

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME
ALGORİTMALARININ KRİPTO PARA FİYAT TAHMİNİNDE
KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

Müberra Beyza ODABAŞI

Endüstri Mühendisliği Anabilim Dalı

ŞUBAT 2023

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME
ALGORİTMALARININ KRİPTO PARA FİYAT TAHMİNİNDE
KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

Müberra Beyza ODABAŞI

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Merve CENGİZ TOKLU

ŞUBAT 2023

Müberra Beyza ODABAŞI tarafından hazırlanan “Yapay Sinir Ağları Ve Derin Öğrenme Algoritmalarının Kripto Para Fiyat Tahmininde Karşılaştırmalı Analizi ” adlı tez çalışması 08.02.2023 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı:

Jüri Üyesi:

Jüri Üyesi:



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Yapay Sinir Ağları Ve Derin Öğrenme Algoritmalarının Kripto Para Fiyat Tahmininde Karşılaştırmalı Analizi ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete ’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(08/02/2023).

(imza)

Öğrencinin Adı Soyadı

Müberra Beyza ODABAŞI





Eşime ve aileme



TEŞEKKÜR

Çalışmam boyunca bana yol gösteren, beni motive eden, desteğini esirgemeyen, öğrencisi olduğum için gurur duyduğum değerli Doç. Dr. Merve CENGİZ TOKLU'ya teşekkürlerimi sunarım.

Her zaman beni destekleyen, hayatımın her aşamasında bana yardımcı olmaya çalışan, tez süreci boyunca gösterdikleri anlayıştan dolayı canım aileme sonsuz teşekkürlerimi sunarım.

Fikirleri ile bana ışık tutan, benden bilgi ve yardımlarını eksik etmeyen, yapıcı eleştirileri ile tez sürecinde beni olumlu yönde motive eden, her zaman yanımda olan Sefa Nadir YILDIZ'a ve ailesine sonsuz teşekkürlerimi sunarım.

.

Ad Soyad

Müberra Beyza ODABAŞI



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Literatür Araştırması	3
1.2. Hipotez	7
2. METOT	9
2.1. Blok Zinciri	9
2.1.1. Blok zinciri şifreleme	11
2.1.2. Blok zinciri eşler arası ağ (P2P) yapısı	11
2.1.3. Blok zinciri çalışma yapısı	12
2.2. Yapay Sinir Ağları	13
2.3. Derin Öğrenme	19
2.3.1. Uzun Kısa Süreli Bellek (LSTM)	21
3. UYGULAMA	23
3.1. Yapay Sinir Ağlarında Ağ Tasarımı	24
3.2. Yapay Sinir Ağlarında Eğitimi ve Test Edilmesi	28
3.3. Derin Öğrenme ile Tahminleme	35
4. SONUÇ VE ÖNERİLER	51
KAYNAKLAR	55
ÖZGEÇMİŞ	59



KISALTMALAR

CNN	: Evriřimli sinir aęları
DBN	: Derin inanç aęları
DOT	: Polkadot
ETH	: Ethereum
GAN	: Üretken düşman aęları
LSTM	: Uzun kısa süreli bellek
MAE	:Ortalama Mutlak Hata
MLP	: Çok katmanlı algılayıcılar
MSE	:Ortalama Hata Karesi
R	:Korelasyon Katsayısı
RBFN	: Radyal temelli fonksiyon aęları
RBM	: Kısaltılmış Boltzmann makineleri
RNN	: Tekrarlayan sinir aęları
SOM	: Kendi kendini düzenleyen haritalar



SİMGELER

A	: Ağırlık
B	: Girdi
F	: Net
S	: Sabit sayı





TABLO LİSTESİ

Sayfa

Tablo 2.1. İleri ve geri beslemeli yapay sinir ağları	18
Tablo 3.1. Normalize edilmiş veriler.....	24
Tablo 4.1. Dört Girdili Derin öğrenme ve Yapay sinir ağı sonuç değerleri.....	52
Tablo 4.2. Üç Girdili Derin öğrenme ve Yapay sinir ağı sonuç değerleri.....	52





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Ağ yapıları	10
Şekil 2.2. Blok zinciri yapısı.....	12
Şekil 2.3. Yapay sinir ağı model yapısı	14
Şekil 2.4. Doğrusal aktivasyon fonksiyonu grafiği.....	16
Şekil 2.5. Adım aktivasyon fonksiyonu grafiği	16
Şekil 2.6. Sigmoid aktivasyon fonksiyonu grafiği.....	17
Şekil 2.7. Tanjant Hiperbolik aktivasyon fonksiyonu grafiği.....	17
Şekil 3.1. Üç girdili tasarlanan ağ yapısı	26
Şekil 3.2. Dört girdili tasarlanan ağ yapısı.....	27
Şekil 3.3. Dört girdili 10 nöronlu tasarlanan ağ yapısı	27
Şekil 3.4. Üç girdili 10 nöronlu %70 eğitim verili gerçek _ tahmin değeri grafiği	28
Şekil 3.5. Üç girdili 10 nöronlu %70 eğitim verili Epoch _MSE grafiği	29
Şekil 3.6. Üç girdili 10 nöronlu %80 eğitim verili gerçek _ tahmin değeri grafiği	29
Şekil 3.7. Üç girdili 10 nöronlu %80 eğitim verili Epoch _MSE grafiği	30
Şekil 3.8. Üç girdili 10 nöronlu %90 eğitim verili gerçek _ tahmin değeri grafiği	30
Şekil 3.9. Üç girdili 10 nöronlu %90 eğitim verili gerçek _ tahmin değeri grafiği	31
Şekil 3.10. Üç girdili 20 nöronlu %70 eğitim verili gerçek _ tahmin değeri grafiği ..	31
Şekil 3.11. Üç girdili 20 nöronlu %70 eğitim verili Epoch _MSE grafiği	32
Şekil 3.12. Üç girdili 20 nöronlu %80 eğitim verili gerçek _ tahmin değeri grafiği ..	32
Şekil 3.13. Üç girdili 20 nöronlu %80 eğitim verili Epoch _MSE grafiği	33
Şekil 3.14. Üç girdili 20 nöronlu %90 eğitim verili gerçek _ tahmin değeri grafiği ..	33
Şekil 3.15. Üç girdili 20 nöronlu %90 eğitim verili Epoch _MSE grafiği	34
Şekil 3.16. Dört girdili 10 nöronlu %90 eğitim verili gerçek _ tahmin değeri grafiği	34
Şekil 3.17. Dört girdili 10 nöronlu %90 eğitim verili Epoch _MSE grafiği.....	35
Şekil 3.18. Kullanılan Kütüphaneler.....	37
Şekil 3.19. Kullanıcıdan girdileri alan fonksiyonun kodları.....	38
Şekil 3.20. Kullanıcıdan girdileri alan fonksiyonun kodları.....	38
Şekil 3.21. İndeks belirleme, veri setinin atanması, test oluşturma ve grafik oluşturma sağlayan kodlar.....	39
Şekil 3.22. Eğitim ve test seti grafiği oluşturan kod.....	39
Şekil 3.23. %70 eğitim verili -Test ve eğitim verilerinin tarih bazlı dağılımı	40
Şekil 3.24. %80 eğitim verili -Test ve eğitim verilerinin tarih bazlı dağılımı	40
Şekil 3.25. %90 eğitim verili -Test ve eğitim verilerinin tarih bazlı dağılımı	41
Şekil 3.26. Eğitim ve test setini hazırlayan kod.....	41
Şekil 3.27. Modeli hazırlayan ve MSE-Epochs grafiğini gösteren fonksiyon kodları	42
Şekil 3.28. Hata oranlarını ve başarı oranlarını ekranda gösteren fonksiyon kodları	43
Şekil 3.29. Model eğitimini sağlayan kodlar	43
Şekil 3.30. Epochs-MSE grafiği	43

Şekil 3.31. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları	44
Şekil 3.32. İndeks belirleme, veri setinin atanması, test oluşturma sağlayan kodlar.	45
Şekil 3.33. Epochs-MSE grafiği	45
Şekil 3.34. Üç girdili gerçek-tahmin grafiği ve hata/başarı oranları.....	46
Şekil 3.35. Epochs-MSE grafiği	46
Şekil 3.36. Üç girdili gerçek-tahmin grafiği ve hata/başarı oranları.....	47
Şekil 3.37. Epochs-MSE grafiği	47
Şekil 3.38. Üç girdili gerçek-tahmin grafiği ve hata/başarı oranları.....	48
Şekil 3.39. Epochs-MSE grafiği	48
Şekil 3.40. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları	49
Şekil 3.41. Epochs-MSE grafiği	49
Şekil 3.42. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları	50



YAPAY SINIR AĞLARI VE DERİN ÖĞRENME ALGORİTMALARININ KRIPTO PARA FİYAT TAHMİNİNDE KARŞILAŞTIRMALI ANALİZİ

ÖZET

Günümüzün gelişen teknolojisi ile internet üzerinden yapılan işlemlerde artış olmuştur. Bunun bir neticesi olarak verilerde artış olduğu gözlemlenmiştir. Verilerde meydana gelen bu artış ile birçok firma verilerin güvenli bir şekilde saklanması, paylaşılması, kontrolünün sağlanması, yönetilmesine yönelik teknoloji arayışına girmektedir. Güncel teknolojilerden biri de blok zinciri (Blockchain) yapısıdır. Blok zinciri yapısı, dağıtık yapıda bir veri tabanı olup bloklardan oluşmakta olan şifrelenmiş iş takibi sağlamaktadır. Daha şeffaf yapıda olması, hiçbir işlemin değiştirilememesi, yüksek güvenlik yapısı, merkezi yapıda olmaması tercih sebeplerinden olmuştur. Blok zinciri yapısı birçok alanda kullanılabilecek bir teknoloji olup günümüzde en popüler kullanım alanı kripto paralar üzerinde olmaktadır. Değişen teknolojiler ile kripto paralar önemli yatırım araçlarından olup finansal piyasalarda önemli hacme sahip olmuştur. Kripto paralarda işlem sayısının her geçen gün arttığı gözükmemekte olup kripto para fiyatlarında meydana gelen artış ve alt kripto paralarda hızlı yükselişler, alt kripto paralara olan talebi arttırmıştır. Bu çalışmada önemli alt kripto para birimlerinden biri olan Polkadot kripto para birimi üzerinde tahminleme işlemi yapılması amaçlanmıştır. Yapılan çalışmada 20.08.2020 - 27.02.2023 tarihleri arasındaki veriler kullanılmış olup, bu verilere göre çıktı değeri olarak günlük ortalama Polkadot değerlerinin tahmin edilmesi amaçlanmıştır. Girdi değerleri için oluşturulan kümeler iki farklı şekilde oluşturulmuştur. İlk girdi değerlerinde; Polkadot YouTube arama sayısı, Polkadot Google sayısı ve Polkadot hacmi kullanılmıştır. İkinci girdi değerlerinde ise ilk girdi değerlerinden farklı olarak alt kripto paraların lideri Ethereum eklenmiştir. Böylece kurucusu aynı kişi olan Polkadot ve Ethereum kripto para birimlerinin birbirine olan etkisi, daha net bir ifade ile Polkadot para birimi üzerinde Ethereum para biriminin etkisini tespit etme imkânı sağlanmıştır. İki farklı girdi yapısından oluşan bu çalışmada Polkadot para birimi günlük ortalama değerlerinin tahminlenebilmesi için yapay sinir ağlarında çok katmanlı algılayıcılar ile derin öğrenme yöntemlerinden olan uzun kısa süreli bellek yapısı kullanılarak tahminleme çalışması yapılmıştır. Çıkan sonuçlara bakıldığında 0.93 korelasyon katsayısı ile yapay sinir ağlarında 4 girdi kümesinden oluşan değerlerin daha iyi sonuç verdiği gözlemlenmiştir.

Yapılan çalışma ile farklı girdi kümeleri, farklı algoritmalar karşılaştırılarak çıktı değerlerine nasıl etkisi olduğu incelenmiştir.



COMPARATIVE ANALYSIS OF ARTIFICIAL NEURAL NETWORKS AND DEEP LEARNING ALGORITHMS FOR CRYPTO PRICE FORECAST

SUMMARY

With today's developing technology, there has been an increase in transactions made over the Internet. As a result of this, an increase in data has been observed. With this increase in data, many companies are in search of technology for the safe storage, sharing, control, and management of data. One of the current technologies is the blockchain structure. The blockchain structure is a distributed database and provides encrypted business tracking consisting of blocks. In blockchain technology, input parameters turn into meaningless output values with hashing. Thus, it becomes impossible to reach the input value from the output value and the information is stored in a secure and unalterable way. Thanks to the hashing process, this decentralized structure is securely stored in everyone. Blockchain technology works with the encryption structure, and the confirmation that the transaction belongs to itself is done by encryption. With the encryption process, it is ensured that the output values generated as a result of the hashing process are the same for everyone. Blockchain technology, which works with the peer-to-peer structure, allows messaging between computers without a direct connection. It is more transparent, no transaction can be changed, high-security structure and not centralized structure are the reasons for preference. The blockchain structure is a technology that can be used in many areas, and the most popular usage area today is on cryptocurrencies. With the changing technologies, cryptocurrencies are important investment tools and have had a significant volume in financial markets. It seems that the number of transactions in cryptocurrencies is increasing day by day, and the increase in crypto money prices and the rapid rise in sub-crypto currencies have increased the demand for sub-crypto currencies.

In this study, it is aimed to make predictions on Polkadot cryptocurrency, which is one of the important sub-cryptocurrencies. Polkadot cryptocurrency allows people to develop blockchain in their own projects, while parallel chain technology allows multiple transactions to be made at the same time without any disruption in the network. The fact that there is no sequential network structure, but parallel network architecture also allows the transactions to be fast. In the study, the data between 20.08.2020 and 27.02.2023 were used, and according to these data, it was aimed to estimate the daily average Polkadot values as output values. The clusters created for the input values were created in two different ways. In the first input values; Polkadot YouTube search number, Polkadot Google number and Polkadot volume are used. In the second input values, unlike the first input values, Ethereum, the leader of the alt cryptocurrencies, was added. Thus, the effect of Polkadot and Ethereum cryptocurrencies, whose founder is the same person, on each other, more precisely, the effect of Ethereum currency on Polkadot currency has been provided. In this study, which consists of two different input structures, in order to estimate the daily average

values of the Polkadot currency, an estimation study was carried out using multi-layered sensors in artificial neural networks and a long-short-term memory structure, which is one of the deep learning methods.

Artificial neural networks develop algorithms by imitating the functioning of the human brain. In artificial neural networks, there are neurons that process information, just like the human brain. Artificial neural networks consist of a hidden layer, an input layer, and an output layer. The information that is not needed in the hidden layer is excluded, and only important information is defined from the input parameters, allowing the network to operate more efficiently. Artificial neural networks can learn and model complex events. After learning from the first input parameters, artificial neural networks can also make predictions on invisible data. Unlike other estimation methods, neural networks do not impose any restrictions on input parameters.

Deep learning, another algorithm in the study, is a branch of machine learning. Unlike artificial neural networks, it uses many more hidden layers. To obtain correct output data in deep learning algorithms, input data is synchronized with previously learned data. In this way, we compare old information with new information when reaching a conclusion. In deep learning methods, it gives better results as the volume of training data increases. The deep learning algorithms can generate new features from the features in the training dataset without outside intervention. Deep learning algorithm can work with unstructured data. Deep learning algorithms can get better results by gaining experience from their own mistakes. It can check the accuracy of deep learning algorithm predictions/outputs and make necessary corrections. A typical neural network or deep learning model takes days to learn the parameters that define the model. Parallel and distributed algorithms address this hotspot by allowing deep learning models to be trained much faster. Deep learning is highly scalable due to its ability to process huge amounts of data and perform large numbers of computations in a cost and time-efficient manner.

To get the best results in the study, 10 neurons and 20 neurons were tested and used. The cross-validation method was used as the training dataset. Training dataset, 70%, 80%, and 90% of the entire data set was created. When the study was examined, it was seen that the data set consisting of 3 input sets and the data set consisting of four input sets gave better results with 10 neurons and 90% training set. In the data set consisting of 90% training set with 10 neurons, when the input set consisting of four inputs was examined, the correlation coefficient of 0.86036, the Mean Squared Error value of 0.01626 and the Root Mean Squared Error value of 0.12751 were obtained because of the development using the deep learning algorithm. Again, when the study, which consists of four input sets, 10 neuron values and 90% training set, was developed using the multilayer backpropagation algorithm in artificial neural networks, the correlation coefficient value was 0.93944, the Mean Squared Error value was 0.01165 and the Root Mean Squared Error value was 0.10793. When two algorithms consisting of four input sets are compared by looking at the correlation coefficient, it has been observed that artificial neural networks give better results. The same improvement, consisting of 90% training set with 10 neurons, made in artificial neural networks and deep learning algorithms, consisting of four input sets, was made for three input sets. In the data set consisting of three input sets, the correlation coefficient value was calculated as 0.84842, the Mean Squared Error value was 0.018 and the Root Mean Squared Error value was 0.13416 in the development made with the deep learning algorithm. When

the same study was done in artificial neural networks, the correlation coefficient value was calculated as 0.91059, the Mean Squared Error value was 0.01975, and the Root Mean Squared Error value was 0.14053. When two algorithms are compared over the correlation coefficient it has been observed that the best results are given in artificial neural networks in both three-input and four-input. In addition, when the study was examined, it was observed that it gave better results when the study was performed using 10 neurons and 90% training set.

In addition, when the correlation coefficient and mean square error are compared in the study, we see that the correlation coefficient increases as the mean square ratio decreases. When the results were examined, it was observed that the values consisting of 4 input sets gave better results in artificial neural networks with a correlation coefficient of 0.93. With the study, different input sets and different algorithms were compared and their effects on output values were examined.

With the developing technology, the demand for virtual investment instruments is increasing day by day. Along with current technologies, the stock market has also had an important place as an investment tool with a significant volume such as cryptocurrencies. Cryptocurrencies, such as Eft/swift/transfer transactions, that allow transactions to be made quickly without high costs and loss of time, are also extremely safe thanks to blockchain technology. It is important that it is a new technology, not open to speculation, has a dynamic structure, for investors who will invest in cryptocurrencies, they should research the crypto money they will invest with minimum risk and have an idea about the movement of that crypto money. Investors investing in cryptocurrencies make their investments in the short-medium-long term. With the awareness that it is necessary to have an idea about its orientation before investing, an estimation was made on the daily average value of Polkadot cryptocurrency, which is one of the important sub-cryptocurrencies. In the study, different algorithms and different input sets were studied and their effects on development were examined. As seen in the study, it has been observed that different algorithms and input parameters have different success rates. The development has been built in a dynamic structure and is suitable for use in different developments. This study is aimed to have an idea for those who invest in cryptocurrency.



1. GİRİŞ

Güncel teknolojilerden biri olan blok zinciri (Blockchain) teknolojisi, 2008 yılında Satoshi Nakamoto tarafından dünyaya tanıtılmıştır. Herhangi bir merkezi yapısı olmayan blok zinciri yapısı, veri giriş tarihine göre art arda bloklardan oluşmakta olup, her bir blokta işleme ait bilgiler ve önceki bloğun şifrelenmiş koduna ait bilgiler bulunduran, verileri saklamaya yardımcı olan bir veri tabanıdır. Blok zinciri teknolojisinde, her bir blok birbiri ile şifreli olacak şekilde bağlantılı olmasından kaynaklı blok oluştuktan sonra veriler üzerinde değişiklik yapılamamaktadır. Blok zinciri teknolojinin ilk örneği Nakamoto (2008) tarafından “Bitcoin: A Peer-to-Peer Electronic Cash System” isimli çalışması ile dünyaya duyurulmuştur (Yavuz vd. 2020). Blok zinciri teknolojisi ilk olarak kripto paralar üzerinden duyurulduğu için kripto paralarla anılmakla beraber, bu teknoloji verinin yer aldığı birçok alanda kullanıma uygundur.

İlk kripto para birimi olan Bitcoin’ in, 2008-2012 ekonomik krizine ve büyük durgunluğa denk gelmesi bu kriz döneminde toplumlar tarafından devlet ve finansal kurumlara olan güvenin azalması, merkezi bir otoriteye sahip olmayan dağıtık ağ yapısı ile çalışan kripto paralara olan yönelimin artmasına sebep olmuştur. Dijital para birimi olan kripto paralar, tüm işlem adımlarının kaydedilip eşler arası (peer-to-peer) transfer adımlarında kullanılmaktadır. Gerçekleştirilen transfer adımlarında işlemi yapanlar arasında direkt olarak paylaşılabılır ve onaylanabilir olması herhangi bir finans sistemi üzerinden doğrulama adımlarının gerekliliği ihtiyacını ortadan kaldırmıştır.

Kripto paraların hareketli bir yapıya sahip olması kısa-orta-uzun vadeli olarak yatırımcılar tarafından finans sektörü için tercih sebebi olmuştur. Yatırımcılar bu hareketli yapıda doğru şekilde yatırım yapabilmeleri için, kripto paraların yönelimi ile ilgili fikir sahibi olma ihtiyacı hissetmektedirler.

Bu çalışmada önemli alt kripto para birimlerinden olan Polkadot kripto para birimi seçilmiştir. Bunun sebebi ise Polkadot kripto para biriminin diğer kripto para birimlerinden farklı olarak arzı sınırlı değildir. Polkadot kripto para birimi, genel ve

özel şifreleme sistemleri kullanıp, transfer işlemlerinde bir dijital cüzdandan diğerine göndermeye izin veren yapısı vardır. Burada, Polkadot kripto para birimini sadece para alıp vermekten ibaret olmadığını da bilmek gerekir. Polkadot, geliştiricilere kendi projeleri için blok zinciri geliştirmesine imkân tanır. Sahip olduğu parachain (paralel zincir) sistemi sayesinde birden fazla işlemde ağda aksaklık olmadan işlemleri gerçekleşmesine imkân sağlar. Bunun sebebi, Polkadot kripto para biriminin paralel zincir olarak bilinen birkaç zincirdeki verileri ve işlemleri paralel olarak işlemesine izin veren merkezi bir aktarma zinciri tarafından koordine edilmekte olan parçalanmış çok zincirli bir ağ olmasıdır. Parçalı mimari sayesinde ağı ayrı bölümlere ve parçalara ayırır. Diğer blok zinciri teknolojilerinde olduğu gibi tüm ağ boyunca sıralı değil, her bir parça üzerinden paralel olarak işlenmelerine izin vererek işlemlerin verimini artırır. Birden fazla paralel zincir Polkadot kripto para birimine bağlanması sağlanabilir, buna bağlı olarak tüm ağın ölçeklenebilirliği, birlikte çalışabilirliği ve zincirler arası işlevliği önemli ölçüde gelişmiş olup diğer blok zinciri teknolojilerindeki gibi aksaklıklar, yüksek ücret ve uyumsuzluklar ortadan kaldırır.

Polkadot kripto para birimi, birçok blok zincirinin aynı anda çalışmasına imkân sağlar. Birçok ağın aynı anda güvenli bir şekilde çalışmasını sağlayan relay chain (düzenleyici zincir) yapısı, Polkadot kripto para biriminin ana blok zinciridir.

Çalışmada Polkadot kripto para biriminin günlük ortalama değerini tahminlenebilmek için 20.08.2020 - 27.02.2023 tarihleri arasındaki veri seti kullanılmıştır. Kullanılan veri setinde iki farklı girdi kümesi oluşturulmuş olup, ilk girdi kümesinde Polkadot hacim sayısı, Polkadot Google da arama sayısı, Polkadot Youtube arama sayısı bulunmakta olup ikinci girdi kümesinde Polkadot hacim sayısı, Polkadot Google da arama sayısı, Polkadot Youtube arama sayısı, Ethereum günlük ortalama değerleri alınarak Polkadot kripto para biriminin günlük ortalama değeri üzerinde tahminleme işlemi yapılmıştır. Ethereum önemli alt kripto para birimlerinden olup, Polkadot kripto para birimine etkisini ölçmek için iki farklı girdili yapı kullanılmıştır. Çalışmada kıyaslama yapabilmek için yapay sinir ağlarında çok katmanlı algılayıcılar ve derin öğrenme yöntemlerinden LSTM kullanılarak tahminleme yapılmıştır. Yapay sinir ağlarında dört girdili veri seti ile yapılan çalışmanın daha iyi sonuç verdiği gözlemlenmiştir.

1.1. Literatür Araştırması

Gelişen teknoloji ile para transferi işlemlerinde de bekleminin olmadığı, güvenilir, merkeziyetsiz olan kripto paralara talep artmış ve bu kapsamda da literatürde birçok çalışma yapılmıştır.

İlk kripto para birimi olan Bitcoin'in 2008 ekonomik krizine denk gelmesi, o dönemdeki finans sektörlerine olan güvenin azalmış olması, kripto paralara olan talebi arttırmıştır. Bitcoin kripto para birimine ait bilgiler, ilk önce Bitcoin.org ile duyurulmaya başlanmıştır. Kripto paraların herhangi bir finans merkezine bağlı olmaması, illegal işlemlerde de para transferlerini kolaylaştırması, bu alanda da talebi arttırmıştır. Kripto paraların değiştirilemez, dağıtık ağ yapısını kullanan bir teknolojiye sahip olması, bilginin daha güvenli bir şekilde tutulmasına da olanak sağlamaktadır (İşgör, 2019). Kripto paralar, blok zinciri teknolojisini kullanmakta olup, finans sektörü için de yenilikler sunmuştur. Merkeziyetsiz bir yapıda olması sebebiyle kimi ülkelerde yasaklanırken, kimi ülkelerde ise yaygın bir şekilde kullanılmaktadır. Özellikle eft/havale veya swift gibi bir sürecin olmaması, işlemlerin hızlı olması ve düşük transfer ücretleri sebebiyle kripto paralar tercih sebebidir. Devlet destekleri ile kripto paralara yapılacak yasal düzenlemeler ile kripto paralara olan talep de artacaktır (Uysal, 2019). Türkiye'de de son yıllarda kripto paralara talep artmıştır, özellikle risk iştahı yüksek yatırımcıların kripto paralara yöneldiği gözükmektedir. Kripto paralara yatırım yapılırken, sosyal medya gibi mecraların önemi azımsanamaz derecededir. Kripto paralarda fayda beklentisi atmasıyla kripto paralara yatırım artarken, endişe seviyesi artması kripto paralara yatırım yapma oranında düşüş olmadığı gözlemlenmiştir. Türkiye enflasyon oranlarının yüksek olması, işlem maliyetinin düşük olduğu 7/24 işlem yapılabilen kripto paralara talebi arttırmaktadır (Mosmer, 2022). Kripto paralarla ilgili olarak çıkan haberlerin de kripto paralar üzerinde önemli etkisi vardır. Bunlara kategori olarak baktığımızda ise olumlu, olumsuz ve nötr haberlerin kripto paralar üzerindeki etkisi ile kripto paralarla ilgili haberlerin yatırımcılar üzerindeki etkisidir. Özellikle haberlere bakıldığında yüksek oranın olumlu haberlerden oluştuğu gözükmektedir, buna rağmen olumlu haberlerin etkisinin kripto para yatırımcıları üzerinde etkisi az olduğu görülmektedir. Bunun sebebi ise haberlerin yatırımcılar için tek yatırım parametresi olmamasıdır

(Yazgan,2022). Kripto paralara baktığımızda yatırımcılar için merkezi bir otoriteye bağlı kalmadan işlemlerin yürütülebilmesi, yüksek gizlilik, düşük işlem maliyeti, gibi durumlar olumlu etki yaratırken, spekülasyonlarda hızlı değişim göstermesi, yasal bir süreç işletilmemesi, piyasalarda anlık değişimlerin olması yatırımcılar için endişe verici durumlar doğurmaktadır (Büyükdoğan, 2022). Genel duruma baktığımızda kripto paraların piyasa büyüklüğü trilyonları aşmış olup gün geçtikçe dahada büyüdüğü gözükmemektedir. Kripto paralara, gelişmesine katkı sağlayacak yasal düzenlemelerinde yapılması, piyasanın gelişimi için önemli bir faktördür (Ünalır, 2021). Yasal düzenlemelerin olmaması, yasa dışı işlerde kullanılması gibi riskler bulunmasına rağmen dünyada kullanımının giderek arttığı gözükmemektedir. Bu artış incelendiğin de kripto paraların gelecekte de önemli yatırım araçları arasına gireceği gözükmemektedir (Ceylan, 2019). Yatırımcılar, için önemli yatırım araçları arasına giren kripto paraların yatırım yapmadan önce ön görülebilir olması, yönelimi hakkında fikir sahibi olmak yatırım aşamasında önem arz etmektedir. Bununla alakalı literatüre de baktığımızda bu konu da birçok çalışma yapılmıştır.

Salman (2020) çalışmasında önemli kripto para birimlerinden olan Bitcoin kripto para birimi ile ilgili olarak teknik ticaret göstergeleri ve yapay sinir ağları kullanılarak fiyat tahminlemesi yapılmıştır. Çalışmada dolar gibi uluslararası para birimlerinin, kripto paralar üzerindeki etkisi de incelenmiş olup, yapay sinir ağları ile yapılan tahminlemenin daha iyi sonuç verdiği gözlenmiştir.

Pamuk (2019) çalışmasında duygu analizi yöntemlerinden Text Blob Twitter metinleri ve Google verileri girdi parametreleri olarak, çıktı değer olarak Bitcoin kripto para biriminde yapay sinir ağları kullanılarak 5,15,30,45,60 dakikalık tahminlemeler yapmıştır.

Sakız ve Gencer (2017) çalışmalarında Bitcoin fiyat tahminlemesi yapmak için son günlük kapanış verileri kullanılarak aylık ortalama alınmış ve aylık bazlı 3 yılın verilerini kullanmışlardır. Veriler üzerinde normalizasyon işlemleri yapılarak yapay sinir ağlarında ileriye dönük tahminleme yapmışlardır.

Şahin (2018) 2012-2018 tarihleri arasında Bitcoin kapanış fiyatları alarak arıma yöntemi ve yapay sinir ağları ile tahminleme yapmıştır. Yapay sinir ağları ile yapılan tahminlemenin arıma yöntemine göre daha iyi sonuç verdiği gözlemlenmiştir.

Aras (2019) çalışmasında Bitcoin, Ethereum, Ripple ve Litecoin kripto para birimlerinde klasik zaman serileri ve yapay sinir ağları yöntemiyle tahminleme yapmıştır. Sonuçları iyileştirmek için birleştirme yöntemi kullanmış olup en iyi sonuçlar, en yüksek işlem hacmine sahip Bitcoin de olduğu gözlemlenmiştir.

Atlan ve ark. (2020) çalışmalarında Bitcoin, Ripple ve Ethereum kripto para birimlerinin 24 saatlik, 1 haftalık ve 1 aylık verileri kullanılarak bulanık çıkarım sistemi, yapay sinir ağları ve polinomsal eğri uydurma, LSTM gibi farklı yöntemlerle ileriye yönelik tahminleme çalışması yapılmıştır. Kullanılan yapay zekâ yöntemleri karşılaştırılmış olup uyarlamalı bulanık çıkarım sisteminin daha iyi sonuç verdiği gözlemlenmiştir.

Çılgın ve ark. (2020) çalışmalarında sosyal medyanın olumlu ve olumsuz sonuçlarının, Bitcoin fiyatları üzerindeki etkisini araştırmışlar ve bunun için ikili korelasyon yönteminden faydalanmışlardır. Bayes, destek vektör makineleri, lojistik regresyon ve yapay sinir ağları yöntemlerinden faydalanılarak karşılaştırmalı olarak en iyi sonucu elde etmeyi hedeflemişlerdir. En başarılı sonuçlar yapay sinir ağlarında metin sınıflandırma yöntemi olduğunu gözlemlenmişlerdir.

Yavuz ve ark. (2020) çalışmalarında Bitcoin' in 2009-2018 arası kur değerlerini kullanarak tahminleme yapabilmek için, cüzdan kullanım oranları, Bitcoin cüzdanı günlük işlem sayısı, Bitcoin cüzdan işlem hacmini yapay sinir ağları eğitimi için kullanarak Bitcoin fiyatlarında tahminleme yapmışlardır.

Sel (2020) çalışmasında Bitcoin, Ripple, EOS, Tether ve TRON kripto para birimlerinin pandemi döneminde altın fiyatları üzerindeki etkisi Phyton programlama dilinde makine öğrenme modellerinden vektör makineleri, çok değişkenlik karar ağacı ve rasgele orman regresyon modeli yardımıyla en iyi sonuçları tespit edilmeye çalışmıştır. Kripto paralardaki regresyon performansları R2, RMSE, MSE değerleri ile hesaplanmıştır. Vektör makinelerinin daha iyi sonuç verdiği gözlenmiş, ayrıca altın

fiyatları üzerinde kripto para birimlerinden Bitcoin ve Tron pozitif, Tether ve EOS ‘un negatif etkilerinin olduğu çalışma sonucu tespit edilmiştir.

Kartal (2020) çalışmasında makine öğrenme yöntemlerinden k-star algoritması yöntemi kullanarak makroekonomik değişkenlerin Bitcoin üzerindeki etkileri incelenmiş olup, geçmiş verilerden yola çıkarak gelecek dönemde verilerde artış mı azalış mı olacağı tahmin etmeye çalışmıştır. K-star algoritması yönteminin Bitcoin fiyatını tahminleme açısından yetersiz kaldığını gözlemlemiştir.

Sel ve ark. (2020) çalışmasında altın, gümüş, sterlin, euro gibi girdileri kullanarak 2013-2018 yılları arasında Bitcoin’ in günlük kapanış değerleri alınarak tahminleme yapılmıştır. Girdi değişkenler olarak çeşitli yatırım araçları dolar fiyatları üzerinden hesaplanmış olup, yapay sinir ağı yöntemi ile 2019 Ocak ayı Bitcoin fiyatı tahminlemesi 0,99 oranında başarılı tahmin edilmiştir.

Avşar (2020) çalışmasında kripto paraların uluslararası piyasalar üzerindeki etkisini anlayabilmek için LSTM metodu ile kripto paralar üzerinde tahminleme için analiz bulguları incelenmiştir.

Köksal ve ark. (2021) çalışmalarında Bitcoin ile ilgili Twitter üzerinde yapılan olumlu, olumsuz ve nötr yorumları, Python programlama dilinde Lojistik regresyon ve Naive Bayes algoritmaları kullanarak başarı oranları karşılaştırılarak duygu analizi yapılmışlardır. Lojistik regresyonun Twitter’ da bulunan duyguları tahmin etmede daha başarılı olduğunu gözlemlemişlerdir. Sonrasında günlük olumlu Bitcoin tweetleri ile Bitcoin açılış değerleri kullanılıp kapanış değerleri için tahminleme çalışması Doğrusal Regresyon ve Rastgele orman regresyon yöntemleri ile modellenmiş olup rastgele orman regresyonun daha iyi sonuç verdiğini gözlemlemişlerdir.

Demirel ve Hazar (2021) çalışmalarında Bitcoin, ETH ve Ripple kripto para birimlerinin 2016-2020 tarihleri arasındaki geçmiş değerleri destek vektör makine eğitiminde kullanmış olup, BITS 100 endeksin hareketteki yönleri fark edilmiştir. Verilerin doğrusal olarak gerçekleşmesinde ve ikili sınıflandırmada çekirdek fonksiyonu kullanmışlardır. Açılış, kapanış, en yüksek değer, en düşük değer ve günlük değişim verisine göre artış azalış yönleri ikili sınıflandırma ile tespit etmeye çalışmışlardır.

Akay ve ark. (2022) çalışmalarında XRP, BNB ve ETH kripto para birimlerinin 2020-2021 arasındaki verileri alınarak yapay sinir ağı ve LSTM yöntemleri ile tahminleme yapmışlardır. Günlük açılış değeri, günlük en düşük değer ve en yüksek değerleri girdi değişkenleri, günlük kapanış değeri ise çıktı değişkeni olarak almışlardır. Hata ölçütlerinden de faydalanarak gerçeğe en yakın değerlerin yapay sinir ağı ile verildiğini gözlemlemişlerdir.

Demirci (2021) çalışmasında Bitcoin, ETH ve Ripple kripto para birimlerinin LSTM ve GRU algoritmalarından yararlanılarak karşılaştırmalı olarak 30 günlük değerlerinde tahminleme yapmıştır. Tahminlemenin başarı oranı MAPE üzerinden kıyaslamıştır.

Hayradi ve ark. (2022) çalışmasında günlük Polkadot kapanış değerleri kullanılarak fiyat tahminlemesi yapılmıştır. Bunun için destek vektör regresyon algoritması kullanılmış olup, mape performans ölçütü kullanıldığında çalışmanın yüzde 87 başarılı olduğu gözlemlenmiştir.

Bu çalışmada hem girdi olarak veri setleri hem de yapay sinir ağı ve derin öğrenme algoritmaları kıyaslanmıştır. Böylece verinin önemi vurgulanırken, farklı algoritmalar ile kıyaslamada imkânı bulunmuştur. Böyle yapılan çalışma ile dört girdili yapay sinir ağlarında çok katmanlı algılayıcılar için daha iyi sonuç verdiği gözlemlenmiştir.

1.2. Hipotez

Kripto paraların günlük ortalama değerlerinin tahminlemesinde YouTube arama sayısı, Google arama sayısı, Hacim değerleri baz alınarak aşağıdaki sorulara yanıt aranmıştır.

Kripto para tahminlemesinde farklı uygulamalar üzerinden geliştirme yapmanın performansa nasıl etkisi olur? Farklı girdi değerlerinin performansa etkisi nedir? Yapay sinir ağlarında derin öğrenmenin etkisi nedir? Model belirleme kriterleri nelerdir?




2. METOT

2.1. Blok Zinciri

Teknolojinin her geçen gün hızlı bir şekilde geliştiği günümüzde, son yılların önemli teknolojilerinden biri de blok zinciri teknolojisidir. Blok zinciri teknolojisi, toplu bir şekilde tutulan güvenilir, merkeziyetçi yapısı olmayan veri tabanının teknik planıdır. (Tian, 2016). Blok zinciri teknolojisinde bir aracıya ihtiyaç duymadan işlemlerin yapılabilmesi, günümüz koşullarındaki araçlara ödenen yüksek miktarların ve aracı zamanı gibi faktörlerin ortadan kalkmasına olanak sağlamaktadır.

Blok zinciri teknolojisi, ortak sunucuya gerek kalmadan kontrol mekanizmasının tek bir yerde olmadığı, bir işlem yapılmak istendiğinde tek tek yapmaya gerek kalmadan, birden fazla bilgisayar üzerinden işlemlerin yapılabildiği veri tabanı türüdür. Blok zinciri ağ yapısı, dağıtık ağ yapısına sahiptir (Şekil 2.1.). Dağıtık ağ yapısının, çok merkezli ve tek merkezli ağ yapılarından farkı; merkezli ağ yapılarında kullanıcı bilgileri, verilerin işleme adımlarının yürütülmesi gibi olaylar merkezi olan bir sunucu etrafında toplanmaktadır, dağıtık ağ yapısında ise tek veya birkaç merkezi sunucu üzerinde işlem yapmayıp ağı katılan her bir cihaz mini bir merkez görevini üstlenir, böylece dağıtık ağ yapısı bir kişi veya kuruluş tarafından kontrolünün olmadığı merkezi olmayan bir ağ yapısı oluşturmaktadır. Merkezi ağ yapısına sahip olanlarda merkezi ağ yapısına sahip olmayanlarında farklı şekillerde avantajları ve dezavantajları bulunmaktadır. Dağıtık ağ yapısının önemli avantajlarından biri merkezi olan sunucularda siber saldırı, çökme gibi durumlarda tüm veriler etkilenmektedir, dağıtık ağda ise bir merkeze bağlı olmaması düğümlerden birinde sorun meydana gelse bile diğerlerinde bir sorun olmadığı için verileri kullanmaya devam edilebilmesini sağlamaktadır. Ayrıca dağıtık ağ yapılarında her bir düğüm bir merkezi oluşturduğundan isteklere cevap verme süreleri daha kısadır, bu da performans açısından olumlu değerlendirilmektedir. Dağıtık ağ yapılarının bir diğer avantajı ise bir ve birkaç sunucu da veriler saklanmayıp birden fazla noktaya

dağıtıldığından her bir düğümde gizlilik sağlanmış olur. Tabi her teknoloji de olduğu gibi dağıtık ağ yapısının dezavantajları bulunmaktadır, dağıtılmış ağ düğümlerden oluştuğundan ve düğümler birbiri ile iletişim kuramadığında bu daha büyük sorunlara sebep olabilir, ayrıca tek veya birkaç merkeze göre daha yüksek bakım maliyetleri bulunmaktadır. Dağıtık ağ yapısının kullanıldığı para transferi işlemlerin de herhangi bir kontrol mekanizmasının olmaması paraların suç için de kullanılabilirliğinin önünü açmış olup önemli dezavantajlarından biridir.



Şekil 2.1. Ağ yapıları

Blok zinciri teknolojisi kriptografik(şifreleme) anahtar, eşler arası ağ (peer-to-peer) ve ağ da meydana gelen işlemleri depolamaya yarayan bir bilgi işlem aracının bütünüdür. Dağıtık ağ yapısı üzerine kurulu olan blok zinciri teknolojisinde bir bilgi binlerce makinede (düğüm üzerinde) yer almakta olup, bilginin düzgün çalışır ve değiştirilemez olması için şifreleme yapısı büyük önem arz etmektedir.

2.1.1. Blok zinciri şifreleme

Blok zinciri teknolojisi kullanılarak yapılan transfer işlemlerinde bilginin /varlığın hiçbir şekilde değiştirilmemesi gerekmekte olup, bu işlem ögütme (hashing) ile olmaktadır. Ögütme, girdi olarak girilen değerleri çıktı değerinde anlamsız sayı ve harflere dönüştürme işlemidir. Girdi değerinde bir değişiklik yapıldığında çıktıdaki karakter sayısı değişmez iken, sayı ve harfler tamamen değişmektedir. Bunu bilginin orijinalliği aşamasında kullanılmaktadır. Girdi değerini biliyorsanız ögütme işlemi yapılmış sonucu bulabilirsiniz ama çıktı değerinden girdi değeri bulunamamaktadır, bu da merkeziyetsiz olup herkeste olan bilginin güvenli bir şekilde saklanmasını sağlamaktadır.

Blok zinciri teknolojisinde yapılan transfer işlemlerinde transferi yapan tarafın yapılacak işlemin kendisine ait olduğunu ve transferi yapılacak varlığın kendisine ait olduğunu teyit etmesi gerekmekte olup, şifreleme ile olabilmektedir. Ögütme işlemi yapılan çıktı değerlerinin tüm katılımcılarda aynı olmasını sağlayan şifrelemedir. Şifreleme mantığı anahtar ve kilitten oluşmakta olup, anahtar verdiğiniz kullanıcılar sadece transfer işlemindeki bilgiyi görebilmektedir. Anahtar yapı iki şekilden oluşmakta olup bunlardan ilki özel, diğeri ise genel anahtar yapısıdır. Özel anahtar yapısı kullanıcıya has olup kimse ile paylaşılmamaktadır, genel anahtar yapısı ise katılımcıya ait olup tüm dünya ile paylaştığıdır. Genel anahtar da bilginin katılımcıdan geldiği bilinse bile ögütme adımıyla geçtiği için kimse tarafından okunamamaktadır.

Dijitalleşen bu dünyada aracıya ihtiyaç duymadan şifreleme sayesinde güvenli bir şekilde transfer işlemleri gerçekleştirilebilmektedir.

2.1.2. Blok zinciri eşler arası ağ (P2P) yapısı


Eşler arası ağ (Peer-to-Peer) veri paylaşımında kullanılan bir protokoldür. Blok zinciri teknolojinde her düğüm bir sunucu görevi görmesinden kaynaklı, birden fazla bilgisayarın birleşip büyük ölçekli veri paylaşımı yapabilmesini sağlayan eşler arası ağ yapısıdır. Bilgisayarlara yaptıkları ağ bağlantısına göre IP adresi atanmakta olup bu IP adresleri tek merkezi çalışmaktadır. Tek merkezli çalışmasından kaynaklı

bilgisayarlar arasında bağlantı sağlanmamaktadır. Eşler arası ağ yapısında bilgisayarlar arasına bağlantı olmadan mesajlaşmaya olanak sağlamaktadır. Eşler arası ağ yapısında her bilgisayar kendi verilerini depoluyor, ama ağda olan diğer bilgisayarlar bu verilere erişim sağlayabilmektedir. Eşler arası ağ yapısını kullanan bilgisayarlar hem istemci hem sunucu görevini üstlenen kullanıcılardan oluşan bir sanal ağ yapısıdır. Ağda bulunan bir dosya indirilmek istendiğinde de ağdaki diğer bilgisayarlardan bitler halinde dosya alınıp, indirilebilir. Eşler arası ağ yapısında ağda bulunan diğer bilgisayarlardaki veriler ve kullanıcıda bulunan veriler birbiri ile paylaşılabilir.

2.1.3. Blok zinciri çalışma yapısı

Blok zinciri teknolojisinde, merkeziyetsiz bir yapı kullandığı için tüm katılımcılar sistemin kendisini oluşturmaktadır. Blok zinciri yapısı bloklardan oluşmakta olup, yapılan her bir işlem adımında, işlemler blok zincirine kaydedilip blok oluşmasına sebebiyet vermektedir. Blok zinciri teknolojisinde oluşan her bir blok birbiri ile bağlantılı olup, herhangi bir blok üzerinde değişiklik yapılmasına uygun değildir. Blok zincirinin değişiklik yapılmasına izin vermeyen yapısı anahtar kilit yapıya uygun olduğunu göstermektedir.

Blok zinciri yapısında transfer işlemlerinde, transfer adımı çevrimiçi platformda blok olarak temsil edilmekte olup, blok ağ da yer alan tüm kullanıcılara dağıtılır. Gönderinin geçerli olduğu onaylandığında anda blok geri dönülemez bir şekilde zincire eklenmektedir. Zincire eklenme sonrası transfer gerçekleşmiş olur (Şekil 2.2.).



Şekil 2.2. Blok zinciri yapısı

2.2. Yapay Sinir Ağları

Yapay sinir ağları insan beyninin bilgiyi işleme özelliğinden esinlenerek geliştirilmiş, biyolojik sinir sisteminin çalışma şeklini taklit eden mantıksal yazılımlardır. Beynin davranışlarını doğru bir şekilde modelleyebilmek için, fiziksel bileşenlerin tam olarak modellenmesi gerektiği düşüncesi ile türlü yapay hücre ve ağ modelleri geliştirilmiştir (Haykin,1998).

İlk ticari yapay sinir ağının geliştiricisi olan Dr. Robert HechtNielsen' e göre: "Yapay sinir ağı, dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgi işlem sistemidir”.


Bilinen diğer yöntemlere göre farklı hesaplama yöntemleri sunan yapay sinir ağları, bulundukları ortama uyum sağlamalarından, eksik bilgi ile çalışabilmelerinden ve belirli bir hata toleransına sahip olmalarından, kaynaklı birçok uygulamada kullanıldıkları görülmektedir. Yapay sinir ağlarının öğrenme ve genelleme yapabilme özellikleri, esneklik ve güçlü olmalarını sağlamakta olup, bu özellikleri karar verme noktasında vazgeçilmez araçlar haline gelmesini sağlamaktadır. Yapay Sinir Ağları, birçok özelliğine bağlı olarak farklı ve karmaşık problemleri çözmede etkili bir sistemdir. Her problemin çözümüne uygun farklı ağ yapıları vardır. Bu problemler için uygun çözüm ağının hangisi olduğuna karar vermek karar verici tarafından gerçekleşir. Farklı ağlar kullanılabilir. Probleme göre bireysellik gösterebilir (Karaatlı, Helvacıoğlu, Ömürbek, Tokgöz, 2012).

Örüntü tanıma, sistem tanılama, robotik, sinyal işleme, non-linear denetim alanları gibi birçok uygulama alanında yapay sinir ağları yaygın olarak kullanılmaktadır.

Teknik açıdan yapay sinir ağlarının görevi, girdi katmanından giren bilgileri ara katmanda işleyerek yani gelen bilgilerin ağırlık değerleri kullanılarak çıktıya dönüştürmesidir (Yavuz ve Deveci, 2015). Yapay sinir ağlarının girdilerden doğru çıktılar üretebilmesi ağırlıklarının doğru değerler olmasına bağlıdır. Doğru ağırlıkların bulunması işlemine ağırlık eğitimi denir. Başlangıç aşamasında rastgele atanan değerler eğitim sırasında her örnek ağına gönderildiğinde ağırlık öğrenme kuralına göre ağırlıklar değişir. Bu işlemler ağı doğru çıktı değerlerinin üretinceye kadar devam eder.

Bu aşama tamamlandıktan sonra test setindeki örnekler ağı gönderilir ve ağı test setindeki örneklerle doğru cevap verirse ağı eğitilmiş olur.

Yapay sinir ağları girdi katman, gizli katman ve çıktı katmandan oluşmaktadır (Şekil 2.3.).



Şekil 2.3. Yapay sinir ağı model yapısı

Yapay sinir ağları yapısı insan; beynine benzemesinin etkisiyle deneyimlerden yararlanır, hata toleransı vardır, girdi ve çıktı bilgileri verilere ağı öğrenmesi sağlanır.

Yapay sinir ağı yapısı beş temel süreç elemanından oluşmakta olup bunlar:

- Girdi değerleri
- Ağırlıklar
- Toplama (Birleştirme) fonksiyonu
- Aktivasyon fonksiyon
- Çıktı değerleri

Girdi değerleri, yapay sinir ağlarına dışarıdan gelen veriler olup, bu verilerin ağı tarafından öğrenilmesi istenir.

Ağırlıklar, girdi olarak gelen verinin hücre üzerindeki etkisini anlamaya yardımcı olmaktadır. Birleştirme fonksiyonu, bir hücredeki net girdiyi hesaplamakta olup, bunun için geliştirilmiş farklı fonksiyonlar bulunmaktadır. Aşağıda yer alan

denklemlerde bu fonksiyonlara yer verilmiş olup A değeri ağırlığı, B değeri ise girdiyi ifade etmektedir.

Denklem (2.1) ağırlık ve girdi değerlerinin çarpılıp, çıkan sonuçların toplanarak net girdinin bulunduğu toplam fonksiyonudur.

$$Net (Toplam) = \sum_{k=1}^n A_k * B_k \quad (2.1)$$

Denklem (2.2) de ağırlık ve girdi değerleri çarpıldıktan sonra çıkan değerlerin hepsi çarpılıp net girdinin bulunduğu çarpım fonksiyonudur.

$$Net (Çarpım) = \prod_{k=1}^n (A_k * B_k) \quad (2.2)$$

Denklem (2.3) de ağırlık ve girdi değerleri çarpıldıktan sonra çıkan değerlerin maksimumunun alınarak net girdinin bulunduğu maksimum fonksiyonudur.

$$Net(Maksimum) = Max (A_k * B_k) \quad (2.3)$$

Denklem (2.4) de ağırlık ve girdi değerleri çarpıldıktan sonra çıkan değerlerin minimumu alınarak net girdinin bulunduğu minimum fonksiyonudur.

$$Net(Minimum) = Min (A_k * B_k) \quad (2.4)$$

Denklem (2.5) de ağırlık ve girdi değerleri çarpıldıktan sonra çıkan değerlerin pozitif ve negatif değerleri bulunmuş olup, büyük sayı ile net girdinin bulunduğu çoğunluk fonksiyonudur.


$$Net (Toplam) = \sum_{k=1}^n Sgn (A_k * B_k) \quad (2.5)$$

Aktivasyon fonksiyonu, net girdi sinyallerini çıkış sinyallerine çevirmeye yarar. Çıkışa aktarılan değerler üzerinde aktivasyon işlemi yapılmaktadır. Aktivasyon fonksiyonu çıkış sinyallerinin doğrusal olmayanlar için de çalışmasını sağlar. Doğrusal fonksiyonlar tek dereceli polinom olup, yapay sinir ağlarında bizim doğrusal olmayan kısımların da bilinmesi gerekir. Bu yüzden aktivasyon fonksiyonları kullanırız. Aktivasyon fonksiyonları için farklı fonksiyonlar geliştirilmiş olup aşağıdaki denklemlerde bu fonksiyonlar belirtilmiştir.

Denklem (2.6) da doğrusal sorunları çözmeye yarayan, birleştirme fonksiyonundaki net değer çıktısını sabit bir kat sayılı ile çarparak hücrenin çıktısını hesaplan fonksiyon

olan doğrusal (linear) aktivasyon fonksiyonun denklemi yer almaktadır. Doğrusal aktivasyon fonksiyonuna ait grafik Şekil 2.4. 'te yer almaktadır.


$$F_{NET} = S * NET \quad (2.6)$$



Şekil 2.4. Doğrusal aktivasyon fonksiyonu grafiği

Denklem (2.7) yer alan adım aktivasyon fonksiyonunun da belirlenen eşik değerine göre birleştirme fonksiyonunda gelen net değer büyük veya küçük olmasına göre 1 veya 0 çıktı değerleri üretilir. Şekil 2.5. 'te adım aktivasyon fonksiyonu grafiği görülmektedir.


$$F_{NET} = \begin{cases} 1 & \text{if Net} > \text{Eşik Değer} \\ 0 & \text{if Net} \leq \text{Eşik Değer} \end{cases} \quad (2.7)$$



Şekil 2.5. Adım aktivasyon fonksiyonu grafiği

Denklem (2.8) yer alan sigmoid (logSig) aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyon olup 0 ile 1 arasında değer üretmektedir. Şekil 2.6. 'da sigmoid aktivasyon fonksiyonunun grafiği görülmektedir.


$$F_{NET} = 1 / (1 + e^{-NET}) \quad (2.8)$$



Şekil 2.6. Sigmoid aktivasyon fonksiyonu grafiği

Denklem (2.9) yer alan Tanjant Hiperbolik aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyon olup -1 ile 1 arasında değer üretmektedir. Şekil 2.7.'de tanjant hiperbolik aktivasyon fonksiyonun grafiği görülmektedir.

$$F_{NET} = (e^{-NET} - e^{NET}) / (e^{-NET} + e^{NET}) \quad (2.9)$$



Şekil 2.7. Tanjant Hiperbolik aktivasyon fonksiyonu grafiği

Denklem (2.10) yer alan eşik değer aktivasyon fonksiyonun da birleştirme fonksiyonundaki net değer 1' den büyük ise 1, 0' dan büyük 1' den küçük ise Net değeri, 0' dan küçük ise 0 değerini almaktadır.

$$F_{NET} = \begin{cases} 1 & \text{if } Net \geq 1 \\ 0 & \text{if } Net < 1 \end{cases} \quad (2.10)$$

$$F_{NET} = Net \text{ if } 0 < Net < 1$$

$$F_{NET} = 0 \text{ if } Net \leq 0$$

Denklem (2.11) yer alan sinüs aktivasyon fonksiyonu, sinüs fonksiyonuna uygun dağılım gösteren, öğrenilmesi düşünülen olaylarda kullanılmaktadır.

$$F_{NET} = \text{Sin} (NET) \quad (2.11)$$

Yapay sinir ağları iki şekilde ele alınmaktadır:

- İleri beslemeli yapay sinir ağları
- Geri beslemeli yapay sinir ağları

Tablo 2.1.'de ileri ve geri beslemeli yapay sinir ağlarının, karşılaştırması yer almaktadır.

Tablo 2.1. İleri ve geri beslemeli yapay sinir ağları

İleri Beslemeli Yapay Sinir Ağı	Geri Beslemeli Yapay Sinir Ağı
Sinyaller girdi değerlerinden çıkış değerlerine doğru tek yöntemle iletilebilir.	Dinamik yapıda olup, Girdi değişene ve yeni bir denge bulunması gerekene kadar denge noktasında kalır. Ağda döngüler oluşturarak her iki yönde de hareket eden sinyallere sahip olabilir
Döngü yoktur.	Döngü vardır.
Ağırlıklı çıktılar, gizli katmanda eş zamanlı olarak beslenir.	
Gizli katman sayısı isteğe bağlıdır.	
Sonuncu gizli katmanın ağırlıklı çıktıları, ağının tahminini yayınlayan çıktı katmanını oluşturan birimlerin girdileridir.	

2.3. Derin Öğrenme

Derin öğrenme, en az bir adet yapay sinir ağının kullanıldığı, insan beyninin bilgi edinme şeklini taklit eden makine öğrenme türüdür. Nöronlar arası sinyal iletimini sağlayıp birbirine bağlı hücreler gibi davranmasını sağlayarak, farklı durumları öğrenip karar verilmesini sağlayan nöron bütünü, yapay sinir ağlarını oluşturmaktadır.

Tüm derin öğrenme modellerinde yapay sinir ağı olup, her yapay sinir ağının derin öğrenme modeli yoktur. Derin öğrenme algoritmaları en az iki katmana sahiptir, girdi çıktı katmanları da göz önünde bulundurulduğunda durumda toplam dört katmandan oluşmaktadır. Katmanlarda farklı nöron sayıları ve aktivasyon işlemleri olabilmekte olup, her düğüm de sonucu optimize edebilmek için ağırlıklar eğitilmektedir.

Phyton üzerinde yapay sinir ağlarını oluşturmak için kullanılan iki kütüphane olup bunlar Tensorflow ve Pytorch' tur. Tensorflow' un Keras sınıfı sinir ağı oluşturmanın en kolay yolu olup, girdilerin nöronları beslediği ve bu nöronların çıktı sağladığı bir yapı oluşmasını sağlamaktadır. Yapay sinir ağı oluşturmanın farklı yolları olmakta olup Keras sınıfı, katmanlar üzerinde kontrol ve esneklik sağlarken çok girdili ve çıktılı değerleri oluşturmakta da kullanılabilir. Eğitim ve test aşamasında optimize edici (optimizer), kayıp değeri (loss) ve metrikler tanımlanmakta olup, günümüzde optimize ediciler arasında en iyi olan Adaptive Moment Estimation (ADAM) en sık kullanılandır.

Derin öğrenmede kullanılan farklı algoritmalar olup bunlar aşağıdaki gibidir:

- Evrişimli (Konvolüsyonel) Sinir Ağları (CNN)
- Tekrarlayan Sinir Ağları (RNN)
- Uzun Kısa Süreli Bellek Ağları (LSTM)
- Çok Katmanlı Algılayıcılar (MLP)
- Radyal Temelli Fonksiyon Ağları (RBFN)
- Kendi Kendini Düzenleyen Haritalar (SOM)
- Üretken Düşman Ağları (GAN)
- Derin İnanç Ağları (DBN)
- Kısıtlanmış Boltzmann Makineleri (RBM)
- Otomatik kodlayıcılar

Evrişimli sinir ağıları (CNN), ileri beslemeli sinir ağı modeli olup nesne algılama ve görüntü işlemede kullanılmaktadır. Evrişimli sinir ağıları havuz katmanı, doğrultulmuş doğrusal birim katmanı, evrişimli katman ve tamamen bağlantılı katmanlarından oluşmaktadır. Evrişimli katmanda, evrişimi gerçekleştirmeye yarayan birkaç filtre mevcuttur. Doğrultulmuş doğrusal birim katmanında çıktı düzeltilmiş özellik haritası olup, öğeler üzerinde işlem yapmaya yaramaktadır. Havuzlama katmanında düzeltilen özellik haritasının ardından havuzlama katmanı beslenmekte olup, özellik haritasının boyutlarını küçültmeye yaramaktadır. Tamamen bağlantı katmanında havuzlama katmanından gelen matris girdi olarak beslendiği durumda tam bağlantı katmanı oluşmaktadır. Zaman serileri, uydu görüntülerini tanıma gibi birçok alanda kullanılabilmektedir.

Tekrarlayan sinir ağıları (RRN), uzun kısa süreli bellek ağılarından gelen çıktı değerlerinin, girdi olarak girilmesine izin verir ve dahili belleği sayesinde bir önceki girdileri ezberler, böylece döngü oluşmasını sağlayan yapılar oluşur.

LSTM, tekrarlayan sinir ağlarının bir türü olup, uzun vade geçmiş verilere ezberleme ve öğrenme yeteneği vardır. Uzun kısa süreli bellek ağlarında önceki girdileri hatırladıkları için zaman serisi tahminlemesi için önemli bir ağ yapısıdır. Uzun kısa süreli bellek ağıları yapısında bir önceki duruma ait alakasız kısımları unutmaktadır.

Çok Katmanlı Algılayıcılar (MLP), ileri beslemeli sinir ağı olup birçok algılayıcı katmana sahiptir. Giriş katmanını besleyen çok katmanlı algılayıcılar, nöron katmanları sayesinde sinyali tek yönde geçecek şekilde grafiklere bağlar. Çok katmanlı algılayıcılar, girdi katmanla ile gizli katman arasındaki ağırlığın hesaplanmasında kullanılır.

Radyal Temelli Fonksiyon Ağları (RBFN), ileri beslemeli yapay sinir ağı olup aktivasyon işlemlerinde radyal tabanları işlevleri kullanmaktadır. Giriş katmanını besleyen giriş vektörüne sahiptir. Transfer fonksiyonu olarak Gauss' u kullanmakta olup, gizli katmandaki nöronlar ile çıktı katmanının nöronuna olan uzaklığı ile ters orantılı hesaplamaktadır. Sınıflandırma, zaman serisi, regresyon analizi gibi birçok kısımda kullanılmaktadır.

Kendi Kendini Düzenleyen Haritalar (SOM), veri boyutlarında küçülmeye giderek veri görselleştirmeyi sağlamakta olup, yüksek boyutlu görselleştirilemeyen verilere anlam kazandırmaktadır. En olası Girdi vektörün de hangi ağırlıkta olduğunu bulmak için tüm düğümler incelenir ve hak eden düğüm en iyi eşleşen birim olarak isimlendirilir. En iyi eşleşen düğüm çevresini inceler, böylece sayı git gide azalır. Bir düğüm en iyi eşleşen birime ne kadar yakınsa, ağırlık o kadar fazla değişmektedir.

Üretken Düşman Ağları (GAN), sahte veri üretmeyi öğrenen oluşturucu ve yanlış bilgiyi öğrenen ayrımcı olmak üzere iki kısımdan oluşur. Eğitim verilerine benzeyen veri setleri oluşturmaktadır. Sahte veri ile gerçek veri arasında ayırım yapmayı öğrenmekte olup, yerçekimi merceklemeyi simüle etmede, karanlık madde araştırması gibi birçok alanda kullanılabilmektedir. Eğitim sırasında sahte veriler üretilir ayrımcı da bunların yanlış olduğunu söylemeyi öğrenir.

Derin İnanç Ağları (DBN), katmanlar arası bağlantıları olup, Boltzmann makinesi yığıdır. Her katman önceki ve sonraki ile iletişim kurar. Derin inanç ağlarını eğiten açgözlü algoritması olup, üretken ağırlıkları öğrenmek için katman yaklaşım uygular.

Kısıtlanmış Boltzmann Makineleri (RBM), girdi değerleri üzerinden olasılık dağılımını öğrenmekte olup regresyon, boyut azaltma, konu modelleme, iş birlikçi filtreleme gibi alanlarda kullanılmaktadır. Kısıtlanmış Boltzmann Makineleri görünür ve gizli birimlerden oluşmakta olup, görünür birim gizli birime bağlıdır. Görünür birimlerde çıkış düğümü bulunmaz. Kısıtlanmış Boltzmann Makineleri girdi değerlerini dizi sayılarına çevirir, her girdi üzerinde ağırlık ve genel sapma ile birleştirip çıktıyı gizli katmana iletir.

Otomatik kodlayıcılar, ileri beslemeli sinir ağı olup denetimsiz öğrenme problemlerini çözmek için geliştirilmiştir. Girdi verilerini çıkış katmanına kopyalanmasını sağlamaktadır.

2.3.1. Uzun Kısa Süreli Bellek (LSTM)

LSTM, tekrarlayan sinir ağı türüdür. Diğer yinelemeli sinir ağlarından farklı olarak uzun süre hatırlayabilen bellek hücreleri vardır. RNN' nin uzun vadede bellekteki bilgiyi tahmin etmekte zorlandığı, yakın tarihli işlemlerde daha iyi sonuç verdiği

gözükmektedir. Bunlardan farklı olarak LSTM yapısı bilgiyi uzun süre saklayabilmektedir. LSTM, verileri işlemeye yarayan özel bir yinelemeli sinir ağıdır. Geleneksel sinir ağlarında girdi alınır ve bir çıktı üretir, LSTM yapısında ise veriler tekrarlayan şekilde işlenir, ilk adımda girdi alınır ve bu sonraki adımlarda çıktıyı etkilemek için kullanılabilir. Bu yineleme işlem adımları sayesinde LSTM yapılarında veri dizileri öğrenilebilir. Sıralı olan verilerde, uzun vadeli verileri LSTM yapısı öğrenip bellek hücrelerinde tutmaktadır. Bellek hücrelerinde üç adet kapı bulunmakta olup bunlar giriş, çıkış ve unutma kapısıdır. Bellek hücresi ve hücre durumu LSTM yapısını oluşturmaktadır. Giriş kapısında belirli zaman aralığında hücre durumuna ne kadar yeni bilgi eklendiğini kontrol edilir. Burada sigmoid işlevi kullanılarak düzenlenir, belirli zamandaki giriş ve önceki hücre çıkışı kullanılarak hatırlanacak veriler filtrelenir. Tahn işlevi kullanılarak -1 ile +1 arası çıktı veren olası tüm değerleri içeren bir vektör oluşturulur. Sonrasında işe yarayabilecek bilgileri elde etmek için vektör değerleri ve düzenlenmiş değerler çarpılır. Çıkış kapısında ise bu zaman aralığında çıktıyı üretirken hücre durumunda ne kadar bilgi kullanıldığını kontrol eder. Bu adımda tahn fonksiyonu kullanılarak bir vektör oluşturulur. Sonrasında bilgi sigmoid işlevi ile düzenlenir, hatırlanacak değerlere göre filtrelenir. Vektör değerleri ile regüle edilen değerler çarpılır. Bir sonraki hücreye çıktı ve girdi olarak gönderilir. Unutma kapısında ise, geçmiş zaman adımlarında ne kadar bilginin mevcut zaman adımlarında tutulacağı kontrol edilir. İki giriş belirli bir zamandaki giriş ve önceki hücre çıkışı ile beslenir. Bu veri ağırlık matrisi ile çarpılıp önyargı eklenir. Çıkan sonuçlarda ikili çıktı veren aktivasyon fonksiyonundan geçirilir. Belirli bir hücre durumunda çıktı 0 ise bilgi unutulur, eğer 1 ise bilgi saklanır. Hücre durumunda artık işe yaramayan bilgiler unutma kapısına kaldırılır. Hücre durumu ise geçmiş ve şimdiki zamanlardan bilgiler içeren, hafızayı temsil eden bir vektördür.

3. UYGULAMA

Bu çalışmada Polkadot kripto para birimi için yapay sinir ağlarında fiyat modellemesi yapılmıştır.

Polkadot para biriminin de gün bazlı tahminleme yapabilmek için yapay sinir ağlarında çok katmanlı algılayıcılar ve derin öğrenme yöntemlerinden LSTM yapısı kullanılarak geliştirme yapılmıştır.

Bu çalışma yapılırken 20.08.2020 - 27.02.2023 arasındaki veriler kullanılmış olup, nöron sayısı, test ve eğitim verilerindeki sayılar seçilirken çapraz doğrulamadan yararlanılarak değerler seçilmiştir. Çıktı değeri olarak Polkadot 'un günlük ortalama değeri alınmıştır. Ortalama değeri o günkü en yüksek ve en düşük değerlerin ortalaması alınarak hesaplanmıştır.

Girdi parametreleri ise iki farklı şekilde test edilmiştir. Bunun sebebi ise Polkadot kripto para biriminin Ethereum ağından türemiş olması olup, Ethereum kripto para biriminin, Polkadot üzerindeki etkisini görebilmektir.

Bunun için

- İlk girdi parametreleri:
- Google arama sayısı
- YouTube arama sayısı
- Polkadot hacim değeri

İkinci girdi parametreleri:

- Google arama sayısı
- YouTube arama sayısı
- Polkadot hacim değeri
- Ethereum ortalama değeri

Yapılan çalışma ile çıktı değeri olarak Polkadot ortalama değerinin, girdi değişkenlerinden olan Ethereum ortalama değeri katılarak ve katılmadan olmak üzere, iki farklı şekilde tahminlenmesi amaçlanmıştır. Bunun için yapay sinir ağlarında çok

katmanlı algılayıcılar ile derin öğrenmede LSTM yapısı kullanılarak başarı oranı (R2 =korelasyon katsayısı) üzerinden değerlendirme yapılarak karşılaştırma yapılmıştır.

3.1. Yapay Sinir Ağlarında Ağ Tasarımı

Bu çalışmada yapay sinir ağlarında çok katmanlı algılayıcılar kullanılarak giriş parametrelerine göre, çıkış değeri olarak Polkadot günlük ortalama fiyatının yer aldığı model yapısı oluşturulmuştur. Polkadot fiyatlarını tahmin etmede kullanılan bir takım girdi parametreleri bulunmaktadır. Parametrelerde günlük değerler kullanılmış olup, Ethereum ve Polkadot fiyatların da günlük en yüksek ve en düşük fiyatın ortalaması alınarak Polkadot fiyatında tahminleme işlemi yapılmıştır. Tahminleme işlemi yapılmadan önce veri seti üzerinde normalizasyon işlemi yapılmıştır.

Yapay sinir ağını modellerken aktivasyon fonksiyonu olarak sigmoid (LOGSIG) fonksiyonu kullanıldığından dolayı, buradaki formüle göre normalizasyon işlemi gerçekleştirilmiştir. Normalize edilen verilerin sonrasında transpozesi alınmıştır.

Hem doğrusal hem doğrusal olmayan fonksiyonlarda çıktı üretilebiliyor olması, Logsig fonksiyonunu bir tercih sebebi haline getirmiştir. Denklem (3.1) de logsig (sigmoid) fonksiyonu için normalizasyon formülü görülmektedir.

$$X_{\text{norm}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}) \quad (3.1)$$

Normalizasyon işlemi sonucu veriler 0-1 aralığına indirgenmiş olup, Tablo 3.1. 'de normalize edilmiş verilerin bir kısmı görülmektedir.

Tablo 3.1. Normalize edilmiş veriler

Ethereum NM Data	Polkadot NM Data	NM Hacim	NM Youtube	NM WEB
0,63828023	0,82115869	0,1476941	0,7012987	0,20588235
0,73648822	0,73047859	0,26444834	0,06493506	0,29411765
0,64567961	0,60957179	0,17104495	0,28571429	0,30882353
0,72273337	0,72292191	0,18661218	0,46753247	0,22058824
0,81341916	0,91939547	0,32282545	0,07792208	0,13235294
0,944561	0,96473552	0,13485114	0,44155844	0,20588235
1	0,95717884	0,12239735	0,4025974	0,16176471

*Tüm veriler kısıtlı alanlar dolayısıyla gösterilemediği için verilerin bir kısmı örnek olarak verilmiştir.

Polkadot kripto para biriminin günlük ortalama değeri üzerinde tahminleme yapabilmek için, simülasyon ve eğitim verilerinden oluşan girdi ve çıktı kümeleri oluşturulmuştur. Yapay sinir ağlarında çok katmanlı algılayıcılarda yapılan geliştirmede MATLAB programlama dilinden yararlanılmış olup, nntool kısmında “data manager” seçilerek girdi ve çıktılar girilerek bir ağ oluşturulmuştur. Yapay sinir ağlarında birçok model bulunmakta olup, bu çalışmada geri yayılım algoritmasını kullanarak bir tahminde bulunulduğu için “feed-forward backdrop” tipi seçildi. Eğitim fonksiyonu (training function) olarak, tahminlemede en çok kullanılan “traingdx” seçildi. “Adaptation learning function” olarak learngdx seçildi. Tahmin verilerin de daha iyi sonuç verdiği için katman sayısı 2 seçildi.


Bu çalışmada iki katmandan oluşan çok katmanlı algılayıcılar kullanılmıştır. Tasarlanan ağda bulunan yapay sinir ağı hücreleri için birleştirme fonksiyonu olarak toplama fonksiyonu kullanılmıştır. Aktarma fonksiyonu olarak ara katmanda bulunan yapay sinir hücreleri için Sigmoid fonksiyonu, çıktı katmanında bulunan yapay sinir hücreleri içinse, doğrusal fonksiyon kullanılmıştır. Ağın eğitiminde eğitmenli öğrenme dizisi ile hatayı geriye doğru yayan Levenberg-Marquardt geri yayılım algoritması kullanılmıştır.

Polkadot para birimini tahminlemek için yapay sinir ağları çok katmanlı algılayıcı algoritması üzerinde yapılan geliştirmede, iki ayrı kümede girdi parametreleri oluşturularak buna göre ağ yapısı oluşturulmuştur.

Oluşturulan ilk ağ yapısında üç parametreden oluşan Polkadot Google arama sayısı, Polkadot YouTube arama sayısı, Polkadot hacmi girdi değerleri, Polkadot günlük ortalama değeri ise çıktı değerlerini vermektedir.

Geliştirme test edilirken çapraz doğrulama yapılmış olup 10- 20 olmak üzere sırayla farklı nöron değerleri ve %70-%80-%90 eğitim verisi olacak şekilde karşılaştırma test yapılmıştır.


Üç girdili tasarlanan ağı yapısı şekil 3.1.'de gösterilmiştir.



Şekil 3.1. Üç girdili tasarlanan ağ yapısı


Yapay sinir ağları çok katmanlı algılayıcı algoritması üzerinde oluşturulan ikinci ağ yapısında, dört girdi parametreden oluşan Polkadot Google arama sayısı, Polkadot YouTube arama sayısı, Polkadot hacmi, Ethereum günlük ortalama değeri girdi değerlerini, Polkadot günlük ortalama değeri ise çıktı değerini vermektedir.

Dört girdili tasarlanan ağın yapısı şekil 3.2.'de gösterilmiştir.



Şekil 3.2. Dört girdili tasarlanan ağ yapısı

Şekil 3.3.' te dört girdili 10 nöronlu tasarlanmış ağ yapısı bulunmaktadır. Üç girdili ağ yapısında farklı olarak input değeri 3 parametreden oluşmaktadır.



Şekil 3.3. Dört girdili 10 nöronlu tasarlanan ağ yapısı

Ara katmanda kullanılan aktarım fonksiyonun yapısı sebebiyle veriler -1 ile 1 aralığında normalleştirilmiştir.


MSE (ağın tahmin ettiği ile gerçek verinin farkının karelerinin toplamı) değerlerinin minimum olması amaçlanmıştır.

R (korelasyon katsayısı) değerleri -1 ile 1 arasında değişen değerler olup, ne kadar 1'e yakınsa o kadar iyidir. R değeri eksi olduğu zaman gerçekleşen değerler ile tahmin edilen değerleri arasında ters orantı var demek olup, bu istenmeyen durumdur. Sıfırda gerçek değerle tahmin değerleri arasında hiç ilişki yok demek olup, bu da istenmeyen bir durumdur.


3.2. Yapay Sinir Ağlarında Eğitimi ve Test Edilmesi

Ağın eğitilmesi aşamasında dört girdili ve üç girdili olmak üzere iki farklı girdi kümesi oluşturulmuştur. Çıktı değerlerinde hangi değerlerde daha iyi sonuç verdiğini gözlemlemek için çapraz doğrulama yöntemi kullanılmıştır. Bunun için 10 ve 20 nöron değerleri seçilerek test edilmiştir. Ayrıca 20.08.2020- 27.02.2023 arasındaki veriler için %70 - %80 - %90 oranlarında eğitim datası olacak şekilde test edilmiştir.

Test sonuçlarına baktığımızda ise, Şekil 3.4'te 3 girdi parametresinden oluşan veri setinde, 10 nöronlu %70 eğitim seti oranına göre grafiği kontrol ettiğimizde 'Traning R' değeri 0.97214, 'Validation R' değeri 0.92212, 'Test R' değeri 0.73158 iken 'All R' değeri ise 0.91656'dır. Şekil 3.4.'e ait epoch mse grafiği ise Şekil 3.5. 'te gözükmemektedir.




Şekil 3.4. Üç girdili 10 nöronlu %70 eğitim verili gerçek _ tahmin değeri grafiği




Şekil 3.5. Üç girdili 10 nöronlu %70 eğitim verili Epoch_MSE grafiği

Şekil 3.6’da 3 girdi parametresi ,10 nöron ve %80 oranındaki eğitim seti için grafik incelendiğinde ‘Training R’ değeri 0.93238, ‘Validation R’ değeri 0.97641, ‘Test R’ 0.81367 iken ‘All R’ değeri ise 0.91656’dır. Şekil 3.7.’de ise Şekil 3.6.’ a ait epoch mse grafiği gözükmemektedir.




Şekil 3.6. Üç girdili 10 nöronlu %80 eğitim verili gerçek _tahmin değeri grafiği




Şekil 3.7. Üç girdili 10 nöronlu %80 eğitim verili Epoch_MSE grafiği

Şekil 3.8’te 3 girdi parametresinden oluşan veri setinde, 10 nöronlu %90 eğitim seti kullanıldığında ‘Training R’ değeri 0.92457, ‘Validation R’ değeri 0.94145, ‘Test R’ değeri 0.90657 iken ‘All R’ değeri 0.92081’dir. Şekil 3.9. ‘da Şekil 3.8.’e ait epoch mse grafiği görülmektedir.




Şekil 3.8. Üç girdili 10 nöronlu %90 eğitim verili gerçek _tahmin değeri grafiği




Şekil 3.9. Üç girdili 10 nöronlu %90 eğitim verili gerçek _ tahmin değeri grafiği

10 nöronlu işlem adımlarında yapılanlar 20 nöronlu içinde yapılmıştır. Şekil 3.10'da 20 nöronla %70 eğitim verisi kullanılarak çıkan grafik incelendiğinde 'Training R' değeri 0.94048, 'Validation R' değeri 0.78926, 'Test R' değeri 0.9475 iken 'All R' değeri 0.91059'dur. Şekil 3.11.'de Şekil 3.10.'a ait epoch mse grafiği gözükmemektedir.




Şekil 3.10. Üç girdili 20 nöronlu %70 eğitim verili gerçek _ tahmin değeri grafiği




Şekil 3.11. Üç girdili 20 nöronlu %70 eğitim verili Epoch_MSE grafiği

Şekil 3.12’de Üç girdili 20 nöronlu, %80 eğitim verisinden oluşan grafik incelendiğinde ‘Training R’ değeri 0.95548, ‘Validation R’ değeri 0.97673, ‘Test R’ değeri 0.3744 iken ‘All R’ değeri 0.91059’dur. Şekil 3.13.’te Şekil 3.12.’de yer alan grafiğin epoch mse grafiği görülmektedir.




Şekil 3.12. Üç girdili 20 nöronlu %80 eğitim verili gerçek_tahmin değeri grafiği




Şekil 3.13. Üç girdili 20 nöronlu %80 eğitim verili Epoch_MSE grafiği

Şekil 3.14'te Üç girdili 20 nöronlu, %90 eğitim verisinden oluşan grafik incelendiğinde 'Training R' değeri 0.88966, 'Validation R' değeri 0.91949, 'Test R' değeri 0.97199 iken 'All R' değeri 0.91059'dur. Şekil 3.15.'te Şekil 3.14.'te yer alan grafiğin epoch mse grafiği görülmektedir.




Şekil 3.14. Üç girdili 20 nöronlu %90 eğitim verili gerçek _tahmin değeri grafiği




Şekil 3.15. Üç girdili 20 nöronlu %90 eğitim verili Epoch_MSE grafiği

Şekil 3.16.'da dört girdili 10 nöronlu, %90 eğitim verisinden oluşan grafik incelendiğinde 'Training R' değeri 0.93206, 'Validation R' değeri 0.97257, 'Test R' değeri 0.92866 iken 'All R' değeri 0.93944'tür. Şekil 3.17.'te Şekil 3.16.'da yer alan grafiğin epoch mse grafiği görülmektedir.



Şekil 3.16. Dört girdili 10 nöronlu %90 eğitim verili gerçek _tahmin değeri grafiği



Şekil 3.17. Dört girdili 10 nöronlu %90 eğitim verili Epoch_MSE grafiği

Eğitim veri seti oranı arttıkça başarı oranı da artmaktadır. Aynı adımlar 4 girdili veri seti için de yapıldığında 10 nöron %90 eğitim seti için daha iyi sonuç verdiği gözlemlenmiştir. Sonuçlara baktığımızda yapay sinir ağlarında 4 girdili 10 nöronlu %90 eğitim setinin olduğu 0.93944 değeri ile daha iyi sonuç verdiği gözlemlenmiştir.

3.3. Derin Öğrenme ile Tahminleme

Derin öğrenme, insan beyni işlevinden ilham almış yapay sinir ağlarını kullanan algoritmalarla alakalı makine öğreniminin bir alt dalıdır (Tuncer, 2022). Derin öğrenme yapay zekânın eğitilmesine olanak sağlayarak belirlenen girdi değerlerine göre, çıktı değerlerinin tahmin edilmesini sağlamaktadır.

Bu çalışmada kullanılan algoritmalarından bir diğeri olan derin öğrenme yöntemlerinden LSTM kullanılarak, Anaconda Navigator uygulaması üzerinden Jupyter Notebook da Python 3 programlama dilinde geliştirme yapılmıştır. Polkadot fiyat tahmini için yapılan geliştirmede farklı kütüphaneler kullanılmıştır.

Şekil 3.18’de de gözüktüğü üzere geliştirmedeki metotları kullanabilmek için eklenen kütüphaneler numpy, pandas, matplotlib, sklearn, tensorflow kütüphaneleridir.

Numpy, çok boyutlu dizi nesneleri, matrisler ve lineer cebir işlemlerini destekleyen matematiksel işlevlerin eklendiği bir kütüphanedir. Çeşitli matematiksel işlemlerde kullanılabilen matrisler gibi varyasyonların yanı sıra çok boyutlu dizi nesneleri sağlamaktadır.

Ayrıca numpy matplotlib, pandas gibi çalışmada kullanılan Python paketleri ile uyumlu çalışmaktadır. Numpy işlemleri ve dizileri vektörel hale getirmekte olup,

kodda açık bir döngü veya indeks oluşturmayıp standart matematiksel gösterime benzetmektedir.

Şekil 3.18.'de gözüktüğü üzere numpy kütüphanesi, np kısaltmasıyla tanımlanmıştır. Numpy, matris ve lineer cebir işlemleri için kullanılmakta olup bu çalışmada yapay zekânın eğitilmesi için oluşturulan veri setini matrise dönüştürülmesin de kullanılmıştır.

Pandas, numpy üzerine inşa edilmiş bir kütüphane olup, oluşturulan veri kümelerindeki işlemleri bölmeye, birleştirmeye, zaman serileri işlevselliği kazandırmaya ve verilerin analiz edilmesini sağlar. Şekil 3.18.' de gözüktüğü üzere pandas kütüphanesi pd kısaltmasıyla tanımlanmış olup, veri seti okuma, veri seti indeks belirleme, model tahmini yaptıktan sonra kullanılmıştır.

Matplotlib matematiksel grafik oluşturmak üzere oluşturulmuş bir kütüphanedir. Şekil 3.18.'de gözüktüğü üzere kütüphanede bulunan pyplot, plt kısaltmasıyla kullanılmıştır. İçeri aktarılan modül alınan verileri bir araya getirerek hata oranı, Epoch değeri, para birimi gibi x ve y axisleri ile spesifik tanım ve görüntü kümesi belirlenerek histogram grafiği oluşturmak amacıyla kullanılmıştır.

Sklearn, Python da makine öğrenmesi yapabilmek için geliştirilmiş veri analizi kütüphanesidir. Numpy, pandas ve matplotlib kütüphaneleri ile uyumlu çalışabilmektedir. Sınıflandırma, regresyon, kümeleme gibi karar verme yöntemlerini içerir. Tahminlemeye dayanalı analizi destekleyen bir algoritma olup bu çalışmada tahminleme sonucu başarı oranlarının gösterildiği aşamada kullanılmıştır. Şekil 3.18.' de gözüktüğü üzere sklearn kütüphanesinde bulunan r2_score modülü alınmıştır.

Tensorflow kütüphanesi derin öğrenmede özellikle ağın eğitiminde kullanılmaktadır. Bir veri girildiğin de sonraki aramada verinin ne olacağını tahmin etmeye yaramaktadır. Tensorflow kütüphanesi kullanılarak katman ve model birleştirilmesi, Epoch, kayıp işlev, optimize gibi parametreleri yapılandırma ve eğitim verisi ile modelin beslenmesin de kullanılmaktadır.

Adaptive Moment Estimation (ADAM), optimizasyon işlemi olup uyarlanabilir moment tahminlerine dayalı amaç fonksiyonları optimize etmeye yaramaktadır.

```

: import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.metrics import r2_score
from tensorflow.keras import layers
from sklearn.metrics import mean_absolute_error
from sklearn.metrics import mean_squared_error
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Activation, Dense, Dropout, LSTM

SCREENLENGTH = 5
DATASETDAYS = 922 # Between 922 days 2020-08-20 00:00:00 - 2023-02-27 00:00:00
AIM = 'NMDATA|'
LOSS = 'mse'
OPTIMIZER = 'adam'
ACTIVATION = 'linear'

```

Şekil 3.18. Kullanılan Kütüphaneler

Şekil 3.19.'da yer alan fonksiyon ile kullanıcıdan test yapılacak coin adı alınır. coin_name parametresin de Polkadot kripto para biriminin kısaltması olan DOT adını kullanıldı. “data_set_file_name” parametresin de, bilgisayarınıza kaydettiği veri setinin oluştuğu csv dosyası eklenir.

“batch_size “ parametresin de, yapılan geliştirmede modelin eğitilmesi sürecinde aynı anda kaç adet verinin işleneceğine karar verilir. Burada sayıyı büyük tutup, eğitim süresini kısaltılabilir, ama bu durumun performansı etkileyeceği göz önünde bulundurmak gerekmektedir. Burada ikinin üstel değerlerini almak başarı oranını etkilemektedir. Çalışmada batch size değeri 2 alınmıştır.

Epochs parametresinde girilen değer döngü sayısını ifade etmekte olup, eğitim sırasında veri setinin ağı bir kere gidip gelme sayısını ifade etmektedir. Bu çalışmada Epochs değerini 1000 kullanıldı.

‘Training Percentage’ değeri eğitim için ne kadar oranlık bir veri seti alınması gerektiği ile ilgili oran girilmesi beklenmektedir. Bu çalışmada %70-%80 ve %90 olmak üzere farklı eğitim seti oranları ile test yapılmıştır.

‘Cells ‘ değeri hücre sayısı olup çalışmada çapraz doğrulama yapmak için 10 ve 20 değerleri için çalışma yapılmıştır.

‘Dropout’ değeri ise eğitim sırasında aşırı öğrenmeyi engellemek için bazı nöronları unutmada kullanılmaktadır. Bu oranı düşük tutmak başarıyı arttıracaktır.

```
# Bu fonksiyon kullanıcıdan coin adı, data set dosyasını, batch size ve epoch değerlerini alır.
def show_menu():
    coin_name = input("Coin adı: ")
    data_set_filename = input("Dosya adı : ")
    batch_size = int(input("Batchsize : "))
    epochs = int(input("Epochs : "))
    training_percentage = int(input("Training Percentage : "))
    cells = int(input("Cells : "))
    dropout = float(input("Dropout : "))
    return coin_name, data_set_filename, batch_size, epochs, training_percentage, cells, dropout
```

Şekil 3.19. Kullanıcıdan girdileri alan fonksiyonun kodları

Şekil 3.19.'da yer alan show_menu fonksiyonu, Şekil 3.20.'de gözüktüğü üzere çağırılır. Burada kullanıcıdan belirtilen parametreleri ekrana yansıyan pencerede giriş yapmaları beklenmektedir.

Şekil 3.20.' de gözüktüğü üzere parametre girişleri yapılmıştır. Bu çalışmada Cells değeri 10 ve 20 olarak girilmiş ayrıca Training Percantage değeri 70-80-90 girilerek sırasıyla test yapılmıştır. Üç ve Dört girdili veriler csv formatında olup dosya adı kısmında sisteme yüklemesi yapılmıştır.

```
# show_menu fonksiyonunu çağır ve kullanıcıdan alınan girdileri değişkenlere ata
coin_name, data_set_filename, batch_size, epochs, training_percentage, cells, dropout = show_menu()
COIN = coin_name
EPOCHS = epochs
BATCHSIZE = batch_size
TRAININGPERCENTAGE = (int)((DATASETDAYS*training_percentage)/100)
CELLS = cells
DROPOUT = dropout

Coin adı: DOT
Dosya adı : DOT.csv
Batchsize : 2
Epochs : 1000
Training Percentage : 70
Cells : 10
Dropout : 0.1
```

Şekil 3.20. Kullanıcıdan girdileri alan fonksiyonun kodları

Şekil 3.21.'de yer alan fonksiyon data set dosyasını alıp açar ve csv dosyasında yer alan başlıkları data set değişkenine atamasını yapar. Csv dosyasında da yer alan date alanı indeks olarak belirlenmiştir. Eğitim ve test verilerini belirlemek için, data_set değişkeninden TRAINANDTEST' e göre train_set ve test_set belirlenerek geri döndürülür. Eğitim verisi ve test verisini oluşturmak için, load_data_set methodu çağırılarak train_set, test_set oluşturulmuştur. Show_on_screen fonksiyonu ile oluşturulan grafiklerin ekranda nasıl gözükeceği belirlenmiştir.

```

# Bu fonksiyon parametre olarak data set dosyasının adını alır. Dosyayı açar ve data_set değişkenine atar.
# Index olarak date alanı belirlenmiştir.
# data_set değişkeninden TRAININGPERCENTAGE'e göre train_set ve test_set belirlenerek geri döndürülür.

def load_data_set(filename):

    data_set = pd.read_csv(filename)
    data_set = data_set.loc[:,['DATE', 'NMMETHEREUM', 'NMMDATA', 'NMMHACIM', 'NMMYOUTUBE', 'NMMWEB']]
    data_set = data_set.set_index('DATE')
    data_set.index = pd.to_datetime(data_set.index, unit='ns')
    test_set = data_set.iloc[TRAININGPERCENTAGE:]
    train_set = data_set.iloc[:TRAININGPERCENTAGE]

    return train_set, test_set

# Load_data_set methodu çağırılarak train_set, test_set oluşturulur.

train_set, test_set = load_data_set(data_set_filename)

# Bu fonksiyon grafikleri ekranda gösterir.

def show_on_screen(line1, line2, label1=None, label2=None, title=''):

    fig, ax = plt.subplots(1, figsize=(13, 7))
    ax.plot(line1, label=label1, linewidth=3)
    ax.plot(line2, label=label2, linewidth=3)
    ax.set_ylabel(COIN + '/USD', fontsize=14)
    ax.set_xlabel('DATE', fontsize=14)
    ax.set_title(title, fontsize=16)
    ax.legend(loc='best', fontsize=16)

```

Şekil 3.21. İndeks belirleme, veri setinin atanması, test oluşturma ve grafik oluşturma sağlayan kodlar

Şekil 3.22.'de yer alan show_on_screen fonksiyonu ile data seti üzerinden oluşturulan eğitim ve test grafiği ekranda gösterilmektedir.

```

# Data set üzerinden oluşturulan eğitim ve test set grafiğini ekranda göster.


show_on_screen(train_set[AIM], test_set[AIM], 'training', 'test', title='TRAIN AND TEST SET')

```


Şekil 3.22. Eğitim ve test seti grafiği oluşturan kod

Şekil 3.23.'de yer alan ekran görüntüsün de gözüktüğü üzere, Şekil 3.20.'de yer alan TRAINANDTEST değerine bağlı olarak eğitim ve test dağılımını tarih bazlı göstermektedir.


Şekil 3.23.'te %70 eğitim seti var iken, Şekil 3.24.'te %80 eğitim seti, Şekil 3.25.'te ise %90 eğitim seti bulunmaktadır.



Şekil 3.23. %70 eğitim verili -Test ve eğitim verilerinin tarih bazlı dağılımı



Şekil 3.24. %80 eğitim verili -Test ve eğitim verilerinin tarih bazlı dağılımı



Şekil 3.25. %90 eğitim verili -Test ve eğitim verilerinin tarih bazlı dağılımı

Şekil 3.26.'da yer alan prepare_date_set metodu ile eğitim ve test verileri hazırlanmıştır.

```
# Eğitim ve test seti hazırlanırken prepare_data_set() methoduna yardımcı olarak kullanılır.
def prepare_test_train_set(data):
    result = []
    for i in range(len(data) - SCREENLENGTH):
        value = data[i: (i + SCREENLENGTH)].copy()
        value = value / value.iloc[0] - 1
        result.append(value.values)
    return np.array(result)

# Eğitim ve test setini hazırla
def prepare_data_set():
    train_set_x = prepare_test_train_set(train_set)
    test_set_x = prepare_test_train_set(test_set)

    train_set_y = train_set[AIM][SCREENLENGTH:].values
    test_set_y = test_set[AIM][SCREENLENGTH:].values

    train_set_y = train_set_y / train_set[AIM][: -SCREENLENGTH].values - 1
    test_set_y = test_set_y / test_set[AIM][: -SCREENLENGTH].values - 1

    return train_set, test_set, train_set_x, test_set_x, train_set_y, test_set_y
```

Şekil 3.26. Eğitim ve test setini hazırlayan kod

RNN, tekrarlayan sinir ağı olup, işlemlerin daha kalıcı olması için kendi içinde bir döngü yapısında çalışmaktadır. Veri setinde bulunan değer nörona verildiğinde tahmin üretilmektedir. Bu tahmin daha sonraki gelen veri ile tekrar giriş yapıp, tekrar kullanılmaktadır. Kısaca çıkan sonuç bir sonrakini beslemektedir. LSTM tekrarlayan sinir ağlarının farklı bir sürümü olup, hafızadaki geçmiş verileri hatırlamayı sağlar. LSTM modeli geri yayılım algoritması olarak eğitmekte olup, zaman serileri ile sınıflandırmada tahmin edilmesinde uygundur. Şekil 3.27.'de gözüktüğü üzere bu çalışmada LSTM kullanıldı. Aktivasyon fonksiyonu olarak Şekil 3.27.'de gözüktüğü üzere lineer kullanılmıştır. Aktivasyon fonksiyonu ile nöronun aktif olup olmadığı anlaşılmaktadır. Şekil 3.27.'de gözüktüğü üzere LSTM, aktivasyon, optimizasyon için modelinin hazırlandığı fonksiyon yer almaktadır.

Şekil 3.27.'de yer alan show_model_fit eğitilen modelin hata oranlarını ekrana yansıtılmasını sağlamaktadır.

```
# Bu fonksiyon modeli hazırlar.
# LSTM kullanılmıştır. Optimizer 'adam', Activation 'Linear'.

def prepare_model(data):
    model = Sequential()
    model.add(LSTM(CELLS, input_shape=(data.shape[1], data.shape[2])))
    model.add(Dropout(DROPOUT))
    model.add(Dense(units=1))
    model.add(Activation(ACTIVATION))
    model.compile(loss=LOSS, optimizer=OPTIMIZER)

    return model

# Bu fonksiyon model.fit sonucunda eğitilen modelin val_loss ve Loss değerlerini ekranda gösterir.
# X eksenini epochs değerleridir.
# Y eksenini MSE (Mean Squared Error) değerleridir.

def show_model_fit(model_fit):
    #plt.plot(model_fit.history['Loss'], Label='Training Loss', linewidth=2)
    #plt.plot(model_fit.history['val_loss'], Label='Validation Loss', linewidth=2)
    #plt.title(COIN + ' ModelFit')
    #plt.xlabel('EPOCHS')
    #plt.ylabel('LOSS')
    #plt.show()

    fig, ax = plt.subplots(1, figsize=(13, 7))
    ax.plot(model_fit.history['loss'], label='Training Loss', linewidth=3)
    ax.plot(model_fit.history['val_loss'], label='Validation Loss', linewidth=3)
    ax.set_ylabel('Loss', fontsize=14)
    ax.set_xlabel('Epochs', fontsize=14)
    ax.set_title(COIN + ' ModelFit', fontsize=16)
    ax.legend(loc='best', fontsize=16)
```

Şekil 3.27. Modeli hazırlayan ve MSE-Epochs grafiğini gösteren fonksiyon kodları

Şekil 3.28.'de yer alan ekran görüntüsünde, show_error_rate fonksiyonu MAE ve MSE oranlarının hesaplanıp ekranda gösterilmesini sağlamaktadır. “show_success_rate” fonksiyonu tahminleme üzerindeki başarı oranı hesaplamaktadır.

```
# Bu fonksiyon MAE, MSE hata oranlarını ekranda gösterir.
def show_error_rate(predict, test):
    print('Mean Absolute Error : ' + str(mean_absolute_error(predict, test)))
    print('Mean Squared Error : ' + str(mean_squared_error(predict, test)))

# Bu fonksiyon tahminleme sonucu başarı oranını ekranda gösterir.
def show_success_rate(predict, test):
    success=r2_score(test, predict)
    print('Success Rate : ' + str(success*100))
```

Şekil 3.28. Hata oranlarını ve başarı oranlarını ekranda gösteren fonksiyon kodları

Şekil 3.29.'da model hazırlanması ve eğitimi sağlanmaktadır.

```
# Model hazırlama ve eğitim aşaması
train_set, test_set, train_set_x, test_set_x, train_set_y, test_set_y = prepare_data_set()


model = prepare_model(train_set_x)

# Modeli eğit
model_fit = model.fit(train_set_x, train_set_y, validation_data=(test_set_x, test_set_y), epochs=EPOCHS, batch_size=BATCHSIZE, ve

# Eğitilen modelin val_loss ve loss değerlerini ekranda göster.
show_model_fit(model_fit)
```

Şekil 3.29. Model eğitimini sağlayan kodlar


Şekil 3.30.'da 10 nöronlu %70 eğitim verisi ile epochs değerlerine göre ortalama karesel hata oranı göstermektedir. MSE değeri ne kadar sıfıra yakınsa o kadar başarılı demektir.



Şekil 3.30. Epochs-MSE grafiği

Şekil 3.31.'de 10 nöronlu %80 eğitim verisi ile gerçek- tahmin grafiği ve hata/başarı oranları bulunmaktadır. Ayrıca MSE, MAE ve başarı oranlarının yer aldığı değerler mevcuttur. Başarı oranı ne kadar

100'e yakınsa o kadar başarılı sayılmaktadır. “model.predict” fonksiyonu ile tahminleme yapılır. Tahminleme üzerinden MSE, MAE hata oranları ve başarı oranları belirlenir. Model eğitimi sonunda test seti ve tahminleme sonuçları karşılaştırılarak ekranda gösterilir.



Şekil 3.31. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları

Şekil 3.32.'de üç girdili dosyadaki veriler data_set değişkinine atanmıştır. Buradaki adımlar dört girdili model ile aynı olup sadece girdi sayısında farklılık bulunmaktadır.

```

# Bu fonksiyon parametre olarak data set dosyasının adını alır. Dosyayı açar ve data_set değişkenine atar.
# Index olarak date alanı belirlenmiştir.
# data_set değişkeninden TRAINANDTEST'e göre train_set ve test_set belirlenerek geri döndürülür.

def load_data_set(filename):


    data_set = pd.read_csv(filename)
    data_set = data_set.loc[:,['DATE','NMDATA','NMHACIM','NMYouTube','NMWEB']]
    data_set = data_set.set_index('DATE')
    data_set.index = pd.to_datetime(data_set.index,unit='ns')
    train_set = data_set.iloc[TRAINANDTEST:]
    test_set = data_set.iloc[:TRAINANDTEST]

    return train_set, test_set

```


Şekil 3.32. İndeks belirleme, veri setinin atanması, test oluşturma sağlayan kodlar

Şekil 3.33. ve Şekil 3.34.'te Üç girdili %70 eğitim seti ile oluşturulmuş grafikler gözükmektedir. Şekil 3.33. Epoch MSE grafiğini verirken, Şekil 3.34. te gerçek ve tahmin değeri grafiği gözükmektedir. Ayrıca Şekil 3.34. te yer alan başarı oranına baktığımızda 73.123 çıktığı gözükmektedir.




Şekil 3.33. Epochs-MSE grafiği

Mean Absolute Error : 0.039752076988587716
Mean Squared Error : 0.0031816589888319143
Success Rate : 73.12397624890204




Şekil 3.34. Üç girdili gerçek-tahmin grafiği ve hata/başarı oranları

Şekil 3.35. ve Şekil 3.36.'da Üç girdili %80 eğitim seti ile oluşturulmuş grafikler gözükmemektedir. Şekil 3.35. Epoch MSE grafiğini verirken, Şekil 3.36.'da gerçek ve tahmin değeri grafiği gözükmemektedir. Ayrıca Şekil 3.36.'da yer alan başarı oranına baktığımızda 84.123 çıktığı gözükmemektedir




Şekil 3.35. Epochs-MSE grafiği

5/5 [=====] - 1s 3ms/step
Mean Absolute Error : 0.030426682206873633
Mean Squared Error : 0.001737670111034905
Success Rate : 84.12324355773612




Şekil 3.36. Üç girdili gerçek-tahmin grafiği ve hata/başarı oranları

Şekil 3.37. ve Şekil 3.38.'de Üç girdili %90 eğitim seti ile oluşturulmuş grafikler gözükmemektedir. Şekil 3.37. Epoch MSE grafiğini verirken, Şekil 3.38.'de gerçek ve tahmin değeri grafiği gözükmemektedir. Ayrıca Şekil 3.38.'de yer alan başarı oranına baktığımızda 84.842 çıktığı gözükmemektedir




Şekil 3.37. Epochs-MSE grafiği

Mean Absolute Error : 0.031951285162638954
Mean Squared Error : 0.0018922609336639464
Success Rate : 84.84280494308506




Şekil 3.38. Üç girdili gerçek-tahmin grafiği ve hata/başarı oranları

Şekil 3.39. ve Şekil 3.40.'ta Dört girdili %70 eğitim seti ile oluşturulmuş grafikler gözükmemektedir. Şekil 3.39. Epoch MSE grafiğini verirken, Şekil 3.40.'ta gerçek ve tahmin değeri grafiği gözükmemektedir. Ayrıca Şekil 3.40.'da yer alan başarı oranına baktığımızda 84.4048 çıktığı gözükmemektedir




Şekil 3.39. Epochs-MSE grafiği

3/3 [=====] - 1s 10ms/step
Mean Absolute Error : 0.02995600854345226
Mean Squared Error : 0.0017372429181908408
Success Rate : 84.4048496144969




Şekil 3.40. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları

Şekil 3.41. ve Şekil 3.42.'de Dört girdili %90 eğitim seti ile oluşturulmuş grafikler gözükmemektedir. Şekil 3.41. Epoch MSE grafiğini verirken, Şekil 3.42.'de gerçek ve tahmin değeri grafiği gözükmemektedir. Ayrıca Şekil 3.42.'de yer alan başarı oranına baktığımızda 86.036 çıktığı gözükmemektedir



Şekil 3.41. Epochs-MSE grafiği

Mean Absolute Error : 0.028975503057850807
Mean Squared Error : 0.0016265029421642365
Success Rate : 86.83640402200583



Şekil 3.42. Dört girdili gerçek-tahmin grafiği ve hata/başarı oranları

Yapılan geliştirme sonrasında çıkan sonuçları incelendiğinde, eğitim verisi sayısı arttığında başarı oranının arttığı görülmüştür. Ayrıca dört girdili olarak Ethereum kripto para biriminin de değerlerini eklemenin çalışmaya olumlu yansıdığı gözükümüştür.

4. SONUÇ VE ÖNERİLER

Finansal piyasada yatırım yaparken, ileriye dönük kar elde edebilmek yatırımcılar için önemlidir. Yatırımcılar nezdinde, yatırım yaparkenki önemli konulardan biri de risk ve kar oranı yaparak minimal riskli adımlar atmaktır. Bunun için yatırımcıların, yatırım yapacakları konuda iyi bir araştırma yapmış olmaları ve bu konu hakkında fikir sahibi olmaları yatırım aşamasında risk oranını minimal tutmak için önem arz etmektedir.

Teknolojinin gelişmesi ile yatırımcılar da yatırım olarak fiziki yatırım araçlarından ziyade sanal yatırım araçlarına yönelmiştir. Son zamanların önemli teknolojilerinden olan blok zinciri teknolojisinin bir ürünü olan kripto paralarda, son zamanların popüler yatırım araçları arasına girmeyi başarmıştır. Bir alım satım işleminin bazen saatler, günler sürdüğü geleneksel para birimleri yerine, kripto paralarda saniyeler içinde işlemler tamamlanabilmekte olup, blok zinciri teknolojisinden de dolayı son derece güvenlidir. Kripto paralarda merkezi kontrolün olmaması, şeffaf olması, değiştirilemez olması yolsuzluk olaylarının da minimum olmasını sağlayacaktır.

Bu çalışma kapsamında da Polkadot kripto para biriminin 20.08.2020 - 27.02.2023 tarihleri arasındaki verileri kullanarak tahminleme yapabilmek için yapay sinir ağlarında çok katmanlı algılayıcılar kullanılırken, derin öğrenme metotlarından ise LSTM kullanılmıştır. Bu çalışmada Polkadot kripto birimini etkileyen girdi değerleri iki farklı şekilde ele alınmıştır. Bunlardan ilkinde Polkadot Youtube arama sayısı, Polkadot web arama sayısı, Polkadot hacim değerinden oluşturmaktadır, ikinci girdi kümesinde ise Polkadot Youtube arama sayısı, Polkadot web arama sayısı, Polkadot hacim değerine ek olarak önemli alt kripto para birimlerinden olan Ethereum da katılarak üzerindeki etkisi anlaşılmaya çalışılmıştır. Çalışma yapılırken çapraz doğrulama yöntemi kullanılarak eğitim verilerinin oranı belirlenmiştir. Ayrıca nöron sayısı belirlenirken 10 ve 20 şeklinde test ederek belirlenmiştir. Yapılan çalışma neticesinde yapay sinir ağlarında çok katmanlı geri yayılım algoritmasında Ethereum değerinin de etkilendiği dört girdili 10 nöron sayılı, %90 eğitim verisinin olduğu veri setinde tahminleme yapıldığında 0.93 korelasyon katsayısı ile en yüksek başarıya

ulaştığı görülmüştür. Aynı çalışma derin öğrenme yöntemlerinden LSTM üzerinde yapıldığında ise en iyi sonuç 10 nöron dört girdili, %90 eğitim verisinin olduğu 0.86 korelasyon katsayısı ile elde edildiği görülmüştür. Yapılan çalışmada dört girdili, 10 nöronlu, %90 eğitim verisi ile yapılan çalışmanın hem yapay sinir ağlarında hem de derin öğrenmede daha iyi sonuç verdiğini gözlemledik. Bu değerler üzerinden Tablo 4.1. elde edilen sonuçlar R (korelasyon katsayısı) kıyaslandığında yapay sinir ağlarında daha iyi sonuç verdiği gözlemlenmiştir.

Tablo 4.1.'de dört girdi parametresi, Tablo 4.2.'de ise üç girdi parametresi için derin öğrenme ve yapay sinir ağları üzerindeki en yüksek değerler eklenmiştir. İki algoritmada da 10 nöron ve %90 test verisi daha iyi sonuç vermiştir. Tablolarda da gözüktüğü üzere MSE oranı düştükçe başarı oranı (R= korelasyon katsayısı) artmaktadır. Tablo 4.1. ve Tablo 4.2. incelendiğinde ise dört girdi parametresinde yapay sinir ağlarında en iyi sonucun verildiği gözükmemektedir.

Tablo 4.1. Dört Girdili Derin öğrenme ve Yapay sinir ağı sonuç değerleri

	R	MSE	RMSE
Derin Öğrenme	0.86036	0.01626	0.12751
Yapay Sinir Ağları	0.93944	0.01165	0.10793

Tablo 4.2. Üç Girdili Derin öğrenme ve Yapay sinir ağı sonuç değerleri

	R	MSE	RMSE
Derin Öğrenme	0.84842	0.018	0.13416
Yapay Sinir Ağları	0.91059	0.01975	0.14053

Yapılan çalışma ile farklı girdi değerlerinin, nöron ve eğitim verisini oranlarının başarıyı nasıl etkilediği görüldü. Ayrıca farklı algoritmalar üzerinde geliştirme yapmanın da başarı oranlarında yakında olsa farklı değerler ortaya çıkarabileceğini gösterdi. Bu çalışma ile kripto paralara yatırım yapmak isteyen yatırımcılar için öncesinde fikir sahibi olmalarına olanak sağlamaktadır.

Yapılacak arařtırmada farklı girdi parametreleri, farklı model yapıları, farklı algoritmalar kullanılarak kıyaslamalar yapılması doğru sonuca ulaşma adımında önem arz ettięi görölmüřtür.





KAYNAKLAR

- Akay, M., Canik, F., Yeşilyurt, C., Günkut, M. (2022). Yapay Zekâ Teknikleri ile Kripto Para Tahmini. *Ekonomi Bilimleri Dergisi*, 14(1), 72-101. <https://doi.org/10.55827/ebd.1060983>
- Aras, S. (2019). Kripto Para Fiyatlarının Klasik ve Yapay Sinir Ağı Modelleri ile Tahmini. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(20), 608-640. <https://doi.org/10.36543/kauibfd.2019.026>
- Atlan, F., Pençe, İ., Çeşmeci, M. (2020). Kripto Paralardan Bitcoin, Ethereum ve Ripple için Yapay Zekâ ile Online Fiyat Tahmin Modeli. 28. *Sinyal İşleme ve İletişim Uygulamaları (SİU) Kurultayı*, 2165-0608. <https://doi.org/10.1109/SIU49456.2020.9302082>
- Avşar, İ. (2020). Kripto Paralar ve Uluslararası Ticaret Üzerine Bir Araştırma: Bibliyometrik, LSTM ve Kümeleme Analizi [Doktora Tezi]. Hasan Kalyoncu Üniversitesi ve Gaziantep Üniversitesi
- Büyükdoğan, B. (2022). Kripto Paranın Uluslararası Ticarete Ödeme Yöntemi Olarak Kullanılmasına Dair Bir İnceleme [Yüksek Lisans Tezi]. Kto Karatay Üniversitesi
- Ceylan, M. (2019). Bitcoin Ekonomisi: Kripto Para Bitcoin'in Finans Sektörü İçindeki Yeri. [Yüksek Lisans Tezi]. Batman Üniversitesi
- Crosby, M., Pattanayak, P., Verma, S. ve Kalyanaraman, V. (2016), "Blockchain Technology: Beyond Bitcoin. Applied Innovation", 2, 6-10. <https://j2-capital.com/wp-content/uploads/2017/11/AIR-2016-Blockchain.pdf>
- Çılgın, C., Ünal, C., Alıcı, S., Akkol E., ve Gökşen, Y. (2020). Metin Sınıflandırmada Yapay Sinir Ağları ile Bitcoin Kodları ve Sosyal Medyadaki Beklentilerin Analizi. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 4(1), 106-126. <https://doi.org/10.31200/makuubd.651904>
- Demirci, E. (2021). Kripto Para Fiyatlarının LSTM ve GRU Modelleri ile Tahmini [Yüksek Lisans Tezi]. Süleyman Demirel Üniversitesi
- Demirel, A., Hazar, A. (2021). Kripto Para Değerlerine Dayanılarak BİST 100 Endeks Hareketi Tahmininde Destek Vektör Makineleri Uygulaması. *Başkent Üniversitesi Ticari Bilimler Fakültesi Dergisi*, 5(1), 27-35. <https://dergipark.org.tr/tr/pub/jcsci/issue/61186/816839>
- Haykin, S. (1998). Neural Networks: A Comprehensive Foundation. *The Knowledge Engineering Review*, 13(4), 409-412
- Hayradi, D., Hâkim, A., Atmaja, D., Yutia, S. (2022). Implementation of Support Vector Regression for Polkadot Cryptocurrency Price Prediction. *Int. J. Inform. Visualization*, 6(1-2). <http://dx.doi.org/10.30630/joiv.6.1-2.945>

- İşgör, M. (2019). Kripto Para Birimi Olan Bitcoin ve Blockchain Teknolojisinin Ortaya Çıkışı Bugüne Kadarki Gelişim Süreci ile Gelecekteki Durumu [Yüksek Lisans Tezi]. Konya Gıda ve Tarım Üniversitesi
- Karaatlı, M., Helvacıoğlu, Ö., Ömürberk, N., ve Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100. <https://doi.org/10.11122/ijmeh.2012.8.17.290>
- Kartal, C. (2020). K-Star Algoritması ile Bitcoin Fiyatları Modelleme. *Business And Management Studies An International Journal*, 8(1), 213-231. <https://doi.org/10.15295/bmij.v8i1.1380>
- Köksal, B., Erdem, G., Türkeli, C., Öztürk, Z. (2021). Twitter’ da Duygu Analizi Yöntemi Kullanılarak Bitcoin Değer Tahminlemesi. *Düzce Üniversitesi Bilim ve Teknoloji*, 9(3), 280-297. <https://doi.org/10.29130/dubited.792909>
- Mosmer, S. (2022). Türkiye’deki Bireysel Kripto Para Yatırımcılarının Kripto Paralara Yaklaşımları [Yüksek Lisans Tezi]. Bandırma On yedi Eylül Üniversitesi
- Pamuk, Ö. (2019). Cryptocurrency Price Prediction By Using Social Media Data [Yüksek Lisans Tezi]. İstanbul Technical University
- Sakız, A., Gencer, B. (2017). Yapay Sinir Ağları ile Bitcoin Fiyatını Tahminleme. *International Conference On Eurasian Economies*, 438-444
- Salman, M. (2020). Price Prediction Of Different Cryptocurrencies Using Technical Trade Indicators And Machine Learning [Yüksek Lisans Tezi]. Altınbas University.
- Satoshi, N. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. <https://bitcoin.org/bitcoin.pdf>
- Sel, A. (2020). Pandemi Sürecinde Altın Fiyatları ile Kripto Para İlişkisinin Makine Öğrenme Metotları ile İncelenmesi. *İstatistik ve Uygulamalı Bilimler Dergisi*, 1(2), 85-98
- Sel, A., Zengin, N., Yıldız, Z. (2020). Alternatif Yatırım Araçları ile Bitcoin Fiyatları Arasındaki İlişkinin Yapay Sinir Ağları ile Tahmini. *Sivas Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(2), 157-169. <https://doi.org/10.37880/cumuiibf.616127>
- Şahin, E.E. (2018). Kripto Para Bitcoin: ARIMA ve Yapay Sinir Ağları ile Fiyat Tahmini. *Fiscaoeconomia*, 2(2), 74-92. <https://doi.org/10.25295/fsan.2018.02.005>
- Tian, F. (2016). An Agri-Food Supply Chain Traceability System for China Base on RFID&BLOCKCHAIN Technology. 13th International Conference on Service Systems and Service Management
- Tuncer, A. (2022). LSTM Metodu Kullanılarak Rüzgâr Hızının Tahmin Edilmesi [Yüksek Lisans Tezi]. Yıldız Teknik Üniversitesi
- Uysal, Ü. (2019). Kripto Para ve Kripto Paranın Ticarete Kullanımı: Girişimcilerin ve Yatırımcıların Kripto Paraya İlişkin Tutumlarının İncelenmesi [Yüksek Lisans Tezi]. Muğla Sıtkı Koçman Üniversitesi
- Ünalır, B. (2021). Kripto Paraların Gelişimi ve Dünya Finans Sektörü İçindeki Yeri [Yüksek Lisans Tezi]. Selçuk Üniversitesi

Yavuz, S., Deveci, M. (2015). İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 0 (40), 167-187.
<https://dergipark.org.tr/tr/pub/erciyesiibd/issue/5897/78019>

Yavuz, U., Özen, Ü., Taş, K., Çağlar, B. (2020). Yapay Sinir Ağları ile Blockchain Verilerine Dayalı Bitcoin Fiyat Tahmini. *Journal of Information Systems and Management Research*, 2 (1), 1-9.
<https://dergipark.org.tr/tr/pub/jismar/issue/55710/656814>

Yazgan, İ. (2022). Kripto Paraların Medyada Temsili ve Çıkan Haberlerin Yatırımcı Algısı Üzerine Etkisi [Yüksek Lisans Tezi]. Atılım Üniversitesi





ÖZGEÇMİŞ

Ad-Soyad : Müberra Beyza ODABAŞI

ÖĞRENİM DURUMU:

- **Lisans** : 2018, Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : 2023, Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği