



T.C.

MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

**KRİZ DÖNEMLERİNDE YAPAY ZEKÂ YÖNTEMLERİ İLE FARKLI
AMAÇ VE ALTYAPIYA SAHİP KRİPTO PARA ENDEKS TAHMİNİ
VE KARŞILAŞTIRMASI: BİTCOİN VE ETHERYUM ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

Fusun ŞENTÜRK

DANIŞMAN

Dr. Öğr. Üyesi Muhammer İLKUÇAR

2023 - Muğla

T.C.
MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

**KRİZ DÖNEMLERİNDE YAPAY ZEKÂ YÖNTEMLERİ İLE FARKLI
AMAÇ VE ALTYAPIYA SAHİP KRİPTO PARA ENDEKS TAHMİNİ
VE KARŞILAŞTIRMASI: BİTCOİN VE ETHERYUM ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

Fusun ŞENTÜRK

DANIŞMAN

Dr. Öğr. Üyesi Muhammer İLKUÇAR

2023 - Muğla

YEMİN

Yüksek Lisans tezi olarak sunduğum “*Kriz Dönemlerinde Yapay Zekâ Yöntemleri ile Farklı Amaç ve Altyapıya Sahip Kripto Para Endeks Tahmini ve Karşılaştırması: Bitcoin ve Ethereum Örneği* ” adlı çalışmanın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanmış olduğumu belirtir ve bunu onurumla doğrularım.

/ / 2023

Fusun ŞENTÜRK

KRİZ DÖNEMLERİNDE YAPAY ZEKÂ YÖNTEMLERİ İLE FARKLI AMAÇ VE ALTYAPIYA SAHİP KRİPTO PARA ENDEKS TAHMİNİ VE KARŞILAŞTIRMASI: BİTCOİN VE ETHERYUM ÖRNEĞİ

ÖZET

Modern dünyada teknolojinin gelişmesiyle ve çeşitlenmesi ile birlikte hayatımız ve yaşam biçimimiz de değişmektedir. En önemli değişikliklerden birisi de blok zinciri teknolojisiyle ortaya çıkan sanal ödeme yöntemleri ve kripto paralardır. blok zincirin en önemli uygulama alanı kripto paralar olmuştur. Bunların öncüsü ve genel kabul görmüş olanı Bitcoin olmakla birlikte ardından birçok yeni kripto para ortaya çıkmıştır. Kripto paralar merkezi bir yapıya sahip olmadıkları için fiyat dalgalanmalarına sebep olmaktadır. Bu bağlamda kripto paraların fiyatının nasıl değişim göstereceği kripto yatırımcılar ve araştırmacılar için merak konusu olup, tahmin ihtiyacını ortaya çıkarmıştır.

Bu çalışma ile dünyada yaşanan pandemi, savaş ve bunlara bağlı ekonomik sorunların neden olduğu kriz dönemlerinde, makine öğrenme ve derin öğrenme yöntemleri kullanılarak farklı kripto paraların fiyat endeks tahmini yapılarak sonuçları karşılaştırılmıştır. Çalışmada, özellikle son dönemlerin, popüler ve başarılı yöntemlerden biri olan yapay sinir ağı algoritmaları kullanılmıştır. Veri seti olarak kripto paraların geçmiş endeks ve hacim verileri kullanılarak eğitilmiş makine öğrenme modeli ile tahmin işlemi yapılmıştır. Veri seti, kamuya açık internet sitesi olan investing.com web adresinden, Bitcoin için 01.01.2018 ile 27.04.2022 tarihleri arasında 1578 adet, Ethereum için 10.03.2016 ile 20.04.2022 tarihleri arasında 2233 adet günlük endeksler ve işlem hacmi olarak ele alınmıştır. Veri seti eğitim, geçerlilik ve test olarak bölme işlemi yapıldıktan sonra, kullanılacak derin öğrenme modelinin yapısına göre düzenlenmiştir. Yapay sinir ağı (YSA) ile birlikte derin öğrenme algoritmalarından, uzun kısa süreli bellek (LSTM- Long Short Term Memory) ve geçişli tekrarlayan ünite (GRU- Gated Recurrent Unit) yöntemleri kullanılmıştır. Bu algoritmaların farklı hiper parametreleri ile eğitim tekrarlanıp, sonuçlar karşılaştırılmıştır.

Buna göre; Bitcoin veri seti için, LSTM algoritmasına göre eğitim R-Kare performans değeri 0,991, test R-Kare değeri ise 0,938 olarak bulunmuştur. GRU algoritmasına göre ise eğitim R-Kare performans değeri 0,991, test R-Kare değeri ise 0,922 olarak bulunmuştur. YSA modeline göre ise eğitim R-Kare performans değeri 0,894, test R-Kare değeri ise 0,917 olarak bulunmuştur.

Etheryum veri seti için, LSTM algoritmasına göre eğitim R-Kare performans değeri 0,994, test R-Kare değeri ise 0,994 olarak bulunmuştur. GRU algoritmasına göre ise eğitim R-Kare performans değeri 0,998, test R-Kare değeri ise 0,992 olarak bulunmuştur. YSA modeline göre ise eğitim R-Kare performans değeri 0,996, test R-Kare değeri de 0,996 olarak bulunmuştur.

Bu sonuçlara göre YSA, LSTM ve GRU modeller arasında anlamlı bir fark olmadığı görülmektedir. Kullanılan tüm makine öğrenme modelleri Eğitim ve Test R-Kare performans değerleri % 90'nın üzerinde olup % 99'a kadar çıkmaktadır. Bu performans değerlerine bakıldığında iyi bir başarımlı gösterdiği sonucuna varılabilir.

Çalışma farklı amaçlar için kullanılan kripto varlıklara yatırım yapan kurumsal ve bireysel yatırımcılara karar destek sistemi sağlayacaktır. Ayrıca farklı dönemlerde ve süreçlerde diğer kripto paraların da tahmin edilebilmesi için literatürde örnek teşkil edebileceği düşünülmektedir.

Çalışmada veri seti olarak geçmiş veriler ve işlem hacmi kullanılmıştır. Ancak fiyatın oluşmasına etki eden başka faktörler (faiz oranları, politik riskler, kurlar, gelir dağılımı vb.) de olabilir. Bu faktörlerden biri ya da birkaçı dikkate alınarak farklı çalışmalar yapılabilir.

Anahtar Kelimeler: Blok zinciri, Kripto Para, Bitcoin, Ethereum, Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme, LSTM, GRU, Yapay Sinir Ağları.

IN CRISIS PERIODS, ARTIFICIAL INTELLIGENCE METHODS AND CRYPTOCURRENCY INDEX ESTIMATION AND COMPARISON WITH DIFFERENT PURPOSES AND INFRASTRUCTURE: THE EXAMPLE OF BITCOIN AND ETHEREUM

ABSTRACT

With the development and diversification of technology in the modern world, our life and lifestyle are also changing. One of the more important technological advancements to happen in recent years is the emergence of blockchain technology and cryptocurrencies. While most people equate cryptocurrency with Bitcoin, there are actually many different cryptocurrencies that exist in the market. Currently, cryptocurrencies do not have a centralized structure. This means that they experience continual price fluctuations. The rate and percentage that the price of cryptocurrencies will change has become a matter of curiosity for both crypto investors and researchers. However, more importantly, it has revealed the need for the ability to predict these changes.

In this study, price index estimation of different cryptocurrencies was made using machine learning methods and deep learning methods. The results were compared during the crisis periods caused by the pandemic, war and related economic problems in the world. Artificial neural network algorithms, which have recently become one of the more popular and successful machine learning methods, were used in this study. The deep learning model was pre-trained using both the historical index and volume data of cryptocurrencies. This model was then used to train our data set. We created a Bitcoin dataset and an Ethereum dataset using the public website “investing.com”. The Bitcoin dataset consisted of 1578 daily indices and a trading volume between 01.01.2018 and 27.04.2022. The Ethereum dataset comprised 2233 indices and a trading volume between 10.03.2016 and 20.04.2022. Each dataset was then trained, validated and tested using each machine learning model. We used the deep learning algorithms, long short term memory (LSTM) and Gated Recurrent Unit (GRU) and the Artificial Neural Network (ANN) to train, test and validate each of the datasets. The training was repeated using different hyper parameters of these algorithms and the results were compared.

In the Bitcoin dataset trained using LSTM, the training R-Square performance value was 0.991 and the test R-Squared value was 0.938. Using the GRU algorithm, the training R-Square performance value was 0.991 and the test R-Square value was 0.922. The ANN model yielded a training R-Square performance value of 0.894, and a test R-Square value of 0.917.

For the Ethereum dataset, the dataset trained using the LSTM algorithm yielded a R-Square performance value of 0.994, and a test R-Square value of 0.994. Using the GRU algorithm, the training R-Square performance value was found to be 0.998, and the test R-Square value was 0.992. With the ANN model, the training R-Square performance value was found to be 0.996, and the test R-Square value was 0.996.

According to these results, it is seen that there is no significant difference between the LSTM, GRU, and ANN models. The values of the Training and Test R-Square performances were between 90% and 99% in each of the machine learning models used. Considering these performance values, it can be concluded that the prediction model has good performance.

The study will provide a decision support system for both institutional and individual investors investing in crypto assets. It can be used for different purposes. In addition, it can serve as an example in the literature for estimating other cryptocurrencies in different periods and processes.

Historical data and transaction volume were used as data sets in the study. However, there may be other factors (interest rates, political risks, exchange rates, income distribution, etc.) that affect the formation of the price. Different studies can be done while considering one or more of these factors.

Keywords: Blockchain, Cryptocurrency, Bitcoin, Ethereum, Artificial Intelligence, Machine Learning, Deep Learning, LSTM, GRU, Artificial Neural Networks.

ÖN SÖZ

Yüksek Lisans eğitimime başladığım ilk dönemden itibaren bilgi ve tecrübesi ile bana yol gösteren, tezimin planlanmasından uygulamasına kadar her aşamasında bana akademik destek ve katkı sağlayan değerli zamanını ve fikirlerini hiçbir zaman esirgemeyen değerli tez danışmanım Sayın Dr. Öğr. Üyesi Muhammer İLKUÇAR' a teşekkürlerimi sunarım.

Yüksek Lisans eğitim döneminde ve tez çalışmamın her sürecinde bana destek olan, tecrübesini, bilgi ve fikirlerini, değerli vaktini, emeğini esirgemeyen, bu yolda beni cesaretlendiren ve yalnız bırakmayan değerli arkadaşım Ömer KURUGÖL' e teşekkürlerimi sunarım.

Hayatım boyunca gücünü, sevgi ve sabrını, inançlarını her daim hissettiğim değerli aileme, doğduğu günden beri hayatımın her anına anlam katan ve beni her zaman yürekten destekleyen, inanan biricik oğlum Utku Ata' ya sonsuz teşekkürlerimi sunarım.

Fusun ŞENTÜRK

Tarih:

MUĞLA

İÇİNDEKİLER

ÖN SÖZ	I
İÇİNDEKİLER	II
ŞEKİLLER DİZİNİ.....	V
TABLolar DİZİNİ	VII
KISALTMALAR	IX
GİRİŞ	1

BİRİNCİ BÖLÜM

BLOK ZİNCİRİ VE KRİPTO PARA KAVRAMI

1.1. BLOK ZİNCİRİ TEKNOLOJİSİ	3
1.2. BLOK ZİNCİRİ UYGULAMA ALANLARI.....	3
1.3. DÜNYADA UYGULANAN BLOK ZİNCİRİ PROJELERİ.....	5
1.4. KRİPTO PARA	7
1.4.1. Kripto Paraların Avantaj ve Dezavantajları.....	8
1.5. BİTCOİN.....	9
1.5.1. Bitcoin Avantajları.....	11
1.5.2. Bitcoin Dezavantajları	12
1.6. ETHERYUM.....	13
1.6.1. Ethereum Avantajları.....	13
1.6.2. Ethereum Dezavantajları	14
1.7. KRİPTO PARA TEKNOLOJİLERİNİN GÜVENLİĞİ VE SUÇ	14
İLİŞKİSİ.....	14
1.8. KRİPTO PARA DOLANDIRICILIK YÖNTEMLERİ	15
1.9. KRİZ VE KRİZ YÖNETİMİ	16
1.9.1 Kriz Yönetim Süreci	17

1.9.2 Kripto Para ve Kriz Yönetimi İlişkisi	18
1.10. LİTERATÜR ÇALIŞMASI	18

İKİNCİ BÖLÜM

MATERYAL VE METOT

2.1. YAPAY ZEKÂ TEKNOLOJİSİ	22
2.2. YAPAY SİNİR AĞLARI.....	24
2.3.YAPAY SİNİR AĞI ELEMANLARI ve ÇALIŞMA ALGORİTMASI	25
2.3.1. Girdiler.....	25
2.3.2. Ağırlıklar.....	25
2.3.3. Birleştirme Fonksiyonu.....	26
2.3.4. Aktivasyon Fonksiyonu	26
2.3.5. Çıktılar	27
2.3.6. Yapay Sinir Ağı Çalışma Algoritması	27
2.4. MAKİNE ÖĞRENME ALGORİTMALARI	28
2.4.1. Denetimli Öğrenme.....	28
2.4.2. Denetimsiz Öğrenme	29
2.4.3. Pekiştirmeli Öğrenme	30
2. 5. TEKRARLAYAN (YİNELENEN) SİNİR AĞLARI (RNN-	32
RECURRENT NEURAL NETWORKS)	32
2.5.1. Uzun Kısa Süreli Bellek Birimi (LSTM–Long Short -Term.....	33
Memory)	33
2.5.2. Kapılı Tekrarlayan Birim (GRU- Gated Recurrent Unit).....	36
2.6. DERİN ÖĞRENME	38

ÜÇÜNCÜ BÖLÜM

VERİ SETİ VE UYGULAMA

3.1. VERİ SETİ	40
3.2. ZAMAN SERİLERİ.....	43
3.2.1. Zaman Serilerinin Makine Öğrenme Yöntemi ile Tahmini.....	44
3.4. VERİ SETİ ANALİZİ VE İSTATİSTİKİ BİLGİLERİ	45
3.4.1. Bitcoin Veri Analizi.....	45
3.4.2. Ethereum Veri Analizi.....	48
3. 5. BİTCOİN UYGULAMA ANALİZLERİ.....	50
3. 5. 1. Bitcoin YSA Uygulaması	50
3. 5. 2. Bitcoin GRU Uygulaması.....	53
3. 5. 3. Bitcoin LSTM Uygulaması.....	56
3. 6. ETHERYUM UYGULAMA ANALİZLERİ.....	59
3. 6. 1. Ethereum YSA Uygulaması	59
3. 6. 2. Ethereum GRU Uygulaması.....	62
3. 6. 3. Ethereum LSTM Uygulaması.....	65

DÖRDÜNCÜ BÖLÜM

SONUÇ VE ÖNERİ

4. 1. SONUÇ	69
4. 2. ÖNERİ.....	74
KAYNAKÇA.....	75
EKLER	

ŞEKİLLER DİZİNİ

Şekil 1. 1: Blok Zinciri Uygulama Alanları	4
Şekil 1. 2: Blok Zinciri Teknolojisine Dünya Üzerinde Yatırım Yapan Bölgeler.....	6
Şekil 1. 3: Kripto Paraların Çalışma Prensibi	7
Şekil 1. 4: Bitcoin 2017-2022 Yılları Arası Fiyat (TL) Grafiği.....	11
Şekil 1. 5: Kriz Yönetim Süreci	17
Şekil 2. 1: Yapay Zekâ Hiyerarşisi	23
Şekil 2. 2: Biyolojik Sinir Ağı.....	24
Şekil 2. 3: Bir Düşümlük Yapay Sinir Ağı	25
Şekil 2. 4: Denetimli Makine Öğrenmesi Algoritması	29
Şekil 2. 5:Denetimsiz Makine Öğrenmesi Algoritması	30
Şekil 2. 6: Pekiştirmeli Makine Öğrenme Algoritması.....	31
Şekil 2. 7: RNN Mimarisi	32
Şekil 2. 8: Tek Hücreli Standart RNN Modülü.....	33
Şekil 2. 9: Dört Hücreli LSTM Modülü.....	34
Şekil 2. 10: LSTM' de Yer Alan Sigmoid Hücresi	35
Şekil 2. 11: GRU Modelinde Sıfırlama ve Güncelleme Geçitleri.....	37
Şekil 2. 12: Derin Öğrenmede Başlıca Kullanım Alan Yelpazesi	39
Şekil 3. 1: Sistem Akış Diyagramı.....	41
Şekil 3. 2: Zaman Serilerinde Tahmin İşlemi Algoritması	44
Şekil 3. 3: Zaman Serisi Verisinin Denetimli Makine Öğrenme Verisine Dönüştürülmesi	45
Şekil 3. 4: Bitcoin 2018-2022 Yıllarına Göre Fiyat Değişim Grafiği.....	47
Şekil 3. 5: Bitcoin Fiyat Yoğunluk Grafiği.....	47
Şekil 3. 6: Ethereum 2016-2022 Yıllarına Göre Fiyat Değişim Grafiği.....	49
Şekil 3. 7: Ethereum Fiyat Yoğunluk Grafiği.....	50
Şekil 3. 8: Bitcoin Kayıp - Yineleme Grafiği- YSA	52
Şekil 3. 9: Bitcoin Tahmin ve Gerçek Değer Grafiği-YSA	53
Şekil 3. 10: Bitcoin Kayıp - Yineleme Grafiği-GRU.....	55
Şekil 3. 11: Bitcoin Tahmin ve Gerçek Değer Grafiği-GRU.....	56

Şekil 3. 12: Bitcoin Kayıp - Yineleme Grafiği-LSTM	58
Şekil 3. 13: Bitcoin Tahmin ve Gerçek Değer Grafiği-LSTM.....	58
Şekil 3. 14: Ethereum Kayıp - Yineleme Grafiği-YSA	61
Şekil 3. 15: Ethereum Tahmin ve Gerçek Değer Grafiği-YSA	61
Şekil 3. 16: Ethereum Kayıp - Yineleme Grafiği-GRU.....	64
Şekil 3. 17: Ethereum Tahmin ve Gerçek Değer Grafiği-GRU.....	64
Şekil 3. 18: Ethereum Kayıp-Yineleme Grafiği-LSTM	67
Şekil 3. 19: Ethereum Tahmin ve Gerçek Değer Grafiği-LSTM.....	67



TABLÖLAR DİZİNİ

Tablo 3. 1: Bitcoin Veri Seti Örneği	46
Tablo 3. 2: Bitcoin Veri Seti İstatistik Bilgileri	46
Tablo 3. 3: Ethereum Örnek Veri Seti	48
Tablo 3. 4: Ethereum Veri Seti İstatistikî Bilgileri	49
Tablo 3. 5: Bitcoin YSA Hiper Parametreleri	51
Tablo 3. 6: Farklı YSA Mimarileri İçin Bitcoin YSA Performans Sonuçları.....	51
Tablo 3. 7: Bitcoin Veri Seti İçin Farklı GRU Mimari Modelleri	53
Tablo 3. 8: Bitcoin GRU Hiper Parametreleri	54
Tablo 3. 9: Bitcoin Makine Öğrenmesi GRU Eğitim ve Test Performans Sonuçları	54
Tablo 3. 10: Bitcoin Veri Seti İçin Farklı LSTM Mimari Modelleri	56
Tablo 3. 11: Bitcoin LSTM Hiper Parametreleri	57
Tablo 3. 12: Bitcoin Makine Öğrenmesi LSTM Eğitim ve Test Performans Sonuçları	57
Tablo 3. 13: Bitcoin Uygulaması için GRU, LSTM, YSA Performans Değerleri	59
Tablo 3. 14: Ethereum YSA Hiper Parametreleri	60
Tablo 3. 15: Farklı YSA Mimarileri İçin Ethereum YSA Performans Sonuçları.....	60
Tablo 3. 16: Ethereum Veri Seti İçin Farklı GRU Mimari Modelleri	62
Tablo 3. 17: Ethereum GRU Hiper Parametreleri	62
Tablo 3. 18: Ethereum Makine Öğrenmesi GRU Eğitim ve Test Performans Sonuçları	63
Tablo 3. 19: Ethereum Veri Seti İçin Farklı LSTM Mimari Modelleri	65
Tablo 3. 20: Ethereum LSTM Hiper Parametreleri	65
Tablo 3. 21: Ethereum Makine Öğrenmesi LSTM Eğitim ve Test Performans Sonuçları	66
Tablo 3. 22: Ethereum Uygulaması için GRU, LSTM, YSA Performans Değerleri.	68
Tablo 4. 1: Ethereum Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Eğitim Performans Değerleri Tablosu	71
Tablo 4. 2: Ethereum Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Test Performans Değerleri Tablosu	71
Tablo 4. 3: Bitcoin Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Eğitim	

Performans Değerleri Tablosu	72
Tablo 4. 4: Bitcoin Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Test	
Performans Değerleri Tablosu	72



KISALTMALAR

Kısaltmalar

Açıklama

AI	Artificial Intelligence
DL	Deep Learning
YSA	Yapay Sinir Ağları
ANN	Artificial Neural Network
RNN	Recurrent Neural Networks
LSTM	Long Short Term Memory
GRU	Gated Recurrent Unit
FİN TECH	Finans Teknoloji
ET	Ether
BTC	Bitcoin
TÜBİTAK	Türkiye Bilimsel ve Teknolojik Araştırmalar Kurumu
BİLGEM	Bilişim ve Bilgi Güvenliği İleri Teknolojiler Araştırma Merkezi
UEKAE	Ulusal Elektronik ve Kriptoloji Araştırma Enstitü
BCLabs	Blok Zincir Araştırma Laboratuvarı
BY	Bayes Regresyonu
BNN	Bayes Sinir Ağı
TARCH	Eşik Oto Regresyon Koşullu Varyans
TDNN	Time Delay Neural Network
ARİMA	Autoregressive Integrated Moving Average
IAPS	International Association People Environment Studies
UCI	Machine Learning Repository
RMSE	Root Mean Square Error
MAPE	Mean Absolute Percentage Error
MAE	Mean Absolute Error
R^2	Coefficient of Determination
IDC	International Data Corporation
P2P	Peer to Peer
SOM	Self Organize Map
RELU	Rectified Linear Units

GİRİŞ

Modern dünyada internetin her alanda yaygın kullanımı ve mobil kullanımın artması sebebiyle internete her yerden erişim sağlanması birçok dijitalleşmeyi de beraberinde getirmiştir. Bu gelişmeler sonucunda farklı para birimleri ve sanal ödeme sistemleri ortaya çıkmıştır. Sanal ödeme yöntemlerinin kullanım alanları da genişlemiş olup dünyada yaygın bir kullanım ağı meydana gelmiştir. Bunların ilk ve en çok kullanılan kripto para olma özelliği taşıyan kripto para birimi Bitcoin'dir. "Bitcoin: Eşten Eşe Nakit Ödeme Sistemi" isimli bir makale ile 2008 finansal krizinden sonra dünyaya tanıtılan kripto para birimidir (Nakamoto, 2008).

Dünyanın değişen yeni ekonomi anlayışı 19. yüzyılda ortaya çıkmış olup FİN TECH (Finans Teknoloji) finans alanında teknolojik yenilik olarak tanımlanmıştır. Dünyadaki herhangi bir kişiye herhangi bir zamanda eş zamanlı para transferine izin veren, merkezi olmayan bir ödeme sistemi olması, blok zinciri teknolojisi ile Bitcoin öncü olmak üzere kripto paraları dünya ekonomisinde önemli bir yere sahip hale getirmektedir (Çağlar & Yavuz, 2021).

Bitcoin' in ardından 2014 yılında Ethereum üzerine çalışılmaya başlanmıştır. Kripto para geliştiricileri Bitcoin sisteminin esnek olmayan bir yapıya sahip olduğunu düşünerek bu anlamda Ethereum' a ağırlık vermeye başlamışlardır. Ethereum merkezi olmayan bir bilgisayar gibidir. Açık kaynak kodludur. Her hangi bir dijital içerik akıllı sözleşmelere kaydedilip başka bir aracı olmadan eşler arasında aktarılabilir. Bitcoin'den sonra en sık kullanılan ve güvenilir olduğu düşünülen kripto para birimidir (Metin, Bilgi Yönetimi ve Blokzinciri Teknolojisi, 2021, s. 102-103).

Kripto para fiyatları başlangıcından günümüze kadar farklı nedenlerden kaynaklanan, özellikle kriz dönemlerinde çok fazla dalgalanmalar göstermiştir. Bu dalgalanmalar kripto para yatırımcılarının karar almalarında güçlüklerle karşı karşıya kalmasına sebep olmaktadır. Bu zorluklar yapay zekâ teknikleri kullanılarak belirli ölçüde aşılmaya çalışılmaktadır.

Bu çalışmada kripto para tahmini için, yapay zekâ uygulaması olarak makine öğrenme yöntemlerinden olan Artificial Neural Network (ANN), derin öğrenme yöntemlerinden olan Long Short Term Memory (LSTM) ve Gated Recurrent Unit (GRU) algoritmaları kullanılmıştır.

Çalışmanın birinci bölümünde giriş kısmı ile blok zinciri ve kripto paralar hakkında bilgiler verilmiş ve literatür taranarak ilgili çalışmalardan bahsedilmiştir. İkinci bölümde çalışmada kullanılan materyal ve metotlara yer verilmiş, üçüncü bölümde veri seti ve uygulamadan bahsedilmiş, dördüncü bölüm de ise karşılaştırmalı sonuçlar sunularak tartışmaya yer verilmiş, gelecek ve benzer çalışmalar için önerilerde bulunulmuştur.



BİRİNCİ BÖLÜM

BLOK ZİNCİRİ VE KRİPTO PARA KAVRAMI

1.1. BLOK ZİNCİRİ TEKNOLOJİSİ

Blok zinciri, güvenli bir şekilde paylaşım yapılan, merkezi olmayan veri kayıt defteri olarak tanımlanmaktadır. Blok zincirleri açık veya özel olabilir. Herkes tarafından okunup kullanılabilen, değiştirilebilen bir yapıda ise açık blok zinciri, sistemde kontrol ve sınırlı erişim olan bir yapıda ise özel blok zinciri olarak tanımlanmaktadır (Tübitak Bilgem Uekae, 2018).

Blok zinciri teknolojisinin çalışma algoritmasına göre sisteme sadece yeni veriler eklenebilmektedir. Mevcut var olan verilerin silinmesi ya da değiştirilmesi çok zordur. Bu önemli özelliğinden dolayı blok zinciri teknolojisi veri güvenliği açısından oldukça güvenli bulunmaktadır. Fakat hala kim ya da kimler tarafından ortaya çıkarıldığı ve kontrol edildiği belirsiz olduğu için yatırımcıların gözünde düşük bir oranda da olsa, gizemli ve riskli görüldüğü düşünülmektedir (Metin, Bilgi Yönetimi ve Blokzinciri Teknolojisi, 2021).

1.2. BLOK ZİNCİRİ UYGULAMA ALANLARI

Blok zinciri teknolojisi başta finans alanında Bitcoin öncülüğünde sanal para birimlerinin altyapısında kullanılacak şekilde geliştirilmiş olsa da günümüze gelindiğinde sağlık, eğitim, sanayi, turizm, gayrimenkul, tedarik zinciri, hükümet kurumları, telekomünikasyon ve e-ticaret gibi birbirinden farklı ve önemli sektörlerde kullanılmaya başlanmıştır. Herhangi bir para kullanımı zorunlu olmayan blok zinciri yapısı, sayısal olarak ifade edilerek işlem transferine olanak sağlamaktadır. Avantajları bakımından hızlı bir şekilde dünya üzerinde geniş uygulama alanlarına sahip olmaya devam etmektedir (Kırbaş, 2018). Son zamanlarda kullanım alanları daha da genişleyen blok zinciri teknolojisi yeni sanal evrenin de ortaya çıkmasına alt yapı sağlamaktadır. Sanal evren (Metaverse) kullanıcılara zamanlarının çoğunu geçirebilecekleri, alışveriş yapıp, eğlenecekleri, toplantılar

düzenleyebilecekleri, kendi sanal kimliklerini (avatar) oluşturabilecekleri sınırsız bir ortam tanınmaktadır. Kullanıcılar bu sanal evreni özgür bir şekilde kullanmaktadırlar. Bireylerin günlük yaşamını etkileyen gerçek hayattaki gibi kanunlar, kurallar yoktur. Bu sanal ortam kullanıcıların sanal evrende zaman geçirmelerini teşvik etmektedir (Kahraman, 2022). Finans alanında para piyasaları ve tahmin işlemlerinde, eğitimde akıllı sertifikalar ile eğitim kalitesinin ve süreç hızının artmasında kullanılmaktadır. Sağlık alanında elektronik sağlık kayıt sistemi ile hızlı ve güvenli yönetsel süreci oluşturmaktadır. İşletmelerde tedarik zincirleri, akıllı tarım, akıllı ev sistemleri, savunma sanayi ve enerji sektörü gibi teknolojinin en ön planda kullanıldığı alt alanlarda kullanılmaktadır. Hükümetlerce vatandaşların kimlik bilgileri ve özlük işlerinde, noter işlemlerinde ve e-seçim uygulamalarında, güvenli dijital depolama işlemleri, işlem şeffaflığı, kişisel verilerin korunması ve güvenlik alanlarında kullanılmaktadır. Veri yönetiminde verilerin dağılımı, işleyiş ve güvenliği, zaman yönetimi ve işletmelerde insan kaynakları yönetiminde işçi ve işverenin hayatını kolaylaştırmada kullanılmaktadır. Bütünlük doğrulama alanında ise para basma işlemleri, fikri mülkiyet ve sigorta işlemlerinde, e-ticaret, dağıtık cihaz yönetimi alanları da nesnelerin interneti başlığı altında kullanılmaktadır (Kayman, 2019). zinciri uygulama alanları ve alt alanları Şekil 1. 1’de gösterilmiştir.

Şekil 1. 1: Blok Zinciri Uygulama Alanları

FİNANS	• Kripto paralar, tahmin piyasası
EĞİTİM	• Sertifika yönetimi, kalite
SAĞLIK	• EHR (Electronic Health Record)
İŞLETME VE SANAYİ	• Tedarik zinciri, tarım, savunma ve enerji
HÜKÜMET	• Kimlik bilgileri, noter, e-seçim
GİZLİLİK VE GÜVENLİK	• Güvenli depolama, şeffaflık
VERİ YÖNETİMİ	• Veri dağılımı, insan kaynakları
BÜTÜNLÜK DOĞRULAMA	• Para basma, fikri mülkiyet, sigorta
NESNELERİN İNTERNETİ	• E-ticaret, dağıtık cihaz yönetimi

Kaynak: (Kayman, 2019)

1.3. DÜNYADA UYGULANAN BLOK ZİNCİRİ PROJELERİ

Blok zinciri uygulamaları dünya üzerinde birçok ülkede ve çeşitli projelerde hızlı bir şekilde kullanılmaya başlanmıştır. Ülkelerin hızla uyum sağladığı blok zincir uygulamaları hayatı kolaylaştırmaya, zaman tasarrufu sağlamaya ve daha güvenli bir yaşam oluşturmaya başlamıştır. Bu konuda bazı örnek projelerden bahsetmek gerekirse; Avustralya, iki yıllık deneme süresinden sonra Menkul Kıymetler Borsası blok zinciri teknolojisini tamamen kabul edeceğini duyurmuş ve Bitcoin ile beraber diğer kripto paralardan da vergi almayacağını bildirmiştir (Altay Topçu & Sümerli Sarıgül, 2020). Hollanda’da emeklilik sisteminde Smart Voucher uygulamasıyla kişilere emekli maaşları Euro yerine dijital makbuzlarla ödenmiştir. Malta’da veri doğrulama sistemi olarak üniversitelerde akademik alanda kullanılmıştır. Singapur’da trafikte kontrol işleminin sağlanmasında kamera ve sensör sistemleri için kullanılmıştır. İsviçre’de ise kişisel kimlik kartlarında kullanılmakta olup bu sisteme Zug ID adı verilmiştir. İsveç’te ise blok zinciri tapu işlemleri, gayrimenkul kayıtları ve finansal işlemlerin çoğu ile akıllı sözleşmeler üzerine kullanılmaktadır. Londra, Oslo ve San Francisco’da ise akıllı otopark sistemi projelerinde kullanılmaya başlanmıştır. Barcelona’ da ise blok zinciri teknolojisi ile atık yönetimi, ses kontrol sistemi ve hava kalitesi ölçümü gibi projelerin gerçekleştirilmesi sağlanmıştır. Rotterdam Belediyesi atık yönetimi ile ilgili blok zinciri tabanlı sistem kurmuştur. Gürcistan’da ise tedarik zincir yönetimi, mal yönetimi ve kimlik yönetimi konularında dijital sertifikasyon sistemi ile kullanılmıştır. Blok zinciri kamuda olduğu kadar özel sektörde de yaygın olarak kullanılmaya başlanmıştır. En önemlisi ise veri güvenliği açısından önem taşıdığı için finans sektörüdür. İnşaat ve emlak sektöründe de akıllı evler hatta akıllı şehirler tasarlanmaktadır (Blockchain Women İstanbul, 2020).

Blok zinciri teknolojisi araştırmaları için dünya üzerinde birçok araştırma şirketleri yer almaktadır. International Data Corporation (IDC) bunlardan biridir. IDC 2018 yılında yayınlanan “*Blockchain: Worldwide Technology Market Update and Spending Outlook*” yayınında 2017 yılında blok zinciri projeleri için harcanan yatırım tutarının toplam 754 Milyon Dolar civarında olduğunu ve 2022 yılına kadar bu rakamın 11,7 Milyar Dolar seviyelerine ulaşacağı tahmin edilmiştir (Blockchain Türkiye, 2019).

Bu yatırımların dünya genelinde dağılım oranları şekiller ve ülkeler birleştirilerek Şekil 1. 2’de gösterilmiştir. Bölge tabanlı olarak yatırım oranlarını karşılaştırdığımızda Kuzey Amerika ve Batı Avrupa’da diğer bölgelere göre daha fazla yatırım yapılması teknolojiye ve blok zincirine bakış açılarını, ekonomik beklentilerini ve devletler ile toplumların blok zincirine bakış açılarını yansıttığı söylenebilir.

Şekil 1. 2’de dünya haritası üzerinde belirtildiği gibi;

-  Kuzey Amerika’ da yapılan yatırım oranı %50,
-  Batı Avrupa ve Asya’da yapılan yatırım oranı %20,
-  Pasifik Asya’da yapılan yatırım oranı %18,
-  Kuzey Afrika’da yapılan yatırım oranı %10,
-  Japonya’da yapılan yatırım oranı %2,
-  Güney Amerika’da yapılan yatırım oranı ise %1, olarak belirtilmiştir.

Şekil 1. 2: Blok Zinciri Teknolojisine Dünya Üzerinde Yatırım Yapan Bölgeler



Kaynak: (Blockchain Türkiye, 2019)

Yapılan araştırmalarda blok zinciri teknolojisine yapılan yatırımların büyük bölümü finansal alanda olsa da, araştırma şirketleri bu durumun tarımsal faaliyet alanında oranların finansal alandan öne geçeceğini öngörmektedir (Blockchain Türkiye, 2019).

1.4. KRİPTO PARA

Kripto para biriminin kökenine baktığımızda ‘cryptocurrency’, ‘crypto’ ve ‘currency’ kelimelerinden türetilmiştir. Günümüzde kullanılan madeni ve kâğıt paralara kıyasla basılı değildir. Belirli algoritmalarla şifrelenmiş dijital veya sanal varlıklardır. Kriptografinin amacı ise paylaşım yapan tarafların işlemlerinin daha güvenli olmasını sağlamaktır (Kripto Para Araştırma Raporu, 2020).

Kripto paralar Avrupa Merkez Bankası tarafından’’ Geliştiricileri tarafından ihraç edilen (piyasaya sürülen) ve genellikle onlar tarafından kontrol edilen ve belirli sanal bir topluluğun üyeleri arasında kabul edilen ve kullanılan, düzenlenmeyen bir dijital para çeşididir’’olarak tanımlanmıştır (European Central Bank , 2012). Günümüzde farklı para birimi ve sanal ödeme sistemi olarak dünya genelinde kullanılmaya başlanan kripto paraların çalışma prensibi aşağıda Şekil 1. 3’de gösterilmiştir.

Şekil 1. 3: Kripto Paraların Çalışma Prensibi



Kaynak: (Blockgeeks, 2016)

1.4.1. Kripto Paraların Avantaj ve Dezavantajları

Kripto paralar günden güne gelişmeye devam ederken aynı zamanda dikkat edilmesi gereken derecede önemli konuları da açığa çıkarmaktadırlar. En önemli konu ise kripto para madenciliğinde kullanılan elektrik enerjisi miktarı görülmektedir. Her ne kadar kazançlı bir yatırım aracı olarak görülse de büyük risk ve dezavantajları da mevcuttur (Metin, Bilgi Yönetimi ve Blokzinciri Teknolojisi, 2021, s. 122-123).

Kripto paraların avantajları arasında;

- Şeffaflık,
- Güvenilirlik,
- Yüksek transfer hızı,
- Düşük maliyet,
- Düşük enflasyon riski,
- Ödeme özgürlüğü,
- Tarafsızlık,
- Anonim,

olmaları şeklinde sıralanabilir. Kripto paraların dezavantajları arasında ise;

- Aşırı enerji tüketimi,
- İzi sürülememesi,
- Yüksek kaybetme riski,
- Belirsizlik,
- Düşük likidite,
- Değişken ve sınırlı kullanım alanı,
- İadesinin mümkün olmaması,
- Siber saldırılara açık olması,
- Vergilendirilememesi,
- Aşırı değer dalgalanmaları yaşanması,

şeklinde sıralanabilir. Bu avantajlar ve dezavantajlar dışında kripto paralar yatırımcı ve kullanıcılar için özellikle belirsizlik ve güvensizlik duygusu barındırdığı için gelecekte nasıl bir seyir izleyeceği bilinmemektedir. Bu durum da kripto paraların tahmin işlemlerinin yapılması ihtiyacını doğurmaktadır (Alpago, 2018).

1.5. BITCOİN

Blok Zinciri teknolojisinin ilk uygulaması olarak bilinen Bitcoin (BTC), dünyada herhangi bir kişinin herhangi bir zamanda üstelik gerçek zamanlı transfer edilmesine olanak sağlayan merkezi olmayan bir ödeme sistemidir. 2008 yılında Satoshi Nakamoto tarafından “Bitcoin: Bir Eşler Arası Elektronik Nakit Sistemi” isimli makale ile dünyaya sunulmuştur (Nakamoto, 2008). Bitcoin protokolü merkezi olmayan eşler arası bir ağa sahiptir. İnternet sayesinde eşler arası bir protokol ile iletişim kurarlar (Metin, Bilgi Yönetimi ve Blokzinciri Teknolojisi, 2021, s. 92-93).

Bitcoin kripto para piyasasındaki en yüksek hacme sahip kripto paradır. Eşler arası peer to peer (P2P) bağlantı esasına dayanmaktadır. Bitcoin ile yapılan işlemler kriptografik algoritmalar içeren ağ düğümleri (network nodes) tarafından doğrulanarak halka açık bir şekilde ana deftere kaydedilir. Dağıtık defter de denilen bu defter, ödemeler de dahil olmak üzere kullanıcılar arasındaki işlemleri kaydetmek için kullanılır. Bitcoin’ler doğrudan kişiden kişiye gönderilirler. Hiçbir kurum ya da banka aracılığı ile işlem yapılmadığı için işlem ücreti çok daha düşüktür. Dünyanın her ülkesinde kullanılabilir ve kullanımı için herhangi bir şart ya da sınır yoktur. Bitcoin ağı madenci denilen teknik altyapı tarafından korunmaktadır. Madenciler ödemeleri doğrulamak koşuluyla yeni oluşturulmuş Bitcoin’ler ile ödüllendirilirler. Açık kaynak kodludur. Doğrulanmış ödemeler açık bir deftere kaydedilir. Bitcoin evrensel bir finans piyasasının oluşmasına yol açmıştır. Üretililecek en fazla Bitcoin sayısı 21 milyon ile sınırlandırılmıştır (bitcoin.org, 2009). Bitcoin merkezi olmayan bir ağ yapısına sahip olması ve güvenli olması bakımından insanlık tarihinin belki de en önemli teknolojisi olduğu düşünülmektedir (Pirinçci, 2018).


İlk kripto para özelliğini taşıyan Bitcoin aynı zamanda (Bozkurt & Armağan, 2015) göre en çok kullanılan sanal paradır. Çalışma prensibi kriptografiye dayanmaktadır. Merkezi olmayan bir sunucu ile bilgisayar sistemleri ile dosya paylaşma mantığıyla çalışmaktadır (Bozkurt & Armağan, 2015). Açık kaynak koda ihtiyaç duyan Bitcoin internetin olduğu tüm dijital platformlarda çalışabilmektedir. Satın alma işlemi gerçekleştirilen Bitcoin’ler dijital cüzdanlarda saklanmaktadır. Alıcıların gönderen kullanıcıya açık anahtarını göndermesi gerekmektedir. Gönderen kullanıcı da alıcı olan kullanıcıya açık anahtarını imzalar ve sayısal transfer gerçekleşmiş olur. Tarafların kimlikleri gizli olup, zaman damgası kullanılarak

birden fazla kullanılmasının önüne geçilmiştir. Zaman damgası zincirleme bir sistemle çalışmaktadır ve her işlemde ağ bunu doğrulamak zorundadır. Doğrulama sistemine ise madenciler (miners) denilmektedir. Yeni Bitcoin üretmenin tek yolu ise madenciliktir (mining). Yapılan bu madencilik sayesinde güvenli bir kullanım ağı ortaya koyulmuş ve yeni Bitcoin'ler oluşturma'nın daha güvenli ve kazançlı olduğu anlaşılmıştır (Pirinçci, 2018).

2017 yılının sonlarında kripto paralarda büyük bir fiyat hareketliliği yaşanmıştır. O dönemde Bitcoin daha çok kişisel olarak kullanılmaktaydı. Günümüze baktığımızda yani 2020 yılı ve sonrası daha çok kurumsal oyuncular devreye girmiştir. Gerçek işi blok zinciri veya kripto para olmayan fakat tamamen kendi nakit fazlasını yatırım yapmak isteyen kurumsal yatırımcılar bu teknolojide 2020 yılı ve sonrası daha fazla yer almaktadır. Aynı zamanda kamunun da dahil olduğu bir sistem haline gelmiştir. Bitcoin' i yasal para birimi olarak ilk kez 09.06.2021 tarihinde Orta Amerika ülkesi olan El Salvador kabul etmiştir. Aynı zamanda bir Bitcoin şehri oluşturacaklarını da duyurmuşlardır. Düzenledikleri güncel yasaya göre Bitcoin' i kullanmayı red eden işletmelere cezai işlem uygulanacak olup, ülkede 3 Bitcoin karşılığında yatırım yapacak yabancılara ise ülkede oturma izni verileceği belirtilmektedir (ntv/teknoloji haberleri, 2021).

Bitcoin, Ocak 2017 ve Nisan 2022 yılları arası zamanını kapsayan Türk Lirası fiyat grafiği aşağıda Şekil 1. 4'de gösterilmiştir. Grafiği oluşturan veriler tr.investing.com/crypto/bitcoin/chart adresinden alınmıştır. Grafikte Bitcoin fiyat sıçramaları ve dönemlerine dikkat çekilmek istenmiştir. 2017 yılı sonları başlayan değişiklikler finansal krizler, pandemi ve savaş gibi başlıca önemli olaylar ve kriz durumlarından etkilenecek büyük sıçramalara yol açmıştır.

Şekil 1. 4: Bitcoin 2017-2022 Yılları Arası Fiyat (TL) Grafiği



Kaynak: (tr.investing.com/crypto/bitcoin/chart, 2022)

1.5.1. Bitcoin Avantajları

Bitcoin, nerede, ne zaman ve kimler arasında olursa olsun, herkesin değer transferine olanak sağlayan eşler arası sistemin dünya çapında ilk başarılı uygulaması olan dijital para birimidir.

En yaygın olarak bilinen Bitcoin avantajları;

- 7/24 ödeme yapılabilir, en açık finansal sistemdir,
- Uluslararası transferlerde klasik bankacılık hizmetlerinden daha hızlı ve düşük maliyetlidir,
- Bitcoin, bir network ortam aracılığıyla aktarılabilir, taşınabilir varlıklardır,
- Çoklu imza özelliği sayesinde işletmelerdeki şeffaflığı artırır,
- En gelişmiş ekosistem ve en çok kabul gören dijital para birimidir,
- Kişi ya da kuruluşlar tarafından marka bilinirliği ve likiditesi diğer sanal paralara göre daha yüksektir,
- Akıllı sözleşmeler gibi programlanabilir yeni finansal hizmetlerin kullanılmasında rol oynar,
- Merkeziyetsizlik özelliği sayesinde güven sorununa bir alternatif olarak paranın tekeli bozmaktadır,
- Zorla ele geçirilemeyen tek varlık özelliğini taşır,
- İşlemler sansüresizdir, işlem engeli oluşturmaz,

- Halka açıktır, herkes internet üzerinden cüzdan açabilir,
 - Yüklü para transferlerinde dahi bilinen tüm yöntemlere göre çok daha güvenlidir,
 - Bilgisayar ya da mobil üzerinden internet erişimi olması koşuluyla harcama yapılabilir,
 - Özellikle üçüncü dünya ülkelerinde paraya erişebilmek adına oldukça yararlıdır,
 - Hareketsiz durmayan bir sistemdir ve inovasyona tabidir,
- şeklinde sıralanabilmektedir (cryptonews.com, 2021).

1.5.2. Bitcoin Dezavantajları

Avantajları olduğu kadar dezavantajları da var olan Bitcoin' in en yaygın olarak bilinen dezavantajları;

- Çevirim dışı etkin değildir, hala büyük çapta internet kullanımına bağlıdır,
- Madencilik verimliliğine bağlı olarak işlem hızı ve ücretleri değişkenlik gösterebilmektedir,
- Sayısı günden güne artmasına rağmen halen Bitcoin' i ödeme aracı olarak kabul etmeyen noktalar vardır,
- Bitcoin' in cüzdandan ayrılıktan sonra geri alınmasının imkânı yoktur,
- Genelde insanlar özel anahtarlarını güvenli bir şekilde yönetemezler,
- Kurtarılamaz şekilde birçok Bitcoin anahtarı kaybolmuştur,
- Kullanıcı ara yüzü kusursuz değildir, hala ağ dünyadaki herkes için kullanıma hazır değildir,
- Siber güvenlik bilgisi ve ağ yapısı güvenliği bilgisi gerektirir,
- Deflasyonisttir,
- Bitcoin' in temel yapısı dünya genelinde bir dirençle karşılaşmaya açıktır (cryptonews.com, 2021).
- Yatırımcılar için ne yönde ilerleyeceğini tahmin etmek güç olduğu için fiyatlardaki dalgalanmalar anlık olarak değişiklik göstermektedir,
- Bitcoin yazılımı hala beta sürümündedir,
- Kullanım olanağı sağlayan firmalar çok yeni olduğu için hala sigorta verememektedirler, şeklinde sıralanabilmektedir (bitcoin.org, 2009).

1.6. ETHERYUM

Etheryum, blok zinciri teknoloji tabanlı geliştiricilerin merkezi olmayan uygulamaların oluşturulabildiği açık kaynak kodlu güvenilir bir hesaplama platformu olarak kabul edilmektedir. Bitcoin'in betik dilinin aksine Turing-complete programlama dili sayesinde akıllı sözleşmelerin yapılması için merkezi olmayan bir platform ve otonom organizasyonlar sunmaktadır. Etheryum Bitcoin'e göre daha fazla özellik taşımaktadır. Bunların başında akıllı sözleşmeler yer almaktadır (Metin, Bilgi Yönetimi ve Blokzinciri Teknolojisi, 2021, s. 102-105).

Rus-Kanada asıllı Vitalik Buterin, Bitcoin'in daha geniş bir uygulama tasarımına sahip olabileceğini düşünerek 2014 yılında Etheryum'u oluşturma çalışmalarına başlamıştır. Etheryum ağı dağıtılmış defter olarak adlandırılmıştır. Ağın bir merkezi işleteni olmaması ve yönetilmemesinden dolayı, dağıtılmış defter sahiplerinin yönetiminde olması nedeniyle merkezi olmayan bir sistemdir. Etheryum'u benzersiz kılan geliştiricilere blok zinciri üzerinde çalışan bir uygulama platformu sunmasıdır. Bir yazılım geliştirme ortamı gibi düşünülebilir. Oluşturulacak uygulamalar karışık finansal işlemleri yönetebilir, kişisel verileri aktarabilir ve depolayabilir niteliktedir (Pulat, 2018).

1.6.1. Etheryum Avantajları

En yaygın olarak bilinen Etheryum avantajları;

- Denenmiş ve doğrulanmış bir ağ kullanılıyor olması,
- Geniş kullanım alanına sahip olması,
- Kripto para olarak kullanılabilmesi,
- Finansal işlem türlerini işleyebilmesi,
- Akıllı sözleşmeler oluşturabilmesi ve yürütebilmesi,
- Veri depolayabilmesi,
- Sürekli yenilenebilir olması,
- Üçüncü tarafları absorbe edebilmesi,
- Arzının her yıl arttırılabilmesi,

şeklinde sıralanabilir (Pulat, 2018).

1.6.2. Ethersum Dezavantajları

Avantajları olduđu kadar dezavantajlara da sahip olan Ethersum' un en yaygın dezavantajları řu řekilde sıralanabilir;

- İşlem masrafları artış göstermektedir,
- Enflasyon baskısı altındadır,
- Öğrenme eğrisi diktir,
- Geleceđi belirsizdir,
- Ağın genişliđi sebebi ile güncelleme işlemlerinde sorun yaratma potansiyeline sahiptir (Pulat, 2018).

1.7. KRİPTO PARA TEKNOLOJİLERİNİN GÜVENLİĞİ VE SUÇ İLİŞKİSİ

Deđişen dünyada blok zinciri teknolojisi ile beraber ödeme sistemleri de gelişmiştir. Dijital para teknolojilerinin günümüzde yeri ve önemi git gide artmaktadır. Günden güne büyüyen bu teknolojinin güvenliđi ve daha kontrollü bir sistemle ilerleyebilmesi için ülkeler çeşitli çalışmalar yapmaktadır. Ülkemizde de bu konuda öncü olan TÜBİTAK Ar-Ge faaliyetlerini sürdürmek üzere, BİLGEM UEKAE Matematiksel ve Hesaplamalı Bilimler Biriminin altında Blok Zinciri Araştırma Laboratuvarı (BCLabs) kurulmuştur. BİLGEM, akademisyenlerin desteklerini de alarak, kamu ve özel kurum/ kuruluşlar ile her türlü sanal işlemi sadeleştirerek ve güvenli yapıda ağlar kurulması üzerine çalışmaktadır. BİLGEM' in gerçekleştirmeye çalıştığı amacı, uzman ekipleri bir araya getirerek işletmelerin blok zinciri teknolojisini hayata geçirme sürecini geliştirmektir. Ayrıca gizlilik ve güvenlik analizi ile izlenebilirlik gibi farklı çözümleri araştırmaktır (Tübitak Bilgem Uekae, 2018).

Bu birim ayrıca blok zincir ve dijital para teknolojilerinin güvenlik analizini de yaparak Bitcoin' in güvenliğini de araştıracaklardır. Bunun için düzenlenmekte olan etkinliklerin başında 2018 tarihinde 1. Ulusal Blok Zincir Çalıştayı ve 2019 yılında düzenlenen 2. Ulusal Blok Zincir Çalıştayı yer almaktadır (Tübitak Bilgem Uekae, 2018). Kripto para suçlarının ortaya çıkma oranı ile kullanım popürlüğünün artması birbirleri ile korelasyon kat sayıları pozitif olarak görölmektedir. Kripto paralar hakkında yeterli bilgi sahibi olmayan güvensiz platformlara yüksek kazanç

elde etmek amaçlı yatırım yapanların sayısı git gide artmaktadır. Kripto para piyasasını takip edenlerin almaları gereken önlemler, kişisel güvenliklerinin yeterince sağlanması için anti-virüs programlarının kullanılması ve şifrelerinin daha güvenilir ortamlarda depolanmasıdır. Ülkemizde Goldex.co, Vebitcoin ve Thodex gibi nitelikli dolandırıcılık olaylarının yüz binlerce kişiyi etkilediği ve geriye milyarlarca liralık kayıp bıraktığı göz önünde bulundurulursa, kripto para konusunda toplumun bilinçlendirilmesi büyük önem taşımaktadır. Kripto para borsalarının toplumda güven kazanma konusuna destek olabilmesi için bu hususta yapılacak güvenlik araştırmalarının yanı sıra, toplumu ve kullanıcıları bilinçlendirme çalışmalarının da ülkemize her açıdan katkısı büyük olacaktır (My Security Analytics, 2021).

1.8. KRİPTO PARA DOLANDIRICILIK YÖNTEMLERİ

Kripto para transferlerinde bir cüzdandan diğerine aktarılan paraların geri döndürülmesi olanaksız görülmektedir. Transferi gerçekleşen paraların adres takibi gerçekleştirilememesi sebebiyle kripto paralarda dolandırıcılık işlemlerini çok daha çekici kılmıştır. Bu işlemler arasında en yaygın kripto para yöntemleri;

- Sahte Borsalar,
- Sahte Hediyeler,
- Sosyal Medya Oltalaması,
- Kopyala Yapıştır Zararlı Yazılımı,
- Oltalama E-Postaları,
- Ponzi ve Piramit Düzenleri,
- Fidyeye Yazılımı,

şeklinde sıralanabilir (Metin, Bilgi Yönetimi ve Blokzinciri Teknolojisi, 2021, s. 123-127).

1.9. KRİZ VE KRİZ YÖNETİMİ


Kriz, küreselleşen dünyada farklı tanım ve yaklaşımlar çerçevesinde, işletmelerin hiç beklenmedik bir anda karşı karşıya kaldığı, işletmenin hayatını ve itibarını tehdit eden, imaj zedelenmesine sebep olan, acil ve önemli bir karar verilmesini gerektiren, uyum ve önlem çalışmalarını yetersiz kılan, farklı karar destek yöntemlerine ihtiyaç duyulan bir gerilim durumu olarak tanımlanabilmektedir. Modern dünyada kriz kavramına online krizler de eklendiği için işletme, kurum ve kuruluşların kriz ve kriz yönetimine bakış açıları da farklılaşma göstermektedir. Günümüzde işletmeler paydaş ve tüketicileri ile daha sağlıklı ve verimli iletişim kurabilmek için 7/ 24 online iletişim halinde olmayı tercih etmektedirler. Bu seçim anında geri bildirim kazanarak hem verimliliği artırmak amaçlı hem de kriz anlarında yönetimi kolaylaştırmak amaçlı tercih edilmektedir (Okkay, 2019).

Kriz yönetimi, kriz anlarının önceden tahmin edilerek belirlenmesini ve herhangi bir kriz döneminde alınacak kararların kararlaştırılması hakkında gerçekleşen yönetim süreçleridir. İşletmelerde bu gibi olağanüstü durumlar için karar destek sistemleri çok önemli bir rol oynamaktadır. Karar destek sistemleri olası bir kriz halinde işletmelerin bu süreci başarılı bir şekilde yönetebilmeleri için alanında bilgili ve yetenekli uzman kişilerden oluşmalıdır. Gerekli altyapı ve kaynağı ayırmaları, donanımsal açıdan her zaman hazır olmaları ve kriz sürecinden en az zararla çıkılabilmesi için işletmede alınacak kararlara destek olmalıdırlar. Krizlerin oluşum zamanının, süreç ve sonuçlarının yaratacağı etkilerinin tahmin edilmesi oldukça güç olduğu için işletmeler, kurum/ kuruluşlar ve devletler için krizler büyük önem taşımaktadır. Özellikle ekonomik krizlerin oluşumunda, finansal alanda talep daralmaları, arz fazlaları, doğal afetler, pandemi, istikrarsız politikalar, siyasal bunalımlar, düzenleme ve denetleme eksiklikleri, askeri müdahaleler, hızla gelişen teknolojiye ayak uyduramamak gibi unsurlar başlıca nedenler olarak gösterilebilir. Her bir kriz yaşanan olumsuzlukların yanında mutlaka bir fırsat niteliği de taşımaktadır. Bu durumun iyi analiz edilip işletme sistemine katılması işletmenin ayakta kalabilmek ve uzun vadeli planlar yapabilmesi için oldukça önemli ve uzmanlık isteyen bir bakış açısı gerektirmektedir (Okkay, 2019).

1.9.1 Kriz Yönetim Süreci

Krizler uygun stratejilerle yönetilebilen süreçlerdir. Yönetim süreçlerine üç ana strateji ile yaklaşılmaktadır. Bunlar, Proaktif Kriz Yönetimi, Reaktif Kriz Yönetimi ve İnteraktif Kriz Yönetimleri'dir (Uyan, 2016). Kriz yönetim süreci Şekil 1. 5'de gösterildiği gibi ifade edilebilmektedir. Şekilde Proaktif kriz yönetimi, krizlerin henüz oluşmadan önce engellenebilmesi için yapılan hazırlık aşaması olarak görülmektedir. Reaktif kriz yönetimi, krizin başlamasıyla birlikte yapılabilecek çalışmalara odaklanan aşama olarak görülmektedir. İnteraktif kriz yönetimi ise kriz oluşmamışken ya da kriz tecrübesi edinildikten sonra sürekli halde planların tüm evrelerini takip eden öğretme odaklı bir aşama olarak görülmektedir (Uyan, 2016).

Şekil 1. 5: Kriz Yönetim Süreci



Kaynak: (Uyan, 2016)

1.9.2 Kripto Para ve Kriz Yönetimi İlişkisi

Kriz yönetimlerinin temel amacı örgütü krize hazırlamaktır. Günümüze kadar yaşanan tüm krizler ve yaşanacak olası krizler için tahmin çalışmaları yapmak kaçınılmaz hale gelmiştir. Özellikle finansal krizlerin önüne geçilebilmek ya da en az hasarla atlatılabilmesi için özel ve tüzel kişiler, kamu ve kuruluşlar, devlet yetkilileri gerekli önlem çalışmaları kapsamında bilimsel tahmin yöntemlerine de yer vermektedirler. Bu çalışmaların özellikle kriz dönemlerini fırsata çevirebilmek adına büyük önem taşıdığı düşünülmektedir. Dünyada ve ülkemizde oluşan her bir yeni kriz bir sonraki oluşacak krizlerde hem öngörülü davranabilme hem de en az hasarla atlatabilme fırsatı sağlar. Ayrıca o an yaşanan kriz durumunda veya bir sonraki krizi fırsata çevirebilmekte değerli bir referans niteliği taşımaktadır. Özellikle kripto para piyasalarında son dönemlerde yaşanan krizler milyarlarca lira mali kayıplara sebebiyet vermiştir. Bu açıdan sistem ağının güvenliğinin önemi kadar takip edilebilirliği ve tahmin edilebilirliği de büyük önem taşımaktadır. Kripto para piyasalarında yaşanan ve yaşanacak krizlere ışık tutma niteliğinde yapılan kripto para fiyat ve işlem hacmi tahminleri bu anlamdaki açığı doldurabilmek adına yardımcı olabilmektedir. Son dönemlerde kripto paraların çok fazla kullanım alanı ve yatırım seçeneği olarak tercih edilmesi de bu önemi arttırmaktadır. Yatırımcılar için çok büyük bir finansal kaynak ve nakit akışı sağlayan bir sistem olarak görülse de, kripto para dünyası üzerinde hep bir gizem taşımaktadır. Kimi ülkeler para birimi haline getirecek kadar önem gösterirken, bazı ülkeler de risk boyutlarını göze alamadığı için hala kripto para kullanmaya sıcak bakmamaktadırlar. Bu konuda doğru zamanda ve uzman ekiplerle doğru kararı almak örgüt iklimi ve ömrü açısından büyük önem taşımaktadır.

1.10. LİTERATÜR ÇALIŞMASI

Tez çalışmasının bu bölümünde tarih sırasına göre kripto para fiyat tahmini ile ilgili yapılmış çalışmalara yer verilmiştir. Farklı yapay zekâ teknikleri kullanılarak yapılmış olan bu çalışmalarda kullanılan metotlar ve sonuçları ele alınmıştır.

Shah ve Zhang (2014), Bitcoin fiyat tahminini gerçekleştirmek için Bayes Regresyonunu (BR) kullanarak Bitcoin yatırımlarını kısa sürede katlayabileceklerini

önermiştir (Shah, 2014).

Yang ve Kim (2015), Bitcoin fiyat değişimi ile işlem akışını karşılaştırarak, piyasa değişimi ile Bitcoin işlem ağı karmaşıklığı arasında bir ilişki olduğu sonucunu elde etmiştir (Yang, 2015).

Matta vd. (2015), Google Trends ve sosyal medyada oluşturulan tweet verileri arasında bir ilişki olup olmadığını araştırmıştır. Araştırmada sonuç olarak Google Trends verileri ile Bitcoin fiyat değişimi arasında anlamlı bir ilişki olduğu tespit edilmiştir (Matta, 2015).

Atlan vd. (2018), çalışmalarında BTC nin Türk Lirası değerinden yapay zekâ yöntemlerinden olan polinomsal eğri uydurma ve ANSİF yöntemi ile tahmini gerçekleştirilmiş olup; sonucunda elde edilen en başarılı sonucun ANSİF yöntemi ile elde edildiği ortaya konmuştur (Atlan & vd., 2018).

Jang ve Lee (2018), çalışmalarında blok zinciri ve Bayes sinir ağı (BNN) modelini kullanarak BTC' nin fiyat zaman serisi analizini ve piyasa belirsizlik halinin yükselme nedenini açıklamada birçok yönteme kıyasla daha başarılı bir sonuca ulaşıldığını göstermiştir (Jang, 2018).

Şahin ve Özkan (2018), bu projede 2015 ve 2018 yılları arasında dolar cinsinden olmak üzere Bitcoin' in günlük kapanış değerlerini tahmin işlemini gerçekleştirmeye çalışmışlardır. Çalışmanın sonucunda Eşik Oto Regresyon Koşullu Varyans (TARCH) kullanılan en iyi sonucu veren model olarak sunulmuştur (Şahin, 2018).

Gullapalli (2018), BTC günlük açılış ve kapanış değerlerinin günlük fiyat değişiminin tahmin edilmesinde etkili bir rol oynadığını öne sürmüştür. Çalışmada RNN, YSA ve zaman gecikmeli sinir ağlarını (TDNN) kullanarak, Bitcoin fiyat tahminini en iyi yapan yöntemin TDNN (Time Delay Neural Network) olduğunu göstermiştir (Gullapalli, 2018).

Spilak (2018), derin öğrenme, makine öğrenmesi ve LSTM algoritmalarını kullanarak kripto döviz piyasasında yer alan şifreleme metodolojisinin yönünü tahmin etmek üzere çalışmıştır. Sonuç olarak LSTM' nin tahmine dayalı en güçlü ve yüksek güvenilirlikli model olduğunu ortaya koymuştur (Spilak, 2018).

Şahin (2018), çalışmasında ARİMA ve yapay sinir ağları modeli ile veri olarak 2012-2018 tarihleri arasında BTC kapanış fiyatlarının sadece zamana bağlı

tahmin edilip edilemeyeceği test edilmiştir. Sonuç olarak yapay sinir ağları ile tahmin edilen fiyatlar, gerçek fiyatlara yakın bulunmuştur (Şahin E. E., 2018).

Polat ve Akbıyık (2019), Granger Nedensellik analizini kullanarak sosyal medyadaki Twitter yorumları ile Bitcoin fiyatları arasında oluşan olumlu-olumsuz ilişkiyi metin madenciliği yöntemi kullanarak incelemiştir. Çalışmasının sonucunda BTC fiyatlarının Twitter yorumlarının Granger nedeni olduğunu gösterirken, Twitter yorumlarının BTC fiyatının Granger nedeni olmadığını ifade etmiştir (Polat & Akbıyık, 2019).

Çılgın vd. (2020), çalışmalarında Twitter platformu üzerinden elde edilen tweetler bazında, Bitcoin fiyatı ile etkileşimini ortaya koymuştur. Bunun için 06.10.2018-19.05.2019 tarihleri arasında Twitter kullanıcıları tarafından oluşturulan toplam 2.819.784 tweet üzerinden bir makine öğrenmesi yöntemi olan sınıflandırma algoritmalarını kullanarak analizler gerçekleştirmişlerdir. Sonuç olarak metin sınıflandırma çalışmasında en yüksek doğruluk oranı olan % 90 ile yapay sinir ağları kullanılmıştır. Ayrıca sınıflandırılmış olumlu/olumsuz tweet oranları ile Bitcoin fiyatları arasında ikili korelasyon yapılmıştır. Elde edilen 0,681 korelasyon katsayısı ile pozitif yönde orta üstü kuvvetli ilişki tespit edilmiştir (Çılgın, Ünal, Alıcı, Akkol, & Gökşen, 2020).

Çağlar ve Yavuz (2021), çalışmalarında yapay sinir ağlarıyla oluşturulan modellerden ileri beslemeli çok katmanlı mimari içerisinde Geri Yayılımlı (Back Propagation) Levenberg-Marquardt (LM) öğrenme algoritması yardımıyla gazete haberlerinin Bitcoin fiyatlarına olan etkisinin tahmin işleminin gerçekleştirilmesini amaçlamışlardır. Çalışmada finansal gazetelerde yayınlanan Bitcoin konulu haberlerin, Bitcoin fiyat tahminine güçlü bir etkisinin olup olmadığı araştırılmış ve güçlü bir etkiye varılmamıştır (Çağlar & Yavuz, 2021).

Tanışman vd. (2021), çalışmalarında çok değişkenli LSTM sinir ağı ve klasik ARIMA zaman serisi modelini kullanarak Bitcoin gelecek zaman fiyat değerinin tahmini için çalışmışlardır. Performans değerlendirme metrikleri olan hata metrikleri kullanılarak uygulanan iki modelin tahmin doğruluğu karşılaştırılmıştır. Sonuç olarak tahmin performanslarında LSTM sinir ağı modeli hem yakın hem uzak gelecek tahmini için de düşük hata oranı ile, ARIMA zaman serisi modeli ise sadece yakın

gelecek tahmini için düşük hata oranı ile tahmin performansı gerçekleştirmiştir (Tanışman, Karcioğlu, Uğur, & Bulut, 2021)

Afteniy (2021), çalışmasında Bitcoin fiyat tahmininde zaman serisi analizi yaparak LSTM ve TRANSFORMER yöntemlerini kullanarak karşılaştırma yapmıştır. Sonuç olarak TRANSFORMER yönteminin sunduğu değer LSTM yöntemine göre daha yüksek yakınlık payına sahip bulunmuştur (Afteniy, 2021).

Bu tez çalışmasında literatürden farklı olarak, kriz dönemlerinde farklı amaç ve altyapıya sahip kripto paraların endeks tahmini yapılmıştır. Kripto paraların tahmini işlemi farklı yapay zekâ yöntemleri kullanılarak performans sonuçları karşılaştırılmıştır. Çalışmada yapay zekâ yöntemlerinden makine öğrenmesi olarak YSA, derin öğrenme olarak ise LSTM ve GRU modelleri kullanılmıştır. Veri seti Python programlama dili ile birlikte Keras, Tensorflow, Numpy, Pandas, Mathplotlib gibi open lisans paketlerden yararlanılarak, kullanılacak modele göre işleminden geçirilip, eğitim, geçerlilik ve test olarak bölümlene işlemi yapılmıştır. Uygulamada zaman serilerinden yararlanılmıştır. Çalışmanın sonuç bölümünde elde edilen değerler; eğitim ve test performansları, modelleri, ağ mimarileri ve kripto para çeşidine göre tablolar halinde karşılaştırılmıştır. Çalışmada, kriz dönemlerinde aşırı dalgalanmalar karşısında yatırımcının karar vermesinde destek olunması amaçlanmıştır. Literatürde bu konuda ilk olma özelliğine sahiptir.

İKİNCİ BÖLÜM

MATERYAL VE METOT

Bu çalışmada dünya genelinde öncü olarak kabul edilen kripto para birimleri olan Bitcoin ve Ethereum' un dolar (\$) cinsinden endeks tahmini yapılmıştır. Çalışmanın amacı kriz dönemlerinde kripto para fiyat tahminin yapılması ve farklı amaçlar için kullanılan kripto varlıklara yatırım yapan kurumsal ve bireysel yatırımcılara karar destek sistemi sağlayabilmesidir. Elde edilen sonuçların ileriki tarihlerde yaşanacak kriz dönemlerinde benzer çalışmalara örnek teşkil edebilmesi açısından önem taşımaktadır. Çalışmada dünyada 2016 yılı sonlarında başlayan ekonomik krizler ve sonrasında 2019 yılında ortaya çıkan ve büyük olumsuzluklara sebep olan Covid-19 pandemi krizi ile 2022 yılı Rusya-Ukrayna savaşı gibi olumsuzluklar etkisinde kripto para fiyat tahmini yapılmıştır. Bu nedenle Bitcoin ve Ethereum veri setleri 2016-2022 tarih aralığını kapsamaktadır. Elde edilen veri setleri yapay zekâ teknolojilerinden, üç katmanlı ileri beslemeli geri yayımlı yapay sinir ağı (YSA) ile uzun kısa süreli bellek (LSTM- Long Short Term Memory) ve geçişli tekrarlayan ünite (GRU- Gated Recurrent Unit) derin öğrenme algoritmaları kullanılmıştır. Bu algoritmaların farklı ağ mimarileri ve hiper parametreleri ile eğitim işlemi tekrarlanıp, eğitim ve test performans sonuçları karşılaştırılmıştır.

2.1. YAPAY ZEKÂ TEKNOLOJİSİ

Literatürde teknolojinin gelişmesiyle birlikte tanımı farklılık gösteren yapay zekâ, verilere veya çevresindeki olaylara bakarak öğrenme ve problem çözme yeteneğine sahip sistemler olarak tanımlanabilmektedir. Akıllı sistemler olarak da adlandırılan bu teknoloji, olayları/durumları değerlendirerek sonuç üretme ve karar verme yeteneğine sahiptir. Bu sistemler matematiksel olarak çözülemeyen problemleri sezgisel yöntemler yolu ile çözebilmektedirler. Günümüz dünyasında bilgisayar ve sistemleri bilgi toplumu için son derece önem taşımaktadır. Günlük kullanılan sıradan eşyalar da akıllı sistemlere sahip olmaya başlamıştır. Kamu,


sağlık, askeri, eğitim, turizm organizasyonlarından uzay bilimlerine kadar hemen her alanda akıllı sistemler olmazsa olmaz hale gelmiştir. Günlük olaylarda karşılaşılan problemler sürekli değişmekte ve karmaşılaşmaktadır. Bu karmaşık problemlerin çözümü için farklı yöntemler denenmektedir. Akıllı sistemlerin insanların problem çözme ve karar verme yöntemlerini taklit etmesi ve öğrenmesi her geçen gün farklı teknolojilerin ortaya çıkmasına yol açmaktadır. Bunlar arasında günümüzde onlarca yapay zekâ teknolojisinden bahsedilebilir (Öztemel, 2016, s. 15).

Temel olarak bilinen yapay zekâ teknolojileri maddeler halinde;

- Uzman Sistemler,
- Makine Öğrenmesi,
- Yapay Sinir Ağları,
- Derin Öğrenme,
- Genetik Algoritmalar,
- Bulanık Önergeler Mantığı,
- Zeki Etmenler,
- Örüntü Tanıma,

şeklinde sıralanabilir (Öztemel, 2016). Yapay zekâ teknolojisinin kapsadığı alanları sıralayan hiyerarşi Şekil 2. 1’de gösterilmiştir.

Şekil 2. 1: Yapay Zekâ Hiyerarşisi




Kaynak: (Çağlar & Yavuz, 2021)

2.2. YAPAY SİNİR AĞLARI


Yapay zekâ hiyerarşisinde yapay sinir ağılar makine öğrenmesinin içinde yer almaktadır. İlk yapay sinir ağı (YSA) modeli 1943 yılında Warren McCulloch ile Walter Pitts tarafından tasarlanmıştır (Çağlar & Yavuz, 2021). YSA modeli insan beyninin biyolojik fonksiyonlarından ilham alınarak tasarlanmıştır. Tahmin temelli bir model olup, onu diğer tahmin modellerinden ayıran en önemli farkı, ara katmanda bulunan toplam ve transfer fonksiyonu çalıştıran doğrusal olmayan bir modeldir. İnsan beyninin biyolojik yapısından esinlenerek tasarlandığından, yapay sinir ağlarını anlamak için önce biyolojik sinir sistemini anlamak gerekmektedir. Sinirler vücudumuzun en karmaşık sistemi olarak bilinmektedir. Çevreden bilgiyi alır, işler, yorumlar ve sonunda karar üretir. Birbirine bağlı nöronlardan oluşan biyolojik sinir ağlarının yapı taşları Şekil 2. 2’ de görüldüğü gibi hücre çekirdeği, dendrit, soma ve aksonlardan meydana gelmektedir. Yapay sinir ağlarının temel elemanları da nöron ya da düğüm olarak isimlendirilmektedir (Çağlar & Yavuz, 2021). Biyolojik ve yapay sinir ağı görselleri arasındaki benzerlik Şekil 2. 2 ve Şekil 2. 3’de gösterilmiştir.

Şekil 2. 2: Biyolojik Sinir Ağı



Kaynak: (Uludağ Sözlük Galeri, 2022)

Şekil 2. 3: Bir Dügümlük Yapay Sinir Ağı



Kaynak: (Jaquart, Dann, & Weinhardt, 2021)

2.3.YAPAY SİNİR AĞI ELEMANLARI ve ÇALIŞMA ALGORİTMASI

Bir yapay sinir ağı hücresi beş bölümden oluşur.

- Girdiler ($x_1, x_2, x_3 \dots x_n$)
- Ağırlıklar ($w_1, w_2, w_3 \dots w_n$)
- Birleştirme Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktılar (y) (Jaquart, Dann, & Weinhardt, 2021)

2.3.1. Girdiler

Girdi katmanını dışarıdan gelen bilgileri toplar, herhangi bir işlem yapmadan bir sonraki katmana aktarım yapar. Giriş katmanını düğüm sayısı veri seti nitelik sayısına bağlıdır. Nitelik sayısı ne kadar ise giriş katman düğüm sayısı o kadar olmalıdır. Örneğin veri setinin beş özelliği (nitelik) varsa giriş katman düğüm sayısı beş olmalıdır.

2.3.2. Ağırlıklar

Ağırlıklar, katmanlar arası bağlantılar ile temsil edilir. Hücreye gelen bilginin etkisini ve önemini ortaya koyar. Pozitif veya negatif olma durumları vardır. Dışarıdan gelen girdiler ağırlıkları ile hücreye bağlanır. Bir düğümün çıktı değerinin

hesaplanması için kullanılır (Formül 1). Net girdi değeri hesaplanarak aktivasyon fonksiyonundan geçirilerek belirli bir aralıkta çıktı elde edilir. Ağırlıkları sabit değildir. Aslında ağın eğitime uygun çıktıyı verecek ağırlık değerlerinin optimizasyonu işlemidir. Ağın çıktısı ile beklenen değer arasındaki hata miktarı minimize edilmiş ise ağ eğitilmiş anlamına gelecektir. Bu hata miktarı belirli bir değer üzerinde ise ağın eğitimi için ağırlıklar değiştirilmeye devam edilir. Başka bir deyişle ağın eğitilmesine devam edilir.

2.3.3. Birleştirme Fonksiyonu

Yapay sinir ağlarının bu bölümünde girdilerin ağırlıklarla çarpılması işlemi gerçekleştirilir. Yapılan çarpım işlemi neticesinde Net Değer hesaplanır. Birleştirme fonksiyonunda bu değeri hesaplamak için farklı yöntemler vardır. Bunlardan en sık kullanılanı Formül (1)'de gösterilen toplama fonksiyonudur. Bu fonksiyon bir düğüme gelen girdi değerleri ile ağırlık değerlerini çarpımlarının toplamı şeklindedir.

$$NetDeğer = \sum_{i=1}^n x_i w_i \quad (1)$$

2.3.4. Aktivasyon Fonksiyonu

Düğüm çıkışı net değeri formül (1)'deki gibi olduğundan düğüm çıkışı çok büyük veya çok küçük değerler olabilir. Düğüm çıkışı bir aktivasyon fonksiyonundan geçirilerek belirli aralığa çekilir. Ayrıca çok küçük veya gürültü sinyallerini (belirli eşik altındaki) elimine etmek için de aktivasyon fonksiyonu kullanılır. Aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen Net Değeri belirli aralıkta bir çıktıya dönüştürür. Literatürde yaygın olarak; Doğrusal, Adım, ReLU, Sigmoid, Hiperbolik Tanjant, vb. aktivasyon fonksiyonları kullanılmaktadır. YSA' da gizli ve çıkış katmanları düğümlerinin hepsi aynı aktivasyon fonksiyonu kullanmak zorunda değildir. Farklı katmanlardaki düğümlerde farklı aktivasyon fonksiyonları kullanılabilir. Ne tür aktivasyon fonksiyonunun kullanılacağı problemin özelliğine göre farklılık arz eder. Dolayısıyla probleme göre hangi aktivasyon fonksiyonu kullanılacağı araştırma yapanların tecrübe edebileceği bir durumdur. Bu nedenle aktivasyon fonksiyonu seçimi YSA hiper parametrelerindendir. Problem farklı aktivasyon fonksiyonları ile eğitilerek ağın performansını artırılabilir.

2.3.5. Çıktılar

Çıktı katmanı, ağ girişinde alınan verilerin ara katmanlarda işlenerek bilgiye dönüştüğü ve bu verilerin son geçiş katmanıdır. Çıktılar, yapay sinir ağlarında bilginin üretildiği bölümdür. Bu katman düğüm sayısı ağdan elde edilen sonucu gerçek dünyada yorumlanabilecek boyutta olmalıdır. Örneğin çıktı olarak 20 x 20 pixel çözünürlükte bir resim elde edilecek ise $20 \times 20 = 400$ pixel çözünürlük için 400 adet çıkış düğümü kullanılmalıdır. Eğer çıktı olarak bir fiyat bilgi olacak ise bu durumda bir düğüm yeterli olacaktır. Eğer Doğru/ Yanlış, Erkek/ Kadın, Hasta/ Değil gibi bir çıktı olacak olursa bir veya iki adet çıkış düğümü kullanılabilir.

2.3.6. Yapay Sinir Ağı Çalışma Algoritması

Yapay sinir ağlarının bir çalışma algoritması vardır. Bunlar sırasıyla;

- 1-Problemin belirlenmesi,
- 2- Değişkenlerin belirlenmesi,
- 3- Verilerin hazırlanması,
- 4- Verilerin ön işleme tabi tutulması,
- 5- Ağ tasarımının yapılması,
- 6- Ağı eğitilmesi,
- 7- Ağı geçerlilik düzeyine bakılıp hata tespit çalışmasının yapılmasıdır,
- 8-Ağdan beklenen sonuçlar alınmaya başlandığında, test verileri ağı sunularak çözüm üretmesi beklenir, şeklinde söylenebilir (Çakır, 2019).

Uygulanan YSA modelinin genel karakteristik özelliklerine göre gerçekleştirilen temel işlemler vardır. Bunlar arasında;

- Makine öğrenmesi gerçekleştirirler,
- Bilinen yöntemlerden farklı programlama yöntemleri vardır,
- Bilgilerin saklanması konusunda oldukça güvenlidir,
- Örnekleri kullanarak öğrenirler,
- Güvenle çalışması eğitimlerinin ve performanslarının test edilmesine bağlıdır,
- Yeni örneklerle bilgi üretebilirler,
- Olayları algılamaya yöneliktirler,
- Örüntü ilişkilendirme ve sınıflandırma yapabilmektedirler,
- Kendi kendine öğrenme ve organize etme gücüne sahiptirler,

- Eksik bilgi ile de çalışmaları mümkündür,
- Hata payına sahiptirler,
- Hücreleri göreceli olarak bozulma gösterebilmektedir,
- Sadece sayısal bilgiler ile çalışabilmektedirler,

şeklinde sıralanabilir (Öztemel, 2016).

2.4. MAKİNE ÖĞRENME ALGORİTMALARI

Makine öğrenmesi; geçmiş verileri ve/veya sensörlerden aldığı verileri girdi olarak alıp uygun çıktıyı üretebilecek parametrelerin belirlenmesi sürecidir. Öğrenen bir sistem; beklenmedik, daha önce karşılaşmadığı durumlara, koşullara, verilere karşı uygun davranışlarda çıktı üretebilme kabiliyetine sahip olmalıdır. Yapay sinir ağlarında öğrenme algoritmaları arasında temel olarak üç tür öğrenme modeli vardır. Bunlar;


- Denetimli Makine Öğrenmesi,
- Denetimsiz Makine Öğrenmesi,
- Pekiştirmeli Makine Öğrenmesi,

temel modeller olarak bilinmektedir.

2.4.1. Denetimli Öğrenme

Sistemden elde edilen çıktıların karşılaştırılabileceği bilinen bir değer (label) ile karşılaştırılarak, elde edilen farkı (hata) azaltacak yönde sistem parametrelerinin değerlerini değiştirerek öğrenme gerçekleştirir. Regresyon, sınıflandırma, zaman serisi gibi problemlerde kullanılmaktadır. Sahtekârlık tespiti, spam mail belirleme, piyasa tahmini, hastalık tespiti, fiyat tahmini, zaman serileri gibi örnekler verilebilir. Şekil 2. 4’de denetimli makine öğrenmesi çalışma algoritması örneği gösterilmiştir. Şekle göre geçmiş veri veya sensörlerden aldığı verileri girdi olarak alıp, uygun çıktıyı üretebilecek parametrelerin belirlenmesi/optimizasyonu süreci ifade edilmektedir.

Şekil 2. 4: Denetimli Makine Öğrenmesi Algoritması



Denetimli öğrenme modelinde makine öğrenme yöntemi olarak;


- Regresyon Analizi,
- Karar Ağacı,
- Rastgele Orman,
- Destek Vektör Makineleri,
- Naive Bayes Sınıflandırma Algoritması,
- Yapay Sinir Ağları

gibi algoritmalar kullanılabilir.

2.4.2. Denetimsiz Öğrenme

Denetimsiz öğrenme modeline herhangi bir öğretici, çıktılarını karşılaştırabileceği bir etiket yoktur. Veriler arasındaki farklılıklara, benzerliklere, mesafelere vb. göre ilişkilendirerek öğrenme işlemi gerçekleştirilir. Veri seti sadece girdi (x_i) verilerinden oluşur. Bu tür öğrenme kümeleme, örüntü tanıma, ilişkilendirme, tavsiye sistemleri, boyut indirgeme gibi problemlerde kullanılmaktadır. Şekil 2. 5’de denetimsiz makine öğrenmesi algoritması örneği gösterilmiştir.

Şekil 2. 5:Denetimsiz Makine Öğrenmesi Algoritması



Denetimsiz öğrenme modelinde makine öğrenme yöntemi olarak;


- K- Means Kümeleme,
- Prensipte Bileşen Analizi,
- Gizli Markov Modeli,
- Yapay Sinir Ağı,

gibi yöntemler kullanılabilir.

2.4.3. Pekiştirmeli Öğrenme

Bu tür öğrenme yöntemi çevreyi gözleyip, buna göre tecrübe edip, elde ettiği tecrübelerle göre kendini yeni durumlara adapte ederek kendi kendine öğrenir. Bir çocuğun yürümeyi öğrenmesi gibi düşünülebilir. Bu yöntemde öğrenme işlemi ödül ve ceza sistemine dayanır. Olumlu hareketler ödüllendirilirken, olumsuz hareketler ise cezalandırılır (negatif ödül). Bu şekilde sistem sürekli hatalarından ders alıp kendisine (öğrenme parametreleri) düzeltme yaparak öğrenme gerçekleşir. Pekiştirmeli öğrenmede her girdi değerine karşılık bir etiket verilmez. Sistemden bu girdilere karşılık çıktıları sistemin kendisinin üretmesi istenir.

Şekil 2. 6: Pekiştirmeli Makine Öğrenme Algoritması



Şekil 2. 6’da görüldüğü üzere bu tür algoritmalarda bir keşif söz konusudur. Burada bir ajan (agent) ve bir çevre (environement) vardır. Ajan temel olarak bu ortam hakkında gözlemde bulunur ve aksiyon gerçekleştirir. Çevre ajana geri dönüt olarak ödül verir. Eylemler oluşturarak çevresi ile birlikte etkileşime girer ve sonuçları gözlemler. Tekrar eden eylemleri meydana getirirken bu sonuçları dikkate alır. Süreç içinde algoritma gelişip doğru seçimi yapana kadar süreç devam eder. Bu süreçte ajan için amaç ödülü maksimum sayıya getirmektir. Pekiştirmeli öğrenme uygulaması olarak bir robotun bisiklet sürmeyi öğrenmesi, satranç ve GO oynayan bilgisayar programı, robot köpek, robot asker gibi örnekler verilebilir. Pekiştirmeli öğrenme modelinde makine öğrenme algoritmaları olarak;


- Q-Öğrenme,
- Tompson Örnekleme,
- Monte Carlo Ağaç Arama
- Yapay Sinir Ağı (YSA)
- Derin Öğrenme

gibi algoritmalar kullanılabilir.

2. 5. TEKRARLAYAN (YİNELENEN) SİNİR AĞLARI (RNN-RECURRENT NEURAL NETWORKS)

1980' lerde basit tekrarlayan sinir ağı olarak ortaya atılan fikir, 1990' larda Jeff Elman tarafından RNN fikri öne sürülmüştür (Elman, 1993). RNN' lerin tekrarlayan olarak adlandırılmasının sebebi sıralı bilgileri kullanıyor olmasıdır. Yani dizideki her öğenin önceki çıktıya göre aynı görevi yerine getirmesidir. RNN' lerde temel düşünce ve amaç ardışık bilgileri kullanabilmektir. Bu ağı yapı olarak bir giriş katmanı, iki gizli katman ve bir çıkış katmanından oluşmaktadır (Elman, 1993). RNN modelleri genellikle konuşma tanıma, doğal dil işleme gibi sıralı veriye sahip problemlerin modellenmesinde kullanılır. Klasik yapay sinir ağlarında bir önceki çıktıyla girdiler arasında bir ilişkilendirme yapılamazken, RNN' lerde ise bir ilişkilendirme söz konusudur. Kendi içlerinde bir döngüye sahiptirler. Çift yönlü RNN' ler, üst üste istiflenmiş iki RNN olup, çıktıların kendinden sonra gelen hücrelere de bağlı olabileceği fikrini taşırlar. Derin RNN' ler ise birkaç katmandan oluşur ve bu da daha fazla öğrenme kapasitesi sunar (stanford.edu, 2019). RNN mimarisi örneği Şekil 2. 7'de gösterilmiştir.

Şekil 2. 7: RNN Mimarisi



Kaynak: (Jaquart, Dann, & Weinhardt, 2021)

Şekil 2. 7’de her bir t zamanında,

$a^{<t>}$ Aktivasyonu,

$a^{<t>} = g_1 (W_a a^{<t-1>} + W_a x^{<t>} + b_a)$ olup,

$y^{<t>}$ Çıktısı,

$y^{<t>} = g_2 (W_y a^{<t>} + b_y)$ şeklinde gösterilir.


$W_{ax}, W_{aa}, W_{ya}, b_a, b_y$ geçici olarak paylaşılan katsayılardır.

g_1, g_2 aktivasyon fonksiyonlarıdır.

2.5.1. Uzun Kısa Süreli Bellek Birimi (LSTM–Long Short -Term Memory)


LSTM modeli, Hochreiter ve Schmidhuber tarafından 1997 yılında tanıtılmış olup, daha sonra birçok araştırmacı tarafından yeni güncellemelerle daha fazla kullanılır hale gelmiştir (Hochreiter & Schmidhuber, 1997). Standart RNN modelinde tekrarlayan modül tek bir ünite içerirken, LSTM modelindeki tekrarlayan modüller dört adet etkileşimli ünite içermektedirler. LSTM yapısındaki üniteler, hangi bilgiyi tutacağına, hangi bilgileri sileceklerine karar verirler (colah.github, 2015). RNN modülü ile LSTM tekrarlayan modülün farkı Şekil 2. 8 ve Şekil 2. 9’da gösterilmiştir.

Şekil 2. 8: Tek Hücreli Standart RNN Modülü



Kaynak: (Kamalov vd., 2022)

Şekil 2. 9: Dört Hücreli LSTM Modülü




Sinir Ağı Katmanı- Puanlama İşlemi- Vektör Taşınması- Birleştirme- Kopyalama

Kaynak: (Kamalov vd., 2022)

LSTM hücresi RNN hücresine göre, eşsiz bir iletişime sahip unutma, giriş, durum ve çıkış olarak dört üniteden oluşmaktadır. Hücreye bilgi ekleme ve çıkarma işlemini kapılar adı verilen yapılar tarafından uygulamaktadırlar. Şekil 2. 9'da gösterilen LSTM hücresi, giriş, unutma ve çıkış adı verilen üç kapıya sahiptir. Kapılar bilginin iletilmesini kullanıcının isteğine bağlı olarak mümkün kılar. Sigmoid fonksiyonu bir önceki çıktının kullanılıp kullanılmayacağına karar verir. Bu kapıya unutma kapısı denir. f_t şeklinde gösterilebilir. Sigmoid katmanı 0 ile 1 arasındaki üretilen değerlerin sonucunu gösterir. 0 değeri hiçbir şeyin geçmemesi anlamında iken, 1 değeri her şeyin geçebileceği anlamında kullanılmaktadır (Er & Işık, 2021). Örnek unutma kapısı Şekil 2. 10'da gösterilmiştir.

Şekil 2. 10: LSTM' de Yer Alan Sigmoid Hücresi



Kaynak: (Kamalov vd., 2022)

LSTM hücresinin amacı hücrenin durumunu korumak ve kontrol etmektir. Öncelikle hücre durumundan hangi bilgilerin unutulacağı (kullanılmayacağı) karar verilir. Bir sonraki adımda hangi bilgilerin depolanacağına karar verilir. Son adımda ise çıktının ne olarak alınacağına karar verilir (Er & Işık, 2021).

$$f_t = Q(W_f[h_{t-1}, X_t] + b_f) \quad (2)$$

Formül (2)'de Q sigmoid fonksiyonu, W_f unutma kapısının ağırlık matrisleri, h_{t-1} bir önceki ünite çıkış bilgisi ve b_f bias'dır.

$$i_t = Q(W_i[h_{t-1}, X_t] + b_i) \quad (3)$$

$$N_t = \tanh(W_n[h_{t-1}, X_t] + b_n) \quad (4)$$

$$C_t = C_{t-1}f_t + N_ti_t \quad (5)$$

Formül (3)'de verilen adımda verilen işlem yeni giriş bilgileri (X_t) kararlaştırılarak depolanır ve güncellenir. Sigmoid katmanında yeni bilginin güncellenip güncellenmeyeceğine (0 ya da 1) karar verilirken, Formül (4)'de tanh katmanında geçen değerlere önem düzeylerine göre (-1 ya da 1) ağırlık verilir. Hücrenin yeni durumu güncellenirken bu iki değer çarpılarak bulunur. C_{t-1} yeni değer eski değere eklenerek C_t ile sonuçlanır. Formül (5)'de bu işlemi göstermektedir. Burada gösterilen C_{t-1} ve C_t , t-1 ile t zamanındaki hücre durumlarını gösterir.

$$O_t = Q(W_o[h_{t-1}, X_t] + b_o) \quad (6)$$

$$h_t = O_t \tanh(C_t) \quad (7)$$


Formül (6) ve (7)'de sigmoid geçidinden elde edilen çıktı (O_t) ile tanh katmanının ürettiği yeni değer (C_t) çıktısı çarpılarak son çıktı değeri (h_t) elde edilir. W_o çıkış kapısının ağırlık matrisini belirtirken, b_o bias'dır (Er & Işık, 2021).

2.5.2. Kapılı Tekrarlayan Birim (GRU- Gated Recurrent Unit)

Geçişli tekrarlayan hücreler olarak da adlandırılan bu birim, tekrarlayan yapay sinir ağlarında bir kapı mekanizması görevini görür. GRU modeli LSTM modelinin sadeleştirilmiş şeklidir. GRU' da çıkış kapısı olmadığından parametreleri daha azdır. GRU, LSTM' nin bir çeşididir ve geleneksel RNN modelindeki kaybolan gradyan (vanishing gradient) problemini ele alır. GRU modelinin içyapısı daha basit ve daha az hesaplama yapıldığı için daha hızlıdır (stringfixer.com/gru, 2016).

GRU' lar yapı olarak LSTM' e göre daha basit ve daha az hesaplama gerektirdiğinden popülerliği artmaktadır. GRU modeli, aynen LSTM' de olduğu gibi el yazısı tanıma, konuşma tanıma, konuşma sinyali modellemesi, dilden dile çeviri gibi sıralı problemlerde sıklıkla kullanılmaktadır. GRU modelinin güncelleme ve sıfırlama geçitleri vardır. Güncelleme geçidi, bir önceki birimden bilginin ne kadarını çarpma işlemi ile hafıza hücresinden geçmesi gerektiğine karar verirken, sıfırlama geçidi ise bilgilerin hangisinin unutulacağına karar verir. Ne kadar bilginin dahili bellek hücresinden geçirileceğine karar verdikten sonra çıkış işlemi gerçekleştirmektedir (Çınar, 2019). GRU modelinde sıfırlama ve güncelleme geçitleri modeli Şekil 2. 11'de gösterilmiştir.

Şekil 2. 11: GRU Modelinde Sıfırlama ve Güncelleme Geçitleri



Kaynak: (dive into deep learning, 2019)

Şekil 2.11’de,

t : Zaman,

n : Örnek Sayısı,

x : Giriş Sayısı,

h : Gizli Birim Sayısı, olmak üzere,

örnek olarak $X_t \in \mathbb{R}^{n \times d}$ ve $H_{t-1} \in \mathbb{R}^{n \times h}$ olduğu varsayılırsa,

Sıfırlama geçidi $R_t \in \mathbb{R}^{n \times h}$,

Güncelleştirme geçidi $Z_t \in \mathbb{R}^{n \times h}$ aşağıdaki formülle hesaplanır.

$$R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r), \quad (8)$$

$$Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z) \quad (9)$$

Formül (8) ve (9)’da W_{xr} , $W_{xz} \in \mathbb{R}^{d \times h}$ ve W_{hr} , $W_{hz} \in \mathbb{R}^{h \times h}$ ağırlık parametreleri olup, b_r , $b_z \in \mathbb{R}^{1 \times h}$ ek girdileri göstermektedir. Girdi değerlerini $[0,1]$ aralık değerine getirmek için sigmoid fonksiyonu kullanılır (dive into deep learning, 2019). Sıfırlama kapısı, geçmiş bilgilerin ne kadarının unutulacağına karar veren kapılardır. Güncelleme kapısı ise LSTM’lerin unutma ve giriş kapısına benzer şekilde hareket etmektedir. Hangi bilgilerin tutulacağına veya atılacağına ve hangi yeni bilgilerin ekleneceğine karar vermektedir. GRU’ların eğitilmeleri LSTM’lerden daha hızlıdır. Genellikle araştırmacılar hangisinin daha iyi sonuç vereceğini belirlemek adına çalışmalarında her ikisini de denemeyi tercih etmektedirler.

2.6. DERİN ÖĞRENME


İnsanları öğrenme yöntemlerini taklit etmeye yönelik bir öğrenme modeli olan derin öğrenme, bir YSA makine öğrenme yöntemi olmasına rağmen YSA makine öğrenmesinden bazı temel farkları vardır. En temel farkı makine öğrenmesinde manüel işlemler oluşurken, derin öğrenme sistemin otomatikleşmesine odaklanmıştır. Derin öğrenmede birden fazla gizli katman kullanılması da bir diğer temel fark olarak görülmektedir. Yapay zekâyı eğitmemizi sağlayan derin öğrenme uygulamalarında denetimli öğrenme, denetimsiz öğrenme gibi farklı modeller kullanılabilmektedir (Çınar, 2019).

Derin öğrenmede asıl amaç bir yazılımda algoritmalara bağlı kalmak yerine alternatifler karşısında seçenekleri kurgulayıp bilgisayar modelinin uygulayabilmesi için alan hazırlamaktır. Yazılımların türeteceği seçenekler kısıtlı olduğu için derin öğrenme uygulamalarından yararlanmak çok daha faydalı görülmektedir. Bu bağlamda derin öğrenme uygulanan makinelerin daha çok çözüm oluşturabildikleri görülmektedir (Çınar, 2019).

Derin öğrenmenin önemi, artan veri hacmini tekrarlı öğrenme modelleri aracılığıyla doğru sonuçlar elde edebilmek için kullanması ve bulgulardaki hatalar ile tutarsızlıkları ortadan kaldırıp güvenilir sonuçlara ulaşılmasını sağlamaktır. Aynı zamanda GoogLeNet, VGG16–19, AlexNet, ZFNet, ResNet vb. gibi farklı derin mimarilerin kullanıma sunulmasını sağlamaktadır. Tensorflow, Keras, Caffe, Pytorch, Theano, MatConvNet vb. gibi kütüphane ve derin öğrenme algoritmalarının da kullanılmaya başlanması bu alandaki benzer çalışmaları olumlu yönde etkileyeceği düşünüldüğünden önemli hale gelmektedir (Savaş, 2020).

Derin öğrenme algoritmaları tıpkı insan beyni sinir ağları gibi neden-sonuç ilişkisi halinde bulunabilirler. Faydasız bilgiler sistemden atılır, faydalı bilgiler ise daha sık ve verimli kullanılmak üzere sistemde tutulur. Derin gizli katman sayısı arttırılarak daha karmaşık problemlerin çözümünde daha etkili olarak kullanılabilmektedir.

Şekil 2. 12: Derin Öğrenmede Başlıca Kullanım Alan Yelpazesi



Kaynak: (Savaş, 2020)

Derin öğrenmede çoklu işleme katmanlarındaki hesaplama modellerinin kullanımına izin verilir. Şekil 2. 12’de görüldüğü üzere derin öğrenmenin kullanıldığı bazı alanları verilmiştir. Bunlar arasında konuşma tanıma, görsel nesne tanıma, karakter tanıma, genomik, nesne algılama, doğal dil işleme, fotoğraflar, sesli aramalar, haritalar, sürücüsüz araçlar, yatırım yönetimi, çeviriler, sağlık tanısında görüntü tanıma, endüstriyel bakım onarım, spor performans yönetimi gibi birçok alanda teknolojiye önemli ölçüde ve geniş yelpazede katkı sağlamaktadır (Savaş, 2020). Çok katmanlı YSA, LSTM ve GRU modelleri de birer derin öğrenme yöntemi olarak görülmektedir.

ÜÇÜNCÜ BÖLÜM


VERİ SETİ VE UYGULAMA

3.1. VERİ SETİ

Bu çalışmada kripto para birimi olan Bitcoin ile sanal paralara altyapı ve geliştirme platformu sağlayıcısı ve kripto para birimi olan Ethereum' un endeks tahmini yapılarak elde edilen sonuçlar karşılaştırılmıştır. Çalışmada özellikle dünyada 2016-2022 yılları arasında yaşanan krizlerin sebep olduğu aşırı dalgalanmalar dönemi ele alınarak kriz dönemlerindeki veriler kullanılarak kriz dönemi tahminleri yapılmıştır.

Tahmin işlemi için yapay zekâ yöntemlerinden makine öğrenmesi olarak yapay sinir ağları (YSA) ve derin öğrenme olarak kısa uzun dönem hafıza üniteleri olan LSTM ve GRU algoritmalarından faydalanılmıştır. Tahmin işleminde geçmiş fiyat bilgilerinin yanında işlem hacmi bilgisi de dikkate alınmıştır. Zaman serisi şeklindeki veri seti kullanılarak yapay sinir ağı makine öğrenme yöntemleri ile tahmin yapılmıştır. Veri seti, kamuya açık internet sitesi olan investing.com web adresinden, günlük endeksler ve işlem hacmi olarak elde edilmiştir. Çalışmada Ethereum için 10.03.2016 ile 20.04.2022 tarihleri arası 2233 adet günlük veriler alınmıştır. Bitcoin için 01.01.2018 ile 27.04.2022 arası 1578 adet günlük veriler alınmıştır. Bitcoin veri setinde önceki veriler daha istikrarlı olduğu için 2018 yılı sonrası veriler kullanılmıştır. Veriler ön işleminden geçirilip düzenlenerek denetimli makine öğrenmesinde kullanılabilir veri seti haline getirilmiştir. İşlem aşamalarını gösteren sistem akış diyagramı Şekil 3. 1'de gösterilmiştir.

Şekil 3. 1: Sistem Akış Diyagramı



Akış diyagramında model kurma aşamasına kadar olan adımlar veri temizleme ve ön işleme adımları olup kullanılacak modelden bağımsızdır. Akış diyagramına göre ilk adım veri toplama sürecidir. Bu aşamada Bitcoin için 01.01.2018 ile 27.04.2022 tarihleri arasında 1578 adet günlük verileri, Ethereum için 10.03.2016 ile 20.04.2022 tarihleri arasında 2233 adet günlük verileri tr.investing.com adresinden Excel formatında çekilmiştir.

İkinci adımda veriler ön işlemde geçirilmektedir. Burada veri setindeki eksik verilerin tamamlanması veya silinmesi, kategorik verilerin dönüştürülmesi, gereksiz özelliklerin atılması gibi işlemler yapılır. Bu çalışmada ön işlem olarak:

- Zaman serisi veri seti açılış ve kapanış verilerinden aritmetik ortalamasından yeni fiyat özelliği oluşturulmuştur.
- İşlem hacmi bilgisi, pencere aralığı dikkate alınarak, yeni bir özellik olarak veri setine eklenmiştir.
- Verilerin zaman boyutu korunarak ilk % 70'lik veri eğitim için, kalan % 30 veri ise test verisi olarak ayrılmıştır.

Üçüncü adım ise modelin kurulum aşamasıdır. Burada modelin seçimi ve parametreleri belirlenmektedir. Örneğin; YSA modeli için; giriş, gizli ve çıkış katmanlarının ve düğüm sayılarının belirlenmesi, gizli ve çıkış katmanı aktivasyon fonksiyonlarının seçimi, kayıp (loss) fonksiyonunun belirlenmesi, varsa düzeltme yöntemi, back büyüklüğü ve yineleme (epoch) sayısı gibi hiper parametreler belirlenir. Dördüncü adımda ise sonlanma kriterleri sağlanana kadar eğitim veri seti kullanılarak modelin eğitim işlemi gerçekleştirilir.

Beşinci adımda, eğitilen model daha önce görmediği test veri seti ile test edilir. Test işleminde; modele test veri seti verilir ve bir tahmin yapması beklenir. Yapılan tahmin ile girilen test veri için bulması gereken gerçek değer arasındaki fark hata miktarını gösterir. Tüm test veri seti hata miktarları ortalaması sistemin test performansını gösterir. Bu değer sıfıra ne kadar yakın ise sistemin performansı o kadar iyidir denebilir. Eğer test performansı çok düşük veya eğitim performansı ile test performansı arasında çok büyük farklar varsa ezberleme veya öğrenememe durumları olabilir. Bunun için iş akışı ilk adımından itibaren tekrar gözden geçirilip gerekirse düzeltmeler yapılarak iş akışının tekrar işletilmesi gerekir. Çalışmada eğitim ve test performansı ölçeği olarak;

Hataların mutlak ortalaması MAE, hataların karesi toplamının ortalaması MSE (Formül 10), hataların karesi toplamının ortalamasının karekökü RMSE (Formül 11) ve R-kare ölçeği (Formül 12) kullanılarak sonuçlar elde edilmiştir.

$$\text{Mean Squared Error (MSE)} = \frac{1}{n} \sum (z_i - y_i)^2 \quad (10)$$

$$\text{Root Mean Squared Error (RMSE)} = \sqrt{\frac{1}{n} \sum (z_i - y_i)^2} \quad (11)$$

$$\text{Coefficient of Determination (R}^2\text{)} = 1 - \frac{\sum (z_i - y_i)^2}{\sum (z_i - \bar{y})^2} \quad (12)$$

y_i : Gerçek, olması gereken değer

z_i : Sistemin tahmin ettiği değer

$\bar{y}$: Gerçek değer ortalaması

n : Örnek sayısı

(R^2) R-kare belirleme katsayısıdır. Verilerin kullanılan model ile ne kadar iyi sonuç aldığı, bir performans, ölçüsüdür. R-kare değeri 1'e yaklaştıkça güçlü bir ilişki söz konusudur. Test işleminden sonra, model daha sonra kullanılmak üzere, saklanabilir. Eğitimi ve test işleminde başarılı olan model kullanılarak tahmin işlemi yapılabilir. Elde edilen tahmin bilgisi karar verme süreçlerinde yardımcı olacaktır.


3.2. ZAMAN SERİLERİ

Zaman serileri değişken değerlerin ardışık olarak izlendiği, bir dönemden başka bir döneme gözlenen sayısal büyüklüklerdir. Başka bir ifade ile zamanın içinden alınan ardışık bir dizide bulunan gözlemlerdir. Verilerin sıralaması önemli olduğu kadar düzenli aralıklarla işlenmesi de dizinin gözlemlenebilmesi için büyük önem taşımaktadır. Serideki gözlem değerlerinin zaman içinde birbirleriyle bağlantılı olması zaman serilerini diğer serilerden farklı kılan en dikkat çeken özelliğidir. Zaman serilerinin gelecekte göstereceği performansları önceden tahmin etme çalışmaları karar verme açısından önem taşımaktadır. Zaman serileri analizi bir serinin istenen önemli noktalarını özet olarak ortaya çıkarmaya çalışır. Değişken sayısına göre tek veya çok değişkenli olarak incelenebilmektedirler. Serinin iç dinamikleri serinin davranışlarını açığa çıkarmaya çalışır. Zaman serileri için oluşturulan model, serinin gelecekte alabileceği değerleri öngörmelidir. Zaman serisi analizi zaman kavramının ölçümleneceği her alanda kullanılabilir. İstatistik, ekonometri, finans, sinyal işleme, deprem ve hava tahmini gibi başlıklar en popüler alanlar olarak gösterilebilir. Bu bağlamda, çalışmada zaman serisi analizinden yararlanılarak, kripto paraların fiyat ve işlem hacmi tahmini yapılmıştır.

3.2.1. Zaman Serilerinin Makine Öğrenme Yöntemi ile Tahmini


Zaman serileri makine öğrenme yöntemleri ile de tahmin edilebilmektedir. Zaman serilerinde zamanın boyutu önemlidir ve farklı algoritmalar kullanılmaktadır. Güvenilir sonuçlar elde etmek için kullanılan makine öğrenme yöntemleri çeşitli analizler kullanılarak yapılmaktadır. Aynı zamanda çeşitli programlar ve yüklenen kütüphaneler aracılığı ile de çalışmalar desteklenebilmektedir. Bu kütüphaneler zaman serilerinde tahmin işlemlerinde oluşabilecek problemleri ortadan kaldırabilmek amacı ile özel olarak tasarlanmaktadır. Gelişmelere ve güncellemelere açık olarak yazılmaktadır. Makine öğrenme yöntemlerinin kullanılmasında da kolaylık sağlamaktadır. Makine öğrenme yöntemleri ile tahmin işlemlerini uygulayabilmek için izlenmesi gereken bazı adımlar bulunmaktadır. Bu adımlar Şekil 3. 2’de gösterildiği gibidir.

Şekil 3. 2: Zaman Serilerinde Tahmin İşlemi Algoritması



Zaman serileri analizinde öncelikle veriler özellik ve etiket olarak ayrılmaktadır. Bunun için bir pencere aralığı belirlenir, belirlenen pencere aralığı kadar özellik ve izleyen veri etiket olarak düzenlenir. Daha sonra veriler eğitim ve test olarak bölümlere ayrılır. Örneğin verilerin %70'i eğitim, %30'u test olarak kullanılır. Daha sonra tahmin işlemi yapılır.

Şekil 3. 3: Zaman Serisi Verisinin Denetimli Makine Öğrenme Verisine Dönüştürülmesi



Şekil 3. 3’de zaman serilerinin makine öğrenmesi ile tahmini için denetimli öğrenme yöntemi kullanılmıştır. Denetimli öğrenmede veri seti nitelik değerleri ve beklenen çıktıyı ifade eden etiket değerlerinden oluşur. Zaman serisini bu şekle dönüştürmek için bir pencere aralığı belirlenip, veriler bu pencere aralığında nitelik ve etiket şeklinde denetimli makine öğrenme veri setine dönüştürülür. Şekil 3. 3’deki örnekte; pencere aralığı: 4 için dönüşüm görülmektedir. Bu işlem için pencere aralığı, veri seti ilk verisinden başlanıp birer adım kaydırılarak dönüştürme işlemi yapılır pencere aralığının devamındaki ilk kayıt ise beklenen değeri yani etiketi ifade eder. Bu aşamadan sonra eğitim ve test bölümlerine ayrılarak tahmin işlemine geçilmektedir.

3.4. VERİ SETİ ANALİZİ VE İSTATİSTİKİ BİLGİLERİ

3.4.1. Bitcoin Veri Analizi

Bitcoin veri analizi için 01.01.2018 ile 27.04.2022 tarihleri arasında 1578 adet günlük veriler kullanılmış ve Tablo 3. 1’de gösterilmiştir. Tablodaki bu veriler Excel formatında <https://tr.investing.com/crypto/bitcoin/historical-data> adresinden alınmıştır. Tablodaki veriler; işlem tarihi, kapanış fiyatı, açılış fiyatı, en yüksek ve en düşük fiyat değerleri dolar (\$) cinsinden, günlük işlem hacmi ise 1000 çarpanı ile verilmiştir. Tablodaki ortalama değer açılış ve kapanış değerlerinin aritmetik ortalaması alınarak elde edilmiştir.

Tablo 3. 1: Bitcoin Veri Seti Örneği


#ID	Tarih	Fiyat Birimi (\$)					Hacim Değeri
		Kapanış Değeri	Açılış Değeri	En Yüksek Değer	En Düşük Değer	Ortalama Değer	
1	01.01.2018	13444,9	13850,5	13921,5	12877,7	13647,7	78,43K
2	02.01.2018	14754,1	13444,9	15306,1	12934,2	14099,5	137,73K
3	03.01.2018	15156,6	14754,1	15435	14579,7	14955,35	106,54K
4	04.01.2018	15180,1	15156,5	15408,7	14244,7	15168,3	110,97K
.....							
1575	24.04.2022	39464	39434	39929	39033	39449	283,63K
1576	25.04.2022	40427	39464	40599	38233	39945,5	654,6K
1577	26.04.2022	38113	40443	40770	37708	39278	681,47K
1578	27.04.2022	38680	38113	38781	37869	38396,5	638,91K

Veri setine ait istatistikî bilgiler vardır. Tablo 3. 2’ de verildiği üzere Bitcoin veri seti için elde edilen istatistikler; veri sayısı: 1578 adet, ortalama değeri: 20055,6; standart sapma değeri: 18124,6; en düşük değeri: 3238,25; en yüksek değeri: 67216,6 olarak bulunmuştur. Verilerin % 25’ine ait değeri: 7274,3; % 50’sine ait değeri: 9827,47; % 75’ine ait değeri: 37069,8 olarak belirtilmiştir. Çarpıklık değeri: 1,007; basıklık değeri: – 0,545 olarak elde edilmiştir.

Tablo 3. 2: Bitcoin Veri Seti İstatistik Bilgileri


İstatistik	Değer
Sayı	1578
Ortalama	20055,6
Standart Sapma	18124,6
En Düşük	3238,25
En yüksek	67216,6
Verilerin % 25	7274,3
Verilerin % 50	9827,47
Verilerin % 75	37069,8
Çarpıklık	1,007
Basıklık	-0,545

Şekil 3. 4: Bitcoin 2018-2022 Yıllarına Göre Fiyat Değişim Grafiği



Şekil 3. 4’de Bitcoin veri seti ve istatistik bilgilerine göre oluşturulan fiyat zaman grafiği verilmiştir. Grafik kriz zamanlarındaki fiyat değişimlerini göstermektedir. Grafiğe göre en düşük fiyat 2019 yılı başlarındayken, en yüksek değer 2021 yılının son aylarında görülmektedir. Grafikten de görüldüğü gibi fiyatlar 10K altı ve 70K arası aşırı bir dalgalanma söz konusudur.

Şekil 3. 5: Bitcoin Fiyat Yoğunluk Grafiği



Şekil 3. 5’de Bitcoin veri seti ve istatistik bilgilerine göre oluşturulan fiyat yoğunluk grafiği verilmiştir. Grafiğe göre veri setinde fiyat yoğunluğunun 10.000 - 15.000 aralığında olduğu, 70.000 - 80.000 aralığında ise yoğunluğun çok daha az olduğu görülmektedir.

3.4.2. Etheryum Veri Analizi

Çalışmada tahmin işlemi yapılan bir diğer kripto para olan Etheryum' un veri analizi için 10.03.2016 ile 20.04.2022 tarihleri arasında 2233 adet günlük veriler kullanılmıştır. Kullanılan veriler, <https://tr.investing.com/crypto/ethereum/historical-data> adresinden Excel formatında alınmıştır ve Tablo 3. 3'de gösterilmiştir. Tablodaki veriler; işlem tarihi, kapanış fiyatı, açılış fiyatı, en yüksek ve en düşük fiyat değerleri \$ (dolar) cinsinden, günlük işlem hacmi ise 1000 çarpanı ile verilmiştir. Tablodaki ortalama değer ise açılış ve kapanış değerlerinin aritmetik ortalaması alınarak elde edilmiştir.

Tablo 3. 3: Etheryum Örnek Veri Seti


#ID	Tarih	Fiyat Birimi (\$)					Hacim Değeri
		Kapanış Değeri	Açılış Değeri	En Yüksek Değer	En Düşük Değer	Ortalama Değer	
1	10.03.2016	11,75	11,2	11,85	11,07	11,475	0,00K
2	11.03.2016	11,95	11,75	11,95	11,75	11,850	0,18K
3	12.03.2016	12,92	11,95	13,45	11,95	12,435	0,83K
4	13.03.2016	15,07	12,92	15,07	12,92	13,995	1,30K
.....	...						
2230	17.04.2022	2989,05	3058,96	3081,14	2983,17	3024,005	311,54K
2231	18.04.2022	3055,64	2989,05	3069,07	2887,25	3022,345	681,76K
2232	19.04.2022	3102,01	3055,86	3128,86	3030,32	3078,935	427,14K
2233	20.04.2022	3110,48	3101,79	3114,83	3067,12	3106,135	413,58K

Veri setine ait istatistikî bilgiler vardır. Tablo 3. 4'de verildiği üzere Etheryum veri seti için elde edilen istatistikler; veri sayısı: 2233 adet, ortalama değeri: 796,29; standart sapma değeri: 1152,77; en düşük değer: 7,05; en yüksek değer: 4770,09 olarak bulunmuştur. Verilerin % 25 'ine ait değer: 134,955; % 50'sine ait değer: 254,41; % 75'ine ait değer: 728,235 olarak belirtilmiştir. Çarpıklık değeri: 1,748; basıklık değeri: 1,806 olarak elde edilmiştir.

Tablo 3. 4: Ethersum Veri Seti İstatistikî Bilgileri


İstatistik	Değer
Sayı	2233
Ortalama	796,29
Standart Sapma	1152,77
En Düşük	7,05
En yüksek	4770,09
Verilerin % 25	134,955
Verilerin % 50	254,41
Verilerin % 75	728,235
Çarpıklık	1,748
Basıklık	1.806

Şekil 3. 6: Ethersum 2016-2022 Yıllarına Göre Fiyat Değişim Grafiği



Şekil 3. 6’da Ethersum veri seti ve istatistik bilgilerine göre oluşturulan fiyat zaman grafiği verilmiştir. Grafikte kriz zamanlarındaki fiyat değişimlerini göstermektedir. Grafiğe göre en düşük fiyat 2016-2017 yılları arasındayken, en yüksek değer 2021 yılının son aylarında görülmektedir. 2017 ile 2019 yılları arasında ve 2021 ile 2022 yılları arasında da aşırı dalgalanmalar gözlemlenmektedir.

Şekil 3. 7: Ethereum Fiyat Yoğunluk Grafiği



Şekil 3. 7'deki Ethereum veri seti ve istatistik bilgilerine göre oluşturulan fiyat yoğunluk grafiği verilmiştir. Grafiğe göre veri setinde fiyat yoğunluğunun 100 - 500 aralığında olduğu, 4.000 - 5.000 aralığında ise yoğunluğun çok daha az olduğu görülmektedir. Şekil 3. 4'deki Bitcoin fiyat yoğunluğu grafiği ile karşılaştırdığımızda Ethereum fiyat yoğunluğunun Bitcoin fiyat yoğunluğuna göre oldukça düşük olduğu görülmektedir.

Ayrıca istatistikî bilgiler arasında Bitcoin ve Ethereum çarpıklık değerlerini incelediğimizde, her ikisi de pozitif değer olduğu için pozitif simetrik çarpıklık değeri gösterdiği söylenebilir. Basıklık değerleri incelendiğinde ise, Ethereum basıklık değeri pozitif değer olduğu için sivri basık durumda sayılırken, Bitcoin basıklık değeri negatif değer olduğundan yassı basık durumda olduğu söylenebilir.

3. 5. BİTCOİN UYGULAMA ANALİZLERİ

3. 5. 1. Bitcoin YSA Uygulaması

Çalışmada Bitcoin tahmin işlemleri için kullanılan yöntemlerden YSA uygulaması için, işlem hacmi (volume) verisi fiyat verisine göre çok büyük olduğundan baskılama yapmaması için veriler [0-1] aralığına ölçeklendirilmiştir (Formül 13). Tahmin işleminde elde edilen veriler ters işlem yapılarak (invers transform) gerçek verilere dönüştürülüp işlem yapılmıştır (Formül 14).

$$\text{Normalized (i)} = \frac{x_i - \text{Min}_i}{\text{Max}_i - \text{Min}_i} \quad (13)$$

$$\text{Denormalized} = \text{Normalized (i)} \cdot (\text{Max}_i - \text{Min}_i) + \text{Min}_i \quad (14)$$

Bitcoin veri seti için YSA modelinde üç katmanlı (giriş- gizli- çıkış) mimari kullanılmıştır. Kullanılan YSA mimarisi hiper parametreleri Tablo 3. 5’de verilmiştir. Model hiper parametreleri olarak; yineleme değeri: 500, paket büyüklüğü (epoch): 30, kayıp fonksiyon: MSE, gizli katman aktivasyon fonksiyonu: ReLU, çıkış katman aktivasyon fonksiyonu: ReLU, öğrenme algoritması: *adam* kullanılmıştır. Modelin ezberleme durumu gözlemlenmediğinden ağda herhangi bir seyreltme (dropout) işlemine ihtiyaç duyulmamıştır.

Tablo 3. 5: Bitcoin YSA Hiper Parametreleri


Parametre	Değeri
Yineleme (epoch)	500
Paket büyüklüğü (back size)	30
Kayıp fonksiyonu (loss function)	MSE
Gizli katman aktivasyon fonksiyonu	ReLU
Çıkış katman aktivasyon fonksiyonu	ReLU
Öğrenme algoritması (learning algorithm)	adam
Seyreltme (dropout)	Yok

Tablo 3. 6: Farklı YSA Mimarileri İçin Bitcoin YSA Performans Sonuçları

Model	YSA mimarisi	Eğitim performans				Test performans			
No	Giriş- Gizli-Çıkış	RMSE	MAE	MAPE	R ²	RMSE	MAE	MAPE	R ²
1	11-5-1	0,032	0,006	9014,8	0,831	0,045	0,032	58712,0	0,886
2	11-10-1	0,032	0,006	7264,7	0,894	0,032	0,030	53756,9	0,917
3	11-15-1	0,031	0,006	9968,1	0,786	0,063	0,050	55457,7	0,809
4	11-20-1	0,031	0,007	12186,8	0,795	0,045	0,034	65022,3	0,882
5	11-30-1	0,032	0,006	8960,9	0,492	0,055	0,042	62136,7	0,715
6	11-40-1	0,032	0,006	9,276	0,795	0,045	0,030	50887,7	0,907
7	11-50-1	0,032	0,006	8,875	0,568	0,063	0,049	34266,0	0,687


Model Bitcoin için farklı YSA mimarileri ile çalıştırılarak, sistemin performansına etkileri gözlemlenmiş ve elde edilen veriler Tablo 3. 6’da gösterilmiştir. Tahmin performans metriği olarak; RMSE, MAE, MAPE ve R-Kare performans parametreleri kullanılmıştır. Kullanılan parametreler doğrultusunda farklı YSA mimarileri ile gerçekleştirilen uygulamada YSA modelinin Tablo 3. 6’daki eğitim performansı için çıkan en iyi değeri 2 numaralı modelde 11-10-1 mimarisinde R-Kare performans değeri 0,894’ dür. R-Kare test performansı için çıkan en iyi değer yine 2 numaralı modelde 11-10-1 mimarisinde 0,917 olup, YSA modelinin elde edilen en yüksek değerlerini göstermektedir. Çıkan rakamları görsel olarak da destekleyen kayıp-yineleme grafiği Şekil 3. 8’ de, tahmin-gerçek değer grafiği ise Şekil 3. 9’da gösterilmiştir. Tahmin ve gerçek değer birbirine yakın olduğu görülmektedir.

Şekil 3. 8: Bitcoin Kayıp - Yineleme Grafiği- YSA



Şekil 3. 8’de eğitim sırasında eğitim ilerledikçe hata miktarının azaldığı görülmektedir. Eğitim ve geçerlilik hata miktarları birlikte azalmıştır. Bu durum normal öğrenme (fitting) gerçekleştiğini göstermektedir.

Şekil 3. 9: Bitcoin Tahmin ve Gerçek Değer Grafiği-YSA



Şekil 3. 9’ da ise eğitilmiş YSA modelinin test sonucu tahmin ettiği veriler ile olması gereken gerçek verileri aynı grafikte gösterilmiş. Bunların birbiri ile çok yakın olduğu nerdeyse örtüştüğü görülmektedir. Bu modelin performansının yüksekliğini (iyi olduğunu) ifade emektedir.

3. 5. 2. Bitcoin GRU Uygulaması

Çalışmada Bitcoin tahmin işlemleri için kullanılan yöntemlerden GRU için sistem farklı GRU ünitesi ve GRU çıktılarından tahmin yapmak için Dense (YSA) farklı mimariler oluşturularak öğrenme işlemi gerçekleştirilmiştir. Bu mimariler GRU ünite sayısı ve YSA düğümlerinden (dense) oluşmakta olup, çalışmada kullanılan farklı mimariler Tablo 3. 7’ de gösterilmiştir.

Tablo 3. 7: Bitcoin Veri Seti İçin Farklı GRU Mimari Modelleri

Model No	Mimari			
	GRU ünite sayısı	GRU ünite sayısı	Dense	Dense
1	64	-	-	1
2	128	-	-	1
3	64	-	64	1
4	64	64	-	1
5	64	64	64	1
6	64 Bi GRU	-	-	1
7	128 Bi GRU	-	-	1

Tablo 3. 8: Bitcoin GRU Hiper Parametreleri

Parametre	Değeri
Yineleme (epoch)	200
Paket büyüklüğü (back size)	30
Kayıp fonksiyonu (loss function)	MSE
Gizli katman aktivasyon fonksiyonu	ReLU
Çıkış katman aktivasyon fonksiyonu	ReLU
Öğrenme algoritması (learning algorithm)	adam
Seyreltme (dropout)	Yok


Bitcoin veri seti için GRU uygulamasında kullanılan hiper parametreler Tablo 3. 8’de verilmiştir. Model hiper parametreleri olarak; yineleme değeri: 200, paket büyüklüğü: 30, kayıp fonksiyon: MSE, gizli katman aktivasyon fonksiyonu: ReLU, çıkış katman aktivasyon fonksiyonu: ReLU, öğrenme algoritması: *adam* kullanılmıştır. Ağda herhangi bir seyreltme yapılmamıştır. Model Bitcoin için farklı GRU mimarileri ile çalıştırılarak, sistemin performansına etkileri gözlemlenmiş ve elde sonuçlar Tablo 3. 9’a aktarılmıştır. Tablodan görüleceği üzere tüm modellerin eğitim ve test performansları birbirine yakındır.

Tablo 3. 9: Bitcoin Makine Öğrenmesi GRU Eğitim ve Test Performans Sonuçları

Model	Eğitim performans				Test performans			
No	RMSE	MAE	MAPE	R ²	RMSE	MAE	MAPE	R ²
1	0,032	0,008	13444,5	0,991	0,071	0,058	13494,0	0,914
2	0,032	0,009	8647,6	0,985	0,077	0,006	8741,7	0,894
3	0,032	0,012	16728,0	0,978	0,084	0,007	16935,9	0,882
4	0,032	0,009	16020,0	0,988	0,071	0,055	16101,0	0,922
5	0,032	0,011	20664,9	0,982	0,084	0,069	20758,0	0,876
6	0,032	0,009	10288,0	0,986	0,077	0,063	10391,6	0,893
7	0,032	0,009	11849,5	0,985	0,084	0,065	12062,1	0,885


Kullanılan parametreler doğrultusunda farklı GRU mimarileri ile gerçekleştirilen uygulamada GRU modelinin Tablo 3. 9’da en iyi eğitim R-Kare performansı değeri 1 numaralı modelde, Tablo 3. 7’deki 1 numaralı mimari olan 64 - - 1 mimarisinde 0,991’dir. Test performansı için çıkan en iyi R-Kare değeri yine 1 numaralı modelde, Tablo 3. 7’deki 1 numaralı mimari olan 64 - - 1 mimarisinde 0,914’ dür. Modelin eğitim kayıp- yineleme grafiği Şekil 3. 10’da gösterilmiştir. Eğitilmiş model tahmin grafiği ise Şekil 3. 11’de gösterilmiştir. Grafikte tahmin edilen değeri ile gerçek değeri birbirine yakın olduğu görülmektedir.

Şekil 3. 10: Bitcoin Kayıp - Yineleme Grafiği-GRU



Şekil 3.10’deki grafiğe göre eğitim sırasında eğitim ilerledikçe hata miktarının azaldığı görülmektedir. Eğitim ve geçerlilik hata miktarları birlikte azalmıştır. Bu durum normal öğrenme gerçekleştiğini göstermektedir.

Şekil 3. 11: Bitcoin Tahmin ve Gerçek Değer Grafiği-GRU



Şekil 3. 11’de ise eğitilmiş GRU modelinin test sonucu tahmin ettiği veriler ile olması gereken gerçek verileri aynı grafikte gösterilmiştir. Bunların birbiri ile çok yakın olduğu nerdeyse örtüştüğü görülmektedir. Bu durum modelin test performansının yüksekliğini ifade emektedir.

3. 5. 3. Bitcoin LSTM Uygulaması

Çalışmada Tablo 3.10’ da görüldüğü gibi farklı mimarileri kullanılarak öğrenme işlemi gerçekleştirilmiş. Tabloya göre yedi farklı modelde farklı LSTM, YSA karma modelleri denenmiştir. Modellerde bir veya iki katman LSTM ile birlikte LSTM çıktılarından tahmin yapmak için bir veya iki katman YSA (Dense) kullanılmıştır.

Tablo 3. 10: Bitcoin Veri Seti İçin Farklı LSTM Mimari Modelleri

Model No	Mimari			
	1. katman LSTM ünite sayısı	2. katman LSTM ünite sayısı	Dense	Dense
1	64	-	-	1
2	128	-	-	1
3	64	-	64	1
4	64	64	-	1
5	64	64	64	1
6	64 Bi LSTM	-	-	1
7	128 Bi LSTM	-	-	1

Tablo 3. 11: Bitcoin LSTM Hiper Parametreleri


Parametre	Değeri
Yineleme (epoch)	200
Paket büyüklüğü (back size)	30
Kayıp fonksiyonu (loss function)	MSE
Gizli katman aktivasyon fonksiyonu	ReLU
Çıkış katman aktivasyon fonksiyonu	ReLU
Öğrenme algoritması (learning algorithm)	adam
Seyreltme (dropout)	Yok

Bitcoin veri seti için LSTM Modeli hiper parametreleri Tablo 3. 11’de verilmiştir. Model hiper parametreleri olarak; yineleme değeri: 200, paket büyüklüğü: 30, kayıp fonksiyon: MSE, gizli katman aktivasyon fonksiyonu: ReLU, çıkış katman aktivasyon fonksiyonu: ReLU, öğrenme algoritması: *adam* olarak ele alınmıştır. Tablo 3.10’daki 7 farklı mimari modeli ile eğitim yapılarak elde edilen eğitim ve test performans değerleri tablo 3. 12’ ye aktarılmıştır. Tabloya göre R-kare ölçeği dikkate alınırsa eğitim R-kare değeri 0,991 olan ile 2 numaralı model (Tablo 3.10), test R-Kare değeri dikkate alınırsa 0,938 ile 3 numaralı model (Tablo 3.10) en iyi performansı göstermiştir.

Tablo 3. 12: Bitcoin Makine Öğrenmesi LSTM Eğitim ve Test Performans Sonuçları


Model No	Eğitim performans				Test performans			
	RMSE	MAE	MAPE	R ²	RMSE	MAE	MAPE	R ²
1	0,032	0,009	8747,8	0,985	0,084	0,067	8822,1	0,881
2	0,032	0,008	9061,3	0,991	0,071	0,056	9138,7	0,917
3	0,032	0,009	11411,2	0,989	0,063	0,048	11411,5	0,938
4	0,032	0,008	15701,5	0,975	0,063	0,048	15709,6	0,934
5	0,032	0,010	18860,6	0,981	0,063	0,049	18868,4	0,933
6	0,032	0,007	8644,9	0,990	0,071	0,055	8713,6	0,918
7	0,032	0,010	9352,1	0,978	0,084	0,065	9419,2	0,885

Şekil 3. 12: Bitcoin Kayıp - Yineleme Grafiği-LSTM



Şekil 3.12’ de ki grafiğe göre eğitim hata ve geçerlilik (validation) değerleri hata miktarları yineleme ilerledikçe birlikte azaldığı görülmektedir. Kayıp ve geçerlilik hata değerlerinin birlikte azalması ve sıfıra çok yakın olması başarılı ve normal bir eğitim işlemi yapıldığının göstergesi olarak kabul edilebilir. Grafiğe göre aşırı öğrenme (overfitting) veya öğrenememe (underfitting) gibi durumlar görülmemektedir.

Şekil 3. 13: Bitcoin Tahmin ve Gerçek Değer Grafiği-LSTM



Şekil 3. 13’de ise test/ tahmin değerleri birlikte grafik halinde gösterilmiştir. Şekilde görüleceği üzere gerçek değer ile tahmin edilen değer birbirine çok yakındır. Bu durum da sistemin başarısının yüksekliğini görsel olarak desteklemektedir.

Tablo 3. 13: Bitcoin Uygulaması için GRU, LSTM, YSA Performans Değerleri

Model	Eğitim Performans			Test Performans		
	RMSE	MAE	R ²	RMSE	MAE	R ²
GRU	0,032	0,008	0,991	0,071	0,055	0,922
LSTM	0,032	0,008	0,991	0,063	0,048	0,938
YSA	0,032	0,006	0,894	0,032	0,030	0,917

Çalışmada uygulanan yöntemlere göre Bitcoin için çıkan en iyi performans değerleri Tablo 3. 13’de gösterilmiştir. Tabloda elde edilen değerlere göre GRU modeli için eğitim performans değeri 0,991, test performans değeri 0,922 olarak elde edilmiştir. LSTM modeli için eğitim performans değeri 0,991, test performansı 0,938 olarak elde edilmiştir. YSA modeli için ise eğitim performans değeri 0,894, test performans değeri 0,917 olarak elde edilmiştir. Bu bağlamda ortaya çıkan bu performans değerleri doğrultusunda Bitcoin için yapılan tahmin işleminde uygulanan modeller arasında en iyi değeri veren uygulama 0,991 ile LSTM modeli olarak görülmektedir.

3. 6. ETHERYUM UYGULAMA ANALİZLERİ

3. 6. 1. Ethereum YSA Uygulaması

Etheryum uygulamasında tahmin işlemleri için kullanılacak olan modellerden biri olan YSA modeli için Ethereum veri setinde üç katmanlı (giriş- gizli- çıkış) mimari kullanılmıştır. Veri setinde işlem hacmi verisi fiyat verisine göre çok büyük olduğundan baskılama yapmaması için veriler [0-1] aralığına dönüştürülmüştür (Formül 13). Tahmin işleminde elde edilen veriler ters işlem yapılarak (invers transform) gerçek verilere dönüştürülüp işlem yapılmıştır (Formül 14). Ethereum veri seti için YSA uygulamasında kullanılan YSA hiper parametreleri vardır. Bu hiper parametreler Tablo 3. 14’de gösterildiği gibidir. Model hiper parametreleri olarak; yineleme değeri: 500, paket büyüklüğü: 30, kayıp fonksiyon: MSE, gizli katman aktivasyon fonksiyonu: ReLU, çıkış katman aktivasyon fonksiyonu: ReLU, öğrenme algoritması: adam olarak ele alınmıştır. Ağda herhangi bir seyreltme yapılmamıştır.

Tablo 3. 14: Ethersum YSA Hiper Parametreleri


Parametre	Değeri
Yineleme (epoch)	500
Paket büyüklüğü (back size)	30
Kayıp fonksiyonu (loss function)	MSE
Gizli katman aktivasyon fonksiyonu	ReLU
Çıkış katman aktivasyon fonksiyonu	ReLU
Öğrenme algoritması (learning algorithm)	adam
Seyreltme (dropout)	Yok

Tablo 3. 15: Farklı YSA Mimarileri İçin Ethersum YSA Performans Sonuçları

Model Numarası	YSA mimarisi Giriş-Gizli-Çıkış	Eğitim performans				Test performans			
		RMSE	MAE	MAPE	R ²	RMSE	MAE	MAPE	R ²
1	11-5-1	0,010	0,001	25,45	0,986	0,010	0,021	12,17	0,986
2	11-10-1	0,010	0,006	559,35	0,995	0,010	0,013	9,018	0,995
3	11-15-1	0,010	0,007	22,47	0,996	0,010	0,016	10,89	0,996
4	11-20-1	0,014	0,031	13,30	0,989	0,010	0,012	27,74	0,989
5	11-30-1	0,010	0,012	28,67	0,992	0,014	0,036	15,79	0,992
6	11-40-1	0,010	0,006	78,78	0,993	0,010	0,019	5089,1	0,990
7	11-50-1	0,010	0,008	4517,2	0,987	0,010	0,023	8521,2	0,989


Modelde veriler Ethersum için yedi farklı YSA mimarileri ile çalıştırılarak, sistemin performansına etkileri gözlemlenmiş ve elde edilen veriler Tablo 3. 15’de gösterilmiştir. Tahmin performanslarının ölçümünde RMSE, MAE, MAPE ve R-Kare performans parametreleri kullanılmıştır. Kullanılan parametreler doğrultusunda farklı YSA mimarileri ile gerçekleştirilen uygulamada YSA modelinin Tablo 3. 15’deki eğitim performansı için çıkan en iyi değeri 3 numaralı modelde 11-15-1 mimarisinde 0,996’dır. Test performansı için çıkan en iyi değer yine 3 numaralı modelde 11-15-1 mimarisinde 0,996 olup, YSA modelinin elde edilen en yüksek değerlerini göstermektedir. Çıkan rakamları görsel olarak da destekleyen kayıp-yineleme grafiği Şekil 3. 14’de, tahmin-gerçek değer grafiği ise Şekil 3. 15’de gösterilmiştir. Tahmin ve gerçek değer birbirine yakın olduğu görülmektedir.

Şekil 3. 14: Ethereum Kayıp - Yineleme Grafiği-YSA



Ethereum için YSA modeli ile yapılan tahmin çalışmasında Şekil 3. 14’de görülen grafiğe göre eğitim ilerledikçe hata miktarının azaldığı görülmektedir. Eğitim ve geçerlilik hata miktarları birlikte azalmıştır. Bu durum öğrenmenin normal olarak gerçekleştiğini göstermektedir.

Şekil 3. 15: Ethereum Tahmin ve Gerçek Değer Grafiği-YSA



Şekil 3. 9’deki grafiğe göre ise YSA modelinin eğitilen test sonucu tahmin edilen veriler ile gerçek verileri birlikte gösterilmiştir. Bunların birbiri ile çok yakın olduğu nerdeyse örtüştüğü görülmektedir. Bu modelin test performansının yüksekliğini ifade emektedir. Tablo 3. 15’de çıkan performans değerlerini de görsel olarak desteklemektedir.

3. 6. 2. Ethersum GRU Uygulaması

Ethersum uygulamasında tahmin işlemleri için kullanılacak olan bir diğer model de GRU modelidir. Sistem farklı GRU ünitesi ve GRU katmanları ve bir veya birden çok dense (YSA) ile farklı mimariler oluşturularak öğrenme işlemini gerçekleştirmiştir. Bu mimariler ünite sayısı ve düğümlerden oluşmaktadır. Farklı yedi mimariden oluşan modeller Tablo 3. 16’da gösterilmiştir.

Tablo 3. 16: Ethersum Veri Seti İçin Farklı GRU Mimari Modelleri

Model No	Mimari			
	GRU ünite sayısı	GRU ünite sayısı	Dense	Dense
1	64	-	-	1
2	128	-	-	1
3	64	-	64	1
4	64	64	-	1
5	64	64	64	1
6	64 Bi GRU	-	-	1
7	128 Bi GRU	-	-	1

Tablo 3. 17: Ethersum GRU Hiper Parametreleri

Parametre	Değeri
Yineleme (epoch)	200
Paket büyüklüğü (back size)	30
Kayıp fonksiyonu (loss function)	MSE
GRU üniteleri aktivasyon fonksiyonu	ReLU
Çıkış katman aktivasyon fonksiyonu	ReLU
Öğrenme algoritması(learning algorithm)	adam
Seyreltme (dropout)	Yok


Veri setinde hiper parametrelerin sistem performansına pozitif etkileri vardır. Ethersum veri seti için GRU uygulamasında kullanılan YSA hiper parametreleri tablo 3. 17’de gösterildiği gibidir. Model hiper parametreleri olarak; yineleme değeri: 200, paket büyüklüğü: 30, kayıp fonksiyon: MSE, gizli katman aktivasyon fonksiyonu: ReLU, çıkış katman aktivasyon fonksiyonu: ReLU, öğrenme algoritması: adam olarak ele alınmıştır. Ağda herhangi bir seyreltme yapılmamıştır. Model Bitcoin için farklı YSA mimarileri ile çalıştırılarak, sistemin performansına etkileri gözlemlenmiş ve elde edilen veriler Tablo 3. 18’de gösterilmiştir. Tablodan görüldüğü üzere tüm modellerin eğitim ve test performansları birbirine yakındır.

Tablo 3. 18: Ethersum Makine Öğrenmesi GRU Eğitim ve Test Performans Sonuçları

Model No	Eğitim performans				Test performans			
	RMSE	MAE	MAPE	R ²	RMSE	MAE	MAPE	R ²
1	0,032	0,010	1148,9	0,986	0,044	0,036	1142,8	0,973
2	0,032	0,011	934,63	0,988	0,032	0,019	927,52	0,991
3	0,032	0,012	1123,3	0,987	0,032	0,021	1137,2	0,990
4	0,032	0,009	1925,9	0,998	0,032	0,020	1967,9	0,992
5	0,032	0,009	4332,5	0,990	0,032	0,019	4208,2	0,992
6	0,032	0,009	922,12	0,992	0,032	0,019	917,46	0,992
7	0,032	0,009	806,56	0,991	0,032	0,023	801,03	0,988


Kullanılan parametreler doğrultusunda farklı YSA mimarileri ile gerçekleştirilen uygulamada GRU modelinin Tablo 3. 18'deki eğitim performansı için çıkan en iyi değeri 4 numaralı modelde, Tablo 3.16'da 4 numaralı mimari olan 64-64 – 1 mimarisinde 0,998'dir. Test performansı için çıkan en iyi değer ise 6 numaralı modelde, 6 numaralı mimari olan iki yönlü (Bidirectional) GRU mimarisidir. İki yönlü GRU çift yönlü hesaplama yapan iki adet GRU' dan oluşur. Bir GRU diziyi ileri yönde, diğer GRU ise geri yönde hesaplama yapar. Dolayısıyla zaman serisi, metin işleme gibi sıralı problemlerde başarı oranını artırmaktadır. Bu bağlamda 6 numaralı mimaride 0,992 değeri test performansı için GRU modelinin elde edilen en yüksek değerini göstermektedir. Çıkan rakamları görsel olarak da destekleyen kayıp- yinleme grafiği Şekil 3. 16'da, tahmin-gerçek değer grafiği ise Şekil 3. 17'de gösterilmiştir. Tahmin ve gerçek değerlerin birbirine yakın olduğu görülmektedir.

Şekil 3. 16: Ethereum Kayıp - Yineleme Grafiği-GRU



Ethereum için GRU modeline göre yapılan tahmin çalışmasında Şekil 3. 16’ da görüldüğü üzere eğitim sırasında eğitim ilerledikçe hata miktarının da azaldığı görülmektedir. Eğitim ve geçerlilik hata miktarları birlikte azalarak seyretmektedir. Bu bağlamda öğrenmenin normal öğrenme olarak gerçekleştiği görülmektedir.

Şekil 3. 17: Ethereum Tahmin ve Gerçek Değer Grafiği-GRU



Şekil 3. 17’deki grafiğe göre ise eğitilmiş GRU modelinin test sonucu tahmin ettiği veriler ile gerçek verileri aynı grafikte verilmiştir. Farklı iki verinin birbiri ile çok yakın olduğu görülmektedir. Neredeyse örtüşmek üzere olan bu değerler, bu modelin test performansının yüksekliğini ifade emektedir.

3. 6. 3. Ethersum LSTM Uygulaması

Çalışmada yedi farklı model kullanılarak eğitim yapılmıştır (Tablo 3.19). Bu modellerde farklı LSTM ünitesi ve LSTM katmanları ile birlikte LSTM çıktıları tahmine dönüştürmek için farklı dense (YSA) kullanılmıştır.

Tablo 3. 19: Ethersum Veri Seti İçin Farklı LSTM Mimari Modelleri

Model No	Mimari			
	LSTM ünite sayısı	LSTM ünite sayısı	Dense	Dense
1	64	-	-	1
2	128	-	-	1
3	64	-	64	1
4	64	64	-	1
5	64	64	64	1
6	64 Bi LSTM	-	-	1
7	128 Bi LSTM	-	-	1

Tablo 3. 20: Ethersum LSTM Hiper Parametreleri

Parametre	Değeri
Yineleme (epoch)	200
Paket büyüklüğü (back size)	30
Kayıp fonksiyonu (loss function)	MSE
GRU üniteleri aktivasyon fonksiyonu	ReLU
Çıkış katman aktivasyon fonksiyonu	ReLU
Öğrenme algoritması (learning algorithm)	Adam
Seyreltme (dropout)	Yok


Modellerin LSTM ve YSA hiper parametreleri Tablo 3. 20’de gösterildiği gibidir. Model hiper parametreleri olarak; yineleme değeri: 200, paket büyüklüğü: 30, kayıp fonksiyon: MSE, gizli katman aktivasyon fonksiyonu: ReLU, çıkış katman aktivasyon fonksiyonu: ReLU, öğrenme algoritması: adam olarak ele alınmıştır. Ağda herhangi bir seyreltme yapılmamıştır. Model Ethersum için farklı YSA mimarileri ile çalıştırılarak, sistemin performansına etkileri gözlemlenmiştir. Elde edilen veriler Tablo 3. 21’de gösterilmiştir. Tablodan görüleceği üzere tüm modellerin eğitim ve test performansları birbirine yakındır.

Tablo 3. 21: Ethersum Makine Öğrenmesi LSTM Eğitim ve Test Performans Sonuçları

Model No	Eğitim performans				Test performans			
	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	R^2
1	0,032	0,010	1482,9	0,990	0,032	0,023	1477,8	0,989
2	0,032	0,011	1590,6	0,985	0,045	0,033	1584,9	0,979
3	0,032	0,008	937,40	0,994	0,032	0,019	951,1	0,992
4	0,032	0,011	3138,0	0,992	0,032	0,016	3165,4	0,994
5	0,032	0,001	3123,7	0,993	0,032	0,018	3145,6	0,994
6	0,032	0,009	920,95	0,991	0,032	0,022	917,73	0,990
7	0,032	0,008	926,47	0,993	0,032	0,018	923,24	0,993


Farklı LSTM ve YSA ile oluşturulan mimariler ile gerçekleştirilen eğitim ve test sonuçları Tablo 3. 21’de verilmiştir. Tabloya göre eğitim performansı için çıkan en iyi değeri 3 numaralı modelde, 3 numaralı mimari olan 64-64-1 mimarisinde elde edilen değer 0,994’dür. Test performansı için çıkan en iyi değer ise 4 numaralı modelde, 4 numaralı mimari olan 64-64-1 mimarisinde elde edilen değer 0,994’dür. Bu değerler LSTM modelinin elde edilen en yüksek değerlerini göstermektedir. Çıkan rakamları görsel olarak da destekleyen kayıp-yineleme grafiği Şekil 3. 18’de, tahmin-gerçek değer grafiği ise Şekil 3. 19’da gösterilmiştir. Tahmin ve gerçek değerlerin birbirine yakın olduğu görülmektedir.

Şekil 3. 18: Ethereum Kayıp-Yineleme Grafiği-LSTM



Şekil 3.18'deki grafiğe göre eğitim hata ve geçerlilik (validation) değerleri hata miktarları yineleme ilerledikçe birlikte azaldığı görülmektedir. Kayıp ve geçerlilik hata değerlerinin birlikte azalması ve sıfıra çok yakın olması başarılı ve normal bir eğitim işlemi yapıldığının göstergesi olarak kabul edilebilir. Grafiğe göre aşırı öğrenme (overfitting) veya öğrenememe (underfitting) gibi durumlar görülmemektedir.

Şekil 3. 19: Ethereum Tahmin ve Gerçek Değer Grafiği-LSTM



Şekil 3. 19’da ise test verileri ve gerçek değeri ile tahmin edilen değerler birlikte grafik halinde gösterilmiştir. Şekilde görüleceği üzere gerçek değer ile tahmin edilen değer birbirine çok yakın ve nerdeyse örtüşmektedir. Bu da sistemin başarısının yüksekliğini görsel olarak desteklemektedir.

Tablo 3. 22: Ethersum Uygulaması için GRU, LSTM, YSA Performans Değerleri

Model	Eğitim Performans			Test Performans		
	RMSE	MAE	R ²	RMSE	MAE	R ²
GRU	0,032	0,009	0,998	0,032	0,019	0,992
LSTM	0,032	0,008	0,994	0,032	0,016	0,994
YSA	0,010	0,007	0,996	0,010	0,016	0,996

Çalışmada Ethersum için uygulanan yöntemlere göre performans değerlerinde çıkan en iyi değerler Tablo 3. 22’de gösterilmiştir. Tabloda elde edilen değerlere göre GRU modeli için eğitim performans değeri 0,998, test performans değeri 0,992 olarak elde edilmiştir. LSTM modeli için eğitim performans değeri 0,994, test performansı 0,994 olarak elde edilmiştir. YSA modeli için ise eğitim performans değeri 0,996, test performans değeri 0,996 olarak elde edilmiştir. Bu bağlamda ortaya çıkan bu performans değerleri doğrultusunda Ethersum için yapılan tahmin işleminde uygulanan modeller arasında en iyi değeri veren uygulama 0,998 ile GRU modeli olarak görülmektedir.

DÖRDÜNCÜ BÖLÜM

SONUÇ VE ÖNERİ

4. 1. SONUÇ

Para kavramının, ilk çağlardan bu yana insanoğlunun sosyal ve ekonomik gelişimini sağlayabilmeleri ve doğacak farklı ihtiyaçların karşılanabilmesi adına tarih boyunca büyük önem taşıdığı görülmektedir. Bu gelişim sürecinde takas yöntemiyle başlayan ve zamanla değerli madenler ve metal para sistemine geçiş yapan insanlar, kullandıkları sistemin içlerinde yetersiz kaldığını düşündükleri için bir temsili para sistemi icat etmek istemişlerdir. Tarih boyunca incelendiğinde para kavramı, takas, mal, temsili ve kaydi para sistemi gibi süreçlerden geçmiştir. Para sisteminde duyulan bu yetersizlik yeni sistemler ortaya çıkmasında etkili olmuştur. Günümüzde de bu etkinin devam ettiği görülmektedir (Öztürk & Demirhan, 2021).

Çalışmada ele alınan konuda Bitcoin ve diğer kripto paraların da bu etki üzerine ortaya çıktığı görülmektedir. Yaşanan krizler her sistemde olduğu gibi para sistemi üzerinde de değişikliklerin ve yeniliklerin oluşmasına sebep olmaktadır. Özellikle Amerika Birleşik Devleti'nde (ABD) 2008 yılında yaşanan Mortgage Krizi'nin ardından aynı dönemlerde ortaya çıkan kripto para sisteminin, o dönemdeki mevcut para düzeninin aksaklıklarının bir sonucu olmak üzere meydana geldiği düşünülmektedir. Finansal krizlerin oluşturduğu sorunlar mevcut para sisteminde alternatif olarak ve çıkış yolu gözüyle düşünülerek sanal para kavramı gün yüzüne çıkmıştır.

Kullanılmaya başlandığı tarihten itibaren fiyat değişikliği gösteren kripto paralar, ilk büyük fiyat artışını 2013 yılında, ikinci büyük fiyat artışını da 2017 yılının son çeyreğinde gerçekleştirmiştir. Ardından dünyadaki Covid-19 pandemi krizi süreci ve sonrasında Bitcoin ve Ethersum dahil tüm kripto paralara ilgi artmıştır.

Covid-19 pandemisinin yol açtığı sorun ve ihtiyaçlar doğrultusunda bu süreçten etkilenen sanal paralar üçüncü büyük fiyat artışını göstermiştir. 2019 yılının son çeyreğinde toplam kripto para piyasa değeri 200-250 Milyar dolar bandında seyrederken, 2021 yılının ikinci çeyreğinde bu rakam yaklaşık 10 katı seviyelerine ulaşmıştır. Sanal paralar arasında en popüler olan para birimi Bitcoin olduğu düşünülen kullanıcılar için ardından onu Ethereum takip etmektedir. Bitcoin bu süreçte en yüksek fiyat bandına ABD Doları (\$) olarak 17 Aralık 2021 tarihinde çıkarak 48.213,70 \$ değerine ulaşmıştır. Bu tarihten sonraki olumsuz gelişmelerden etkilenen Bitcoin 2022 yılı ilk aylarında 35.070,10 \$ bandına kadar düşüş yaşamış ve Nisan 2022 tarihinde tekrar 45.857,00 \$ bandına yükselmiştir. 1 Temmuz 2022 tarihi itibari ile de 19.224,00 \$ fiyat bandında seyretilmiştir.

Ethereum ise en yüksek fiyat bandına 12 Kasım 2021 tarihinde çıkarak 4.644,43 \$ değerine ulaşmıştır. 2022 yılının başlarında yaklaşık yarı fiyatı bandına düşen Ethereum, 1 Temmuz 2022 tarihi itibari ile 1.065,60 \$ fiyat bandında seyretilmiştir. Kriz dönemlerinde bu fiyat dalgalanmalarının tahmin işlemlerinin yapay zekâ teknolojileri ve farklı bilimsel yöntemlerle yapılabilmesi, finansal anlamda büyük mali kayıplar yaşanmaması adına büyük önem taşımaktadır.

Çalışmada sonuç olarak görülüyor ki, bir finansal krizin ardından ihtiyaca yönelik ortaya çıkarılan yeni para birimleri pandemi veya savaş gibi krizlerin etkisi ile de fiyat olarak dalgalanmalara yol açtığı ya da açabileceği bilindiğinden, kullanıcıları risk alma ya da almama konusunda düşündürmektedir. Çalışmada Bitcoin ve Ethereum için yapılan tahmin işlemlerinde geleneksel tahmin işlemleri dışında YSA ve derin öğrenme modellerinden LSTM ve GRU modelleri kullanılmıştır. Bu çalışma ile aşırı fiyat dalgalanmaları olan endeks tahminlerinde YSA, LSTM ve GRU modelleri arasında anlamlı bir fark olmadığı görülmüştür. Çalışmada kullanılan yapay zekâ modellerinin eğitim ve test R-Kare performans değerleri % 90'nın üzerinde olup % 99'a kadar çıkmaktadır. Bu performans değerlerine bakıldığında iyi bir başarıyı gösterdiği sonucuna varılabilir. Uygulanan modellerde elde edilen sonuçlar Ethereum için Tablo 4. 1 ve 4. 2'de, Bitcoin için Tablo 4. 3 ve 4. 4'de gösterilmiştir.

Tablo 4. 1: Ethereum Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Eğitim Performans Değerleri Tablosu

Model Numarası	Mimari	Eğitim Performans		
		RMSE	MAE	R ²
1	YSA-11-15-1	0,010	0,007	0,996
2	Bi LSTM(64)-Dense(64)-Dense(1)-	0,032	0,008	0,994
3	GRU(64) – Dense(64) – Dense(1)-	0,032	0,009	0,998

Tablo 4. 2: Ethereum Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Test Performans Değerleri Tablosu

Model Numarası	Mimari	Test Performans		
		RMSE	MAE	R ²
1	YSA-11-15-1	0,010	0,016	0,996
2	Bi LSTM(64)-Dense(64)-Dense(1)-	0,032	0,016	0,994
3	GRU(64) – Dense(64) – Dense(1)-	0,032	0,019	0,992

Ethereum için yapılan tahmin çalışmasına ait en yüksek eğitim performans değerleri Tablo 4. 1’de ve en yüksek test performans değerleri sonucu Tablo 4. 2’de gösterilmiştir. Buna göre Ethereum fiyat endeks tahmini için farklı YSA tahmin modellerinde ortaya çıkan sonuçlarda Tablo 4. 1’de 3 numaralı modelde GRU (64)-Dense (64)- Dense (1) mimarisinde en iyi değer olan **0,998** ile **GRU** modeline ait olduğu görülmektedir.

Tablo 4. 3: Bitcoin Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Eğitim Performans Değerleri Tablosu

Model Numarası	Mimari	Eğitim Performans		
		RMSE	MAE	R ²
1	YSA-11-10-1	0,032	0,032	0,894
2	Bi LSTM(128) Dense(1)-	0,032	0,063	0,991
3	GRU(64) – Dense(1)-	0,032	0,071	0,991

Tablo 4. 4: Bitcoin Fiyat Tahmini İçin Farklı Yöntemlere Ait En Yüksek Test Performans Değerleri Tablosu

Model Numarası	Mimari	Test Performans		
		RMSE	MAE	R ²
1	YSA-11-10-1	0,032	0,030	0,917
2	Bi LSTM(128) Dense(1)-	0,063	0,048	0,938
3	GRU(64) – Dense(1)-	0,071	0,055	0,922

Bitcoin için de yapılan tahmin çalışmasına ait en yüksek eğitim performans değerleri Tablo 4. 3’de ve en yüksek test performans değerleri sonucu Tablo 4. 4’de gösterilmiştir. Buna göre Bitcoin fiyat endeks tahmini için farklı YSA tahmin modellerinde ortaya çıkan sonuçlarda Tablo 4. 3’de 2 numaralı modelde Bi LSTM (128) Dense (1) mimarisinde en iyi değer olan **0,991** ile **LSTM** modeline ait olduğu görülmektedir.

Literatüre bakıldığında çalışmaya benzerlik gösteren çalışma, Tanışman vd. (2021) tarafından yapılan çalışma olduğu söylenebilir. Çalışmada çok değişkenli LSTM sinir ağı ve klasik ARIMA zaman serisi modelini kullanarak Bitcoin gelecek zaman fiyat değerinin tahminini yapmışlardır. Yapılan bu çalışma ile kullanılan yöntem ve sonuç bazında benzerlik görülmektedir. Sonuç olarak LSTM yöntemi daha düşük hata oranına sahip bulunmuştur. Yöntem açısından ise Spilak (2018) yılında yaptığı tahmin çalışmasında kullanılacak en güçlü yöntemin LSTM yöntemi olduğu sonucuna ulaşmıştır. Shah ve Zhang (2014), Yang ve Kim (2015), Matta vd. (2015), Atlan vd. (2018), Jang ve Lee (2018), Şahin ve Özkan (2018), Polat ve Akbıyık (2019), Çılgin vd. (2020), Çağlar ve Yavuz (2021) tarafından yapılan çalışmalarda ise tahmin için kullanılan değişkenler, yöntemler ve sonuçlar bu çalışma ile benzerlik göstermemektedir. Bu çalışmada YSA, LSTM ve GRU gibi farklı yöntemler iterasyonel olarak farklı mimari modelleri için yapılmış ve kısa dönem dalgalanmalar durumunda tahmin yapılabilme imkânı araştırılmıştır. Zamansal fiyat endeksi veri setinin yanına işlem hacmi de ayrı bir nitelik olarak veri setine eklenmiştir. Veri seti olarak sadece kriz dönemi verileri alındığından yapay zekâ için az (yaklaşık 1.500-2.000 veri) sayılabilecek veri seti ile çalışılmasına rağmen tatmin edici sonuçlar elde edilmiştir.

Bu çalışmayı diğer çalışmalardan ayıran en önemli özellikleri ise; kriz dönemlerini kapsaması, farklı altyapıya sahip kripto paralar olan Bitcoin ve Ethereum'un bir arada kullanılması, farklı yapay zekâ yöntemleri ile farklı değişken, farklı parametreler ve farklı ağ mimarileri ile fiyat endeksinin tahmin edilmesi olduğu söylenebilir. Literatür başlığı altında yapılan çalışmalar da incelendiğinde, kripto para fiyat tahmininde yapay zekâ yöntemleri ile deterministik yöntemlere göre daha yüksek oranla başarı sağlandığı bu çalışma ile bir kez daha kanıtlanmış olduğu söylenebilir.

Sonuç olarak farklı tarih aralığında farklı kripto paraların fiyat endeksinin farklı modellerle tahmini yapılmış ve çıkan değerlerde Ethereum için en iyi model GRU modeli iken, Bitcoin için LSTM modeli olduğu görülmektedir. Tahmin işlemlerinde Ethereum ve Bitcoin için çıkan değerlerin birbirine yakın değerler olduğu görülmektedir. Yapılan çalışma sonucunda sistemin genelleme yapabilme özelliği olduğu görülmekte ve hiper parametrelerin sistem performansına olumlu

etkisi olduğu düşünülmektedir. Öğretilen sistem yatırımcıya geçmiş 10 günlük veri kullanılarak daha sonraki gün ya da günler için bir tahmin üretebilmektedir. Bu yatırımcıya karar vermede önemli bir öngörü ve destek sağlayacaktır. Ancak fiyat endeksin oluşmasında öngörülebilir ve öngörülemez pek çok faktör bulunmaktadır. Veri olarak endeksin yanında endekse etki edebilecek farklı faktörler de dikkate alınarak eğitimler yapılabilir. Gerçek ortamda fiyat endeksini etkileyen birçok faktör vardır. Dolayısıyla modellerden elde edilecek tahmin bilgisi, karar vericiler için karar verme sürecinde sadece bir bakış açısı sağlamak ve fikir vermek adına kullanılabilir. Yatırım tavsiyesi olarak değerlendirilemez.

4. 2. ÖNERİ

Bu çalışmada öğretilmiş model ile farklı veri setleri için de geçmiş kısa dönem (örneğin 10 günlük) veri ile tahminler yapılabilir. Fiyatların aşırı dalgalı olması durumunda dahi yatırımcıya belirli ölçüde fikirler verebilir. Farklı YSA, LSTM ve GRU mimari modelleri ile denemeler yapılarak daha az parametrelili mimariler ile de iyi sonuçlar alınabileceği, böylece daha az kaynak (işlemci, bellek vb.) ile de tahminler yapılabileceğini göstermiştir. Bu durum aynı zamanda küçük akıllı cihazlarda da kullanılabilir olması dolayısıyla yaygın kullanım imkânı sunacaktır. Konu ile ilgili gelecek dönem çalışmalarında, kullanılan sistem diğer varlık sistemlerine entegre edilebilir. Kullanılacak olan modellerin tahmin performanslarını iyileştirmek için farklı veri setleri ve parametreler kullanılabilir. Farklı etki faktörleri (yorumlar, influencer, haberler, dolar endeksleri, teknoloji, borsa endeksleri, vb.) dikkate alınarak fiyatlara etkisinin analizi araştırmaya açık hususlardır.

Finansal tahminlerin dışında YSA modelleri ile farklı alanlarda da tahmin işlemleri yapılması insan hayatını kolaylaştırmak ve önlem almak açısından oldukça önemli görülmektedir. Ülkemizde ve dünyada doğa olaylarının yol açtığı veya açacağı krizleri önleme gerekliliği ortaya çıkmaktadır. Hava tahminleri, orman yangınları ve özellikle depremler gibi afet ve doğa olayları için de çok daha büyük ölçüde can ve mal kaybına yol açılmaması adına tahmin işlemleri çalışılabilir önemli konu başlıkları olarak görülmektedir.

KAYNAKÇA

Afteniy, M. (2021). Predicting Time Series With Transformer. *Aalto University School Of Science* .

Alpago, H. (2018). Bitcoin'den Selfcoin'e Kripto Para. *Uluslararası Bilimsel Araştırmalar Dergisi* , 411-428.

Altay Topçu, B., & Sümerli Sarıgül, S. (2020). Dünyada ve Türkiye’de Blok Zinciri Teknolojisi: Finans Sektörü, Dış Ticaret ve Vergisel Düzenlemeler Üzerine Genel Bir Değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi* , 27-39.

Atlan, F., & vd. (2018). Bitcoin’in Türkiye Piyasasındaki Değerinin Yapay Zeka Teknikleri ile Tahmini. *International Management Information Systems Conference* .

bitcoin.org. (2009). OCAK 20, 2022 tarihinde bitcoin.org: <https://bitcoin.org/tr/> adresinden alındı

Blockchain Türkiye. (2019, Mart 7). Mart 4, 2022 tarihinde bctr.org: <https://bctr.org/arastirma-sirketlerinin-gozunden-blokszincirin-gelecegi-8127/> adresinden alındı

Blockchain Women İstanbul. (2020, Nisan 23). Ekim 8, 2021 tarihinde Blockchain Women İstanbul: <https://istanbulblockchainwomen.org/> adresinden alındı

Blockgeeks. (2016). Şubat 24, 2022 tarihinde <https://blockgeeks.com/guides/what-is-cryptocurrency>: www.blockgeeks.com adresinden alındı

Bozkurt, Y., & Armağan, E. (2015). Elektronik Para, Sanal Para, Bitcoin, ve Linden Doları'na Hukuki Bir Bakış. *İstanbul Üniversitesi Hukuk Fakültesi Mecmuası* , 173-220.

colah.github. (2015, Ağustos 27). Nisan 07, 2022 tarihinde [www.colah.github.io: http://colah.github.io/posts/2015-08-Understanding-LSTMs/](http://colah.github.io/posts/2015-08-Understanding-LSTMs/) adresinden alındı

cryptonews.com. (2021). Mart 29, 2022 tarihinde [tr.cryptonews.com: https://tr.cryptonews.com/guides/bitcoin-artilari-eksileri.htm](https://tr.cryptonews.com/guides/bitcoin-artilari-eksileri.htm) adresinden alındı

Çağlar, B., & Yavuz, U. (2021). Finansal Haberlerin Bitcoin Fiyatlarına Etkisinin Yapay Sinir Ağları İle Analizi. *Bilişim Teknolojileri Dergisi* , C14 S1.

Çakır, D. S. (2019). *Yapay Sinir Ağları Matlab Kodları ve Matlab Toolbox Çözümleri*. Ankara: Nobel Yayın Grubu.

Çılgın, C., Ünal, C., Alıcı, S., Akkol, E., & Gökşen, Y. (2020). Metin Sınıflandırmada Yapay Sinir Ağları ile Bitcoin Fiyatları ve Sosyal. *MAKÜ-Uygulamalı Bilimler Dergisi* , 4(1), 106-126.

Çınar, R. (2019, Aralık). Derin Öğrenme Yöntemleri ile Lisans Öğrencilerinin Akademik Performanslarına Dayalı Mezuniyet Tahmini. Eskişehir, Türkiye: Ulusal Tez Merkezi.

dive into deep learning. (2019, Temmuz 15). Nisan 11, 2022 tarihinde [d2l.ai: https://d2l.ai/chapter_recurrent-modern/gru.html](https://d2l.ai/chapter_recurrent-modern/gru.html) adresinden alındı

Elman, J. L. (1993). Learning and development in neural networks: The importance of starting small. *Cognition* , 7199.

Er, M. B., & Işık, İ. (2021). LSTM Tabanlı Derin Ağlar Kullanılarak Diyabet Hastalığı Tahmini. *Türk Doğa Ve Fen Dergisi* , Cilt 10, Sayı 1, Sayfa 68-74.

European Central Bank . (2012). Mart 23, 2022 tarihinde Virtual Currency Schemes: <https://www.ecb.europa.eu/pub/pdf/other/virtualcurrencyschemes201210en.pdf> adresinden alındı

Gullapalli, S. (2018). *Learning to Predict Cryptocurrency Price Using Artificial Neural Network Models of Time Series*. Manhattan: Kansas State University.

Hochreiter, S., & Schmidhuber, J. (1997). Long Short Term Memory. *Neural Computation* 9 , 1735-1780.

Jang, H. &. (2018). An Empirical Study on Modeling and Prediction of Bitcoin Prices with Bayesian Neural Networks Based on Blockchain Information. *IEEE Access Vol.6* , 5427-5437.

Jaquart, P., Dann, D., & Weinhardt, C. (2021). Short-Term Bitcoin Market Prediction Via Machine Learning. *The Journal of Finance and Data Science* 7 , 45-66.

Kahraman, M. E. (2022). Blok zincir, Deepfake, Avatar, Kripto para, Değiştirilemez Belirteç (NFT) ve Sanal Evren. *Uluslararası Kültürel ve Sosyal Araştırmalar Dergisi (UKSAD)* , 149-162.

Kamalov vd., F. (2022). Deep learning for Covid-19 forecasting: State-of-the-art review. *Neurocomputing* 511 , 142-154.

Kayman, Ş. (2019). Finansal Ödemeler Sisteminde Blok Zincir ve Dijital Para. Edirne.

Kırbaş, İ. (2018). Blokzinciri Teknolojisi ve Yakın Gelecekteki Uygulama Alanları. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Dergisi* , 75-82.

Kripto Para Araştırma Raporu. (2020). Mart 23, 2022 tarihinde [btk.gov.tr: https://www.btk.gov.tr/uploads/pages/arastirma-raporlari/kripto-para-raporu-5f11dfe709c25.pdf](https://www.btk.gov.tr/uploads/pages/arastirma-raporlari/kripto-para-raporu-5f11dfe709c25.pdf) adresinden alındı

Matta, M. L. (2015). Bitcoin Spread Prediction Using Social and Web Search Media. *In UMAP Workshops* , 1-10.

Metin, S. (2021). *Bilgi Yönetimi ve Blokzinciri Teknolojisi*. Ankara: Gazi Kitabevi.

My Security Analytics. (2021, Haziran 06). Mart 30, 2022 tarihinde [mysecurityanalytics.com](https://mysecurityanalytics.com/kripto-para-ve-suc-iliskisi/adresinden%20alindi): [https://mysecurityanalytics.com/kripto-para-ve-suc-iliskisi/adresinden alındı](https://mysecurityanalytics.com/kripto-para-ve-suc-iliskisi/adresinden%20alindi)

Nakamoto, S. (2008). Bitcoin:A Peer-to-Peer Electronic Cash System. *Journal for General Philosophy of Science* , Eylül 2021 tarinde <https://bitcoin.org/bitcoin.pdf> adresinden alındı.

ntv/teknoloji haberleri. (2021, 09 07). 03 28, 2022 tarihinde [ntv.com.tr](https://www.ntv.com.tr/teknoloji): <https://www.ntv.com.tr/teknoloji> adresinden alındı

Okkay, İ. (2019). Küreselleşen Dünyada Kriz Yönetiminin Önemi. *Avrasya Sosyal ve Ekonomik Araştırmalar Dergisi* , 308-317.

Öztemel, P. (2016). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim.

Öztürk, S., & Demirhan, H. (2021). Bitcoin ve Ethereum'un Türkiye'deki Fiyat Dinamikleri Karşılaştırması. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi* , 11(4), 2110-2119.

Pirinççi, A. E. (2018). Yeni Dünya Düzeninde Sanal Para Bitcoin'in Değerlendirilmesi. *International Journal of Economics Politics Humanities and Social Sciences* .

Polat, M., & Akbıyık, A. (2019). Sosyal Medya ve Yatırım Araçlarının Değeri Arasındaki İlişkinin İncelenmesi:Bitcoin Örneği. *Akademik İncelemeler Dergisi* , 14/1:443-462.

Pulat, A. (2018, Ekim 28). [koinfinans.com/ethereum](https://www.koinfinans.com/ethereum). Mayıs 6, 2022 tarihinde www.koinfinans.com: https://www.koinfinans.com/ethereum-nedir-bitcoin-ile-ethereum-arasindaki-fark-nedir/?gclid=EAIaIQobChMI_Mnf37mb-AIVHJBoCR3fOgoxEAAAYBCAAEgKpnfD_BwE adresinden alındı

Savaş, S. (2020, Mayıs 30). *Derin Öğrenme*. Kasım 6, 2022 tarihinde medium.com: <https://medium.com/yapay-zeka-makine-%C3%B6%C4%9Frenmesi-derin-%C3%B6%C4%9Frenme/derin-%C3%B6%C4%9Frenme-78e3f5d2765> adresinden alındı

Shah, D. &. (2014). Bayesian Regression and Bitcoin. *Allerton conference on communication, control, and computing* , 409-414.

Spilak, B. (2018). Deep Neural Networks for Cryptocurrencies Price Prediction.

Master's thesis, Humboldt-Universität zu Berlin .

stanford.edu. (2019). Nisan 07, 2022 tarihinde [www.stanford.edu: https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks](https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks) adresinden alındı

stringfixer.com/gru. (2016). Nisan 11, 2022 tarihinde [stringfixer.com/tr: https://stringfixer.com/tr/Gated_recurrent_unit](https://stringfixer.com/tr/Gated_recurrent_unit) adresinden alındı

Şahin, E. E. (2018). Asimetrik Volatilitenin Tahmini: Kripto Para Bitcoin Uygulaması. *Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, C.3, S.2 , 240-247.

Şahin, E. E. (2018). Kripto Para Bitcoin: ARIMA ve Yapay Sinir Ağları İle Fiyat Tahmini. *Fiscaoeconomia 2018*, Vol.2(2) , 74-92.

Tanışman, S., Karcıoğlu, A. A., Uğur, A., & Bulut, H. (2021). LSTM Sinir Ağı ve ARIMA Zaman Serisi Modelleri Kullanılarak Bitcoin Fiyatının Tahminlenmesi ve Yöntemlerin Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi* , Özel Sayı 32, S. 514-520,.

tr.investing.com/crypto/bitcoin/chart. (2022). Mart 28, 2022 tarihinde [tr.investing.com: https://tr.investing.com/crypto/bitcoin/chart](https://tr.investing.com/crypto/bitcoin/chart) adresinden alındı

Tübitak Bilgem Uekae. (2018). 2022 tarihinde [tubitak.gov.tr: https://blockchain.bilgem.tubitak.gov.tr/](https://blockchain.bilgem.tubitak.gov.tr/) adresinden alındı

Uludağ Sözlük Galerisi. (2022). Mart 31, 2022 tarihinde [uludagsozluk.com: https://galeri.uludagsozluk.com/g/bilincin-matematiksel-bir-yap%C4%B1-olma-ihhtimali/](https://galeri.uludagsozluk.com/g/bilincin-matematiksel-bir-yap%C4%B1-olma-ihhtimali/) adresinden alındı

Uyan, Ö. (2016). İşletmelerde Kriz Yönetimi Çalışmaları ve İşletmelerin Kriz Öncesi, Kriz Anı ve Kriz Sonrası Yaptıkları Uygulamalara Yönelik Alan Araştırması. *International Conference on Eurasian Economies* , 695.

Yang, S. Y. (2015). Bitcoin Market Return and Volatility Forecasting Using Transaction Network Flow Properties. *In 2015 IEEE Symposium Series on Computational Intelligence* , 1778-1785.