değeri ile çarpılır. Örneğin, t ayı boyunca hisse senedi piyasası oynaklığındaki para politikası değerlendirmelerinin önemini ölçmek için Eşitlik (2) kullanılmaktadır:

$$\left(\frac{(\#\{E\cap M\cap V\cap \text{Monetary Policy}\})_t}{(\#\{E\cap M\cap V\})_t} \right) EMV_t \quad (2)$$

Hesaplama da bulunan #, belirtilen setteki gazete makalelerinin sayısını, EMV_t ise t ayındaki genel EMV izleyicilerinin değerini göstermektedir.

Yapılacak olan uygulamada ise “ABD Finansal Krizler Endeksi” içerisinde yer alan 45 endeksten “Financial Crises EMV Tracker (Finansal Krizler EMV Takibi) Endeksi” analize dahil edilmiştir (Ekonomik Politika Belirsizliği, 2012). Grafik 16’da 12.2013-09.2020 dönemi ABD finansal krizler endeksi grafiği yer almaktadır.

Grafik 16. 12.2013-09.2020 Dönemi ABD Finansal Krizler Endeksi Grafiği




3.2.10. Kripto Para Piyasasında Gerçekleşen İşlem Hacimleri (24h Volume)

Finansal hacim; her işlem piyasasında gerçekleşen günlük alım ve satımların toplam değeridir. Yapılan işlem hacmi, işlem piyasasında işlem gören varlığın işlem adeti ile alış ve satış fiyat değerlerinin çarpılmasıyla hesaplanmaktadır. Kripto paralarında kendine ait işlem piyasaları bulunmaktadır (Coin Rivet, 2018). Veri setinde kullanılan hacim değişkeni ise her kripto paranın belirli süreler içinde yapılan işlem hacmini göstermektedir. Grafik 17’de 01.08.2017-15.09.2020 dönemi kripto paraların hacim (24h volume) grafikleri yer almaktadır.




Grafik 17. 01.08.2017-15.09.2020 Dönemi Kripto Para Piyasasında Gerçekleşen İşlem Hacim (24h Volume) Grafikleri



3.2.11. Kripto Paraların Para Arzı (Supply, Free Float)

Serbest dolaşım arzı olan supply, free float; bir kripto paranın belirli bir zaman içinde açık piyasalarda işlem görmeye hazır halinin geleneksel para olarak karşılığıdır. Kurucu şirketlerin ortaya koydukları coin miktarları hariç, piyasada kripto para birimine ait olan tüm işlemler arzı oluşturmaktadır (Coin Metrics, 2020). Grafik 18’de 01.08.2017-15.09.2020 dönemi kripto paraların para arzı (supply, free float) grafikleri yer almaktadır.


Grafik 18. 01.08.2017-15.09.2020 Dönemi Kripto Paraların Para Arzı (Supply, Free Float) Grafikleri



3.2.12. Kripto Paraların Günlük Kapanış Fiyatları (Price/USD)

Bahsi geçen kripto para biriminin fiyatı gece 12.00'de sabitlenip günlük kapanış fiyatı olarak tanımlanmaktadır. Bu fiyat Coin Metrics'in sabit fiyatı/referans oranı baz alınarak oluşturulmaktadır. Gerçek zamanlı bir kapanış fiyatı (madencinin bloğu oluşturduğu tarih) ise, blok madencisinin blok oluşturma tarihi olarak belirlenen zaman damgasıyla belirlenmektedir (Coin Metrics, 2020). Grafik 19'da 01.08.2017-15.09.2020 dönemi kripto paraların günlük kapanış fiyatları (price/USD) grafikleri yer almaktadır.

Grafik 19. 01.08.2017-15.09.2020 Dönemi Kripto Paraların Günlük Kapanış Fiyatı (Price/USD) Grafikleri



3.3. ARAŞTIRMA İÇİN YAPILAN HAZIRLIKLAR

Araştırmada kullanılacak modeli oluşturmadan önce model üzerinde en sağlıklı eğitimi yapabilmek için özgün bir veri seti oluşturmak gerekmektedir. Çalışmada kullanılacak olan veri seti analize uygun hale getirilirken verilerin hazırlanması ve normalizasyon işlemine tabi tutulmuştur.

- **Verilerin Hazırlanması**

Euro/Dolar paritesi, altın spot Amerikan Doları (altının USD bazında ons fiyatı), 12 aylık Londra bankalararası faiz oranı (LIBOR), ham petrol WTI vadeli işlem fiyatı ve S&P 500 endeksi gibi makrodeğişkenlerin haftasonu ve tatil günleri verileri açıklanmadığı için o günler çalışmaya dahil edilmemiştir. Oluşturulan veri setinde Bitcoin verileri 2455'ten 1674'e, Ethereum verileri 1867'den 1273'e ve Ripple verileri 2224'den 1517'ye düşmüştür.

- **Normalizasyon**

ÇKA (Çok Katmanlı Ağ) modelin girdi ve çıktılarının ölçeklendirilmesi işlemine normalizasyon denmektedir. Daha kapsamlı bir şekilde anlatılacak olursa uygulamada kullanılacak olan veriler incelendiğinde aralarında uç sınırlar görülebilmekte ya da birden çok değişkenin yer aldığı çalışmalarda farklı birimlere sahip birçok veri yer alabilmektedir. Bazen de bu veriler yanlışlıkla girdi veri setine dahil olmuş olabilmektedir. Bu da ağın işleyişinde yanlış yönlendirmelere neden olabilmekte ve ağın performansını olumsuz yönde etkileyebilmektedir. Bunun gibi nedenlerden dolayı uygulamada yer alacak olan tüm verilerin çoğunlukla 0 ile 1 aralığında yer alması değişik ortamlardan gelen bilgilerin aynı ölçek üzerinde bulunmasına ayrıca yanlış girilmiş olabilen uç değerler etkilerinin kaybolmasına yardımcı olmaktadır (Öztemel, 2003, s.101-102).

Makine öğrenmesi ve derin öğrenme uygulamalarında verilere bazı ön işlemlerde bulunarak verilerin eğitimi diğer bir deyişle işleyişi daha elverişli hale getirebilmekte ve yöntemin performansını arttırabilmektedir. Ham verilere uygulanan normalizasyon tekniği uygulamada kullanılacak olan değişken verilerini eğitim için hazır hale gelmesine yardımcı olmaktadır. Uygulanacak bazı yöntemlerde verilere normalizasyon tekniği uygulanmaması eğitim aşamasında yavaşlamaya neden olabilmektedir (Jayalakshmi ve Santhakumaran, 2011, s. 89-93). Bu yüzden derin öğrenme yöntemi kullanılarak yapılacak olan bu çalışmada da model kurulmadan önce veriler normalize edilmiştir.

Birçok farklı normalizasyon tekniği bulunmaktadır. Bunlardan bazıları; MinMaxScaler, MaxAbsScaler, RobustScaler, Normalizer, QuantileTransformer, StandartScaler ve PowerTransformer yöntemi gibi sıralanabilmektedir. Bu çalışmada veri seti Sklearn-Preprocessing kütüphanesi kullanılarak MinMaxScaler kuralı ile normalize edilmiştir. Bunun nedeni ise MinMaxScaler tekniğinin daha hassas sonuçlar elde etmeye olanak sağlamasıdır (Scikit-Learn, 2020). MinMaxScaler normalizasyon tekniğinin matematiksel formülü Eşitlik (3)'de yer almaktadır.

$$x_{scaled} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3)$$

Eşitlikte yer alan x_{scaled} normalize edilmiş veriyi, x_i girdi değerini, x_{min} girdi seti içerisinde yer alan en küçük sayıyı, x_{max} ise girdi seti içerisinde yer alan en büyük sayıyı ifade etmektedir.

3.4. EĞİTİMDE KULLANILAN ARAÇLAR

Kripto paraların tahmini aşamasında, veri boyutunun büyük olması ve kullanılacak modelin bir derin öğrenme modeli olmasından dolayı donanımsal ihtiyaçlar artmaktadır. Bu çalışmada kullanılacak olan analizleri yapmak için Google'ın bulut bir yapı olarak hizmete sunduğu Google Colabatory'ı kullanılmıştır. Modelin eğitimi için ihtiyaç duyulan işlem gücü Google Colabatory'nin sunduğu Grafik İşleme Birimi (Graphics Process Unit-GPU) tabanlı hizmette yer aldığı için eğitim hızlı bir şekilde gerçekleştirilmiştir.

Modelin eğitiminden önce veriyi işlemek ve gerekli görselleştirmeleri yapmak gerekmektedir. Bunun içinse temel veri bilimi kütüphaneleri olan Pandas, Numpy ve Matplotlib gibi kütüphaneler kullanılmaktadır. Kurulacak modelin eğitimi içinse açık kaynak kodlu bir yapay sinir ağı kütüphanesi olan "Keras" kullanılmıştır. Keras kütüphanesi Theano ve TensorFlow'u backend olarak kullanabilen bir wrapperdir. Bu modelin eğitiminde ise backend olarak TensorFlow kullanılmıştır.

3.4.1. Google Colaboratory

Günümüzde Python programlama dilini derleyen birçok IDE bulunmaktadır. Bu IDE'lerden bazıları sisteme local olarak yüklenirken bazıları ise bulut olarak kullanılabilir. Google Colabatory ise bu IDE'ler içerisinde bulut ortamında çalışan, kurulum gerektirmeyen ve ücretsiz erişilebilen bir Jupyter notebook ortamıdır.

Google Colabatory, araştırmacıların kodlarını yazıp yürüttüğü ve çeşitli modeller kurarak analizlerini yapıp kaydedebildikleri bulut tabanlı bir sistemdir. Araştırmacılar Google Colabatory sayesinde güçlü işlem kapasitesine sahip olmaktadır. Google Colabatory'de yapılan çalışmalar .ipynp ve .py formatlarında kaydedilebilmekte ve local IDE'lerle kullanılabilir. Google Colabatory, Python 3.x sürümlerini desteklemektedir. Bu sayede Python programlama diline ait local IDE'lerde kullanılan tüm kütüphaneler yüklenebilmektedir.

Google Colabratory arařtırmacılara kullandırdıkları sanal makinelerin yanında Grafik İşleme Birimi (Graphics Process Unit-GPU) ve Tensor İşleme Birimi (Tensor Processing Unit-TPU) tabanlı render fırsatı da sunmaktadır. Google Colabratory, Tesla K80 GPU gibi GPU'ları arařtırmacılara sunarak derin öğrenme modellerini eğitmelerine olanak sağlamaktadır. Ancak Google Colabratory arařtırmacılara verdiği bu destekleri 12 saatlik süreyle sınırlı tutmaktadır. Bu süre bittiğinde sistem döngüsü yeniden başlatılarak modelin eğitimine devam edilebilmektedir.

3.4.2. Keras

Teknoloji çağının getirilerinden biride artan veri miktarlarıdır. İnternetin gelişmesi ile birlikte verilerin paylaşılması ve depolanması kolaylaşmıştır. Verilerin Megabaytlardan Exabyte ulaşması, beraberinde bazı problemleri de getirmiştir. Bu problemlerden biri de verilerin analiz edilmesidir. Büyük verilerin analizi için derin öğrenme sistemleri geliştirilmiştir. Derin öğrenme sistemlerinin kullanılmasındaki artışın bir diğer sebebi ise Merkezi İşlem Birimi (Core Processing Unit-CPU) nun gücünün yetersiz kaldığı yerlerde GPU sayesinde işlem derinliği sağlanarak analizlerin ve problemlerin çözümünün daha hızlı ve daha doğru bir şekilde yapılmasıdır.

Derin öğrenme sistemleri karşı karşıya kalınan problemleri çözmek için belirli kütüphaneleri kullanmaktadır. Bu kütüphanelerden biri de Keras'tır. Keras en temelde Python diliyle yazılmış açık kaynak kodlu bir sinir ağı kütüphanesidir. Fakat Keras'ı diğer kütüphanelerden ayıran bazı özellikler bulunmaktadır. Bunlardan en önemlisi ise Keras backend olarak Tensorflow, CNTK ve Theano gibi diğer derin öğrenme kütüphanelerini de kullanan bir wrapperdir. Bu özellikleri sayesinde Keras, arařtırmada kullanılacak olan derin öğrenme modelini farklı kütüphaneler kullanarak hızlı ve kolayca eğitebilmektedir. Bu çalışmada backend olarak Tensorflow kütüphanesi kullanılmıştır.

3.4.3. TensorFlow

TensorFlow 2015 yılında Google tarafından geliştiricilerin kullanıma sunduğu uçtan uca açık kaynak kodlu bir kütüphanedir. TensorFlow birden fazla platformda kullanılabilir. TensorFlow kütüphanesi Python, C++, C# ve

javascript gibi dillere de uyum sağladığından dolayı çok yaygın bir şekilde kullanılmaktadır. TensorFlow temelde “tensor” ve “flow” şeklinde ikiye ayrılmaktadır. Tensor, yüksek hacimli verilerin çok boyutlu dizileridir. FLOW ise tensorler üzerinde gerçekleşen işlemlerdir.

3.5. ARAŞTIRMADA KULLANILAN PERFORMANS ÖLÇÜTLERİ

Uygulama kısmında test adımı aşamasına geçildiğinde o modelin ya da uygulanan yöntemin ne derece iyi bir öngörü yapabildiği bazı performans ölçütleriyle test edilebilmektedir. Bu aşama da veriler ilk olarak eğitim ve test verileri olarak ayrılır. Eğitim verileri programa gösterildikten sonra tahmin dönemine ait olan değerler göz ardı edilerek yani henüz belli olmadığı varsayımı ile hareket edilerek o dönemlere ait değişkenlerin gelecek tahminlerinde bulunulur. Daha sonra analiz sonucunda çıkan değerler orijinal haline dönüştürülür yani denormalize edilir (Zhang vd., 1998, s. 49). Sonrasında ise o dönemlere ait gerçek veriler ile tahmin değerleri arasındaki hata oranlarının tahmininde bulunan performans ölçütleri denilen formüller uygulanır ve bu ölçütler modelin doğruluğunu test etmekte yardımcı olur (Akal, 2008).

Bu çalışmada kullanılan performans ölçüt değerleri Ortalama Mutlak Hata (Mean Absolute Error-MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE), Ortalama Hata Kareleri (Mean Square Error-MSE) ve Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE)'dir. Sırasıyla bu performans (hata) ölçütlerine değinilecektir.

Ölçeğe bağlı olan Ortalama Mutlak Hata (*MAE*), iki sürekli değişken arasındaki fark ve zaman serisi tahmini için yaygın olarak kullanılan bir kıyaslama ölçütüdür (Hyndman ve Koehler, 2006). Bir dizi tahmindeki hataların yönlerini dikkate almadan ortalama büyüklüğünü ölçmektedir. Tüm bireysel farklılıkların eşit ağırlığa sahip olduğu tahmin ile gerçek gözlem arasındaki mutlak farkların ortalaması şeklinde ifade edilmektedir (Willmott ve Matsuura, 2005, s. 80). Bu ölçümüne göre, ortalama mutlak hata (*MAE*) en küçük olan tahmin ya da öngörü modelini, en başarılı model olarak kabul edilmektedir. Bu ölçütün matematiksel ifadesi Eşitlik (5)'da yer almaktadır.

Denkleimde yer alan e_t t dönemi için tahmin hatasını göstermektedir. F_t t dönemi için tahmin değeri ve D_t ise t dönemi için gerçekleşen değeri olması durumunda tahmin hatası Eşitlik (4)'deki gibi hesaplanmaktadır.

$$e_t = D_t - F_t \quad (4)$$

n dönemde gerçekleşen tahmin hataları e_1, e_2, \dots, e_n olması durumunda aşağıdaki formüller kullanılarak sonuca ulaşılmaktadır.

$$MAE = (1/n) \sum_{i=1}^n |e_i| \quad (5)$$

Ortalama Hata Kareleri (Mean Square Error-MSE) ölçütü içerisinde en sık kullanılan performans ölçütüdür. Bu yöntemi diğer yöntemlerden üstün kılan özellik ise tahminde bulunan hatanın varyans toplamına ayrıştırılabilmesidir. Bu özellik, MSE ölçütünün yalnızca gerçek ve tahminlere ait olan birleşik dağılımın ikinci momenti ile bağlantılı olduğunu açıklamaktadır (Zhang, 1998, s. 52). Bu ölçüme göre, hata kareleri ortalaması (MSE) en küçük olan tahmin ya da öngörü modeli, en başarılı model olarak kabul edilmektedir. Bu ölçütün matematiksel ifadesi Eşitlik (6)'da yer almaktadır.

$$MSE = (1/n) \sum_{i=1}^n |e_i|^2 \quad (6)$$

Değişkenlerin tahmin değerleri ile gerçek değerleri arasındaki hata oranını bulmak amacıyla kullanılan başka bir hata ölçütü de Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE)'dür. Tahminler hata büyüklüklerini tanımladıkları için diğer performans ölçütlerine göre çoğu araştırmacı tarafından kullanılmaktadır. Bu ölçüte göre, hata kareleri ortalaması karekökü (RMSE) en küçük olan tahmin ya da öngörü modeli, en iyi model olarak kabul edilmektedir. Bu ölçütün matematiksel ifadesi Eşitlik (7)'de yer almaktadır (Hyndman ve Koehler, 2006, s. 682).

$$RMSE = \sqrt{(1/n) \sum_{i=1}^n e_i^2} \quad (7)$$

MAPE performans ölçütü yüzdellik hataların mutlak değerleri toplamının ortalaması alınarak hesaplanmaktadır. MAPE ölçütünde hata değerleri birbirlerini ortadan kaldırmamakta ve tahminde meydana gelen hata büyüklüğünü kendilerini ortaya çıkarabilmektedir. Ayrıca yüzdellik hata değerleri, tahminde bulunan değerleri daha anlamlı hale getirmekte ve yorumlanmasına da kolaylık sağlamaktadır. Bundan

dolayı MAPE performans (hata) ölçütü sıkça tercih edilmektedir (Makridakis vd., 1998). Bu ölçüte göre, yüzde mutlak ortalama hatası (MAPE) en küçük olan tahmin ya da öngörü modeli, en iyi model olarak kabul edilmektedir. Ayrıca gerçek değerden sapma yüzdesi de bu performans ölçütü ile görülebilmektedir. Bu ölçütün matematiksel ifadesi Eşitlik (8)'de yer almaktadır.

$$MAPE = \frac{1}{T} \sum \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (8)$$

Bu çalışmanın analiz sonuçlarının grafikleri ve tahmin değerleri, regresyon ve zaman serisi analizlerindeki doğruluğu ölçmeyi sağlayan metriklerden biri olan MAPE'ye göre hazırlanmıştır. Çünkü MAPE performans ölçütü, gerçek verilerin içinde sıfır değeri olmamasından dolayı kolaylıkla kullanılabilen ve ana ölçüm metriği olarak baz alınabilmektedir.

3.6. ANALİZ VE BULGULAR

Çalışmanın bu bölümünde Bitcoin, Ethereum ve Ripple kripto paralarının Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) modelleri ile yapılan tahmin sonuçlarına ve model sonuçlarının karşılaştırmasına yer verilmiştir.

3.6.1. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Modelinin Eğitimi ve Testi

Sinir ağlarının en önemli özelliklerinden biri öğrenebilme yeteneğine sahip olmasıdır. Derin öğrenme modellerinde kullanılan sinir ağlarında, modelin eğitiminde başarı elde edilmesi için veriler ağırlıklandırılmaktadır. İlk olarak ağın eğitimi için bağlantılara rastgele ağırlık değerleri atanır. Eğer bu bağlantılar istenildiği gibi değilse var olan ağırlıklar değiştirilir ve kullanılmayan bağlantılar yok edilir. Modelin eğitimi sırasında elde edilen bu ağırlıklandırmalar sinir hücreleri arasında bağlantı ağırlıkları olarak saklanır.

Bu çalışmada, tahmininde bulunulacak her kripto para için analize başlamadan önce eğitim seti belirlenmiştir. Bu eğitim setlerine ait window size, unit ve epoch sayıları değiştirilerek birçok deneme yapılmış ve en düşük hata değerleri elde edilene kadar devam edilmiştir. Çünkü ağ çıkışında hesaplanan hata değerlerinin en aza indirgenmesi ağırlıkların kararlılık kazanması anlamına gelmektedir.

Çalışmada ele alınan kripto para fiyatlarının açıklanma tarihlerinin başlangıçları her biri için farklı olduğundan dolayı farklı zaman aralıkları alınarak veri seti oluşturulmuştur.

Tablo 10’da araştırmada kullanılan kripto paralar için ayrılan eğitim ve test sayıları gösterilmektedir.

Tablo 10. Araştırmada Kullanılan Kripto Paralar İçin Ayrılan Eğitim ve Test Sayıları

Kripto Para Birimleri	Dönem	Eğitim Veri Sayıları	Dönem	Test Veri Sayıları
BTC	27.12.2013-03.08.2020	1644	04.08.2020-15.09.2020	30
ETC	10.08.2015-03.08.2020	1243	04.08.2020-15.09.2020	30
XRP	15.08.2014-03.08.2020	1487	04.08.2020-15.09.2020	30

Kripto paralara ait tüm veriler ile analize başlanmadan önce *MinMaxScaler* yöntemi ile normalize edilmiştir. Daha sonra LSTM ve GRU ile normalize edilen bu veriler eğitilmiştir. Eğitim sonucunu en iyi veren model ile kripto paraların 30 günlük tahmininde bulunulmuştur. Son adımda ise eğitim ve tahmin verileri denormalize edilerek gerçek veriler ile aralarındaki hata değerleri hesaplanmıştır.

3.6.2. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Modeli ile Tahmin Sonuçlarının Elde Edilmesi

Goggle Colaboratory üzerinde oluşturulan LSTM modeline ilk olarak Keras’ın sıralı katmanları içeren sequential modeli eklenmiştir. Daha sonra bunun için tam bağlı katman olarak da bilinen dense ağ mimarisi eklenmiş, son olarak ise dropout katmanı eklenerek modelin aşırı öğrenmesi-ezberlemesi (overfitting) engellenmeye çalışılmıştır.

3.6.2.1. Bitcoin Günlük Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Model Tahmini

LSTM modelinde Bitcoin günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemi 30 günlük tahmini gerçekleştirilmiştir. Daha sonra tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan window size, unit ve epoch sayıları için performans ölçüt değerlerine Tablo 11’de yer verilmektedir.

Tablo 11. LSTM Modelinde Bitcoin Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

	Performans Ölçütleri	5 Window Size 80 Unit 110 Epoch	4 Window Size 90 Unit 105 Epoch	4 Window Size 70 Unit 120 Epoch	5 Window Size 50 Unit 115 Epoch	5 Window Size 75 Unit 100 Epoch	4 Window Size 50 Unit 110 Epoch	4 Window Size 75 Unit 120 Epoch
Eğitim	MAE	304.39	267.82	318.03	538.61	297.65	393.03	259.94
	MSE	281745.35	237536.58	292558.22	862597.28	289300.96	379520.49	227707.10
	RMSE	530.80	487.38	540.89	928.76	537.87	616.05	477.19
	MAPE	13.27	9.26	18.01	19.13	10.54	15.03	9.21
Test	MAE	566.07	657.53	657.03	670.85	629.11	646.96	802.16
	MSE	568051.32	617449.66	604703.18	593237.71	799424.08	703252.49	1165059.00
	RMSE	753.69	785.78	777.63	770.22	894.11	838.60	1079.38
	MAPE	5.08	5.76	5.77	5.77	5.83	5.93	7,29

Tablo 11’de yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 4 window size, 75 unit ve 120 epoch sayısı ile elde edildiği görülmektedir. En iyi test modelinin ise 5 window size, 80 unit ve 110 epoch sayısı ile elde edilmiştir. Tablo 12’de ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.


Tablo 12. LSTM En İyi Modeli İçin Bitcoin Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri

Tarih	Bitcoin Gerçek Değerleri	Bitcoin Tahmin Değerleri
04.08.2020	11202.6519	10809.3662
05.08.2020	11721.4385	10822.2588
06.08.2020	11769.3091	11033.5439
07.08.2020	11598.9691	10996.8643
10.08.2020	11870.3695	11135.4609
11.08.2020	11392.6441	11113.6006
12.08.2020	11575.5125	11245.6885
13.08.2020	11773.4481	11042.7773
14.08.2020	11774.4083	11440.1436
17.08.2020	12315.7624	11351.9756
18.08.2020	11992.6960	11596.3945
19.08.2020	11736.8491	11603.5283
20.08.2020	11867.5203	11140.8057
21.08.2020	11524.6989	10747.3252
24.08.2020	11771.4081	11411.1807
25.08.2020	11358.4543	11496.1641
26.08.2020	11472.0491	11408.3135


27.08.2020	11314.6737	11105.3887
28.08.2020	11527.8830	11084.8701
31.08.2020	11678.3482	11151.3604
01.09.2020	11970.3649	11338.0723
02.09.2020	11414.5209	11256.1533
03.09.2020	10261.4944	11299.5762
04.09.2020	10471.9664	12362.8633
08.09.2020	10108.6354	12456.7832
09.09.2020	10223.1114	10429.5586
10.09.2020	10334.6307	10651.0293
11.09.2020	10387.0207	10042.9990
14.09.2020	10662.7199	10582.8027
15.09.2020	10779.3810	10969.5400

Elde edilen eğitim ve test verilerinin gerçek ve tahmin değerlerinin karşılaştırması Grafik 20 ve 21’de gösterilmektedir.

Grafik 20. LSTM En İyi Modeli İçin Bitcoin Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



Grafik 21. LSTM En İyi Modeli İçin Bitcoin Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



3.6.2.2. Ethereum Günlük Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Model Tahmini

LSTM modelinde Ethereum günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemi 30 günlük tahmini gerçekleştirilmiştir. Daha sonra tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan window size, unit ve epoch sayıları için performans ölçüt değerlerine Tablo 13'de yer verilmektedir.

Tablo 13. LSTM Modelinde Ethereum Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

	Performans Ölçütleri	2 Window Size 100 Unit 105 Epoch	2 Window Size 100 Unit 100 Epoch	2 Window Size 75 Unit 115 Epoch	3 Window Size 90 Unit 115 Epoch	3 Window Size 80 Unit 105 Epoch	4 Window Size 70 Unit 100 Epoch	2 Window Size 60 Unit 120 Epoch
Eğitim	MAE	51.45	40.79	45.26	21.35	21.30	32.07	27.74
	MSE	5963.36	4379.20	6484.18	1469.17	1274.61	2238.10	2198.88
	RMSE	77.22	66.18	80.52	38.33	35.70	47.31	46.89
	MAPE	164.89	133.72	125.52	30.79	94.64	161.92	33.46
Test	MAE	27.13	27.47	34.36	36.81	37.42	38.75	61.01
	MSE	1316.01	1262.66	2444.39	2270.87	2065.39	2414.68	4509.34
	RMSE	36.28	35.53	49.44	47.65	45.45	49.14	67.15
	MAPE	6.53	6.64	8.85	8.92	9.16	9.48	14.95


Tablo 13’de yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin MAE, MSE ve RMSE değerlerine göre 3 window size, 80 unit ve 105 epoch sayısı ile MAPE değerine bakıldığında ise 3 window size, 90 unit ve 115 epoch sayısı ile elde edildiği görülmektedir. En iyi test modelinin ise MAE ve MAPE değerlerine göre 2 window size, 100 unit ve 105 epoch sayısı ile, MSE ve RMSE değerlerine bakıldığında ise 2 window size, 100 unit ve 100 epoch sayısı ile elde edildiği görülmektedir. Tablo 14’de ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 14. LSTM En İyi Modeli için Ethereum Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri


Tarih	Ethereum Gerçek Değerleri	Ethereum Tahmin Değerleri
04.08.2020	390.6629	375.6541
05.08.2020	400.6012	373.3761
06.08.2020	393.9959	374.5442
07.08.2020	380.3301	375.7236
10.08.2020	395.4079	375.6098
11.08.2020	379.1113	375.9246
12.08.2020	387.2082	375.4205
13.08.2020	424.7995	374.7244
14.08.2020	438.0769	374.2784
17.08.2020	432.8415	376.3648
18.08.2020	423.3463	376.1752
19.08.2020	406.8794	376.9656
20.08.2020	416.2598	376.4894
21.08.2020	387.2406	372.7093
24.08.2020	408.7922	375.9520
25.08.2020	383.6050	375.0718
26.08.2020	386.3438	376.0341
27.08.2020	382.3492	375.5568
28.08.2020	395.0397	375.8682
31.08.2020	436.0908	375.0323
01.09.2020	480.7492	376.8203
02.09.2020	441.2141	376.1119
03.09.2020	383.5426	374.2912
04.09.2020	386.6691	375.2690
08.09.2020	336.7166	375.3999
09.09.2020	352.0539	375.7878
10.09.2020	367.3809	374.9095
11.09.2020	373.9666	375.0991
14.09.2020	375.8010	375.2542
15.09.2020	363.9366	374.9235

Elde edilen eğitim ve test verilerinin gerçek ve tahmin değerlerinin karşılaştırılması Grafik 22 ve 23’de gösterilmektedir.

Grafik 22. LSTM En İyi Modeli İçin Ethereum Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



Grafik 23. LSTM En İyi Modeli İçin Ethereum Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



3.6.2.3. Ripple Günlük Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) Model Tahmini

LSTM modelinde Ripple günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemi 30 günlük tahmini gerçekleştirilmiştir. Daha sonra tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan window size, unit ve epoch sayıları için performans ölçüt değerlerine Tablo 15’de yer verilmektedir.

Tablo 15. LSTM Modelinde Ripple Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

Performans Ölçütleri	3 Window Size	2 Window Size	2 Window Size	4 Window Size	2 Window Size	4 Window Size	4 Window Size	
	80 Unit 100 Epoch	100 Unit 105 Epoch	80 Unit 115 Epoch	50 Unit 120 Epoch	60 Unit 110 Epoch	100 Unit 115 Epoch	90 Unit 110 Epoch	
Eğitim	MAE	0.07353	0.08202	0.031177	0.03629	0.03718	0.05582	0.04819
	MSE	0.03541	0.04449	0.00611	0.00804	0.00947	0.02052	0.02035
	RMSE	0.18818	0.21092	0.07817	0.08967	0.09730	0.14325	0.14267
	MAPE	229.74139	129.99571	52.53857	41.41565	27.88150	61.88256	36.20587
Test	MAE	0.01954	0.02322	0.02537	0.03042	0.02886	0.02956	0.03621
	MSE	0.00054	0.00078	0.00110	0.00131	0.00131	0.00165	0.00177
	RMSE	0.02323	0.02786	0.03320	0.03623	0.03619	0.04065	0.04205
	MAPE	7.10898	8.31782	9.35979	10.52110	10.83310	11.11106	12.57738


Tablo 5’de yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin MAE, MSE ve RMSE değerlerine göre 2 window size, 80 unit ve 115 epoch sayısı ile MAPE değerine göre ise 2 window size, 60 unit ve 110 epoch sayısı ile elde edildiği görülmektedir. En iyi test modeli ise 3 window size, 80 unit ve 100 epoch sayısı ile elde edilmiştir. Tablo 16’da ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 16. LSTM En İyi Modeli için Ripple Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri


Tarih	Ripple Gerçek Değerleri	Ripple Tahmin Değerleri
04.08.2020	0.30091	0.27249
05.08.2020	0.30284	0.26848
06.08.2020	0.30321	0.27671
07.08.2020	0.29490	0.28182
10.08.2020	0.29453	0.27697
11.08.2020	0.28347	0.28153
12.08.2020	0.28223	0.28033
13.08.2020	0.29394	0.28473
14.08.2020	0.30023	0.26295
17.08.2020	0.31668	0.26839
18.08.2020	0.30298	0.27044
19.08.2020	0.29012	0.27028
20.08.2020	0.29218	0.27459
21.08.2020	0.27930	0.27188
24.08.2020	0.28921	0.26756
25.08.2020	0.27762	0.26877
26.08.2020	0.27688	0.27198
27.08.2020	0.26397	0.26983
28.08.2020	0.27169	0.27148
31.08.2020	0.28227	0.27715
01.09.2020	0.29665	0.27361
02.09.2020	0.27655	0.27400
03.09.2020	0.24787	0.27417
04.09.2020	0.25462	0.28115
08.09.2020	0.23600	0.27521
09.09.2020	0.23900	0.27204
10.09.2020	0.24293	0.26926
11.09.2020	0.24302	0.26359
14.09.2020	0.24556	0.27060
15.09.2020	0.24291	0.26411

Elde edilen eğitim ve test verilerinin gerçek ve tahmin değerlerinin karşılaştırması Grafik 24 ve 25’de gösterilmektedir.

Grafik 24. LSTM En İyi Modeli için Ripple Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



Grafik 25. LSTM En İyi Modeli için Ripple Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



3.6.3. Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Modeli ile Tahmin Sonuçlarının Elde Edilmesi

Google Colaboratory üzerinde Keras kütüphanesi kullanılarak GRU modeli oluşturulmuştur. GRU modeli oluşturulurken ilk olarak Keras'ın sıralı katmanlarını kullanmak için sequential eklenmiştir. Sequential'ın eklenmesinden sonra tam bağlı katman eklemek için dense ağ mimarisi kullanılmıştır. Yeterli miktarda veri olmasına rağmen verilerde kırılmanın fazla olması gibi sebeplerden ötürü aşırı öğrenme- ezberleme (overfitting) ihtimali ortaya çıkmıştır. Overfitting durumunu engellemek için ise ağı dropout hiper parametresini eklenmiştir. Dropout ekleyerek nöronların tamamı eğitime dahil edilmemiş ve kullanılan dropout oranı kadar nöronun eğitime tabi olması engellenmiştir. Dropoutların LSTM modelinde değiştirilmeyip, GRU modelinde değiştirilmesinin sebebi ise; LSTM'de mevcut olan unutmama kapısının GRU'da olmamasıdır. LSTM'de yer alan dropoutlar sadece düzenleyici görevi görmektedirler.

3.6.3.1. Bitcoin Günlük Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Model Tahmini

GRU modelinde Bitcoin günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemi 30 günlük tahmini gerçekleştirilmiştir. Daha sonra tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan window size, unit, epoch ve dropout sayıları için performans ölçüt değerlerine Tablo 17'de yer verilmektedir.

Tablo 17. GRU Modelinde Bitcoin Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

		2	5	5	5	5	3	3
		Window	Window	Window	Window	Window	Window	Window
		Size	Size	Size	Size	Size	Size	Size
Performans Ölçütleri		75 Unit	50 Unit	100 Unit	70 Unit	70 Unit	100 Unit	80 Unit
		110	100	110	115	115	120	120
		Epoch	Epoch	Epoch	Epoch	Epoch	Epoch	Epoch
		0.2	0.3	0.2	0.2	0.2	0.3	0.2
		Dropout	Dropout	Dropout	Dropout	Dropout	Dropout	Dropout
Eğitim	MAE	271.10	548.25	263.02	278.51	270.37	272.80	233.52
	MSE	229667.59	715322.13	311693.97	261288.10	264251.90	252558.70	202809.60
	RMSE	479.24	845.77	558.30	511.16	514.05	502.55	450.34
	MAPE	10.83	20.87	11.76	8.36	9.00	9.58	7.54
Test	MAE	412.47	424.06	457.55	482.14	469.99	479.22	564.84
	MSE	238304.02	258233.57	297582.11	342007.01	390391.82	515003.69	449186.38
	RMSE	488.16	508.17	545.51	584.81	624.81	717.64	670.21
	MAPE	3.66	3.74	4.07	4.24	4.28	4.44	5.08

Tablo 17’de yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 3 window size, 80 unit, 120 epoch ve 0.2 dropout sayısı ile elde edildiği görülmektedir. En iyi test modeli ise 2 window size, 75 nöron, 110 epoch ve 0.2 dropout sayısı ile elde edilmiştir. Tablo 18’de ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 18. GRU En İyi Modeli İçin Bitcoin Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri


Tarih	Bitcoin Gerçek Değerleri	Bitcoin Tahmin Değerleri
04.08.2020	11202.65191	11361.81934
05.08.2020	11721.43847	11308.46484
06.08.2020	11769.30911	11501.36523
07.08.2020	11598.96906	11523.83008
10.08.2020	11870.36954	11572.39746
11.08.2020	11392.64409	11517.93359
12.08.2020	11575.51247	11610.81152
13.08.2020	11773.44812	11302.17578
14.08.2020	11774.40825	11383.35449
17.08.2020	12315.76242	11442.72266
18.08.2020	11992.69600	11404.25586
19.08.2020	11736.84906	11579.91895
20.08.2020	11867.52034	11365.51172
21.08.2020	11524.69895	11094.60645
24.08.2020	11771.40805	11048.16406
25.08.2020	11358.45432	11257.90918
26.08.2020	11472.04912	10919.25684
27.08.2020	11314.67374	11344.93164
28.08.2020	11527.88303	11250.31543
31.08.2020	11678.34823	11260.67773
01.09.2020	11970.36486	11066.04980
02.09.2020	11414.52093	10954.60742
03.09.2020	10261.49441	10622.62305
04.09.2020	10471.96641	10975.46387
08.09.2020	10108.63545	10866.56543
09.09.2020	10223.11141	10923.26563
10.09.2020	10334.63073	10323.71582
11.09.2020	10387.02074	10952.82520
14.09.2020	10662.71991	10359.56934
15.09.2020	10779.38102	9860.83203

Elde edilen eğitim ve test verilerinin gerçek ve tahmin değerlerinin karşılaştırması Grafik 26 ve 27’de gösterilmektedir.

Grafik 26. GRU En İyi Modeli için Bitcoin Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



Grafik 27. GRU En İyi Modeli için Bitcoin Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



3.6.3.2. Ethereum Günlük Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Model Tahmini

GRU modelinde Ethereum günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemi 30 günlük tahmini gerçekleştirilmiştir. Daha sonra tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analiz yaparken kullanılan window size, unit, epoch ve dropout sayıları için performans ölçüt değerlerine Tablo 19’da yer verilmektedir.

Tablo 19. GRU Modelinde Ethereum Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

		5 Window Size 70 Unit 105 Epoch 0.2 Dropout	2 Window Size 100 Unit 105 Epoch 0.2 Dropout	2 Window Size 70 Unit 115 Epoch 0.2 Dropout	4 Window Size 80 Unit 115 Epoch 0.2 Dropout	5 Window Size 75 Unit 100 Epoch 0.2 Dropout	3 Window Size 80 Unit 105 Epoch 0.2 Dropout	2 Window Size 80 Unit 115 Epoch 0.2 Dropout
Eğitim	MAE	30.61	20.57	21.21	21.24	27.88	25.26	18.99
	MSE	2645.86	1436.45	1687.81	1588.83	2290.88	1832.83	1233.54
	RMSE	51.44	37.90	41.08	39.86	47.86	42.81	35.12
	MAPE	94.60	69.51	86.00	117.45	44.94	32.82	25.73
Test	MAE	28.05	32.31	36.37	36.22	41.30	41.12	62.92
	MSE	1204.22	1718.69	2311.35	2176.20	2509.83	2466.41	4914.30
	RMSE	34.70	41.46	48.08	46.65	50.10	49.66	70.10
	MAPE	7.16	7.83	8.91	9.37	10.13	10.39	15.57


Tablo 19’da yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 2 window size, 80 unit, 115 epoch ve 0.2 dropout sayısı ile elde edildiği görülmektedir. En iyi test modeli ise 5 window size, 70 unit, 105 epoch ve 0.2 dropout sayısı ile elde edilmiştir. Tablo 20’de ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 20. GRU En İyi Modeli İçin Ethereum Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri


Tarih	Ethereum Gerçek Değerleri	Ethereum Tahmin Değerleri
04.08.2020	390.66286	390.84238
05.08.2020	400.60120	405.40610
06.08.2020	393.99593	397.52582
07.08.2020	380.33005	384.06879
10.08.2020	395.40785	420.02841
11.08.2020	379.11134	397.89023
12.08.2020	387.20817	405.33908
13.08.2020	424.79946	410.74814
14.08.2020	438.07687	417.40088
17.08.2020	432.84146	424.70184
18.08.2020	423.34633	440.14343
19.08.2020	406.87943	439.50150
20.08.2020	416.25979	430.67780
21.08.2020	387.24061	430.33722
24.08.2020	408.79220	423.10284
25.08.2020	383.60497	427.43179
26.08.2020	386.34382	424.82693
27.08.2020	382.34915	425.45074
28.08.2020	395.03973	435.45465
31.08.2020	436.09077	411.62827
01.09.2020	480.74918	409.85281
02.09.2020	441.21413	395.22211
03.09.2020	383.54259	392.65015
04.09.2020	386.66908	379.99960
08.09.2020	336.71656	385.96344
09.09.2020	352.05395	409.72287
10.09.2020	367.38087	372.48163
11.09.2020	373.96662	418.85721
14.09.2020	375.80100	426.29974
15.09.2020	363.93660	437.28204

Elde edilen eğitim ve test verilerinin gerçek ve tahmin değerlerinin karşılaştırması Grafik 28 ve 29’da gösterilmektedir.

Grafik 28. GRU En İyi Modeli için Ethereum Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



Grafik 29. GRU En İyi Modeli için Ethereum Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



3.6.3.3. Ripple Günlük Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Model Tahmini

GRU modelinde Ripple günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemi 30 günlük tahmini gerçekleştirilmiştir. Daha sonra tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analiz yaparken kullanılan window size, unit, epoch ve dropout sayıları için performans ölçüt değerlerine Tablo 21’de yer verilmektedir.

Tablo 21. GRU Modelinde Ripple Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

		2 Window Size 80 Unit 105 Epoch 0.4 Dropout	2 Window Size 70 Unit 100 Epoch 0.3 Dropout	5 Window Size 80 Unit 120 Epoch 0.2 Dropout	2 Window Size 70 Unit 105 Epoch 0.3 Dropout	4 Window Size 70 Unit 105 Epoch 03 Dropout	2 Window Size 50 Unit 115 Epoch 0.3 Dropout	2 Window Size 75 Unit 115 Epoch 0.2 Dropout
Eğitim	MAE	0.05619	0.03780	0.03192	0.02858	0.04546	0.03133	0.02487
	MSE	0.02273	0.00934	0.00479	0.00681	0.01572	0.00746	0.00420
	RMSE	0.15077	0.09664	0.06919	0.08250	0.12537	0.08634	0.06478
	MAPE	50.0715 6	31.3043 9	45.6782 4	23.1702 5	27.7227 6	22.0895 4	17.7301 6
Test	MAE	0.01723	0.01807	0.01811	0.01985	0.01956	0.02181	0.02882
	MSE	0.00054	0.00063	0.00044	0.00059	0.00059	0.00083	0.00105
	RMSE	0.02334	0.02511	0.02097	0.02422	0.02424	0.02884	0.03246
	MAPE	6.42178	6.50478	6.55218	6.94716	6.99505	7.93005	10.2593 7


Tablo 8’de yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 2 window size, 75 unit, 115 epoch ve 0.2 dropout sayısı ile elde edildiği görülmektedir. En iyi test modeli ise MAE ve MAPE değerlerine göre 2 window size, 80 unit, 105 epoch ve 0.4 dropout sayısı ile, MSE ve RMSE değerlerine bakıldığında ise 5 window size, 80 unit, 120 epoch ve 0.3 dropout sayısı ile elde edilmiştir. Tablo 22’de ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 22. GRU En İyi Modeli İçin Ripple Kapanış Fiyatlarının 30 Günlük Tahmin Değerleri


Tarih	Ripple Gerçek Değerleri	Ripple Tahmin Değerleri
04.08.2020	0.30091	0.26360
05.08.2020	0.30284	0.28529
06.08.2020	0.30321	0.28646
07.08.2020	0.29490	0.28468
10.08.2020	0.29453	0.28364
11.08.2020	0.28347	0.28918
12.08.2020	0.28223	0.27475
13.08.2020	0.29394	0.28948
14.08.2020	0.30023	0.28305
17.08.2020	0.31668	0.27856
18.08.2020	0.30298	0.28117
19.08.2020	0.29012	0.28572
20.08.2020	0.29218	0.27969
21.08.2020	0.27930	0.28797
24.08.2020	0.28921	0.28786
25.08.2020	0.27762	0.27529
26.08.2020	0.27688	0.26928
27.08.2020	0.26397	0.27864
28.08.2020	0.27169	0.27254
31.08.2020	0.28227	0.28351
01.09.2020	0.29665	0.27693
02.09.2020	0.27655	0.27776
03.09.2020	0.24787	0.30850
04.09.2020	0.25462	0.30301
08.09.2020	0.23600	0.28391
09.09.2020	0.23900	0.27723
10.09.2020	0.24293	0.27066
11.09.2020	0.24302	0.25430
14.09.2020	0.24556	0.25729
15.09.2020	0.24291	0.25189

Elde edilen eğitim ve test verilerinin gerçek ve tahmin değerlerinin karşılaştırması Grafik 30 ve 31’de gösterilmektedir.

Grafik 30. GRU En İyi Modeli için Ripple Eğitim Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



Grafik 31. GRU En İyi Modeli için Ripple Test Verilerinin Gerçek ve Tahmin Değerlerinin Karşılaştırması



3.6.4. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) Modellerinin Tahmin Sonuçlarının Karşılaştırılması

Basit RNN modelleriyle gelecek tahmini yapıldığında her zaman sağlıklı sonuçlar alınamamaktadır. Bunun sebebi ise “geri yayılımın” kullanılmasıdır. Geri yayılımın kullanılması gradient değerlerin geriye doğru küçülmesi ve en sonunda yok olmasına sebep olmaktadır. Gradient değerlerinin giderek küçülmesi ya da yok olması, RNN’de oluşturulan modelin her adımda sahip olduğu dahili hafızanın üzerine çok fazla yazma eğiliminde olmasına sebep olmaktadır. RNN’in üzerine yazma eğiliminin artması ise oluşturulan modelin geçmişteki verilerden çıkarım yapma yeteneğinin kaybolmasına yol açmaktadır. Bu yetenek kaybı “vanishing gradient Problemi” olarak da adlandırılmaktadır. Vanishing gradient problemi, ağı eğitimi için sunulan verileri ezberlemesi ya da uydurma veriler yaratmasıyla sonuçlanmaktadır. Bu problemleri ortadan kaldırmak için RNN temelli olan LSTM ve GRU mimarileri geliştirilmiştir. LSTM ve GRU’da bulunan kapı yapıları sayesinde, modelin eğitimi sırasında kullanılan bir ağı üstünden her döngü (epoch) de sadece bir veri katmanı geçmektedir. Böylece bu modellerdeki hücreler her döngü de farklı verileri görüp anlamlı bütün oluşturabilmekte ve verilerin üzerine yazma durumu olmamaktadır.

LSTM ile GRU mimarileri temelde birbirlerine çok benzemektedir. LSTM’de üç kapı bulunurken GRU’da ise iki kapı bulunmaktadır. LSTM daha karmaşık modellerde daha iyi sonuç verse de GRU basit yapısı gereği daha hızlı ve daha doğru sonuçlar verebilmektedir.

Bu çalışmada ise iki farklı yöntemle fiyat tahmininde bulunulmuştur. Tablo 23’de görüldüğü gibi çalışmada en iyi tahmin sonucunu Bitcoin ve Ripple için GRU, Ethereum için ise MAE ve MAPE değerlerinde en düşük hata oranını LSTM verirken, MSE ve RMSE değerlerinde GRU vermiştir.

Tablo 23. LSTM ve GRU Modellerinin Performans Ölçüt Değerlerinin Karşılaştırılması

BİTCOİN	LSTM EĞİTİM	LSTM TEST	GRU EĞİTİM	GRU TEST
Performans Ölçütleri	4 Window Size 75 Unit 120 Epoch	5 Window Size 80 Unit 110 Epoch	3 Window Size 80 Unit 120 Epoch 0.2 Dropout	2 Window Size 75 Unit 110 Epoch 0.2 Dropout
MAE	259.94	566.07	233.52	412.47
MSE	227707.10	568051.32	202809.60	238304.02
RMSE	477.19	753.69	450.34	488.16
MAPE	9,21	5.08	7.54	3.66
ETHEREUM	LSTM EĞİTİM	LSTM TEST	GRU EĞİTİM	GRU TEST
Performans Ölçütleri	3 Window Size 90 Unit 115 Epoch	2 Window Size 100 Unit 105 Epoch	2 Window Size 80 Unit 115 Epoch 0.2 Dropout	5 Window Size 70 Unit 105 Epoch 0.2 Dropout
MAE	21.35	27.13	18.99	28.05
MSE	1469.17	1316.01	1233.54	1204.22
RMSE	38.33	36.28	35.12	34.70
MAPE	30.79	6.53	25.73	7.16
RİPPL	LSTM EĞİTİM	LSTM TEST	GRU EĞİTİM	GRU TEST
Performans Ölçütleri	2 Window Size 60 Unit 110 Epoch	3 Window Size 80 Unit 100 Epoch	2 Window Size 75 Unit 115 Epoch 0.2 Dropout	2 Window Size 80 Unit 105 Epoch 0.4 Dropout
MAE	0.03718	0.01954	0.02487	0.01723
MSE	0.00947	0.00054	0.00420	0.00054
RMSE	0.09730	0.02323	0.06478	0.02334
MAPE	27.88150	7.10898	17.73016	6.42178

SONUÇ VE DEĞERLENDİRME

Hem bireysel hem de kurumsal yatırımcılar tasarrufları ile yapmış oldukları yatırımlardan maksimum kâr elde etmek isterler. Fakat kazanma arzusunun yanında tasarruflarını kaybetme korkusu da onlar için riski oluşturur. Yapmış olduğu yatırımlarla daha az risk alarak kaybetmek istemeyenler yatırımlarını vadeli mevduat hesapları veya tahvil & bono gibi yatırımlara yönlendirebilirler. Daha fazla getiri elde edebilmek için bir miktar daha fazla risk alabilen yatırımcılar ise yatırım fonları, döviz, altın, hisse senedi veya vadeli işlem piyasası ürünleri gibi araçlara yatırım yapabilmektedirler. Tüm bu araçlara ilave kripto paralar da yatırım alanına girmiş ve portföylerde yer almaya başlamıştır. Kripto paralara yatırım genel olarak dijital sistemler üzerinden gerçekleştirildiği için konu ile ilgili hem teknik hem de sistematik bilgi açığı bulunmaktadır. Yatırımcılar açısından tüm yatırım araçlarında olduğu gibi kripto paralara yatırım zamanlaması da en çok merak edilen konulardandır. Çünkü doğru zamanlama kâr ettirirken, yanlış zamanlama para kaybettirmektedir. Bir yatırım aracının gelecekteki fiyat seyriyle ilgili projeksiyona sahip olmak yatırımcılara önemli bir avantaj kazandırmaktadır.

Bu çalışmada Bitcoin, Ethereum ve Ripple dijital para birimlerinin, 30 günlük fiyat tahmini için özel bir RNN yöntemi olan LSTM ve GRU modelleri kullanılmıştır. Kripto para fiyatlarının tahmininde hata oranlarının minimize edilebilmesi için günlük verilerden yararlanılmıştır. Çalışmada kripto para fiyatlarını etkileyen 11 farklı değişken kullanılmış, fiyatlarının açıklanma tarihlerine göre her kripto para için farklı zaman aralıkları baz alınmıştır. Yapılan analizlerde öğrenme tekrarı arttırıldıkça ve hiperparametre değerleri değiştirildikçe başarı oranında da artış gözlenmiştir. Çalışmanın sonucunda, MAPE performans ölçütüne göre Bitcoin ve Ripple için GRU modelinin, Ethereum için ise LSTM modelinin daha iyi sonuçlar verdiğini göstermiştir. Analize dahil edilen kripto paraların bir aylık test değerlerinin MAPE performans ölçütüne göre başarı oranları sırasıyla; Bitcoin için %94-%96 arası, Ethereum için %85-%93 ve Ripple için ise %89-%93 arası bulunmuştur. Bu değerler herhangi bir merkeze bağlı olmayan ve dış faktörlerden oldukça az etkilenen dijital paralar için yüksek bir başarıdır.

Tahmin sonuçları incelendiğinde Bitcoin'in hem LSTM hem de GRU modellerinde test ve eğitim verilerinin başarı oranının Ethereum ve Ripple'a göre çok daha yüksek olduğu görülmüştür. Bunun nedeni ise son yıllarda Bitcoin'in diğer kripto paralara göre artan risk ortamından, ekonomik ve siyasi belirsizliklerden daha çok etkileniyor olmasıdır. Bununla birlikte son yıllarda geleneksel paralar ile uyum içine girmeye başlayan kripto paralar siyasi ve ekonomik dalgalanmalardan etkilenmeye başladığı ve risk ortamlarında geleneksel paralar ile birlikte değer kaybettiği görülmüştür. İşlem hacmi ve piyasa değeri en yüksek olan Bitcoin'in ise diğer kripto para birimlerine bakılarak Çin ve ABD gibi ülkelerde oluşan siyasi ve ekonomik dalgalanmalardan oldukça fazla etkilenmesi analiz sonuçlarına da açık bir şekilde yansımıştır. Çünkü analize dahil edilen bağımsız değişkenler arasında risk ve belirsizliği ölçen değişkenler tahmin başarı düzeyinin yükselmesini sağlamıştır.

Kripto paraların volatilesini etkileyen birkaç ana başlık sayılabilmesine rağmen bu başlıklar kendi içinde birden fazla durumu barındırmaktadır. Örnek olarak haberler her yatırım aracını etkilediği gibi kripto paraların da volatilité seyrini etkilemektedir. Fakat diğer yatırım araçlarına ulusal düzeydeki ya da uluslararası düzeydeki haberler etki etmekteyken, kripto paralara sosyal medyada oluşan trendlerin bile etkisi olmaktadır. Bunun yanı sıra kripto paraların piyasadaki bilinirliği az olmakla birlikte değişkenler kendi içinde birçok faktör barındırmaktadır. Bu faktörler de kripto paraların volatilesinde kırılmalara sebep olmaktadır. Tüm bu nedenlerden dolayı kripto para endeksleri diğer para birimleri ve yatırım araçlarına göre daha fazla ve daha keskin kırılmalara sahiptirler. Bu durumda kripto para tahminini diğer yatırım araçlarının tahmininden daha zor kılmaktadır.

Makine öğrenme ve derin öğrenme gibi yapay zekanın alt dalları kullanılarak yapılan tahminleme modellerinde sonuçlar gerçeğe oldukça yakındır. Özellikle derin öğrenme yöntemleri kullanılarak oluşturulan modellerde daha iyi sonuçlar elde etmek için büyük veriye ihtiyaç duyulmaktadır. Veri miktarının fazlalığı modelin daha doğru tahmin yapması ve gelecekteki her duruma adapte olabilecek bir öğrenme yapısına sahip olmasını sağlamaktadır. Kripto para piyasasının ise görece yeni bir piyasa olması ve istenilen miktarlarda büyük veriye ulaşamaması bazı kripto paralar için tahmin başarısını düşürmektedir. Bunun yanı sıra yatırımcılar tarafından kabul

görmüş para birimlerinin aksine yeni olan bu dijital para birimleriyle ilgili yatırımcıların yeterli bilgiye sahip olmaması da bu sebeplerden biridir.

Kripto paralar genel itibarıyla merkezi bir otoriteye bağlı değildir. Bu bağımsızlık kripto paraları ülke bazlı alınabilecek siyasi ve ekonomik kararların etkisinden kurtarabilir diye düşünülebilir. Kripto paralar uluslararası alanda alınıp satılan yatırım araçları olduğu için diğer uluslararası yatırım araçlarının alternatifi niteliğindedir. Bu durum kripto paraları altın, diğer kıymetli metaller, önemli borsa endeksleri, fonlar, tahviller, vadeli mevduat hesapları ve petrol için alternatif yatırım aracı haline getirmiştir. Kripto paralar da diğer sayılan yatırım araçları gibi gelişmiş ülke ekonomilerinde meydana gelen değişimlerden etkilenebilir. Bu çalışma kapsamında oluşturulan modellere alternatif yatırım araçlarıyla birlikte, piyasalara olan güven ve belirsizlikleri ölçen değişkenler de eklenmiştir. Bu değişkenlerin tahmin başarı düzeyini arttırdığı düşünülmektedir.

Bundan sonra yapılacak çalışmalarda araştırmacılar daha fazla kripto para ile çalışabilir ve kuracakları modellere kripto paralar ile ilişkili olabilecek diğer değişkenler ekleyebilirler. Finans dünyasında dinamik bir yapı olduğu unutulmamalı ve içinde bulunulan dönemin dinamikleri kurulacak modellere yansıtılmalıdır.

KAYNAKÇA

- Akal, M. (2008). “Optimum Öngörü Tekniğinin Seçimi”, <http://web.sakarya.edu.tr/~hgurak/yazilar/makale/ONGOM.doc>, Erişim Tarihi: 11.11.2020.
- Alpaydın, E. (2011). *Yapay Öğrenme*, İstanbul, Boğaziçi Üniversitesi Yayınevi.
- Aminanto, M. E. ve Kim, K. (2016). “Deep Learning in Intrusion Detection System: An Overview, 2016 International Research Conference on Engineering and Technology (2016 IRCET), 1-12.
- Ankalkoti, P. ve Santhosh, M. (2017). “A Relative Study on Bitcoin Mining”, *Imperial Journal of Interdisciplinary Research (IJIR)*, 3(5), 1757-1761.
- Antonopoulos, A. M. (2014). *Mastering Bitcoin: Unlocking Digital Cryptocurrencies*, Yayıncı (lar):O'Reilly Media, Inc., ISBN: 9781449374044.
- Aslan, A. (2018). Kripto Para Olgusu ve Blockchain Teknolojisi: Ekonomik Aktörlerin Tepkisi, Maliyet Analizi, VAR Modeli ve Granger Nedensellik Testi, Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, Hacettepe Üniversitesi, Ankara. 1-109.
- Atlan, F. (2019). Kripto Para Değerlerinin Yapay Zeka Teknikleri ile Tahmini, Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, Burdur Mehmet Akif Ersoy Üniversitesi, Burdur.
- Avrupa Merkez Bankası, “US Dollar (USD)”, https://www.ecb.europa.eu/stats/policy_and_exchange_rates/euro_reference_exchange_rates/html/usd.xml, Erişim Tarihi: 23.09.2020.
- Bengio, Y. (2009). “Learning Deep Architectures for AI”, *Foundations and trends® in Machine Learning*, 2(1), 1–127.
- Beyaz Net, (2019). “Kriptografik Hash Fonksiyonu Nedir?”, https://www.beyaz.net/tr/guvenlik/makaleler/kriptografik_hash_fonksiyonu_nedir.html, Erişim Tarihi: 03.11 2020.
- Bfmedia, (2019). “ASIC Madenciliği Nedir?”, <https://www.bfmedia.io/sikca-sorulan-sorular/asic-madenciligi-nedir-5386.html>, Erişim Tarihi: 04.11 2020.
- Blockchain, (2020). “Madencilik Bilgileri-Toplam İşlem Ücretleri (USD)”, <https://www.blockchain.com/charts/transaction-fees-usd>, Erişim Tarihi: 04.11 2020.

- Bloomberght, (2016). “Libor Nedir?”, [https://businessht.bloomberght.com/piyasalar/haber/1280890-libor-nedir#:~:text=Libor%20\(London%20Interbank%20Offered%20Rate,bir birlerine%20uygulad%C4%B1klar%C4%B1%20referans%20faiz%20oran%C4%B1d%C4%B1r.](https://businessht.bloomberght.com/piyasalar/haber/1280890-libor-nedir#:~:text=Libor%20(London%20Interbank%20Offered%20Rate,bir birlerine%20uygulad%C4%B1klar%C4%B1%20referans%20faiz%20oran%C4%B1d%C4%B1r.), Erişim Tarihi:14.11.2020.
- Bitcoin Gündem, (2020). “Bitcoin (BTC) Adresi Nedir?”, <https://www.bitcoingundem.com/amp/bitcoin-btc-adresi-nedir/>, Erişim Tarihi: 03.11 2020.
- Boyraz, C. (2019). Derin Öğrenme ile Debi Tahmini, Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul.
- BtcTurk, (2020). “Bitcoin (BTC) Nedir?”, <https://www.btcturk.com/bilgi-platformu/bitcoin-btc-nedir/>, Erişim Tarihi:21.10.2020.
- BtcTurk, (2020). “Kriptopara Madenciliği (Mining) Nedir?”, <https://www.btcturk.com/bilgi-platformu/quiz/kriptopara-madenciligi-mining-nedir/>, Erişim Tarihi: 04.11 2020.
- BtcTurk, (2020). “Tether (USTD) Nedir?”, <https://www.btcturk.com/bilgi-platformu/tether-usdt-nedir/>, (Erişim Tarihi:21.10.2020).
- Business Insider, (2018). “The 11 Biggest ICO Fundraises of 2017”, <https://www.businessinsider.com/the-10-biggest-ico-fundraises-of-2017-2017-12?r=UK#1-filecoin-257-million-10>, Erişim Tarihi: 27.10 2020.
- Buterin, V. (2014). “A Next-Generation Smart Contract and Decentralized Application Platform”, <https://github.com/ethereum/wiki/wiki/White-Paper>, Erişim Tarihi: 12.11 2020.
- Chen, J., (2020). “West Texas Intermediate (WTI)”, <https://www.investopedia.com/terms/w/wti.asp#:~:text=Key%20Takeaways,the%20NYMEX's%20oil%20futures%20contract.>, Erişim Tarihi:14.11.2020.
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. ve Bengio, Y. (2014). “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation”, arXiv:1406.1078, 1724–1734.
- CIS 3347 Cruz Guzman, (2020). “Client Server and Peer-to-Peer Networking”, <https://sites.google.com/site/cis3347cruzguzman014/module-2/client-server-and-peer-to-peer-networking>, Erişim Tarihi: 27.10 2020.
- Ciaian, P. ve Rajcaniova, M. (2016). “The Digital Agenda of Virtual Currencies: Can Bitcoin Become a Global Currency?”. Information Systems and e-Business Management, 14(4), 883-919.

- Cireşan, D.C., Meier, U., Masci, J. ve Gambardella, L. M. (2011). “Flexible, High Performance Convolutional Neural Networks for Image Classification”, *Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence*, 1237–1242.
- Cognizant, (2016). “Blockchain in Banking: A Measured Approach”, <https://www.cognizant.com/whitepapers/Blockchain-inBanking-A-Measured-Approach-codex1809.pdf>, Erişim Tarihi: 27.10.2020.
- Coin Medya, (2018). “Ethereum Nedir?”, <https://btc.coinmedya.com/ethereum-nedir.html>, Erişim Tarihi: 12.11.2020.
- Coin Metrics, (2020). “Bitcoin Price (USD)”, <https://coinmetrics.io/tools/>, Erişim Tarihi: 14.11.2020.
- Coin Metrics, (2020). “Bitcoin Price (USD) and Supply, Free Float”, <https://coinmetrics.io/tools/>, Erişim Tarihi: 23.09.2020.
- Coin Metrics, (2020). “Ethereum Price (USD) and Supply, Free Float”, <https://coinmetrics.io/tools/>, Erişim Tarihi: 23.09.2020.
- Coin Metrics, (2020). “Supply, Free Float”, <https://coinmetrics.io/tools/>, Erişim Tarihi: 14.11.2020.
- Coin Metrics, (2020). “XRP (Ripple) Price (USD) and Supply, Free Float”, <https://coinmetrics.io/tools/>, Erişim Tarihi: 23.09.2020.
- Coin Rivet, (2018). “Is Volume Important for Cryptocurrency Exchanges?”, <https://coinrivet.com>, Erişim Tarihi:14.11.2020.
- CoinMarketCap (2020). “All Cryptocurrencies”, <https://coinmarketcap.com/all/views/all>, Erişim Tarihi: 27.10.2020.
- CoinMarketCap (2020). “Bitcoin Cash Charts ve About Bitcoin Cash”, <https://coinmarketcap.com/currencies/bitcoin-cash/>, Erişim Tarihi: 12.11.2020.
- CoinMarketCap (2020). “Bitcoin Charts and About Bitcoin”, <https://coinmarketcap.com/tr/currencies/bitcoin/>, Erişim Tarihi: 12.11.2020.
- CoinMarketCap, (2020). “Bitcoin Volume”, <https://coinmarketcap.com/currencies/bitcoin/historical-data/?start=20130429&end=20200916>, Erişim Tarihi: 23.09.2020.
- CoinMarketCap (2020). “Ethereum Charts ve About Ethereum”, <https://coinmarketcap.com/tr/currencies/ethereum/>, Erişim Tarihi: 12.11.2020.

- CoinMarketCap, (2020). “Ethereum Volume”, <https://coinmarketcap.com/currencies/ethereum/historical-data/?start=20140906&end=20200916>, Erişim Tarihi: 23.09.2020
- CoinMarketCap (2020). “Tether Charts ve About Tether”, <https://coinmarketcap.com/currencies/tether/>, Erişim Tarihi: 12.11.2020.
- CoinMarketCap (2020). “XRP Charts ve About XRP”, <https://coinmarketcap.com/tr/currencies/xrp/>, Erişim Tarihi: 12.11.2020.
- CoinMarketCap, (2020). “XRP(Ripple) Volume”, <https://coinmarketcap.com/currencies/xrp/historical-data/?start=20130429&end=20200916>, Erişim Tarihi: 23.09.2020.
- CoinMarketCap (2020). “Piyasa Başına Göre Bugünün Kripto Para Birimi Fiyatları”, <https://coinmarketcap.com/>, Erişim Tarihi: 04.11.2020.
- Coinkazanma, (2018). “Kriptolojik Özet Fonksiyonu (Hash Function) Nedir?”, <https://coinkazanma.com/kriptolojik-ozet-fonksiyonu-hash-function-nedir/>, Erişim Tarihi: 03.11 2020.
- Cointelegraph, (2019). “Ripple nedir? Ripple Hakkında Bilmeniz Gereken Her Şey”, <https://tr.cointelegraph.com/ripple-101/what-is-ripple>, Erişim Tarihi: 13.11 2020.
- CoinTürk, (2020). “Yeni Başlayanlar İçin 12 Maddelik Kripto Para Başlangıç Rehberi”, <https://coin-turk.com/yeni-baslayanlar-icin-13-maddelik-bitcoin-rehberi>, Erişim Tarihi: 12.11. 2020.
- Colah’s Blog (2015). “Understanding LSTM Networks”, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>, Erişim Tarihi:18.11.2020.
- Corbet, S., Meegan, A., Larkin, C., Lucey, B. ve Yarovaya, L. (2018). “Exploring The Dynamic Relationships Between Cryptocurrencies and Other Financial Assets”, *Economics Letter*, 165, 28-54.
- Crosby, M., Pattanayak, P., Verma, S. ve Kalyanaraman, V. (2016), “Blockchain Technology: Beyond Bitcoin. Applied Innovation”, 2, 6-10.
- Çarkacı, N. (2017). “Derin Öğrenme Uygulamalarında Temel Kavramlar: Perceptron, Skor Fonksiyonu ve Hata Hesaplaması (Loss Function)”, <https://tr.linkedin.com/pulse/derin-%C3%B6%C4%9Frenme-uygulamalar%C4%B1nda-temel-kavramlar-skor-ve-%C3%A7arkac%C4%B1>, Erişim Tarihi:17.11.2020.

- Çetinkaya, Ş. (2018). “Kripto Paraların Gelişimi Ve Para Piyasalarındaki Yerinin Swot Analizi ile İncelenmesi”, *Uluslararası Ekonomi ve Siyaset Bilimleri Akademik Araştırmalar Dergisi*, 2 (5), 11-21.
- Deloitte, (2015). “Blockchain Distrupting the Financial Services Industry”, https://www2.deloitte.com/content/dam/Deloitte/ie/Documents/FinancialServices/IE_Cons_Blockchain_1015.pdf, Erişim Tarihi: 27.10 2020.
- Demir, E., Gozgora, G., Lau, C.K.M. ve Vigne, S.A. (2018). “Does Economic Policy Uncertainty Predict the Bitcoin Returns? An Empirical Investigation”, *Finance Research Letters*, 26, 145-149.
- Deng, L. (2014). “A Tutorial Survey Of Architectures, Algorithms and Applications for Deep Learning”, *APSIPA Transactions" on Signal and Information Processing*, 3, 3-8.
- Deng, L. ve Yu, D. (2014). “Deep Learning: Methods and Applications”, *Found. Trends® Signal Process*, 7(3–4), 197–387.
- Diffie, W. ve Hellman, M.E. (1976). “New Directions in Cryptography”, *IEEE Transactions on Infermation Theory*, 22(6), 644-654.
- Doğan, M. ve Ertugay, E. (2019). “Blokzinciri ve Muhasebe Alanındaki Uygulamaları”, *Üçüncü Sektör Sosyal Ekonomi Dergisi*, 54(4), 1654-1670.
- Dutta, A., Kumar, S. ve Basu, M. (2020). “A Gated Recurrent Unit Approach to Bitcoin Price Prediction”, *Journal of Risk and Financial Management*, 13(2), 1-16.
- Economic Policy Uncertainty, (2012). “US Equity Market Volatility Index (Financial Crises EMV Tracker)”, https://www.policyuncertainty.com/categorical_epu.html, Erişim Tarihi:14.11.2020.
- Economic Policy Uncertainty, (2012). “Monetary Policy Uncertainty Indices (Economic Policy Uncertainty)”, https://www.policyuncertainty.com/categorical_epu.html, Erişim Tarihi: 14.11.2020.
- Economic Policy Uncertainty, (2012). “Geopolitical Risk Index”, <https://www.policyuncertainty.com/gpr.html>, Erişim Tarihi: 14.11.2020.
- Economic Policy Uncertainty, (2012). “Twitter-based Uncertainty Indices”, https://www.policyuncertainty.com/twitter_uncert.html, Erişim Tarihi: 14.11.2020.
- Elman, J.L. (1990). “Finding Structure in Time”, *Cognitive Science*, 14, 179-211.

- Erdoğan, E. ve Özyürek, H. (2012). “Yapay Sinir Ağları ile Fiyat Tahminlemesi”, *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), 85-92.
- Erdogan, S. ve Dayan, V. (2019). *Analysis of Relationship Between International Interest Rates and Cryptocurrency Prices: Case for Bitcoin and LIBOR*, U. Hacıoglu içinde, *Blockchain Economics and Financial Market Innovation* (s. 486-513). Basakşehir, Istanbul, Turkey, Springer.
- Erözel Durbilmez, S. ve Yılmaz Türkmen, S. (2019). “Blockchain Teknolojisi ve Türkiye Finans Sektöründeki Durumu”, *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 4(1), 30-45.
- European Central Bank (ECB), (2012). *Virtual Currency Schemes*, Frankfurt.
- Evans, C. W. (2015). “Bitcoin in Islamic Banking and Finance”, *Journal of Islamic Banking and Finance*, 3(1), 1-11.
- Everis Next, (2016). “17 Blockchain Disruptive Use Cases”, <https://everisnext.com/2016/05/31/17-blockchain-disruptive-use-cases/>, Erişim Tarihi: 27.10.2020.
- Farell, R. (2015). “An Analysis of the Cryptocurrency Industry, Wharton Research Scholars”, *University of Pennsylvania Scholarly Commons*, 130. http://repository.upenn.edu/wharton_research_scholars/130, Erişim Tarihi: 06.11.2020.
- François-Lavet, V., Islam, R., Pineau, J., Henderson, P. ve Bellemare, M.G. (2018). *An Introduction to Deep Reinforcement Learning*, Boston/Delft, Now the Essence of Knowledge.
- Frankenfield, J. (2017). “Bitcoin Cash Nedir?”, <https://www.investopedia.com/terms/b/bitcoin-cash.asp>, Erişim Tarihi:21.10.2020.
- Fred (Economic Research Federal Reserve Bank of st. Louis), (2020). “12-Month London Interbank Offered Rate (LIBOR), based on U.S. Dollar”, <https://fred.stlouisfed.org/series/USD12MD156N>, Erişim Tarihi: 23.09.2020.
- Fung, B., Molico, M. ve Stuber, G. (2014). “Electronic Money and Payments: Recent Developments and Issues”, *Bank of Canada Banque Du Canada*, 1-34.
- Gartner, (2016). “Gartner's 2016 Hype Cycle for Emerging Technologies Identifies Three Key Trends That Organizations Must Track to Gain Competitive Advantage”, <https://www.gartner.com/en/newsroom/press-releases/2016-08-16-gartners-2016-hype-cycle-for-emerging-technologies-identifies-three-key-trends-that-organizations-must-track-to-gain-competitive-advantage>, Erişim Tarihi: 26.10.2020.

- Gemici, E. ve Polat, M. (2019). "Relationship Between Price and Volume in the Bitcoin Market", *Journal of Risk Finance*, 20(5), 435-444.
- Gezer, M. ve Saylan, S. (2017). *Açık Kaynaklı Makine Öğrenmesi Kütüphaneleri*, O. Torkul, S. Gülseçen, Y. Uyaroglu, G. Çağıl ve M. K. Uçar, (Editörler). "Mühendislikte Yapay Zeka ve Uygulamaları", Sakarya, Sakarya Üniversitesi Kütüphanesi Yayınevi.
- Gruber, N. ve Jockisch, A. (2020). "Are GRU Cells More Specific and LSTM Cells More Sensitive in Motive Classification of Text?", *Frontiers in Artificial Intelligence*, 3, 1-6.
- Gullapalli, S. (2018). Learning to Predict Cryptocurrency Price Using Artificial Neural Network Models of Time Series, Department of Computer Science College of Engineering, Master Thesis, Kansas State University, Manhattan, Kansas.
- Günen, E. (2020). "Bitcoin'in Piyasa Değeri 30 Saatte 11 Milyar Dolar Arttı", <https://tr.cointelegraph.com/news/bitcoin-market-capitalization-rised-11b-in-30-hours>, Erişim Tarihi: 07.03.2021.
- Gürbüz, F.B. (2018). "Tekrarlayan Sinir Ağı -Recurrent Neural Networks (RNN)", <https://medium.com/@batincangurbuz/tekrarlayan-sinir-a%C4%9F%C4%B1-recurrent-neural-networks-rnn-17b517dd0b3e>, Erişim Tarihi: 22.10.2020.
- Haenlein, M. ve Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence, *Haas School of Business University of California Berkeley*, 1-10.
- Hayes, A. S. (2017). "Cryptocurrency Value Formation: An Empirical Study Leading to a Cost Of Production Model for Valuing Bitcoin", *Telematics and Informatics*, 34(7), 1308-1321.
- Hendrickson, J. R., Hogan, T. L. ve Luther, W. J. (2016). "The Political Economy of Bitcoin", *Economic Inquiry*, 54(2), 925-939.
- Hewlett Packard Enterprise (2016). "Blockchain in the Financial Services Industry", *Business White Paper*, 61(4), 1-10.
- Hirano, Y., Pichl, L., Eom, C. Ve Kaizoji, T. (2018). "Analysis Of Bitcoin Market Efficiency By Using Machine Learning", *In CBU International Conference Proceedings*, 6, 175-180.
- Hochreiter, S. ve Schmidhuber, J. (1997). "Long Short-Term Memory", *Neural Computation*, 9(8), 1735-1780.
- Hyndman, R.J. ve Koehler, A.B. (2006). "Another Look at Measures of Forecast Accuracy", *International Journal of Forecasting*, 22(4), 679-688.

- IEEE (Balıkesir University IEEE Student Branch), “Yapay Zeka (Artificial Intelligence)”,
<http://www.balikesir.edu.tr/~ieeee/index.php/2019/10/29/yapay-zeka-artificial-intelligence/>, Erişim Tarihi:14.14.2020.
- IKON Menkul (2020). “S&P 500 Endeksi (ABD)”, <https://ikonmenkul.com.tr/sp500-endeksi>, Erişim Tarihi:14.11.2020.
- Indera, N.I., Yassin, I.M., Zabidi, A. ve Rizman, Z.I. (2017). “Non-Linear Autoregressive with Exogeneous Input (Narx) Bitcoin Price Prediction Model Using Pso-Optimized Parameters and Moving Average Technical Indicators”, *Journal of Fundamental and Applied Sciences*, 9(3S), 791-808.
- Inshyn, M., Mohilevskiy, L. ve Drozd, O. (2018). “The Issue of Cryptocurrency Legal Regulation in Ukraine and All over the World: A Comparative Analysis”, *Baltic Journal of Economic Studies*, 4(1), 169-174.
- Investing.com, (2007). “Ham Petrol WTI Vadeli İşlemleri”, <https://tr.investing.com/commodities/crude-oil-historical-data>, Erişim Tarihi: 23.09.2020.
- Investing.com, (2021). “Kripto Paralar”, <https://tr.investing.com/crypto/>, Erişim Tarihi: 06.03.2021.
- Investing.com, (2018). “Kripto Paranın Geleceği Nasıl? Hayaller ve Gerçekler...”, <https://tr.investing.com/news/cryptocurrency-news/kripto-parann-gelecegi-nasl-hayaller-ve-gercekler-542825>, Erişim Tarihi: 26.10 2020.
- Investing.com, (2007). “S&P 500 (SPX)”, <https://tr.investing.com/indices/us-spx-500-historical-data>, Erişim Tarihi: 23.09.2020.
- Investing.com, (2007). “XAU/USD-Altın Spot Amerikan Doları”, <https://tr.investing.com/currencies/xau-usd-historical-data>, Erişim Tarihi: 23.09.2020.
- İslamoğlu, E. (2015). “Aralık Değerli Zaman Serilerinde Kullanılan Modelleme Teknikleri”, *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8(2), 178–193.
- Jayalakshmi, T. ve Santhakumaran, A. (2011). “Statistical Normalization and Back Propagation for Classification”, *International Journal of Computer Theory and Engineering*, 3(1), 1793-8201.
- Ji, S., Kim, J. ve Im, H. (2019). “A Comparative Study of Bitcoin Price Prediction using Deep Learning”, *Mathematics*, 7, 898.
- Kahya, H. (2018). “Bitcoin Nedir?”, <https://www.yatirimkredi.com/bitcoin-nedir.html>, Erişim Tarihi: 06.11.2020.

- Kar, I. (2016). "The Latest Customers for the Technology Behind Bitcoin are Nato And the Us Military", <https://qz.com/681580/the-latest-customers-for-the-technology-behind-bitcoin-are-nato-and-the-us-military/>, Erişim Tarihi: 06.11.2020.
- Karpathy, A. (2015). "The Unreasonable Effectiveness of Recurrent Neural Networks", <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>, Erişim Tarihi:19.11.2020.
- Karthikeyan, R., Geetha, T., Santhini, T. ve Santhiya, R. (2017). "Classification of Peer-To-Peer Architectures and Applications", *International Journal of Engineering Science and Computing*, 7 (8), 14394-14397.
- Kaya, K. (2020). "Proof of Work (Pow) Nedir?", <https://bitcosar.com/proof-of-work-pow-nedir/>, Erişim Tarihi: 03.11 2020.
- Kenger, E. ve Tokmak, E (2018). "Ödeme Sistemleri ve Kripto Para (Payments Systems and Crypto Money)", *International Social Sciences Studies Journal*, 4 (23), 4696-4705.
- Kızrak, A. (2018). "ŞU KARA KUTUYU AÇALIM: Yapay Sinir Ağları", <https://ayyucekizrak.medium.com/%C5%9Fu-kara-kutuyu-a%C3%A7alim-yapay-sinir-a%C4%9Flar%C4%B1-7b65c6a5264a>, Erişim Tarihi:14.11.2020.
- Kostadinov, S. (2017). "Understanding GRU Networks", <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>, Erişim Tarihi:19.11.2020.
- Krause, E.G., Velamuri, V.K., Burghardt, T., Nack, D., Schmidt, M. ve Treder, T.M. (2016). "Blockchain Technology and the Financial Services Market State-of-the-Art Analysis", HHL, 6.
- Kristoufek, L. (2015). "What Are the Main Drivers of the Bitcoin Price? Evidence from Wavelet Coherence Analysis", *Plos One*, 1-15.
- Lahmiri, S. ve Bekiros, S. (2019). "Cryptocurrency Forecasting with Deep Learning Chaotic Neural Networks", *Chaos, Solitons & Fractals*, 118, 35-40.
- Lamport, L., Shostak, R. ve Pease, M. (1982). "The Byzantine Generals Problem", *ACM Transactions on Programming Languages and Systems (TOPLAS)*, 4 (3), 382-401.
- Livieris, I.E., Pintelas, E., Stavroyiannis, S. ve Pintelas, P. (2020). "Ensemble Deep Learning Models for Forecasting Cryptocurrency Time-Series", *Algorithms*, 13 (5), 1-21.
- Makridakis, S.G., Wheelwright, S.C. ve Hyndman, R.J. (1998). *Forecasting Methods and Applications*, New York, John Wiley and Sons.

- Marr, B. (2018). “What Is Deep Learning AI? A Simple Guide With 8 Practical Examples”, <https://www.forbes.com/sites/bernardmarr/2018/10/01/what-is-deep-learning-ai-a-simple-guide-with-8-practical-examples/#2407f3eb8d4b>, Erişim Tarihi: 21.10.2020.
- McNally, S., Roche, J. ve Caton. S. (2018). “Predicting the Price of Bitcoin using Machine Learning”, *26th Euromicro International Conference on Parallel, Distributed and Network-based Processing (PDP)*, 339-343.
- Melih Güney, (2020). “Bitcoin Nedir? Bitcoin Nasıl Üretilir?”, <https://www.melihguney.com/bitcoin-nedir-nasil-uretilir.html>, Erişim Tarihi: 19.10 2020.
- Mitchell, T.M. (1997). *Machine Learning*, USA, Boston, McGraw-Hill Science.
- Nakamoto, S. (2008). “Bitcoin: A Peer-to-Peer Electronic Cash System”, 1-9.
- Nakano, M., Takahashi, A. ve Takahashi, S. (2018). “Bitcoin Technical Trading with Artificial Neural Network”, *Physica A: Statistical Mechanics and its Applications*, 510, 587-609.
- Narayanan, A., Bonneau, J., Felten, E., Miller, A. ve Goldfeder, S. (2016). *Bitcoin and Cryptocurrency Technologies*, New Jersey, Princeton University Press, Princeton.
- National Seminar (2018). Bitcoin Glossary: 2018 Annual National Seminar.
- Nunes, B. S. R. (2017), Virtual Currency: a Cointegration Analysis Between Bitcoin Prices and Economic and Financial Data, Master Thesis, ISCTE Business School, Lizbon.
- Okorie, D.I. ve Lin, B. (2020). “Crude Oil Price and Cryptocurrencies: Evidence of Volatility Connectedness and Hedging Strategy”, *Energy Economics*, 87, 1-10.
- Ølnes S., Ubacht, U. ve Janssen, M. (2017). “Blockchain İn Government: Benefits And İmplications Of Distributed Ledger Technology For İnformation Sharing”, *Government Information Quarterly*, 34 (3), 355-364.
- Odabaş, S. (2017). “Ethereum ve Bitcoin Arasındaki Farklar ve Benzerlikler Nelerdir?”, <https://coin-haber.com/ethereum-ve-bitcoin-arasindaki-farklar-ve-benzerlikler-nelerdir.html>, Erişim Tarihi: 12.11 2020.
- Ömrüuzun, B. (2019). Yapay Sinir Ağları ile Kripto Paraların Fiyat Modellemesi, Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, İstanbul Üniversitesi, İstanbul.
- Öztemel, E. (2003). *Yapay Sinir Ağları*, İstanbul, Papatya Yayıncılık.

- Panagiotidis, T., Stengos. T. ve Vravosinos, O. (2019). “The Effects of Markets, Uncertainty and Search Intensity on Bitcoin Returns”, *International Review of Financial Analysis*, 63, 220-242.
- Paribulog, (2019). “6 Maddede Ripple (XRP)”, <https://www.paribu.com/blog/kriptopara/6-maddede-xrp-nedir/>, Erişim Tarihi:21.10.2020.
- Patterson, J. ve Gibson, A. (2017). *Deep Learning*, Kaliforniya, O’Reilly Media, Inc.
- Phi, M. (2018). “Illustrated Guide to LSTM’s and GRU’s: A Atep by Atep Explanation”, <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>, Erişim Tarihi: 19.11.2020.
- Pisa, M. ve Juden, M. (2017). “Blockchain and Economic Development: Hype vs. Reality”, *Center For Global Development*, 107, 1-47.
- Polat, A. ve Akbıyık, A. (2019). “Sosyal Medya ve Yatırım Araçlarının Değeri Arasındaki İlişkinin İncelenmesi: Bitcoin Örneği”, *Akademik İncelemeler Dergisi*, 14 (1), 443-462.
- Rosic, A. (2016). “What is Cryptocurrency? [Everything You Need To Know!]”, <https://blockgeeks.com/guides/what-is-cryptocurrency/>, Erişim Tarihi: 05.11.2020.
- Reece, S. (2020). “What are the 3 Types of AI? A Guide to Narrow, General, and Super Artificial Intelligence”, <https://codebots.com/artificial-intelligence/the-3-types-of-ai-is-the-third-even-possible>, Erişim Tarihi: 17.11.2020.
- Price waterhouse Cooper (PwC) (2017). “Building Blocks: How Financial Services Can Create Trust in Blockchain”, <https://www.pwc.com/publications/pwc-whitepaper-blockchain-trust.pdf>, Erişim Tarihi: 01.07.2018
- Ripple, (2020). “Ripple”, <https://ripple.com/>, Erişim Tarihi: 12.11.2020.
- Russell, S.J. ve Norvig, P. (1995). “*Artificial Intelligence a Modern Approach*”, Contributing Writers: John F. Canny, Jitendra M. Malik, Douglas D. Edwards. New Jersey, Prentice Hall, Englewood Cliffs.
- Sabahlatan, (2020). “P2P Network Yapısı ve Kullanım Alanları”, <https://sabahlatan.com/blog/p2p-network-ve-kullanim-alanlari/>, Erişim Tarihi: 26.10.2020.
- Scikit-Learn, (2020). Compare The Effect of Different Scalers on Data with Outlier, https://scikit-learn.org/stable/auto_examples/preprocessing/plot_all_scaling.html, Erişim Tarihi: 11.11.2020.

- Schuster, M. ve Paliwal, K.K. (1997). “Bidirectional Recurrent Neural Networks”, *IEEE Transactions on Signal Processing*, 45(11), 2673-2681.
- Seyhan, A. (2018). “SHA-256 Kriptografik Hash Algoritması”, [https://medium.com/@ahmetseyhan/sha-256-kriptografik-hash-algoritmas%C4%B1-294d13f0ca5d#:~:text=SHA%2D256%20\(Secure%20Hash,Ajans%C4%B1%20\(NSA\)%20taraf%C4%B1ndan%20geli%C5%9Ftirilmi%C5%9Ftir.&text=SHA%2D256'da%20veriler%20hash,hash%20de%C4%9Ferleri%20verilere%20geri%20%C3%A7evrilemez](https://medium.com/@ahmetseyhan/sha-256-kriptografik-hash-algoritmas%C4%B1-294d13f0ca5d#:~:text=SHA%2D256%20(Secure%20Hash,Ajans%C4%B1%20(NSA)%20taraf%C4%B1ndan%20geli%C5%9Ftirilmi%C5%9Ftir.&text=SHA%2D256'da%20veriler%20hash,hash%20de%C4%9Ferleri%20verilere%20geri%20%C3%A7evrilemez), Erişim Tarihi: 03.11.2020.
- Sistemkoin, (2020). “Bitcoin Fiyatını Etkileyen En Önemli 4 Faktör”, <https://blog.sistemkoin.com/bitcoin-fiyati-etkileyen-en-onemli-4-faktor/>, Erişim Tarihi:22.10.2020.
- Song, H.A. ve Lee, S.Y. (2013). “Hierarchical Representation Using NMF”, *International Conference on Neural Information Processing*, 466–473.
- Spirina, K. (2018). “How Artificial Neural Networks Can Code Smarter Than GUI Programmer”, <https://hackernoon.com/how-artificial-neural-networks-can-code-smarter-than-gui-programmer-1cdfaeb4851>, Erişim Tarihi: 22.10.2020.
- Statista, (2020). “Ekim 2020 İtibarı ile Dünya Genelinde Seçili Ülkelerdeki Bitcoin ATM Sayısı”, <https://www.statista.com/statistics/343147/number-of-bitcoin-atms-countries/>, Erişim Tarihi: 05.11.2020.
- Stenqvist, E ve Lönnö, J. (2017). *Predicting Bitcoin Price Fluctuation with Twitter Sentiment Analysis*, Degree Project in Technology, First Cycle, 15 Credits, 1-31.
- Strauss, M. (2010). “A Comparison of Virtual Currency Systems”, Helium, May.
- Swan, M. (2015). “Blockchain Blueprint for a New Economy”, Sebastopol, O'Reilly Media, Inc.
- Şahin, E.E. (2020). “Bitcoin Fiyatına Etki Eden Faktörlerin Mars Metodu ile Belirlenmesi”, *Uluslararası Ekonomi, İşletme ve Politika Dergisi*, 4 (1), 171-184.
- Tan, A., Robertson, B. ve Leising, M. (2018). “Why Crypto Traders Are So Worried About Tether: QuickTake Q&A”, <https://www.bloombergquint.com/quicktakes/why-crypto-traders-are-so-worried-about-tether-quicktake-q-a>, Erişim Tarihi: 05.11.2020.
- Tandon, S., Tripathi, S., Saraswat, P. ve Dabas, C. (2019). Bitcoin Price Forecasting using LSTM and 10-Fold Cross Validation, 2019 International Conference on Signal Processing and Communication (ICSC), 323-328.

- Tekeli, A. (2021). “Proof of Work (PoW) Nedir: İş İspatı Nasıl Çalışır?”, <https://www.coinkolik.com/proof-of-work-pow-nedir-is-ispatti-nasil-calisir/>, Erişim Tarihi: 03.11.2020.
- Tunalı, M. M. (2020). “Genel ve Dar Yapay Zeka Farkları”, <https://www.tekyolbilim.com/genel-ve-dar-yapay-zeka-farklari/>, Erişim Tarihi: 19.11.2020.
- Twentify, (2018). “Türkiye’nin Sanal Cüzdanı”, *Kripto Para Birimleri Algı & Güven Araştırması*, 1-54.
- UBS, (2017). “Cryptocurrencies”, <https://www.ubs.com/content/dam/WealthManagementAmericas/cio-impact/cryptocurrencies.pdf>, Erişim Tarihi: 05.11.2020.
- Ünsal, E. ve Kocaoğlu, Ö. (2018). “Blok Zinciri Teknolojisi: Kullanım Alanları, Açık Noktaları ve Gelecek Beklentileri”, *Avrupa Bilim ve Teknoloji Dergisi*, 13,54-64.
- Weiss, G., Goldberg, Y. ve Yahav, E. (2018). On the Practical Computational Power of Finite Precision RNNs for Language Recognition, arXiv:1805.04908, 740-745.
- Willmott, C. ve Matsuura, K. (2005). “Advantages of The Mean Absolute Error (Mae) Over The Root Mean Square Error (Rmse) in Assessing Average Model Performance”, *Climate Research*, 30(1), 79–82.
- Vranken, H. (2017). “Sustainability of Bitcoin and Blockchains”, *Current Opinion in Environmental Sustainability*, 28, 1-9.
- Yampolskiy, R. V. (2015). *Artificial Superintelligence: A Futuristic Approach*, Boca Raton, Florida, Chapman and Hall/CRC.
- Yavuz, M.S. (2019). “Ekonomide Dijital Dönüşüm: Blockchain Teknolojisi ve Uygulama Alanları Üzerine Bir İnceleme”, *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 4(1), 15-29.
- Yıldırım, H. (2018). “Günlük Bitcoin ile Altın Fiyatları Arasındaki İlişkinin Test Edilmesi: 2012-2013 Yılları Arası Johansen Eşbütünleşme Testi”, *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 7(4), 2328-2343.
- Yılmaz, A. (2019). *Yapay Zeka*, KODLAB Yayın Dağıtım Yazılım ve Eğitim Hizmetleri San. Ve Tic. Ltd. Şti.
- Yılmaz, A ve Kaya, U. (2019). *Derin Öğrenme*, İstanbul, KODLAB Yayın Dağıtım Yazılım ve Eğitim Hizmetleri San. Ve Tic. Ltd. Şti.

- Yılmaz, Y. (2007). “Kriptoloji Uygulamalarında Hukuki Boyut”, *Marmara Üniversitesi Hukuk Fakültesi Hukuk Araştırmaları Dergisi*, 13(1-2), 137-147.
- Zafari, A., Kianmehr, M.H. ve Abdolazadeh, R. (2013). Modeling the Effect of Extrusion Parameters on Density of Biomass Pellet using Artificial Neural Network, *International Journal Of Recycling of Organic Waste in Agriculture a SpringerOpen Journal*, 1-11.
- Zhang, G. P., Patuwo, B. E. ve Hu, M. Y. (1998). “Forecasting With Artificial Neural Networks: The State Of The Art”, *International Journal Of Forecasting*, 14(1), 35-62.
- Zocca, V., Spacagna, G., Slater, D. ve Roelants, P. (2017). *Python Deep Learning*, Birleşik Krallık, Packt Publishing.
- Zoumpikas, T., Houstis, E. ve Vavalis, M. (2020). “ETH Analysis and Predictions Utilizing Deep Learning”, *Expert Systems With Applications*, 162, 1-15.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı ve Soyadı : Esranur DEMİRCİ

Eğitim Durumu

Lisans Öğrenimi : Akdeniz Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Anabilim Dalı, 2017.

Yüksek Lisans Öğrenimi : Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme ABD – Sayısal Yöntemler Anabilim Dalı, 2021.

Yabancı Dil (ler) ve Düzeyi

1. İngilizce – Orta Düzey

İş Denevimi

1. Akbank Konyaaltı (Antalya) Şubesi – Asistan (Haziran 2015 – Eylül 2015)

2. Lukoil Petrol Ofisi Polatlı (Ankara) Emek Petrol Ltd. Şti. – Ön Muhasebe ve İdari İşler Sorumlusu (Eylül 2017 – Mayıs 2018)

Bilimsel Çalışmalar ve Yayınlar

1. Demirci, E. ve Palancı, O. (2019). Ulusal Yazında Oyun Teorisi Üzerine Genişletilmiş Bir Literatür Taraması, Mehmet Akif Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, Cilt: 11 Sayı: 29, 530-549.

2. Demirci, E. ve Karaatlı, M. (2019). Ülkelerin Gelişmişlik Seviyelerinin Tahmininde Kullanılan Sınıflandırma Algoritmalarının Karşılaştırılması, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Cilt: 24 Sayı: 3, 703-714.

3. Karaatlı, M., Demirci, E. ve Baykaldı, A. (2020). Ticari Kredi Faiz Oranlarının YSA NARX ve VAR Modelleri ile Öngörülmesi, İşletme Araştırmaları Dergisi, Cilt: 12 Sayı: 3, 2327-2343.