



KRİPTO PARA FİYATLARININ LSTM VE GRU MODELLERİ İLE TAHMİNİ* PREDICTION OF CRYPTOCURRENCY PRICES WITH LSTM AND GRU MODELS

Esranur DEMİRÇİ¹, Meltem KARAATLI²



1. Doktora Öğrenci, Pamukkale Üniversitesi, Sosyal Bilimler Enstitüsü, esra09393@gmail.com, <https://orcid.org/0000-0002-7840-2398>
2. Prof. Dr., Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, meltemkaraatli@sdu.edu.tr, <https://orcid.org/0000-0002-7403-9587>

Makale Türü Article Type
Araştırma Makalesi Research Article

Başvuru Tarihi Application Date
10.12.2021 12.10.2021

Yayına Kabul Tarihi Admission Date
28.05.2022 05.28.2022

DOI
<https://doi.org/10.30798/makuiibf.1035314>

* Bu çalışma Prof. Dr. Meltem KARAATLI danışmanlığında tamamlanan, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı öğrencisi Esranur DEMİRÇİ'nin 2021 Nisan ayında teslim ettiği Yüksek Lisans tezinden türetilmiştir.

Öz

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 paraların merkezi bir otoritenin kontrolünde olmaması bu araçların fiyatlarında dalgalanmaları beraberinde getirmiştir. Bu nedenle, akıllı bir tahmin modelinin geliştirilmesi, yatırım yapılacak finansal varlıkların seçimi ve yatırım kararlarının hayata geçirilmesi açısından oldukça önemlidir. 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'in 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 found a place in the financial markets in a short time, are used both as a means of exchange and an investment tool. The fact that cryptocurrencies are not under the control of a central authority has brought about fluctuations in the prices of these tools. Therefore, the development of an intelligent forecasting model is very important for the selection of financial assets to be invested and the realization of investment decisions. 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 Recurrent 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 cryptocurrencies 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: Cryptocurrency, Bitcoin, Ethereum, Ripple, Deep Learning, RNN, LSTM, GRU, Predict.

EXTENDED SUMMARY

Research Problem

The fluctuations in the Cryptocurrency markets are much more and uncertain compared to the traditional money markets. Cryptocurrencies have experienced serious price jumps and decreases since the years they were produced. Due to this structure, it is very difficult to predict cryptocurrency indices with classical statistical estimation methods. Therefore, predictions of cryptocurrencies can be made more easily with machine learning and deep learning methods. The main purpose of choosing the deep learning model in this study; deep learning models can achieve healthy results with big data, missing data and data with high breaks. The aim of this study is to predict prices with LSTM and GRU, which are a deep learning model of cryptocurrencies, which are increasingly popular today and are seen as an alternative investment tool and payment method by people.

Research Questions

How is the forecasting success of cryptocurrency prices with LSTM and GRU models? Does the LSTM model or the GRU model give more successful results?

Literature Review

Gullapalli (2018) made an Artificial Neural Networks (ANN) application to predict Bitcoin's highest and closing price one day in advance. Model comparison has been made using two temporal neural network architectures, Time-Delay Neural Network (TDNN) and Recurrent Neural Network (RNN). It has benefited from the Bitcoin price data set for the period September 2011-2018. It has been determined that the TDNN model trains Bitcoin data in a shorter time than RNN and gives predictive values closer to the real price. Hirano et al. (2018) used RNN, GRU and LSTM methods to predict the price of Bitcoin. The dataset includes all 822 closing Bitcoin prices for AUD, CAD, CNY, EUR, GBP, JPY and USD for the period 01.01.2015-16.02.2018. To analyze the USD type triangle arbitrage, they used the closing values of the XBT-CRC-USD, USD/AUD, USD/CAD, USD/CNY, USD/EUR, USD/GBP and USD/JPY exchange rates, and accordingly, they did not include the data points in the data set until the holidays of each foreign exchange market. They found that deep learning algorithms can predict the direction of price change for the next day based on historical data with an F-measure in the range of 67% to 73%. As a result of the analysis, they concluded that the Bitcoin market is more inefficient than the USD/EUR market according to the Efficient Market Hypothesis (EMH). Nakano et al. (2018) predicted Bitcoin's intraday technical trading closing prices by creating a multi-layered neural network architecture by making use of the highest and lowest price variables. The time range is taken from 31.07.2016 15:00 (GTM) to 24.01.2018 07:30. The closing, high and low prices refer to the last, maximum and minimum (traded) prices every 15 minutes, respectively. A seven-layered neural network structure has been created for specific input data of technical indicators calculated using historical time series data every 15 minutes with deep learning method and trade signals have been successfully predicted. Dutta et al. (2020) estimated the price of Bitcoin using Shallow Neural Network, LSTM and

GRU methods. The data set is composed of daily Bitcoin closing prices for the period 01.01.2010-06.30.2019 and internal and external factors affecting the Bitcoin price. In the study, it was concluded that LSTM and GRU predicted better than SARIMA, which is called the classical method. Zoumpekas et al. (2020) made predictions for 6 time periods, each of which was determined by using Ethereum's daily opening, high, low, closing and daily average price data for the period 08.08.2015-28.05.2018. They benefited from CNN, LSTM, GRU, Stacked Long-Short Term Memory (sLSTM) and Bidirectional Long-Short Term Memory (BiLSTM) methods. By looking at RMSE, normalized RMSE (nRMSE), MAE, normalized MAE (nMAE) and MDA performance criteria, the most successful results were obtained with the LSTM and GRU model. However, LSTM performed slightly better than GRU. In his study, Kristoufek (2015) looked at the relationship between the Bitcoin price and the Wavelet Coherence analysis by using the Bitcoin circulation, Bitcoin supply, Bitcoin estimated transaction volume, volume ratio, hash rate and difficulty values for the period 14.09.2011-28.02.2014. No relationship was found between Bitcoin price and Bitcoin circulation and difficulty. However, a positive relationship was found between Bitcoin price and Bitcoin supply, hash rate and Bitcoin estimated transaction volume. In his study, Nunes (2017) examined the relationship between Bitcoin and Bitcoin using daily crude oil and gold prices, 6-month and 1-year American bond yields, S&P 500 indices for the period 01.01.2013-28.08.2017. He used the VAR Analysis method. All variables had an effect on the price of Bitcoin, but it was determined that especially the six-month US government bond yields had a higher effect. In their study, Stenqvist and Lönnö (2017) examined 2.27 million tweets related to Bitcoin for emotional fluctuations that may indicate a price change in the near future. They collected 31 consecutive days of Bitcoin-related tweets and USD/BTC exchange rate data for the period 11.05.2017-11.06.2017. With the sentiment analysis, the effect of tweet data in accordance with the predetermined parameters on the downward and upward movement of the USD/BTC parity has been examined. With the sentiment analysis, they concluded that the tweet data in accordance with the predetermined parameters affected the downward and upward movement of the USD/BTC parity. Demir et al. (2018) used Bayesian causality analysis in their study to see if there is a relationship between the economic policy uncertainty index and daily Bitcoin return. Then, by using Ordinary Least Squares (OLS) and the Quantile-on-quantile Regression (QQ), they examined the effect of economic policy uncertainty index on Bitcoin returns. It has been determined that there is a positive relationship between the economic policy uncertainty index and the daily Bitcoin return, and it is observed that the importance value is sometimes high and sometimes low. Erdogan and Dayan (2019) examined the relationship between Bitcoin and the London Interbank Interest Rate (LIBOR) by using Correlation, Vector Autoregression, Causality and ARDL analyzes in their study. Weekly Bitcoin closing prices for the period 21.10.2013-21.09.2018 were used as the data set, and LIBOR rates were included in the study annually. As a result of the analysis, although the effect of Bitcoin on LIBOR was not observed, the effect of LIBOR on Bitcoin in the long term was determined. Şahin (2020) examined the relationship between Bitcoin

closing prices for the period 01.2012-10.2019 and the financial pressure index, gold, US dollar and geopolitical risk index using the Multivariate Adaptive Regression Extensions (MARS) method. He concluded that the independent variables considered have an effect on the price of Bitcoin.

Methodology

In the study, the prediction results made with Long-Short Term Memory (LSTM) and Gated Recurrent Unit (GRU) models of Bitcoin, Ethereum and Ripple cryptocurrencies and the comparison of the models are given.

Results and Conclusions

In this study, LSTM and GRU models, which are a special RNN method, are used for 30-day price prediction of Bitcoin, Ethereum and Ripple digital currencies. Daily data was used to minimize the error rates in the prediction of cryptocurrency prices. In the study, 11 different variables affecting the prices of cryptocurrencies were used, and different time intervals were taken as a basis for each cryptocurrency according to the dates of the announcement of the prices. In the analysis, as the learning repetition is increased and the hyperparameter values are changed, an increase in the success rate has been observed. As a result of the study, it has been shown that the GRU model for Bitcoin and Ripple and the LSTM model for Ethereum give better results according to the MAPE performance criterion. The success rates of the one-month test values of the cryptocurrencies included in the analysis according to the MAPE performance criterion are respectively; It was found between 94% and 96% for Bitcoin, 85% to 93% for Ethereum, and 89% to 93% for Ripple. These values are a high success for digital currencies that are not connected to any center and are affected by external factors very little. Although there are several main topics that affect the volatility of cryptocurrencies, these topics contain more than one situation in themselves. For example, news affects every investment tool, as well as the volatility of cryptocurrencies. However, while news at the national or international level affects other investment tools, even the trends in social media have an impact on cryptocurrencies. In addition, although the awareness of cryptocurrencies in the market is low, the variables contain many factors. These factors also cause breaks in the volatility of cryptocurrencies. For all these reasons, Cryptocurrency indices have more and sharper breaks than other currencies and investment instruments. In this case, it makes the prediction of Cryptocurrency more difficult than the prediction of other investment tools. In prediction models made using sub-branches of artificial intelligence such as machine learning and deep learning, the results are very close to the truth. Especially in models created using deep learning methods, big data is needed to achieve better results. The excess amount of data ensures that the model makes more accurate predictions and has a learning structure that can adapt to every future situation. The fact that the Cryptocurrency market is a relatively new market and the large data cannot be gathered in the desired amounts reduces the prediction success for some cryptocurrencies. In addition, one of these reasons is that investors do not have enough information about these new digital currencies, unlike the currencies accepted by the investors. Cryptocurrencies are generally not dependent on a central

authority. It can be thought that this independence can save cryptocurrencies from the influence of country-based political and economic decisions. Cryptocurrencies are an alternative to other international investment instruments, as they are investment instruments that are bought and sold internationally. This has made cryptocurrencies an alternative investment tool for gold, other precious metals, major stock market indices, funds, bonds, time deposit accounts and oil. Cryptocurrencies, like other investment instruments, can be affected by changes in the economies of developed countries. In addition to alternative investment instruments, variables measuring market confidence and uncertainty were added to the models created within the scope of this study. It is thought that these variables increase the level of estimation success. In future studies, researchers can work with more cryptocurrencies and add other variables that may be related to cryptocurrencies to their models. It should not be forgotten that there is a dynamic structure in the world of finance and the dynamics of the current period should be reflected in the models to be established.

1. GİRİŞ

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

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 çoğu alanında şiddetini göstermiş ve uzun vadede siyasi istikrarsızlığa ve daha fazla ekonomik reform ihtiyacına yol açmıştır. Hükümetleri ve finansal kurumların manipülasyonunu 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, 2020).

Çetinkaya (2018) yaptığı çalışmada Bitcoin ve diğer 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 sınırlar 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). 15.06.2020-16.06.2020 tarihleri arasında ise şimdiye kadar üretilen Bitcoin'lerin toplam değeri 16 milyar dolar artış göstererek yüksek seviyelere ulaşmıştır (Günen, 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 milyar dolarlık işlem hacmine gelmiştir. Kripto para fiyatlarının düşmesi ve yükselmesini takip etmek isteyen kurum ve kişiler sosyal medyanın her türlü mecrasından yararlanabilmektedir, bu da küçük veya

büyük çaplı her türlü yatırım ve yatırımcıya büyük bir bilgi kaynağı olarak yol göstermektedir (Polat ve Akbıyık, 2019).

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 kısa dönemli fiyat tahmininde bulunulacaktır.

Çalışma toplamda beş bölümden oluşmaktadır. Çalışmanın giriş bölümünden sonra yer alan ikinci bölümde araştırmada kullanılan kripto paralar ve blok zincir sistemi anlatılmıştır. Üçüncü bölümde uygulamada kullanılan derin öğrenme metotlarına değinilmiştir. Dördüncü bölümde uygulama anlatılmış ve son bölümde ise uygulamanın sonuç ve değerlendirme kısmına yer verilmiştir.

2. KRİPTO PARALAR VE BLOK ZİNCİRİ (BLOCKCHAIN)

Bitcoin, Ethereum, Litecoin, Tether, Bitcoin Cash, Peercoin, Dogecoin ve Ripple gibi son on yıldan beri birçok kripto para birimi oluşturulmuştur. Bitcoin, diğerlerine kıyasla en popüler ve değerli kripto para birimidir. Bunun nedeni ise Bitcoin' in fiyat gelişimi ve oynaklığıdır (Tun ve Majid, 2018). Araştırmada kullanılmak üzere işlem hacmi en fazla olan 3 kripto para ele alınmıştır. Bunlar sırasıyla; Bitcoin, Ethereum ve Ripple' dir.

2.1. 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 oluşturulmuştur (CoinMarketCap, 2020; Nakamoto, 2008).

Bitcoin'in toplam arzı yazılımıyla sınırlıdır ve asla 21.000.000 coini geçmeyecektir. "Madencilik" olarak bilinen süreç sırasında yeni madeni paralar üretilir. İşlemler ağ üzerinden

aktarılırken, madenciler tarafından alınır ve bloklar halinde paketlenir ve karmaşık kriptografik hesaplamalarla korunur (CoinMarketCap, 2020).

2.2. 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) 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.

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).

2.3. Ripple (XRP)

Ryan Fugger tarafından fikri temel 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 (CoinMarketCap, 2020).

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'ın temel amacı, bankacılık sektörüne girerek işlem kolaylığı sağlamak ve bunu olabildiğince daha hızlı ve daha düşük maliyetlerle gerçekleştirmektir (Ripple, 2020).

2.3. Blok Zinciri (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).

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 dağıtılmış veri tabanıdır. Blok zincir teknolojisini günümüzde var olan ağlardan farklı olmasının nedeni ise eşler arası ağ (peer-to-peer network), mutabakat mekanizması (consensus mechanism), dağıtılmış defter (distributed ledger) ve kriptografi (cryptografy) teknolojisine sahip olmasıdır (Krause vd., 2016; Pisa ve Juden, 2017; Hewlett Packard Enterprise (HPE), 2016; Price waterhouse Cooper (PwC), 2017).

3. DERİN ÖĞRENME

Derin öğrenme insan beyninden ve yapay sinir ağlarından esinlenen algoritmaların veriden öğrendiği bir makine öğrenmesi alt dalıdır. Derin öğrenmedeki asıl amaç, insan beyninden esinlenerek oluşturulan bu algoritmalarla, daha iyi bir sonuç elde etmek için her seferinde yapılan hataları azaltıp gerekli olan değişiklikleri yaparak daha iyi bir sonuç elde etmektir (Alpaydın, 2011). Derin öğrenme, nitelik çıkarma ve dönüştürme amacıyla birden çok doğrusal olmayan işlemci katmanı kullanmaktadır. Ardışık olan her katman, önceki katmanda yer alan çıktıyı girdi olarak işleme dahil etmektedir (Deng ve Yu, 2014).


Bu çalışmada geleneksel sinir ağlarından farklı olan ve onların eksikliklerini tamamlayan Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN) nın özel bir türü olan Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) mimarilerinden yararlanılmıştır.

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

RNN'in temeli, 1980 senelerinde Basit Tekrarlayan Ağ (Simple Recurrent Network) olarak ortaya çıkmıştır. 1990 senelerinde ise Jeff Elman RNN' i önermiştir. RNN'in temel yapısı sıralı bilgileri kullanmaya dayanmaktadır. Geleneksel bir sinir ağında yer alan bütün girdi ve çıktılar 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 gerçekleştirilmesidir (Gürbüz, 2020). RNN mimarisinin çalışma prensibi Şekil 1’de gösterilmektedir.

Şekil 1. Tekrarlayan Sinir Ağları Mimarisi




Kaynak: Spirina, 2018

RNN 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).

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

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’ler de, bu tekrar eden modül, aktivasyon fonksiyonlarından biri olan “tanh” katmanına benzer çok basit bir yapıya sahip olacaktır. 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 2’de dört katmana sahip tekrarlayan bir modül yapısı gösterilmektedir.

Şekil 2. Tek Modül İçerisinde 4 Katmana Sahip Bir Uzun-Kısa Süreli Hafıza Nöral Ağı




Kaynak: Colah's Blog, 2015

Şekil 2'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. 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 (Colah's Blog, 2015).

LSTM, kapı (gate) olarak adlandırılan yapılar tarafından dikkatlice düzenlenen hücelere 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 (Colah's Blog, 2015).

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

Cho vd. (2014) tarafından geliştirilen GRU standart tekrarlayan sinir ağına geliştirilmiş bir versiyonudur. GRU'lar kaybolan gradyan problemi (vanishing gradient problem)'ni 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 3'de GRU ve LSTM'a ait kapılar (gates) gösterilmektedir.

Şekil 3. Geçitli Tekrarlayan Birim ve Uzun-Kısa Süreli Hafıza Ağları'na Ait Kapılar

Kaynak: 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.

4. 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 modellerin karşılaştırılmalarına yer verilmiştir.

a. Araştırmada Kullanılan Değişkenler ve Veri Seti

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. Bağımsız değişken olarak ise Euro/Dolar paritesi, Altın spot Amerikan Doları, LIBOR, ham petrol WTI vadeli işlemleri, S&P 500, Twitter tabanlı ekonomik belirsizlik endeksi, jeopolitik risk endeksi, ekonomik politika belirsizliği endeksi, Amerika finansal krizler endeksi, hacim ve para arzı günlük verileri kullanılmıştır. Tablo 1'de çalışmada kullanılan değişkenlere ve veri tabanlarına yer verilmektedir.

Tablo 1. 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/

b. Eğitimde Kullanılan 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 wrapper'dır. Bu modelin eğitiminde ise backend olarak TensorFlow kullanılmıştır.

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 .ipynb 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.

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 wrapper'dır. Bu özellikleri sayesinde Keras, araştırmada kullanılacak olan derin öğrenme modelini farklı kütüphaneler kullanarak hızlı ve kolayca eğitebilmektedir. Bu çalışmada backend olarak Tensorflow kütüphanesi kullanılmıştır.

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 (Maptriks, 2020). TensorFlow temelde “tensor” ve “flow” şeklinde ikiye ayrılmaktadır. Tensor, yüksek hacimli verilerin çok boyutlu dizileridir. Flow ise tensorler üzerinde gerçekleşen işlemlerdir (Gökkaya, 2020).

c. LSTM ve GRU Modellerinin Eğitimi ve Testi

Yapılan bu uygulamada, tahmininde bulunulacak her kripto para için analize başlamadan önce eğitim seti belirlenmiştir. Sonrasında 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. Tablo 2’de araştırmada kullanılan kripto paralar için ayrılan eğitim ve test sayıları gösterilmektedir.

Tablo 2. 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 Eşitlik (1)’de yer alan “MinMaxScaler” yöntemi ile normalize edilmiştir. Bunun nedeni ise MinMaxScaler tekniği daha hassas sonuçlar elde etmeye olanak sağlamasıdır (Scikit-Learn, 2020).

$$x_{scaled} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

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.

Sonrasında LSTM ve GRU ile normalize edilen bu veriler eğitime tabi tutulmuştur. Eğitim sonucunu en iyi veren model ile kripto paraların 30 günlük tahmini yapılmıştır. Son adımda ise eğitim

ve tahmin verileri normalize edilmiş halinden orijinal haline çevrilerek gerçek veriler ile aralarındaki hata değerleri hesaplanmıştır.

d. LSTM Modeli ile Tahmin Sonuçlarının Elde Edilmesi

Bu uygulamada window size, unit ve epoch sayıları değiştirilerek birçok deneme yapılmış ve en düşük hata değerleri elde edilene kadar devam edilmiştir.

LSTM modelinde Bitcoin, Ethereum ve Ripple günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemlerini kapsayan 30 günlük tahmini gerçekleştirilmiştir. Ardından tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analiz yaparken kullanılan window size, unit ve epoch sayıları için performans ölçüt değerlerine her bir kripto para birimi için Tablo 3, 4 ve 5’de yer verilmiştir.

Tablo 3. LSTM Modelinde Bitcoin Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

Performans Ölçütleri	5	4	4	5	5	4	4	
	Window Size	Window Size	Window Size	Window Size	Window Size	Window Size	Window Size	
	80 Unit	90 Unit	70 Unit	50 Unit	75 Unit	50 Unit	75 Unit	
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 3’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 4. LSTM Modelinde Ethereum Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

Performans Ölçütleri	2	2	2	3	3	4	2	
	Window Size	Window Size	Window Size	Window Size	Window Size	Window Size	Window Size	
	100 Unit	100 Unit	75 Unit	90 Unit	80 Unit	70Unit	60 Unit	
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 4’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 5. 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 Unit	80 Unit	50 Unit	60 Unit	100 Unit	90 Unit	
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.

e. GRU Modeli ile Tahmin Sonuçlarının Elde Edilmesi

Bu uygulamada window size, unit, epoch ve dropout (rastgele seçilen belirli nöron kümesinin eğitim aşaması sırasında birimleri (yani nöronları) göz ardı etmesi durumunu ifade etmektedir) sayıları değiştirilerek birçok deneme yapılmış ve en düşük hata değerleri elde edilene kadar devam edilmiştir.

GRU modelinde Bitcoin, Ethereum ve Ripple günlük kapanış fiyatlarının 04.08.2020-15.09.2020 dönemlerini kapsayan 30 günlük tahmini gerçekleştirilmiştir. Ardından tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analiz yaparken kullanılan window size, unit ve epoch sayıları için performans ölçüt değerlerine her bir kripto para birimi için Tablo 6, 7 ve 8’de yer verilmiştir.

Tablo 6. GRU Modelinde Bitcoin Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

Performans Ölçütleri		2	5	5	5	5	3	3
		Window Size	Window Size	Window Size	Window Size	Window Size	Window Size	Window Size
		75 Unit	50 Unit	100 Unit	70 Unit	70 Unit	100 Unit	80 Unit
		110 Epoch	100 Epoch	110 Epoch	115 Epoch	115 Epoch	120 Epoch	120 Epoch
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 6’da 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 7. GRU Modelinde Ethereum Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

Performans Ölçütleri		5	2	2	4	5	3	2
		Window Size	Window Size	Window Size	Window Size	Window Size	Window Size	Window Size
		70 Unit	100 Unit	70 Unit	80 Unit	75 Unit	80 Unit	80 Unit
		105 Epoch	105 Epoch	115 Epoch	115 Epoch	100 Epoch	105 Epoch	115 Epoch
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
	MAE	28,05	32,31	36,37	36,22	41,30	41,12	62,92

Test	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	783	8,91	9,37	10,13	10,39	15,57

Tablo 7’de 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 8. GRU Modelinde Ripple Eğitim ve Test Verilerinin Performans Ölçüt Değerleri

Performans Ölçütü	2 Window Size	2 Window Size	5 Window Size	2 Window Size	4 Window Size	2 Window Size	2 Window Size	
	80 Unit	70 Unit	80 Unit	70 Unit	70 Unit	50 Unit	75 Unit	
	105 Epoch	100 Epoch	120 Epoch	105 Epoch	105 Epoch	115 Epoch	115 Epoch	
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	50,07156	31,30439	45,67824	23,17025	27,72276	22,08954	17,73016
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	10,25937

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 0.2 dropout sayısı ile elde edilmiştir.

f. LSTM ve 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, ağın 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 ağın 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 9'da görüldüğü gibi çalışmada en iyi tahmin sonucunu Bitcoin ve Ripple için GRU modeli, Ethereum için ise MAE ve MAPE değerlerinde en düşük hata değerini LSTM modeli verirken, MSE ve RMSE değerlerinde GRU modeli vermiştir.

Tablo 9. LSTM ve GRU Modellerinin Performans Ölçüt Değerlerinin Karşılaştırılması

BITCOIN	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
RIPPLE	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

5. SONUÇ VE DEĞERLENDİRME

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 değerini 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 kripto 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 volatilitelerini 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 volatiliteleri 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 volatilitelerinde 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 ulaşılamaması 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

- Avrupa Merkez Bankası. (2020, Eylül). US Dollar (USD). Erişim adresi https://www.ecb.europa.eu/stats/policy_and_exchange_rates/euro_reference_exchange_rates/html/usd.xml
- BtcTurk. (2013). Bitcoin (BTC) Nedir?. Erişim adresi <https://www.btcturk.com/bilgi-platformu/bitcoin-btc-nedir/>
- Buterin, V. (2014). A Next-Generation Smart Contract and Decentralized Application Platform. Erişim adresi <https://github.com/ethereum/wiki/wiki/White-Paper>
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y. (2014). *Learning phrase representations using RNN encoder-decoder for statistical machine translation*. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), Doha, Qatar, June 3.
- Coin Medya. (2020). Ethereum Nedir?. Erişim adresi <https://btc.coinmedya.com/ethereum-nedir.html>
- CoinMarketCap. (2020, Aralık). About Bitcoin. Erişim adresi <https://coinmarketcap.com/tr/currencies/bitcoin/>
- CoinMarketCap. (2020, Aralık). About Ethereum. Erişim adresi <https://coinmarketcap.com/currencies/ethereum/>
- CoinMarketCap. (2020, Eylül). About XRP. Erişim adresi <https://coinmarketcap.com/tr/currencies/xrp/>
- CoinMarketCap. (2020, Eylül). Bitcoin Volume. Erişim adresi <https://coinmarketcap.com/currencies/bitcoin/historical-data/?start=20130429&end=20200916>

- CoinMarketCap. (2020, Eylül). Ethereum Volume. Erişim adresi
<https://coinmarketcap.com/currencies/ethereum/historical-data/?start=20140906&end=20200916>
- CoinMarketCap. (2020, Eylül). XRP (Ripple) Volume, Erişim adresi
<https://coinmarketcap.com/currencies/xrp/historical-data/?start=20130429&end=20200916>
- Coin Metrics. (2020, Eylül). Bitcoin Price (USD) and Supply, Free Float. Erişim adresi
<https://coinmetrics.io/tools/>
- Coin Metrics. (2020, Eylül). Ethereum Price (USD) and Supply, Free Float. Erişim adresi
<https://coinmetrics.io/tools/>
- Coin Metrics. (2020, Eylül). XRP(Ripple) Price (USD) and Supply, Free Float. Erişim adresi
<https://coinmetrics.io/tools/>
- Colah's Blog. (2015). Understanding LSTM Networks. Erişim adresi
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Çetinkaya, Ş. (2018). Kripto paraların gelişimi ve para piyasalarındaki yerinin Swot analizi ile incelenmesi. *Uluslararası Ekonomi ve Siyaset Bilimleri Akademik Araştırmalar Dergisi*, 2 (5), 11-21.
- Demir, E., Gozgora, G., Lao, 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. <https://doi.org/10.1016/j.frl.2018.01.005>
- Deng, L. ve Yu, D. (2014). Deep learning: Methods and applications. *Found. Trends® Signal Process*, 7(3-4), 197-387. DOI: 10.1561/20000000039
- Dutta, A., Kumar, S. ve Baus, M. (2020). A Gated Recurrent Unit Approach to Bitcoin Price Prediction. *Journal of Risk and Financial Management*, 13(2), 1-16. DOI: 10.3390/jrfm13020023
- Economic Policy Uncertainty. (2020, Kasım). US Equity Market Volatility Index (Financial Crises EMV Tracker). Erişim adresi
https://www.policyuncertainty.com/categorical_epu.html
- Economic Policy Uncertainty. (2020, Kasım). Monetary Policy Uncertainty Indices (Economic Policy Uncertainty). Erişim adresi
https://www.policyuncertainty.com/categorical_epu.html
- Economic Policy Uncertainty. (2020, Kasım). Geopolitical Risk Index. Erişim adresi
<https://www.policyuncertainty.com/gpr.html>
- Economic Policy Uncertainty. (2020, Kasım). Twitter-Based Uncertainty Indices. Erişim adresi
https://www.policyuncertainty.com/twitter_uncert.html
- Erdoğan, S. ve Dayan, V. (2019). *Blockchain economics and financial market innovation*. Editors: Umit H. Analysis of Relationship Between International Interest Rates and Cryptocurrency Prices: Case for Bitcoin and LIBOR. Istanbul: Springer.
- FRED (Economic Research Federal Reserve Bank of St. Louis). (2020, Eylül). 12-Month London Interbank Offered Rate (LIBOR), Based on U.S. Dollar. Erişim adresi
<https://fred.stlouisfed.org/series/USD12MD156N>
- Gökkaya, H. (2020). *Derin öğrenme teknikleri ile anomali içeren metal somunların hata tespit ve sınıflandırılması*. (Yüksek Lisans tezi, Dokuz Eylül Üniversitesi, İzmir). Erişim adresi <https://acikbilim.yok.gov.tr/handle/20.500.12812/550910>

- 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. <https://doi.org/10.3389/frai.2020.00040>
- Gullapalli, S. (2018). *Learning to predict cryptocurrency price using artificial neural network models of time series*. (Yayımlanmamış yüksek lisans tezi). 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. Erişim adresi <https://tr.cointelegraph.com/news/bitcoin-market-capitalization-rised-11b-in-30-hours>
- Gürbüz, F.B. (2020). Tekrarlayan Sinir Ağı-Recurrent Neural Networks (RNN). Erişim adresi <https://medium.com/@batincangurbuz/tekrarlayan-sinir-a%C4%9F%C4%B1-recurrent-neural-networks-rnn-17b517dd0b3e>
- 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.
- 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. DOI: 10.12955/cbup.v6.1152
- Hochreiter, S. ve Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. DOI: 10.1162/neco.1997.9.8.1735
- Investing.com. (2020, Eylül). Ham Petrol WTI Vadeli İşlemleri. Erişim adresi <https://tr.investing.com/commodities/crude-oil-historical-data>
- Investing.com. (2020, Eylül). S&P 500. Erişim adresi <https://tr.investing.com/indices/us-spx-500-historical-data>
- Investing.com. (2020, Eylül). XAU/USD-Altın Spot Amerikan Doları. Erişim adresi <https://tr.investing.com/currencies/xau-usd-historical-data>
- Krause, E.G., Velamuri, V.K., Burghardt, T., Nack, D., Schmidt, M. ve Treder, T.M. Blockchain technology and the financial services market State-of-the-Art Analysis. *HHL*, 6, 2016.
- Kostadinov, S. (2017). Understanding GRU Networks. Erişim adresi <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>
- Kristoufek, L. (2015). What are the main drivers of the Bitcoin price?. Evidence from Wavelet Coherence Analysis, *Plos One*, 10(4), 1-15. <https://doi.org/10.1371/journal.pone.0123923>
- 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. <https://doi.org/10.3390/a13050121>
- Maptriक्स, (2020). Uzmanından Örneklerle Tensorflow Nedir Açıklyyoruz?. Erişim adresi <https://maptriक्स.com/tr/teknoloji/uzmanindan-orneklerle-tensorflow-yapay-zeka-nedir-acikliyoruz/>
- Melih Güney, (2015). Bitcoin Nedir? Bitcoin Nasıl Üretilir?. Erişim adresi <https://www.melihguney.com/bitcoin-nedir-nasil-uretilir.html>
- 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. <https://doi.org/10.1016/j.physa.2018.07.017>

- Nunes, B.S.R. (2017). *Virtual currency: A Cointegration Analysis between Bitcoin prices and economic and financial data*. (Yayınlanmış Yüksek Lisans Tezi). ISCTE Business School, Lizbon, 1-88.
- Paribulog. (2019). 6 Maddede Ripple (XRP). Erişim adresi <https://www.paribu.com/blog/kriptopara/6-maddede-xrp-nedir/>
- Phi, M. (2018). Illustrated Guide to LSTM's and GRU's: A Step by Step Explanation. Erişim adresi <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>
- 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 ilişkinin incelenmesi: Bitcoin Örneği. *Akademik İncelemeler Dergisi*, 14 (1), 443-462. DOI: 10.17550/akademikincelemeler.543486
- PricewaterhouseCoopers (PwC). (2017). Building Blocks: How Financial Services Can Create Trust in Blockchain. Erişim adresi <https://www.pwc.com/publications/pwc-whitepaper-blockchain-trust.pdf>
- Ripple. (2020). Ripple. Erişim adresi <https://ripple.com/xrp/>
- Scikit-Learn. (2020). Compare The Effect of Different Scalers on Data with Outlier. Erişim adresi https://scikit-learn.org/stable/auto_examples/preprocessing/plot_all_scaling.html
- Spirina, K. (2018). How Artificial Neural Networks Can Code Smarter Than GUI Programmer. Erişim adresi <https://hackernoon.com/how-artificial-neural-networks-can-code-smarter-than-gui-programmer-1cdfaeb4851>
- Stenqvist, E. ve Lönnö, J. (2017). Predicting Bitcoin price fluctuation with twitter Sentiment Analysis. *Degree Project in Technology, First Cycle*, 15 Credist, 3-31.
- Şahin, E.E. (2020). Bitcoin Fiyatına etki eden faktörlerin Mars Metodu ile belirlenmesi. *Uluslararası Ekonomi, İşletme ve Politika Dergisi*, 4 (1), 171-184.
- Tun, C.C. Majid, N. (2018). Comparison between Artificial Neural Network and autoregressive integrated moving average model in Bitcoin price forecasting. *Journal of Quality Measurement and Analysis*, 14(2), 45-53.
- Weiss, G., Goldberg, Y. ve Yahay, E. (2018). On the Practical Computational Power of Finite Precision RNNs for Language Recognition. arXiv:1805.04908, 2018. Erişim adresi <https://arxiv.org/abs/1805.04908>
- Zoumpakas, T., Houstis, E. ve Vavalos, M. (2020). ETH Analysis and Predictions Utilizing Deep Learning. *Expert Systems With Applications*, 162, 1-15. <https://doi.org/10.1016/j.eswa.2020.113866>