



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME İLE ETHEREUM FİYAT TAHMİNİ

Mustafa YALÇIN

**Ağustos-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME İLE ETHEREUM FİYAT TAHMİNİ

Mustafa YALÇIN

**Danışman
Prof. Dr. Ömer Faruk ERTUĞRUL**

**Ağustos-2024
BATMAN**

TEZ KABUL VE ONAYI

Mustafa YALÇIN tarafından hazırlanan “Derin Öğrenme ile Ethereum Fiyat Tahmini” adlı tez çalışması 28/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Cafer BUDAK

.....

Danışman

Prof. Dr. Ömer Faruk ERTUĞRUL

.....

Üye

Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü V.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Mustafa YALÇIN

28.08.2024

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME İLE ETHEREUM FİYAT TAHMİNİ

Mustafa YALÇIN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ömer Faruk Ertuğrul

2024, 72 Sayfa

Jüri

Prof. Dr. Ömer Faruk ERTUĞRUL

Doç. Dr. Cafer BUDAK

Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

Yapay zeka, hayatımızın pek çok alanına entegre olarak, günlük yaşantımızı önemli ölçüde kolaylaştırmıştır. Bu kolaylık ise her türlü alanda sağlanmaktadır. Özellikle finansal teknolojilerde, yapay zeka ve makine öğrenimi yöntemleri, kripto para piyasalarında öngörü ve analiz yapma süreçlerini dönüştürmüştür. Bu bağlamda, Ethereum gibi popüler kripto para birimlerinin fiyat tahminleri, ileri yapay zeka modelleri kullanılarak daha doğru ve güvenilir hale gelmektedir. Yatırımcılar, bu modeller sayesinde piyasa hareketlerini daha iyi anlayabilir ve daha bilinçli kararlar alabilirler. Yapay zeka tabanlı analizler, sadece yatırım stratejilerini iyileştirmekle kalmaz, aynı zamanda piyasa dalgalanmalarına karşı daha etkin risk yönetimi sağlar. Böylece, kripto para dünyasında güvenlik ve karlılık artırılarak, dijital finansal ekosistemin sürdürülebilirliği desteklenmiş olur. Bu çalışmada ise Ethereum kripto para biriminin fiyat tahmininde yapay zeka modellerinin kullanımı araştırılmaktadır. LSTM, ANN, GRU ve RNN modelleri kullanılarak, Ethereum fiyat verileri üzerinde analizler gerçekleştirilmiştir. Çalışmanın amacı, bu modellerin fiyat tahminindeki etkinliğini değerlendirmek ve kripto para piyasasındaki öngörü kabiliyetlerini ortaya koymaktır. Elde edilen bulgular, yapay zeka tekniklerinin finansal piyasalarda nasıl kullanılabileceğine dair önemli bilgiler sunmaktadır.

Anahtar Kelimeler: ANN, Blokszincir, Derin Öğrenme, Ethereum, GRU, LSTM RNN, Yapay Zeka

ABSTRACT

MS THESIS

ETHEREUM PRICE PREDICTION WITH DEEP LEARNING

Mustafa YALÇIN

Batman University Graduate Education Institute

Electrical And Electronics Engineering Department

Advisor: Prof. Dr. Ömer Faruk ERTUĞRUL

2024, 72 Pages

Jury

Prof. Dr. Ömer Faruk ERTUĞRUL

Assoc. Prof. Cafer BUDAK

Asst. Prof. Üyesi Abdulkarim ÖZTEKİN

Artificial intelligence has significantly integrated into many aspects of our lives, greatly simplifying our daily routines. This convenience is provided across various fields. In particular, in financial technologies, artificial intelligence and machine learning methods have transformed the processes of prediction and analysis in cryptocurrency markets. In this context, price predictions of popular cryptocurrencies like Ethereum have become more accurate and reliable using advanced AI models. Investors can better understand market movements and make more informed decisions through these models. AI-based analyses not only improve investment strategies but also provide more effective risk management against market fluctuations. Thus, security and profitability are enhanced in the cryptocurrency world, supporting the sustainability of the digital financial ecosystem. This study investigates the use of AI models in predicting the price of the Ethereum cryptocurrency. Using LSTM, ANN, GRU, and RNN models, analyses were conducted on Ethereum price data. The aim of the study is to evaluate the effectiveness of these models in price prediction and to demonstrate their forecasting capabilities in the cryptocurrency market. The findings provide significant insights into how AI techniques can be utilized in financial markets.

Keywords: ANN, Artificial Intelligence, Blockchain, Deep Learning, Ethereum, GRU, LSTM, RNN

ÖNSÖZ

Bu tez çalışmasında, benden her türlü maddi ve manevi desteklerini esirgemeyen aileme, özellikle hoşgörüsünden ve yardımlarından dolayı sevgili eşim Gamze YALÇIN'a, dünyaya gelmeye hazırlanan biricik kızım Asya YALÇIN'a hayatımıza katacağı mutluluk ve ilham için şimdiden teşekkür ederim. Bilgi ve öğütlerinden yararlandığım danışman hocam Sayın Prof. Dr. Ömer Faruk ERTUĞRUL'a, benden hiçbir zaman yardım ve desteklerini esirgemeyen, hayata bakış farkındalığımı artıran değerli hocam Dr. Öğr. Üyesi Süleyman KARDAŞ'a teşekkürü bir borç bilirim.

Mustafa YALÇIN
BATMAN-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
KISALTMALAR	ix
ŞEKİLLER DİZİNİ.....	x
TABLolar DİZİNİ	xii
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	6
3.1 Veri Seti	6
3.1.1 Veri Seti ve Ön İşleme	6
3.1.2 Veri Seti Analizi	7
3.2. Blokzincir Teknolojisi	11
3.3. Yapay Zeka	13
3.4. Makine Öğrenmesi.....	17
3.4.1. Makine öğrenmesi türleri.....	19
3.5. Derin Öğrenme	22
3.6. Kullanılan Yapay Zeka Modelleri	24
3.6.1. ANN.....	24
3.6.2. RNN	28
3.6.3. LSTM.....	29
3.6.4. GRU	29
3.7. Modelin Eğitim ve Test Metodolojisi	30
3.8. Tahmin Modellerinin Performans Değerlendirmesi	32

3.9. Kullanılan Yazılım ve Yapay Zeka Kütüphaneleri.....	34
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	36
4.1. Uzun-Kısa Süreli Bellek (LSTM) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi	36
4.2. Kapılı Tekrarlayan Birim (GRU) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi	42
4.3. Tekrarlayan Sinir Ağları (RNN) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi	48
4.4. Yapay Sinir Ağları (ANN) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi	54
4.5. Genel Sonuçlar ve Genel Değerlendirme	60
4.6. Çalışmada Elde Edilen Sonuçların Literatürle Karşılaştırılması	63
5. SONUÇLAR VE ÖNERİLER.....	66
5.1 Sonuçlar	66
5.2 Katkıları ve Öneriler	67
KAYNAKLAR	68
ÖZGEÇMİŞ	72

KISALTMALAR

- ANN:** Artificial Neural Network (Yapay Sinir Ağı)
RNN: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
LSTM: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
GRU: Gated Recurrent Unit (Geçitli Tekrarlayan Birim)
MAPE: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
RMSE: Root Mean Squared Error (Kök Ortalama Kare Hatası)
MSE: Mean Squared Error (Ortalama Kare Hatası)
MAE: Mean Absolute Error (Ortalama Mutlak Hata)
USD: United States Dollar (Amerikan Doları)
ETH: Ethereum (Cryptocurrency) [Ethereum (Kripto Para)]
AI: Artificial Intelligence (Yapay Zeka)
ML: Machine Learning (Makine Öğrenmesi)
DL: Deep Learning (Derin Öğrenme)
DNN: Deep Neural Network (Derin Sinir Ağı)
CNN: Convolutional Neural Network (Evrışimli Sinir Ağı)
GPU: Graphics Processing Unit (Grafik İşlemci Ünitesi)

ŞEKİLLER DİZİNİ

Şekil 3. 1. Ethereum Kapanış Fiyatları 2019- 2024.....	8
Şekil 3. 2. Ethereum Haftalık Kapanış Fiyatları.....	8
Şekil 3. 3. Ethereum Aylık Kapanış Fiyatları.....	9
Şekil 3. 4. Ethereum Mevsimler Kapanış Fiyatları.....	9
Şekil 3. 5. Ethereum Yıllık Kapanış Fiyatları.....	10
Şekil 3. 6. Ethereum Kapanış Fiyatı Mum Çubuğu Grafiği	10
Şekil 3. 7. Merkezi ve Dağıtık Ağ Yapısı (Usta & Doğanterkin, 2019)	11
Şekil 3. 8. Sunucu Tabanlı Ağ ile Eşler Arası Ağ (Erözel Durbilmez, 2018)	12
Şekil 3. 9. Bloklar ve İşlemler	13
Şekil 3. 10. Yapay Zekanın Alt Dal Şematiği (Deniz, 2023)	17
Şekil 3. 11. Makine Öğrenmesinin Çalışma Yöntemi	18
Şekil 3. 12. Biyolojik bir nöronun sadeleştirilmiş diyagramı (Mellit & Kalogirou, 2008)	24
Şekil 3. 13. ANN Yapısı- Girdi vektörü, ağırlık matrisi, bias, dönüşüm fonksiyonu ve çıktı (Bozorg-Haddad ve ark., 2022)	26
Şekil 3. 14. Tek girişli bir nöron (Bozorg-Haddad ve ark., 2022).....	27
Şekil 3. 15. Çok girişli nöron (Bozorg-Haddad ve ark., 2022).....	28
Şekil 3. 16. Yapay Zeka Modelinde Veri Analizi İşleyiş Akış Şeması	31
Şekil 4. 1. LSTM En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği.....	37
Şekil 4. 2. LSTM En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları	37
Şekil 4. 3. LSTM En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği (Dropout Açık)	39
Şekil 4. 4. LSTM En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları (Dropout Açık).....	40
Şekil 4. 5. GRU En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği.....	43
Şekil 4. 6. GRU En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları	43

Şekil 4. 7. GRU En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği (Dropout Açık)	45
Şekil 4. 8. GRU En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları (Dropout Açık).....	46
Şekil 4. 9. RNN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği.....	49
Şekil 4. 10. RNN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları	49
Şekil 4. 11. RNN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği (Dropout Açık)	52
Şekil 4. 12. RNN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları (Dropout Açık).....	52
Şekil 4. 13. ANN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği.....	55
Şekil 4. 14. ANN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları	56
Şekil 4. 15. ANN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği.....	58
Şekil 4. 16. ANN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları	58
Şekil 4. 17. Tüm Modellerin En İyi Sonuçlarının Gerçek ve Tahmin Edilen Değerleri (Dropout Kapalı).....	61
Şekil 4. 18. Tüm Modellerin En İyi Sonuçlarının Gerçek ve Tahmin Edilen Değerleri (Dropout Açık).....	62

TABLÖLAR DİZİNİ

Tablo 3. 1.Ethereum Veri Seti	7
Tablo 3. 2. Keccak-256 ile Hash Değeri Hesaplama	12
Tablo 4. 1. LSTM Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı).....	36
Tablo 4. 2. LSTM En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri	38
Tablo 4. 3. LSTM Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık).....	39
Tablo 4. 4. LSTM En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)	41
Tablo 4. 5. GRU Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı).....	42
Tablo 4. 6. GRU En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Kapalı)	44
Tablo 4. 7. GRU Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık).....	45
Tablo 4. 8. GRU En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)	47
Tablo 4. 9. RNN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı).....	48
Tablo 4. 10. RNN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri	50
Tablo 4. 11. RNN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık).....	51
Tablo 4. 12. RNN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)	53
Tablo 4. 13. ANN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı).....	54
Tablo 4. 14. ANN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri	56

Tablo 4. 15. ANN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık).....	57
Tablo 4. 16. ANN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)	59
Tablo 4. 17. Tüm Modellerin En İyi Sonuçlarının MAPE Değerleri (Dropout Kapalı). 60	
Tablo 4. 18. Tüm Modellerin En İyi Sonuçlarının MAPE Değerleri (Dropout Açık) ...	61
Tablo 4. 19. Literatürde Kullanılan Modeller, MAPE Sonuçları ve Çalışma Sonuçlarım	63



1. GİRİŞ

Dijital para birimleri, son on yıl içerisinde finansal piyasalarda önemli bir yer edinmiş ve özellikle kripto para birimleri, büyük bir yatırımcı kitlesinin dikkatini çekmiştir. Ethereum, Bitcoin'in ardından en popüler ikinci kripto para birimi olarak öne çıkmakta ve akıllı sözleşme yetenekleri sayesinde yalnızca bir dijital para birimi olmanın ötesine geçmektedir. Bu çalışmada, Ethereum fiyatlarının tahmini için yapay zeka modellerinin kullanımı incelenecektir.

Kripto para piyasalarının yüksek volatilitesi ve karmaşıklığı, geleneksel finansal analiz yöntemlerinin ötesinde yeni yaklaşımlar gerektirmektedir. Bu bağlamda, yapay zeka ve makine öğrenmesi teknikleri, büyük veri setlerinden anlamlı desenler çıkarma ve gelecekteki fiyat hareketlerini tahmin etme konusunda önemli avantajlar sunmaktadır. Özellikle Zaman Serisi Analizi, bu tür verilerin analizi için kritik bir rol oynamaktadır. Yapay zeka modelleri, finansal verilerin karmaşıklığı ve dinamik doğası nedeniyle tercih edilmektedir. Bu modeller, verilerin içindeki karmaşık ilişkileri ve desenleri öğrenme kapasitesine sahiptir (Goodfellow, Bengio, & Courville, 2016). Özellikle derin öğrenme yöntemleri, büyük ve karmaşık veri setlerinde üstün performans göstermektedir (LeCun, Bengio, & Hinton, 2015).

Bu çalışmada, Uzun Kısa Süreli Hafıza (LSTM), Gated Recurrent Unit (GRU), Tekrarlayan Sinir Ağı (RNN) ve Yapay Sinir Ağları (ANN) modellerinin Ethereum fiyat tahmininde nasıl kullanılabileceği araştırılacaktır. Bu modeller, özellikle zaman serisi verilerini işlemede etkili olup, karmaşık ve dinamik yapıları sayesinde finansal verilerdeki trendleri ve desenleri öğrenme kapasitesine sahiptirler (Hochreiter & Schmidhuber, 1997). Çalışma, 01.01.2019- 18.01.2024 tarihleri arasındaki Ethereum fiyat verilerini kullanarak, bu modellerin performanslarını karşılaştırmayı amaçlamaktadır.

Son yıllarda, yapay zeka ve makine öğrenmesi yöntemleri finansal piyasaların analizinde önemli bir rol oynamaya başlamıştır. Araştırmalar, bu yöntemlerin geleneksel analiz yöntemlerine göre daha yüksek doğruluk oranlarına sahip olduğunu göstermektedir (Chen, Leung, & Daouk, 2003). Derin öğrenme algoritmaları, özellikle karmaşık veri setlerinde üstün performansları ile öne çıkmaktadır (Zhang, Aggarwal, & Qi, 2017).

Bu çalışmanın amacı, yapay zeka tabanlı modellerin kripto para piyasalarındaki uygulama potansiyelini değerlendirmek ve yatırımcılara daha bilinçli kararlar almaları için gerekli araçları sağlamaktır. Aynı zamanda, finansal piyasalarda yapay zeka

kullanımının artan önemini vurgulamak ve bu alanda yapılacak gelecekteki çalışmalara ışık tutmak hedeflenmektedir. Elde edilen bulgular, sadece akademik literatüre katkıda bulunmakla kalmayacak, aynı zamanda finansal piyasalarda stratejik kararlar almayı hedefleyen profesyonellere de yol gösterici olacaktır.



2. LİTERATÜR ARAŞTIRMASI

Gunarto, Sa'adah ve Utama (2023) çalışmalarında, Bitcoin ve Ethereum fiyatlarını tahmin etmek için Recurrent Neural Network (RNN) ve Long-Short Term Memory (LSTM) modellerinin etkinlikleri karşılaştırılmıştır. Araştırma sonuçları, LSTM modelinin RNN modeline kıyasla daha düşük Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Yüzde Hatası (MAPE) değerleri elde ederek daha iyi performans gösterdiğini ortaya koymuştur. LSTM modeli, Bitcoin tahmininde 0.061 RMSE ve %5.66 MAPE, Ethereum tahmininde ise 0.036 RMSE ve %4.58 MAPE değerlerine ulaşmıştır. Bu sonuçlar, LSTM modelinin kripto para fiyat tahmininde RNN modelinden daha etkili olduğunu göstermektedir (Gunarto, Sa'adah, & Utama, 2023).

Hansun, Wicaksana ve Khaliq (2022) çalışmalarında, kripto para birimlerinin gelecekteki değerlerini tahmin etmek için çok değişkenli bir yaklaşım ve üç farklı tekrarlayan sinir ağı modeli (LSTM, Bi-LSTM ve GRU) kullanılmıştır. Araştırmada ayrıca, regresyon görevi için basit bir üç katmanlı derin ağ mimarisi önerilmiştir. Beş büyük kripto para birimi (Bitcoin, Ethereum, Cardano, Tether ve Binance Coin) üzerindeki deneysel sonuçlar, Bi-LSTM ve GRU'nun doğruluk açısından benzer performans gösterdiğini, ancak çalışma süresi açısından LSTM ve GRU'nun benzer sonuçlar verdiğini, GRU'nun ise biraz daha iyi ve daha düşük varyasyonlu sonuçlar elde ettiğini göstermektedir (Hansun, Wicaksana, & Khaliq, 2022).

Jagannath, ve diğerleri (2021) çalışmalarında, Ethereum blok zincirinin oluşturduğu on-chain veriler kullanılarak ağın sağlığı ve kullanımını değerlendirmek için LSTM-RNN modeli geliştirilmiştir. On-chain verilerin zaman damgalı, entegre ve açık bir deftere kaydedilmesi, karmaşık tahmin algoritmalarıyla gelecekteki davranışları öngörme olanağı sağlar. Bu çalışmada, fiyatla en yakından ilişkili metrikler kullanılarak ağın gerçek parasal değeri belirlenmiştir. RNN modellerinde öğrenme sürecini düzenleyen birkaç hiperparametre vardır ve bunların değerlerine çok duyarlıdır. Bu nedenle, eğitimin hızlı ve etkili olabilmesi için optimal hiperparametrelerin seçilmesi kritik öneme sahiptir. Bu çalışmada, optimal parametreleri belirlemek için üç öz-uyarlamalı teknik önerilmiş ve geleneksel LSTM modeliyle karşılaştırılmıştır. Önerilen yaklaşım, %86.94 doğruluk oranı ve minimum hata oranı sergilemiştir (Jagannath, ve diğerleri, 2021).

Canitez ve Savaş (2022) çalışmalarında, son on yılda bilişim teknolojilerinin gelişimi ile birlikte kripto paralar, küresel yapının en etkili ürünlerinden biri haline gelmiştir. Kripto

paraların işlem hacmi artmış ve sayıları beş bini aşmıştır. Bu gelişim, varlık transferini kolaylaştırmış ve paranın tanımını yeniden şekillendirmiştir. Ancak, kripto para birimlerinin yüksek volatilité ve piyasayı karakterize eden yeni mekanizmalar nedeniyle fiyat tahmini zordur. Bu çalışmada, Bitcoin'in piyasa değeri tahmini için Uzun Kısa Süreli Bellek (LSTM) algoritması ve Otoregresif Entegre Hareketli Ortalama (ARIMA) modelleri kullanılmıştır. Çalışmada 10,309 Bitcoin verisi ve ek olarak RSI, SMA, BBANDS, MA ve EMA teknik indikatörleri kullanılmıştır. Sonuç olarak, ARIMA modelinin, belirli test verileri üzerinde LSTM modeline göre %3.8 ve %4.1 oranlarında daha iyi performans gösterdiği bulunmuştur (Canitez & Savaş, 2022).

Demirci ve Karaatlı (2023) çalışmalarında, kripto paralar, finansal piyasalarda kısa sürede önemli bir yer edinmiş ve hem değişim hem de yatırım aracı olarak kullanılmaya başlanmıştır. Merkezi otorite kontrolünde olmamaları, fiyatlarında dalgalanmalara yol açmaktadır. Bu nedenle, akıllı tahmin modellerinin geliştirilmesi, yatırım kararları açısından büyük önem taşımaktadır. Derin öğrenme ve yapay zeka teknikleri, kripto para birimlerinin ve diğer yatırım araçlarının seçimi için kullanılmaktadır. Araştırmalar, RNN, LSTM ve GRU gibi derin öğrenme modellerinin, kripto para fiyat tahmininde geleneksel zaman serisi modellerine göre daha iyi performans gösterdiğini göstermektedir. Bu çalışmada, LSTM ve GRU modelleri kullanılarak Bitcoin, Ethereum ve Ripple'ın 30 günlük fiyat tahminleri yapılmıştır. Sonuçlar, her iki modelin de en iyi tahmin sonuçlarını Bitcoin için verdiğini, Ripple'ın ikinci ve Ethereum'un üçüncü sırada yer aldığını göstermiştir. MAPE performans ölçütüne göre, Bitcoin ve Ripple için en iyi sonuçlar GRU modeliyle, Ethereum için ise LSTM modeliyle elde edilmiştir (Demirci & Karaatlı, 2023).

Akay, Canik, Yeşilyurt ve Günkut (2021) çalışmalarında, teknolojik gelişmelerle birlikte, internetin yaygın kullanımı ödeme araçlarında değişikliklere yol açmış ve kripto paralar alternatif bir ödeme aracı olarak öne çıkmıştır. Bu çalışmanın amacı, kripto para birimlerinin gelecekteki fiyatlarını gerçeğe en yakın şekilde tahmin edecek yöntemi belirlemektir. Yapay sinir ağları (YSA) ve uzun kısa süreli bellek (LSTM) yöntemleri kullanılarak, XRP, BNB ve ETH kripto paralarının fiyat tahminleri yapılmıştır. 01.01.2020-07.05.2021 tarihleri arasındaki veriler Yahoo web sitesinden alınmış ve bu veri seti üzerinde analizler gerçekleştirilmiştir. Sonuçlar, her iki yöntemin de performansını değerlendirerek kıyaslamıştır. Matlab ile yapılan YSA tahminlerinin başarılı ve anlamlı sonuçlar verdiği ortaya konmuştur (Akay ve ark., 2021).

Eylasov ve Çiçek (2024) çalışmalarında, Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) getirilerini öngörmek için ARIMA-GARCH ve LSTM modellerini karşılaştırmaktır. Günlük veriler %90 eğitim ve %10 test olarak ayrılmış, RMSE ve MSE kriterleri ile değerlendirilmiştir. Sonuçlar, BTC için ARIMA-GARCH'ın eğitim verisinde, LSTM'nin ise test verisinde daha iyi performans gösterdiğini, BNB için LSTM'nin her iki veri setinde üstün olduğunu ve ETH için ARIMA-GARCH'ın daha iyi sonuçlar verdiğini göstermiştir. Çalışma, her iki yöntemin de finansal tahminlerde etkili olabileceğini vurgulamaktadır (Eylasov & Çiçek, 2024).

Şenol ve Denizhan (2023) çalışmalarında, yatırımcılara doğru kararlar alabilmeleri için Bitcoin, Ethereum ve Cardano kripto paralarının fiyat tahmini yapılmıştır. Yapay Sinir Ağları ve Regresyon Analizi yöntemleri kullanılarak, bu kripto paraların açılış, kapanış, gün içindeki en düşük ve en yüksek değerlerine dayanarak bir sonraki günün kapanış değeri tahmin edilmiştir. Sonuçlar, Yapay Sinir Ağları ile yapılan tahminlerin, Regresyon Analizi ile yapılan tahminlerden daha başarılı olduğunu göstermiştir (Şenol & Denizhan, 2023).

3. MATERYAL VE YÖNTEM

3.1 Veri Seti

Kripto para birimleri, son yıllarda finansal piyasalarda büyük ilgi görmüş ve yatırımcılar için önemli fırsatlar sunmuştur. Bu bağlamda, Ethereum ve Bitcoin gibi önde gelen kripto para birimlerinin fiyat hareketlerini tahmin etmek, yatırımcılar ve analistler için büyük önem taşımaktadır. Kripto para piyasalarının yüksek volatilitesi ve karmaşık yapısı, geleneksel finansal analiz yöntemlerinin ötesinde, yapay zeka ve makine öğrenmesi tekniklerinin kullanılmasını gerektirmektedir.

Ethereum fiyat verileri, birçok finansal platform ve veri sağlayıcı aracılığıyla kolayca erişilebilen ve sürekli olarak güncellenen bir veri setidir. Bu fiyat verileri, zaman içinde sürekli değişen bir zaman serisi yapısına sahiptir. Ethereum'un tarihsel fiyat hareketleri, yüksek volatilitesi ve piyasa eğilimleri, finansal analizlerde ve öngörülerde kritik rol oynar. Bu özellikleri nedeniyle, Ethereum veri seti, yalnızca geçmiş fiyat hareketlerini incelemekle kalmaz, aynı zamanda piyasadaki gelecekteki olası senaryoları değerlendirmek için de oldukça uygundur.

Kripto para piyasalarının doğası gereği yüksek volatilité ve belirsizlik göstermesi, yatırımcılar ve traderlar için önemli riskler ve fırsatlar yaratır. Bu volatilité, piyasalarda büyük fiyat dalgalanmalarına yol açarak hızlı karar almayı zorunlu kılar. Ethereum gibi büyük ve likiditesi yüksek bir kripto para biriminin fiyat hareketleri, yatırımcılar için stratejik kararlar almakta önemli bir gösterge niteliğindedir. Ethereum fiyatlarındaki değişimler, yatırımcıların risk yönetimi stratejilerini belirlemelerine, alım-satım pozisyonlarını optimize etmelerine ve piyasa duyarlılığını ölçmelerine yardımcı olur. Bu yüzden bu çalışmada Ethereum fiyat verileri tercih edilmiştir.

Bu çalışmada, Kaggle'da bulunan Ethereum ve Bitcoin fiyat verisi kullanılarak yapay zeka modellerinin kripto para fiyat tahminlerindeki etkinliği incelenecektir. Veri seti, 2017 yılından 2024 yılına kadar olan Ethereum ve Bitcoin fiyat verilerini içermektedir ve bu veriler, çeşitli yapay zeka modelleri ile analiz edilecektir.

3.1.1 Veri Seti ve Ön İşleme

Veri seti, günlük olarak kaydedilmiş fiyat bilgilerini içermektedir. Her bir kayıt, ilgili kripto para biriminin tarih, açılış fiyatı, kapanış fiyatı, en yüksek ve en düşük


fiyatları, hacim ve piyasa değeri gibi bilgilerden oluşmaktadır. Analiz öncesinde veri setinin temizlenmesi, eksik verilerin tamamlanması ve gerekli dönüşümlerin yapılması gerekmektedir. Özellikle fiyat verilerinin normalize edilmesi ve zaman serisi formatına uygun hale getirilmesi önemlidir.

Tablo 3. 1.Ethereum Veri Seti


Date	Open	High	Low	Close	Adj Close	Volume
2019.01.01	133.4181	141.3975	132.6507	140.8194	140.8194	2258709868
2019.01.02	141.5195	156.9291	140.6509	155.0476	155.0476	3328240369
2019.01.03	155.1960	155.8630	147.1983	149.1350	149.1350	2676164880
2019.01.04	148.9128	156.8789	147.9071	154.5819	154.5819	3126192535
2019.01.05	154.3374	160.8248	154.3374	155.6385	155.6385	3338211928
2019.01.06	155.8042	159.3714	152.0859	157.7462	157.7462	3231294371
2019.01.07	157.8094	158.4504	151.1507	151.6992	151.6992	2712108388
2019.01.08	151.9675	153.6257	148.6695	150.3596	150.3596	2459808140
2019.01.09	150.5546	153.6222	150.2883	150.8031	150.8031	2369241197
2019.01.10	150.8435	152.1482	126.5293	128.6251	128.6251	3397734456

3.1.2 Veri Seti Analizi


Veri setinin başlangıcından Ocak 2024'e kadar olan Ethereum kapanış fiyatı hareketleri 104.53 ile 4812.087 USD arasında değişmektedir. Veri setinin ilk yıllarındaki (2019-2021) fiyat dalgalanmaları nispeten istikrarlı olup 105-750 USD arasında değişmiştir. Sonuç olarak, bu çalışmada verilerin eğitimi için 2019 yılından sonraki veri seti kullanılmıştır ve bu durum Şekil 3.1'de gösterilmiştir. Ethereum'un ghaftalık, aylık, yıllık ve mevsimsel bazda ortalaması, fiyat hareketini daha iyi anlamak için sırasıyla Şekil 3.2, Şekil 3.3, Şekil 3.4 ve Şekil 3.5'te çizilmiştir. Ethereum fiyatlarının mum grafiği görünümü de Şekil 3.6'da sunulmuştur.




Şekil 3. 1. Ethereum Kapanış Fiyatları 2019- 2024




Şekil 3. 2. Ethereum Haftalık Kapanış Fiyatları




Şekil 3. 3. Ethereum Aylık Kapanış Fiyatları



Şekil 3. 4. Ethereum Mevsimler Kapanış Fiyatları



Şekil 3. 5. Ethereum Yıllık Kapanış Fiyatları




Şekil 3. 6. Ethereum Kapanış Fiyatı Mum Çubuğu Grafiği

Ethereum, 2020'nin Mart ayına kadar süren bir istikrar dönemiyle yükseliş trendini sürdürdü. COVID-19 salgınının ilk dalgasında sadece bir günde 194.86'dan 112.34'e kadar düştü. Ancak yılın sonunda yani Aralık 2020'de 751.61 değerlerini gördü. Mayıs 2021 ortalarında Ethereum'un 4168 dolara ulaşmışken Çin'in kripto para madenciliği ve ticaretine yönelik düzenlemeleri ani düşüşlere sebep oldu. Temmuz 2021 tarihinde tekrardan toparlamaya başlayan Ethereum Kasım 2021'de kripto piyasasındaki genel belirsizlikler ve enflasyon endişeleri tekrardan düşüşe neden oldu. Sonra tekrar toparlamaya başlamışken Mayıs 2022'de kripto para borsası Celsius'un likidite sorunları ve Terra (LUNA) ekosisteminin çöküşü, piyasalarda güvensizlik yaratarak Ethereum fiyatının düşmesine yol açtı. 2023'ün başlarında ise toparlanmaya başladı.

3.2. Blokzincir Teknolojisi


Blokzincir, kripto paraların alım-satımının ötesinde, verilerin güvenli ve şeffaf bir biçimde saklanması sağlayan bir teknolojidir. İşlemler, birbirine kriptografik olarak bağlı bloklar halinde kaydedilir ve merkezi olmayan bir ağda herkes tarafından erişilebilir.



Şekil 3. 7. Merkezi ve Dağıtık Ağ Yapısı (Usta & Doğantekin, 2019)

Bu teknoloji, verilerin değiştirilemez bir şekilde kaydedilmesini ve herkes tarafından doğrulanabilir olmasını sağlar. Üçüncü bir kişiye veya otoriteye ihtiyaç duymadan, işlemlerin güvenli bir şekilde gerçekleştirilmesine olanak tanır. Bilgiyi

değiştirmek, blokların birbirine bağlı yapısı nedeniyle sistemin bütünlüğünü bozar ve geriye dönük olarak değişiklik yapılmasını zorlaştırır.



Şekil 3. 8. Sunucu Tabanlı Ağ ile Eşler Arası Ağ (Erözel Durbilmez, 2018)

Blokzincir, akıllı sözleşmeler aracılığıyla insan aracılığı azaltır ve işletmelerin işleyişini dönüştürür. Bu teknoloji, verilerin güvenli bir şekilde saklanmasını sağlarken işlemlerin doğrulanabilirliğini ve kalıcılığını da temin eder.


Blokzincir, güvenilir bir elektronik ödeme sistemi sunar ve geri döndürülmesi zor işlemler dolandırıcılığa karşı bir koruma sağlar (Nakamoto, 2008). Blokzincir teknolojisinin geniş bir uygulama yelpazesi bulunmakta ve sosyo-ekonomik alanlarda yenilikçi temellerin oluşturulabileceği potansiyeli vurgulanmaktadır (Iansiti & Lakhani, 2017).

Tablo 3. 2. Keccak-256 ile Hash Değeri Hesaplama

Veri	Ethereum
Keccak	564ccaf7594d66b1eaaea24fe01f0585bf52ee70852af4eac0cc4b04711cd0e2
-256	
Veri	ethereum
Keccak	541111248b45b7a8dc3f5579f630e74cb01456ea6ac067d3f4d793245a2551
-256	55

Bloklar zincir halinde birbirine bağlıdır ve birbirleriyle hash değeri kullanılarak bağlanır. Her blok, önceki bloğun hash değerini içerir. Bu sayede, ilk bloktan son bloğa

kadar tüm bloklar birbirleriyle bağlantılıdır. Herhangi bir bloktaki işlemlerde veya parametrelerde yapılan değişiklikler, bloğun hash değerini değiştirir ve bu nedenle zincirde kopukluk oluşur. Bu şekilde, değiştirilmiş blokların tespiti kolaylaşır ve diğer düğümler tarafından reddedilir (Yaga, Mell, Roby, & Scarfone, 2019).



Şekil 3. 9. Bloklar ve İşlemler

Birçok kullanıcının etkileşimi sonucunda ortaya çıkan kayıtlara "işlem" adı verilir. Bu işlemler, bloklarda depolanır ve bir blok içerisinde birden fazla işlem bulunabilir. İşlemler, henüz onaylanmamış olanlarını içeren bir havuzda madenciler için bekletilir. Madenciler, havuzdaki işlemleri doğrular ve bunları bir blok haline getirir. Oluşturulan bu blok, madenci tarafından ağda paylaşılır ve diğer düğümlerin bu değişiklikleri senkronize etmesini sağlar.

3.3. Yapay Zeka

Yapay zeka, hayatımızın birçok alanına entegre olarak, günlük yaşantımızı önemli ölçüde kolaylaştırmıştır. Bu kolaylık, çeşitli alanlarda kendini göstermektedir. Özellikle finansal teknolojilerde, yapay zeka ve makine öğrenimi yöntemleri, kripto para piyasalarında öngörü ve analiz yapma süreçlerini köklü bir şekilde dönüştürmüştür. Bu bağlamda, Ethereum gibi popüler kripto para birimlerinin fiyat tahminleri, ileri yapay zeka modelleri kullanılarak daha doğru ve güvenilir hale getirilmektedir. Yatırımcılar, bu modeller sayesinde piyasa hareketlerini daha iyi anlayabilir ve daha bilinçli kararlar alabilirler. Yapay zeka tabanlı analizler, sadece yatırım stratejilerini iyileştirmekle kalmaz, aynı zamanda piyasa dalgalanmalarına karşı daha etkin risk yönetimi sağlar. Böylece, kripto para dünyasında güvenlik ve karlılık artırılarak, dijital finansal ekosistemin sürdürülebilirliği desteklenmiş olur.

1955'te John McCarthy, Marvin Minsky, Nathaniel Rochester ve Claude Shannon tarafından sunulan "Yapay Zeka Yaz Araştırma Projesi" metni, yapay zekânın sadece insan zekâsının matematiksel bir modellemesini yapmakla sınırlı olmadığını ve bu alanın bağımsız bir araştırma alanı olarak ele alındığını ortaya koymuştur. 1956 yazında Dartmouth Koleji'nde Hanover, New Hampshire'da, yapay zeka üzerine iki aylık bir çalışma yapılması önerilmiştir. Bu çalışma, öğrenme ve zekânın tüm yönlerinin prensipte bir makine tarafından taklit edilebileceği fikrinden yola çıkacaktır. Makinelerin dili kullanma, soyutlama yapma, kavram oluşturma, insanlara özgü problemleri çözme ve kendini geliştirme yeteneklerinin nasıl sağlanabileceği araştırılacaktır. Bu konularda dikkatle seçilmiş 10 bilim insanının birlikte çalışmasının önemli ilerlemeler sağlayacağı düşünülmektedir (McCarthy ve ark., 1956). Yapay zeka algoritmaları üzerine yapılan çalışmalar, 1956 yılı ve sonrasında çeşitli kurumlar bünyesinde devam etmiş ve başarılı sonuçlar elde edilmiştir. Yapay zeka alanında öncü kabul edilen Herb Simon'un, 1956 sonbaharında IBM 650 model bilgisayar kullanarak ilk karmaşık bilgi işlem çalışmalarını gerçekleştirdiği bilinmektedir (Nilsson, 2010).

Günümüz algoritmaları, insan kapasitesinin ötesinde hızlarda hesaplamalar yapabilmekte ve bu yetenekleri sayesinde finansal piyasalarda önemli bir rol oynamaktadır. Çeşitli analizler, simülasyonlar ve geriye dönük testler, algoritmalar aracılığıyla hızlı ve etkili bir şekilde gerçekleştirilmektedir. Büyük veri, veri bilimi, derin öğrenme ve görsel unsurların dijitalleştirilmesi gibi konular ve alanlar, her dönemde olduğu gibi günümüzde de büyük ilgi görmektedir. Yapay zeka ve algoritmalar, yazılımlar, robotlar ve kendini öğrenebilen bilgisayarlar, insan becerilerini taklit edebilen uygulamalar ile birlikte, teknolojinin gelişmesiyle birlikte daha fazla önem kazanmaktadır. Teknolojik ilerlemeler, insanlığa sunulan imkanları artırmakta ve bu imkanlar, işlemlerin daha hızlı ve daha az insani müdahale ile gerçekleştirilmesine olanak tanımaktadır. En önemlisi, hata payının azalması ile birlikte, insanlara duyulan ihtiyacın azaldığı yeni bir sisteme doğru ilerlemekteyiz.

Yapay zekanın yapabileceği şeyler her geçen gün artmaktadır. Örneğin :

- ❖ **Veri Analizi ve Tahmin:** Büyük veri setlerini hızlı ve etkin bir şekilde analiz edebilir. Bu analizler, finansal piyasalarda yatırım kararları vermekten, pazarlama stratejileri oluşturmaya kadar geniş bir yelpazede kullanılabilir. Örneğin, makine öğrenimi algoritmaları, geçmiş verilerden öğrenerek gelecekteki trendleri ve anormallikleri tahmin edebilir.


- ❖ **Doğal Dil İşleme (NLP):** İnsan dilini anlamak ve işlemek için kullanılabilir. Bu, metin ve konuşma verilerini analiz edebilme, dil çevirisi yapabilme, sohbet botları ve sanal asistanlar oluşturma gibi uygulamaları içerir. NLP, müşteri hizmetleri, içerik yönetimi ve dil eğitimi gibi birçok alanda kullanılmaktadır.
- ❖ **Görsel Tanıma:** Bilgisayarla görme teknolojileri, yapay zekanın görsel verileri analiz etmesini sağlar. Bu teknoloji, yüz tanıma, nesne tanıma ve görüntü sınıflandırma gibi uygulamalarda kullanılır. Güvenlik sistemleri, sağlık teşhisleri (örneğin, tıbbi görüntülerin analizi) ve otonom araçlar gibi alanlarda görsel tanıma büyük bir rol oynamaktadır.
- ❖ **Otonom Sistemler:** Otonom araçlar ve robotik sistemlerde kullanılarak insan müdahalesi olmadan görevleri yerine getirebilmektedir. Otonom araçlar, trafik düzenlemelerini optimize edebilir, güvenli ve verimli bir şekilde seyahat edebilir. Endüstriyel robotlar ise üretim süreçlerini otomatikleştirerek verimliliği artırabilir.
- ❖ **Sağlık Hizmetleri:** Sağlık sektöründe tanı ve tedavi süreçlerini iyileştirmede önemli bir rol oynamaktadır. Tıbbi verilerin analizi, hastalıkların erken teşhisi ve kişiselleştirilmiş tedavi planlarının oluşturulması yapay zeka ile mümkün hale gelmiştir. Ayrıca, AI destekli cerrahi robotlar, hassas ve minimal invaziv ameliyatlara gerçekleştirebilmektedir.
- ❖ **Finans ve Ekonomi:** Finansal piyasaların analizinde ve risk yönetiminde kullanılmaktadır. Algoritmik ticaret, kredi riski analizi, sahtekarlık tespiti gibi uygulamalar, finans sektöründe AI'nın yaygın kullanım alanlarıdır. Bu teknolojiler, daha hızlı ve doğru kararlar alınmasına yardımcı olmaktadır.
- ❖ **Eğitim:** AI, eğitim alanında da devrim yaratmaktadır. Öğrenci performansını izleyen ve bireysel öğrenme planları oluşturan akıllı eğitim sistemleri, eğitimde kişiselleştirilmiş yaklaşımlar sunmaktadır. Ayrıca, dil öğrenme uygulamaları ve sanal öğretmenler, eğitim sürecini daha erişilebilir ve etkili hale getirmektedir.

Finansal piyasalarda mevcut enstrümanların alım satım işlemlerinde kullanılmak üzere kurgulanan algoritmaların haricinde, bu algoritmaları inceleyerek ve performanslarını değerlendirerek yeni algoritmalar yazan ve geliştiren yazılımlar da mevcuttur. Bu yazılımlar, enstrümanların fiyat hareketlerini, performanslarını, alıcı-satıcı miktarlarını ve hacimlerini analiz ederek optimize edilmiş algoritmalar oluştururlar.

Gelişen yazılım imkanları ile algoritmaların işlevleri de gelişmiş ve algoritmalar, gerekli durumlarda kendilerini optimize edebilir, güncelleyebilir ve geliştirebilir hale gelmiştir. Makine öğrenimi ve derin öğrenmede gerçekleşen ilerlemeler, algoritmaların da kendilerini güncelleyebilmelerine imkan tanımaktadır. Böylelikle algoritmalar, belirli bir amaca yönelik olmaktan çıkarak farklı amaçlar için kullanılabilen verilere ulaşan, verileri inceleyebilen ve bu verilerle manipülasyon yaparak analiz edebilen, elde ettiği sonuçlara göre verimliliği artırmak üzere gerekli düzenlemeleri yapabilecek hale gelmiştir.

Gelecekte, cerrahi operasyonlar otomasyon ve uzaktan erişim ile gerçekleştirilebilecektir. Bu sayede, ameliyatlara gerçekleştiren doktorların yaşlanması veya ellerinin titremesi gibi sağlık sorunlarının önemi ortadan kalkarak, tüm hastaların aynı riskli ameliyatlara tedavi edilmesi mümkün hale gelecektir. Ulaşım ve taşımacılıkta, sürücüsüz araçlar sayesinde insan kaynaklı zaman kaybı ve kaza riski en aza indirilebilecektir. Yapay zeka algoritmaları, makine öğrenimi ve derin öğrenme birlikteliğinde finansal amaçlı kullanımlara son derece uygun kabul edilmektedir. Riskin erken saptanması, risk simülasyonları ve risk beklentilerinin hesaplanmasında yapay zeka algoritmalarının kullanımı tercih edilebilir. Risk yönetimi süreçlerinde potansiyel yardımcı argümanlar olarak yer almaları muhtemeldir.

Algoritmaların, insan iş gücüne duyulan ihtiyacı azaltarak işsizliği artırabileceği ve robot askerlerden oluşan ordulara sahip ülkelerin, diğerlerine karşı ezici üstünlük sağlayabileceği gibi endişeler mevcuttur. Yapay zeka ve algoritma aktivitelerinin sınırları hakkında kesin bir bilgi bulunmamakla birlikte, gerçekleştirilen uygulamalar bu alanda sınırların olmadığını göstermektedir. Bu çalışmada, algoritmaların tanımı, tarihsel kullanım alanları ve günümüzde bilgisayarlar üzerinde yapay zeka ile gelişen diğer algoritma unsurları incelenmiştir. Bu unsurların gelecekte nasıl evrileceği ve hayatımızı nasıl şekillendireceği konusundaki tahminler de değerlendirilmiştir.



Şekil 3. 10. Yapay Zekanın Alt Dal Şematiği (Deniz, 2023)

Şekil 3.10, yapay zekanın (AI) hiyerarşik yapısını ve alt dallarını görsel olarak temsil etmektedir. En dıştaki yeşil oval, yapay zekanın genel alanını gösterirken, onun içinde yer alan sarı bölge makine öğrenimini (ML) temsil etmektedir. Makine öğreniminin içerisinde, yapay sinir ağları (ANN) yer almakta olup, bu ağlar insan sinir sisteminden ilham alır ve veri yoluyla öğrenme ve çıkarım yapma yeteneğine sahiptir. Daha derinde, mor renkle belirtilen derin öğrenme (DL) bulunur; bu alan, çok katmanlı yapay sinir ağlarını kullanarak daha karmaşık veri analizleri yapabilmektedir. En içte ise derin sinir ağları (DNN) yer almakta olup, gelişmiş derin öğrenme teknikleriyle yüksek doğrulukta tahmin ve sınıflandırma işlemleri gerçekleştirir. Bu figür, yapay zekanın geniş kapsamını ve alt dallarının birbirleriyle olan ilişkilerini açık bir şekilde göstermektedir.

3.4. Makine Öğrenmesi


Makine öğrenmesi kavramı, ilk olarak 1959 yılında Arthur Samuel tarafından ortaya atılmıştır. Samuel'in yazdığı dama oyunu algoritması, yaptığı hatalardan ders çıkaran ve zamanla daha iyi performans sergileyen bir algoritmadır. Bu algoritma, makinelerin kendilerine sunulan problemlere çözüm bulma yeteneğini geliştiren bir yapay zeka sınıfının temelini oluşturmuştur. Samuel, makine öğrenmesini “bilgisayarların açıkça programlanmadan öğrenmesini sağlaması gereken bir araştırma alanı” olarak tanımlamıştır (Mockenhaupt, 2021).

Makine öğrenmesi, resim tanımlama gibi alanlarda yoğun bir şekilde kullanılmaktadır. Bu alanda, algoritmalar çok sayıda nesne veya canlı resmi parametresi tanıtılır. Bu parametreler eğitildikten sonra, daha önce görmediği bir resim sunulduğunda, makinenin bu resmi tanımlayabilmesi beklenir. Bu, makinelerin kendi kendilerine karar verebilme yeteneğini geliştirme fikrine dayanmaktadır. Yani, makine öğrenmesi, sadece belirli modelleri veya verilen görevleri yerine getiren bir mekanizma olmanın ötesine geçerek, geçmişten ders çıkarabilen ve bu dersler ışığında karar verebilen bir yapıyı temsil eder (Boyras, 2019).

Teknik açıdan ifade etmek gerekirse, makine öğrenmesi, karşılaştığı problemleri çözmek için çeşitli kuramlar ve teknikler geliştirerek mantıksal işlemler gerçekleştiren bir yapay zeka türüdür. Bilgisayar veya makineler, çeşitli yöntemlerle elde ettikleri verileri öğrenir ve bu verilerden yararlanarak matematiksel algoritmalar ve modeller oluştururlar. Bu süreç, problemlere insanlara benzer şekilde yaklaşmayı ve geçmiş deneyimlerden faydalanarak anlamlı çıkarımlar yapmayı içerir. Öğrenme algoritmaları sayesinde, veriler arasındaki bağlantılar kurulur ve çözülecek probleme uygun modeller geliştirilir, böylece nihai sonuca ulaşılır (Gezer & Saylan, 2017).

Günümüzde makine öğrenmesi, bankacılık, eğlence, finans, biyoteknoloji, eğitim, oyun ve pazarlama gibi birçok sektörde kullanılmaktadır. Verilerin artan hacmi ve karmaşıklığı, insanoğlunun bu verileri kısa sürede anlamlandırma kapasitesinin ötesine geçmiştir. Bu noktada makine öğrenmesi devreye girerek, karmaşık verilerden ileriye dönük doğru analizler çıkarılmasını sağlar (Türkmenoglu & Tantug, 2014).

Makine öğrenimi, yapay zekanın bir alt katmanında olup, derin öğrenmenin bir üst kümesinde yer alır. Şekil 3.10'da görüldüğü gibi sinir ağları, derin öğrenme, makine öğrenmesi ve yapay zeka hiyerarşisinde sıralanır. Algoritmalar, büyük veri kümelerindeki kalıpları ve korelasyonları bulmak için eğitilir ve bu analizlere dayanarak en iyi kararları ve tahminleri yaparlar. Kullanım süreciyle birlikte gelişen makine öğrenimi uygulamaları, ne kadar fazla veriye sahip olursa o kadar doğru sonuçlar üretir (SAP, 2021).



Şekil 3. 11. Makine Öğrenmesinin Çalışma Yöntemi

Makine öğrenmesi, geleneksel programlamadan farklı olarak, minimal insan girdisi ile çalışır ve sistemin geçmiş gözlemleri değerlendirerek otonom olarak hareket etmesini sağlar. Geleneksel programlamada, IF-THEN yapısı ile belirlenen talimatlar doğrultusunda işlem yapılırken, makine öğreniminde algoritmalar, verilerden otomatik olarak kalıplar çıkararak öğrenir ve kararlar alır (Monkeylearn, 2024). Şekil 3.11’de makine öğrenmesinin çalışma yöntemi incelenebilir. Bu süreç, makine öğrenimi ve yapay zeka arasındaki farkları da net bir şekilde ortaya koyar; yapay zeka, makinelerin kendi kararlarını verip yeni beceriler öğrenmesini sağlarken, makine öğrenimi, verilerden beslenerek yeni bilgiler edinme sürecidir.

3.4.1. Makine öğrenmesi türleri

Makine öğrenimi, bilgisayarların verilerden öğrenmesini ve bu öğrendiklerini kullanarak tahminler veya kararlar almasını sağlayan bir yapay zeka dalıdır. Temel olarak, makine öğrenimi algoritmaları büyük veri setleri üzerinde çalışarak örüntüleri tanımlar ve bu örüntülerden yararlanarak gelecekteki olayları veya davranışları tahmin eder. Makine öğrenimi, çeşitli türlere ayrılır ve her bir tür, farklı veri türleri ve problem türleri için uygundur. İşte makine öğreniminin ana türleri:

Denetimli Öğrenme; makine öğreniminde en çok kullanılan ve en popüler yöntemlerden biri denetimli öğrenmedir. Denetimli öğrenmede, her eğitim etiketi bir çıktı etiketi üretir ve sistem, etiketli verilerle eğitilir. Bu süreçte, sistemin belirli sorunları öğrenmesi sağlanır ve eğitim verileri genellikle manuel olarak etiketlenir; bu veriler resimler, kelimeler veya diğer veri türleri olabilir (Çoban, 2016).

Denetimli öğrenme, bazı kaynaklarda "gözetimli öğrenme" olarak da adlandırılmaktadır. Bu yöntemde, tahminler yapılırken genellikle regresyon veya sınıflandırma teknikleri kullanılır. Örneğin, gelen bir e-postanın spam olup olmadığını belirlemek için bu yöntem kullanılabilir. Spam olarak sınıflandırılan e-postalar, önemli örnekler olarak makine öğrenimi algoritmasına beslenir ve bu sayede algoritma, hangi e-postaların spam olarak değerlendirileceğini öğrenir.

Denetimli öğrenmenin temel amacı, etiketli eğitim verilerinden öğrenerek yeni ve görülmemiş veriler üzerinde doğru tahminler yapmaktır. Bu yöntem, geniş bir uygulama yelpazesine sahiptir ve günlük yaşamda sıklıkla karşılaştığımız birçok teknoloji ve hizmetin temelini oluşturur. Örneğin, konuşma tanıma, görüntü işleme ve doğal dil işleme gibi alanlarda yoğun bir şekilde kullanılmaktadır. Bu sayede, denetimli öğrenme

algoritmaları, kullanıcıların konuşmalarını metne dönüştürebilir, fotoğrafları analiz edebilir veya metinleri anlamlandırabilir.

Ayrıca, finansal hizmetlerde kredi risk analizi, sağlık sektöründe hastalık teşhisi ve pazarlamada müşteri segmentasyonu gibi çeşitli alanlarda denetimli öğrenme uygulamaları yaygın olarak kullanılır. Eğitim verilerinin kalitesi ve çeşitliliği, denetimli öğrenmenin başarısını doğrudan etkiler. Bu nedenle, veri toplama ve etiketleme süreçleri büyük önem taşır.

Denetimli öğrenme, makine öğreniminin temel taşlarından biridir ve doğru verilerle beslenip eğitildiğinde, birçok karmaşık sorunu çözmede etkili sonuçlar verir. Bu yöntem, geniş uygulama alanı ve yüksek başarı oranıyla, makine öğrenimi projelerinin vazgeçilmez bir parçası haline gelmiştir.

Denetimsiz Öğrenme; denetimsiz öğrenme, etiketlenmemiş verilerde bulunan iç görüleri ve ilişkileri ortaya çıkarmak için kullanılan bir makine öğrenimi türüdür. Bu sistemde, eğitim sırasında etiketsiz veriler kullanılır ve bu verilerden anlamlı kalıplar, ilişkiler ve yapılar keşfetmeye çalışılır. Eğitim süreci, gözetim veya belirli bir çıktı olmaksızın gerçekleşir, bu nedenle sistemden beklenen sonuçlar önceden bilinmez. Model, doğru cevaplarla eğitilmediği için kendi başına kalıpları ve ilişkileri bulması gerekmektedir (Monkeylearn, 2024).

Denetimsiz öğrenme, eldeki verilerden gruplama yaparak benzerlikleri ve farklılıkları belirler. Bu tür bir model, müşteri verilerini analiz etmek için de kullanılabilir; müşterilerin davranışlarına veya özelliklerine göre benzer ve farklı olanları gruplandırarak pazarlama stratejilerini optimize edebilir.

Denetimsiz öğrenmenin en yaygın uygulamalarından biri olan kümeleme (clustering), verileri doğal gruplara ayırma sürecidir. Bu süreçte, model veri noktaları arasındaki benzerlikleri ve farklılıkları analiz ederek gruplar oluşturur. Kümeleme, pazar segmentasyonu, sosyal ağ analizi, biyoinformatik ve birçok diğer alanda yaygın olarak kullanılır. Bir diğer yaygın uygulama ise boyut azaltma (dimensionality reduction) teknikleridir; bu teknikler, yüksek boyutlu verileri daha düşük boyutlu temsillerine indirger ve verilerin görselleştirilmesi ve işlenmesi süreçlerini kolaylaştırır.

Denetimsiz öğrenmenin gücü, verilerdeki gizli kalıpları ve ilişkileri keşfetme yeteneğinden gelir. Bu yöntem, verilerin önceden etiketlenmesine gerek kalmadan çalıştığı için geniş veri setleri üzerinde etkili bir şekilde uygulanabilir. Ayrıca, denetimsiz öğrenme algoritmaları, verilerdeki anormallikleri ve olağandışı durumları tespit etmede de kullanışlıdır. Örneğin, siber güvenlikte anomali tespiti, kredi kartı sahtekarlığı

algılama ve sağlık sektöründe anormal hasta verilerinin tespiti gibi uygulamalarda denetimsiz öğrenme modelleri başarılı sonuçlar verebilir.

Sonuç olarak, denetimsiz öğrenme modelleri, verilerden etiketlenmemiş bilgiler çıkararak geniş bir uygulama yelpazesinde kullanılabilir. Bu modeller, verilerin doğal yapısını anlamada ve yeni, beklenmedik kalıplar keşfetmede büyük bir potansiyele sahiptir. Her model, kendi kullanım alanına göre belirli ihtiyaçları karşılar ve çeşitli sektörlerde değerli iç görüler sağlar.

Pekiştirmeli Öğrenme; Pekiştirmeli öğrenme, davranışçılığın temel prensiplerine dayanan bir öğrenme yöntemidir. Bu yaklaşımda, eğitim süreci en iyi sonuca ulaşana kadar devam eder ve model, problem çözmek için en doğru sonuçları ve en büyük başarıyı elde etmeyi amaçlar. Pekiştirmeli öğrenmede model, bulunduğu ortamla sürekli etkileşim halindedir ve bu etkileşimler sonucunda öğrenir. Ayrıca, sistem aldığı sonuçlara göre karar verme yeteneğine sahiptir, bu da onu dinamik ve uyarlanabilir kılar.

Pekiştirmeli öğrenme modelinde, genellikle büyük miktarda veri kullanılmaz. Ancak, eğitim süreci boyunca modelin performansı izlenir ve doğru yönde ilerlediği gözlemlenirse ek veri ile beslenebilir. Bu yönüyle modelin eğitimine dışarıdan müdahale edilebilir ve gerektiğinde veri sağlanabilir.

Pekiştirmeli öğrenmeyi denetimli öğrenmeden ayıran en önemli özellik, tüm verilerin bir kerede verilmemesi, bunun yerine verilerin uzmanlar tarafından bölünerek ve başarı oranına göre sırayla sunulmasıdır. Bu süreç, modelin adım adım öğrenmesine ve her adımda performansını artırmasına olanak tanır (François-Lavet, Islam, Pineau, Henderson, & Bellemare, 2018).

Pekiştirmeli öğrenme, özellikle oyun teorisi ve robotik gibi dinamik ve sürekli değişen ortamlarda çok etkilidir. Model, her adımda çevresinden aldığı geri bildirimlerle stratejilerini günceller ve optimize eder. Örneğin, bir robotun engellerle dolu bir ortamda hareket etmeyi öğrenmesi veya bir oyun ajanının en iyi hamleleri belirlemesi gibi durumlarda, pekiştirmeli öğrenme yöntemleri büyük başarı sağlar.

Bu öğrenme modeli, ödül ve ceza mekanizmalarını kullanarak modelin istenen davranışları öğrenmesini sağlar. Ödüller, doğru hareketler veya kararlar için verilirken, cezalar yanlış veya istenmeyen hareketler için uygulanır. Bu şekilde model, zamanla en iyi stratejileri ve kararları öğrenir, performansını sürekli olarak geliştirir.

Pekiştirmeli öğrenme, dinamik ve karmaşık problemleri çözmede etkili bir yöntemdir. Bu model, sürekli etkileşim ve geri bildirim süreciyle öğrenir, adapte olur ve optimize eder. Pekiştirmeli öğrenme, özellikle veri toplama ve işleme süreçlerinin zor olduğu

durumlarda veya modelin çevreyle sürekli etkileşimde bulunması gerektiğinde ideal bir öğrenme yaklaşımıdır.

3.5. Derin Öğrenme

Derin öğrenme, makine öğrenmesi kapsamındaki en güçlü tekniklerden biri olarak, birçok doğrusal olmayan işlem birimi katmanını kullanarak özellik çıkarımı ve dönüşüm işlemlerini gerçekleştirir. Bu işlem sürecinde, veri bir dizi katman boyunca aktarılır ve her bir katman, bir önceki katmandan aldığı çıktıyı girdi olarak kullanarak veriyi daha karmaşık bir hale dönüştürür. Bu katmanlı yapı, verilerin hiyerarşik bir biçimde temsil edilmesine olanak tanır ve bu sayede üst düzey soyutlamalar elde edilebilir (Deng & Yu, 2014).

Derin öğrenme algoritmaları, hem denetimli hem de denetimsiz öğrenme yöntemlerinde kullanılabilme esnekliğine sahiptir. Denetimli öğrenme, genellikle sınıflandırma ve regresyon gibi belirli tahmin görevlerinde kullanılırken, denetimsiz öğrenme algoritmaları desen tanıma ve kümeleme gibi veri keşif görevlerinde uygulanır (Deng ve ark., 2014). Bu yetenekleri sayesinde derin öğrenme, büyük ve karmaşık veri setleri üzerinde oldukça etkili sonuçlar sunar.

Derin öğrenme, verilerin çok katmanlı özellik seviyelerini öğrenmeye dayanır. İlk katmanlar basit ve genel özellikleri öğrenirken, üst katmanlara geçildikçe daha karmaşık ve soyut özellikler elde edilir. Örneğin, görüntü işleme alanında, ilk katmanlar kenar ve köşe gibi temel yapıları tanıırken, üst katmanlar bu bilgilerden hareketle daha karmaşık nesneleri ve şekilleri tanımlayabilir. Bu hiyerarşik yapı, verinin anlamlı yapılarının ve ilişkilerinin yakalanmasını sağlayarak daha güçlü modellemelerin oluşturulmasına olanak tanır (Bengio, 2009).

Derin öğrenmenin en büyük avantajlarından biri, özellik çıkarımını otomatik olarak gerçekleştirebilmesidir. Geleneksel makine öğrenmesi tekniklerinde, özelliklerin elle çıkarılması gerekirdi; ancak derin öğrenme, veriden otomatik olarak özellikler çıkararak en uygun temsilleri elde eder. Bu, özellikle yüksek boyutlu ve karmaşık veri setleri ile çalışırken büyük bir avantaj sağlar. Örneğin, görüntü verilerinde, ham piksellerden başlayarak daha yüksek seviyelerde yüz tanıma ve nesne algılama gibi karmaşık görevleri yerine getirebilecek özellikler otomatik olarak çıkarılabilir (Song ve ark., 2013).

Derin öğrenme, geniş bir uygulama yelpazesine sahiptir. Görüntü işleme, doğal dil işleme, ses tanıma, biyoinformatik, finans ve otonom araçlar gibi alanlarda başarıyla kullanılmaktadır. Özellikle Konvolüsyonel Sinir Ağları (CNN), görüntü işleme alanında yaygın olarak kullanılırken; Tekrarlayan Sinir Ağları (RNN) ve daha yeni yöntemler olan Dönüştürücüler (Transformers), zaman serisi verileri ve dil modelleme gibi sıralı verilerde büyük başarı sağlamıştır.

Derin öğrenme tarihi boyunca birçok önemli gelişme yaşanmıştır. İlk kez 1965 yılında Ivakhnenko ve Lapa tarafından denetimli derin beslemeli çok katmanlı perceptron üzerine yapılan çalışma, bu alanda bir mihenk taşı olarak kabul edilir (Ivakhnenko & Lapa, 1966). Her katmanda en uygun özelliklerin istatistiksel yöntemlerle seçilip sonraki katmana aktarılması ve geri yayılım algoritmasının kullanılmaması, o dönem için yenilikçi bir yaklaşım olarak öne çıkmıştır.

1979 yılında, Fukushima tarafından geliştirilen "Neokognitron" mimarisi, omurgalıların görsel sinir sistemlerinden esinlenilerek tasarlanmış ve denetimsiz öğrenme ile kendi kendine organize olabilen bir yapı sunmuştur. Bu mimari, modern derin öğrenme ağlarına benzer bir şekilde, çoklu bükülme ve havuzlama katmanlarına sahipti (Fukushima, 1980). Ancak, geri yayılım algoritmasının etkin kullanımı eksikti ve bu durum, derin öğrenmenin potansiyelini tam olarak ortaya koyamamıştı.

1989'da Yann LeCun ve ekibi, el yazısı rakamlarını tanımak için ilk başarılı derin sinir ağı uygulamasını gerçekleştirmiştir (LeCun, ve ark., 1989). LeCun'un geliştirdiği "LeNet" yapısı, kıvrımlı sinir ağları ve geri yayılım algoritmasının birlikte kullanıldığı ilk örneklerden biridir (LeCun Y. , ve diğerleri, 1989). Bu başarı, derin öğrenme algoritmalarının potansiyelini ortaya koysa da, o dönemdeki hesaplama güçleri nedeniyle eğitim süreleri oldukça uzundu.


2000'li yıllarda, bilgisayar işlem hızlarının ve GPU'ların kullanımıyla birlikte, derin öğrenme alanında önemli gelişmeler kaydedilmiştir. Bu dönemde, Igor Aizenberg ve arkadaşları tarafından "Derin Öğrenme" terimi literatüre kazandırılmıştır (Aizenberg ve ark., 2000). 2006'da Geoffrey Hinton, çok katmanlı ileri beslemeli sinir ağlarının her iterasyonda bir katmanının denetimsiz olarak nasıl etkili şekilde eğitilebileceğini ve ardından denetimli geri yayılım yöntemi ile ince ayar yapılabileceğini gösteren önemli bir çalışma yayımlamıştır (Hinton, 2007). Bu çalışmalar, derin öğrenme tekniklerinin temel taşlarını oluşturarak, bu alandaki araştırmaların ve uygulamaların hız kazanmasına zemin hazırlamıştır.

Bu hızla gelişen teknoloji ve teorik ilerlemeler, derin öğrenmenin farklı sektörlerdeki uygulama alanlarını genişletmiştir. Günümüzde, derin öğrenme sadece akademik ve araştırma odaklı değil, aynı zamanda endüstriyel ve ticari alanlarda da geniş çapta kabul görmekte ve benimsenmektedir. Yenilikçi uygulamaların geliştirilmesi ve hayata geçirilmesi, derin öğrenmenin geniş kabul görmesine katkıda bulunmuş, bu teknolojilerin etkin bir şekilde kullanılmasını sağlamıştır. Bu ilerlemeler, yapay zekanın gelecekteki gelişimi için güçlü bir temel oluşturmakta ve çeşitli sektörlerdeki iş süreçlerini dönüştürmektedir.

3.6. Kullanılan Yapay Zeka Modelleri

3.6.1. ANN

Bir sinir ağı, biyolojik sinir sisteminin işleyişini taklit eden matematiksel bir hesaplama yöntemidir. Biyolojik olarak, nöronlar dokunma, ses ve ışık gibi çeşitli kaynaklardan sinyaller alır ve işler ve bu sinyalleri kasları ve bezleri kontrol etmek için gönderir. Nöronlar, giriş sinyallerini alan dendritlere ve sinyalleri nörondan uzaklaştıran aksonlara sahiptir. Bir nöronun birçok dendriti olmasına rağmen, yalnızca bir aksonu vardır. Ayrıca, nöronlar birçok kez dallanabilir ve karmaşık yapılar oluşturabilir. Nöronun elektriksel potansiyeli belirli bir seviyeyi aştığında, nöronu ateşlemeye tetikleyen bir aksiyon potansiyeli üretilir. Bu şekilde, sinyal iletimi gerçekleşir (Mellit & Kalogirou, 2008).




Şekil 3. 12. Biyolojik bir nöronun sadeleştirilmiş diyagramı (Mellit & Kalogirou, 2008)

Yapay Sinir Ağı (ANN), biyolojideki sinir sistemi gibi küçük, bireysel olarak birbirine bağlı işlem birimlerinin bir koleksiyonudur. Bilgi, bu birimler aracılığıyla bağlantılar boyunca iletilir. Gelen bir bağlantının iki değeri vardır: giriş ve ağırlık. Birimin çıktısı, toplanan değerlerin bir fonksiyonudur. ANN, bilgisayarlara uygulanırken belirli görevleri yerine getirmek üzere programlanmazlar. Bunun yerine, girdiler olarak kullanılan örüntüleri öğrenene kadar veri kümeleri üzerinde eğitilirler. Bir kez eğitildiklerinde, tahmin veya sınıflandırma için yeni modellerle sunulabilirler. ANN, gerçek sistemlerden, fiziksel modellerden, bilgisayar programlarından veya diğer kaynaklardan gelen verilerdeki desenleri otomatik olarak öğrenebilir. Bir ANN birçok girişi işleyebilir ve yanıtlar üretebilir (Mellit & Kalogirou, 2008).

ANN'ler, sinir sisteminin matematiksel olarak basitleştirilmiş versiyonu olarak düşünülebilir. Senkron bilgisayar ağları gibi çalışabilirler, ancak belirli bir amaç için önceden programlanmış geleneksel bilgisayarların aksine, ANNs eğitilmeli ve öğretilmelidir. Bu şekilde, yeni işlevsel ilişkileri ve desenleri anlayabilirler (Mellit & Kalogirou, 2008).


Şekil 3.13, ANN'nin yapısını göstermektedir. Buna göre, ANN mimarisinde, giriş, gizli ve çıkış katmanları, ağırlıklar olarak tanımlanan bir dizi parametre ile birbirine bağlanmıştır. Bu ağırlıklar, bireysel nöronlar arasındaki bağlantıları artırır veya azaltır. Bir nöronun diğerini aktive etmesi pozitif ağırlık ile ifade edilirken, diğerini baskılamak veya engelleme negatif ağırlık ile ifade edilir. Bir nöronun diğerine olan etkisi, bu ağırlıkların büyüklüğü ile orantılıdır (Bozorg-Haddad & Zolghadr-Asli, 2022).



Şekil 3. 13. ANN Yapısı- Girdi vektörü, ağırlık matrisi, bias, dönüşüm fonksiyonu ve çıktı (Bozorg-Haddad ve ark., 2022)

Şekil 3.13'teki $(x_1, x_2, \dots, x_i)$ değerleri girdi vektörünü, $(w_1, w_2, \dots, w_n)$ değerleri ağırlık matrisini, $(b_1, b_2, \dots, b_i)$ değerleri biası, (f) aktivasyon fonksiyonunu ve (a) çıktıyı göstermektedir. Bir nöronun çıktısını belirlemek için girdiler ağırlıklarla çarpılır ve sigma toplam fonksiyonu kullanılarak toplanır. Ancak, bu toplam her zaman aktivasyon fonksiyonunun eğrisinin optimal aralığında olmayabilir, bu da hatalı çıktılara neden olabilir. Bu sorunu çözmek için, toplam değere bir bias değeri (b) eklenir ve eğri boyunca eşik konumu ayarlanarak daha doğru çıktılar elde edilir.

Nöronlar tek veya birden fazla girdiye sahip olabilir. Şekil 3.14, tek girişli bir nöronu göstermektedir. Bu, tek girişli nöron ANN'nin basit bir modelidir ve ağırlık (w) ile çıktı (a) içerir.




Şekil 3. 14. Tek girişli bir nöron (Bozorg-Haddad ve ark., 2022)

Şekil 3.14'teki işlem, girdi değeri x 'in bir ağırlık w ile çarpılarak $w.x$ elde edilmesi ve ardından bir toplayıcıya gönderilmesiyle başlar. Ağırlık w , girdinin x 'in çıktısı a ne kadar etkilediğini belirler. Ayrıca, bir bias b , başka bir girdi değeri (1) ile çarpılarak ayrı bir girdi olarak toplayıcıya gönderilir. Son olarak, toplayıcıdan çıkan değer (n), aktivasyon fonksiyonundan (f) geçirilerek nöron çıktısı (a) elde edilir. Bu çıktı genellikle ağ girişine bağlıdır. Tek girişli bir nöronun denklemi aşağıda gösterilmiştir.

$$\alpha = f(w.x + b) \quad (3.1)$$

ANN yapısında, genellikle giriş sayısı birden fazladır. Bu türde birden fazla girişi olan nöronlara çok girişli nöronlar denir (Şekil 3.15). Tanımlandığı gibi, x değerleri giriş vektörünü ve w değerleri ağırlık matrisini temsil eder. Ağırlıklı girişler $(x_1, x_2, \dots, x_m)$, karşılık gelen ağırlıklarıyla $(w_{1,1}, w_{1,2}, \dots, w_{1,m})$ çarpılarak ağırlık matrisi w oluşturulur. Ağırlık w iki indekse sahiptir: birincisi o ağırlığın bağlı olduğu bir sonraki nöronu, ikincisi ise besleyici nörona karşılık gelen sinyal kaynağını gösterir. Ayrıca, ağırlıklı girişlere $(w_{i,j})$ eklenen ve ağ girişini n oluşturan bir bias (b) vardır. Bu bilgiler, sinir ağlarını anlamak için önemlidir ve denklemler aşağıda gösterilmiştir (Bozorg-Haddad ve ark., 2022).



Şekil 3. 15. Çok girişli nöron (Bozorg-Haddad ve ark., 2022)

$$n = w_{1,1}x_1 + w_{1,2}x_2 + \dots + w_{1,m}x_m + b \quad (3.2)$$

$$n = \sum_{i=0}^m (x_i \cdot w_{i,j} + b) \quad (3.3)$$

$$a = f \sum_{i=0}^m (x_i \cdot w_{i,j} + b) \quad (3.4)$$

3.6.2. RNN

RNN (Tekrarlayan Sinir Ağı), ardışık veri veya zaman serisi verilerini işlemek için özel olarak tasarlanmış bir yapay sinir ağı türüdür. Bu nedenle, bu derin öğrenme tekniği, dil çevirisi, doğal dil işleme (NLP), konuşma tanıma ve görüntü açıklaması gibi sıralı veya zamansal problemlerin çözümünde yaygın olarak kullanılır. Tekrarlayan Sinir Ağı (RNN), yapılandırılmış veya yapılandırılmamış ardışık verileri işlemek için yaygın olarak kullanılan bir derin öğrenme modeli olarak da tanımlanabilir. Konuşma tanıma, duygu analizi ve video aktivite tanıma gibi çeşitli alanlarda uygulamaları bulunmaktadır.

Geleneksel sinir ağı modellerinden farklı olarak, RNN'ler değişen boyut ve uzunluklardaki girdi ve çıktıları işleyebilir. RNN'ler ile geleneksel sinir ağları arasındaki

önemli bir fark, geleneksel sinir ağlarının sabit giriş ve çıkış boyutlarına sahip olmasıdır. RNN'ler ise değişken giriş ve çıkış boyutlarına uyum sağlayabilir. Bu esneklik, her bir dizinin uzunluğunun değişebileceği ardışık verileri etkili bir şekilde modellemelerini sağlar.

RNN modelinin çok yönlülüğü, ardışık verilerdeki bağımlılıkları ve desenleri yakalama yeteneğinde yatar ve bu da onu sıraların analizini ve işlenmesini içeren görevler için uygun hale getirir. Ağ içindeki tekrarlayan bağlantıları kullanarak, RNN'ler geçmiş girdilerden gelen bağlam bilgilerini etkili bir şekilde öğrenebilir ve her adımda tahminler veya sınıflandırmalar için kullanabilir.

3.6.3. LSTM

LSTM, Tekrarlayan Sinir Ağı (RNN) türüdür. RNN'lerin, ileri beslemeli sinir ağlarına (örneğin, Çok Katmanlı Algılayıcı) göre eğitilmesindeki temel fark, zaman üzerinden geri yayılım algoritmaları ile eğitilmeleridir. RNN'lerdeki temel sorunlardan biri, zaman içinde geri yayılım yoluyla elde edilmek istenen gradyan değerinin, serinin belirli bir derinliğinden sonra zincir kuralına göre kısmi türevlerin çarpılması nedeniyle azalması olan kaybolan gradyan problemidir. LSTM yapısı, belirtilen zaman derinliğinde bu kaybolan gradyan problemine bir çözüm sunar. LSTM'nin mimarisi nedeniyle, geri yayılım algoritmasıyla gradyanların hesaplanması sırasında, kısmi türev çarpım terimlerinin (kısa vadeli) yanı sıra, kısmi türevlerin toplamını içeren terimler de (uzun vadeli) bulunur, böylece "kaybolan gradyan problem" azalır. LSTM veya RNN'nin çeşitli varyasyonları, kısmi türevleri birleştirerek uzun vadeli bilgiyi korur (Greff, Srivastava, Koutník, Steunebrink, & Schmidhuber, 2016).

3.6.4. GRU

(Cho, ve diğerleri, 2014) tarafından geliştirilen GRU (Geçitli Tekrarlayan Birim), standart bir tekrarlayan sinir ağında karşılaşılan kaybolan gradyan problemini çözmek amacıyla tasarlanmıştır. GRU, LSTM'in bir varyasyonu olarak düşünülebilir çünkü her ikisi de benzer şekilde tasarlanmış ve bazı durumlarda eşit derecede başarılı sonuçlar verebilen ağ yapılarıdır. Her iki yapının da temel amacı aynıdır: kısa süreli bellek sorunlarını çözmek. Bu ağlar, bilgi akışını düzenleyebilen “kapı (gate)” adı verilen iç mekanizmalara sahiptirler (Phi, 2018). Ancak, GRU'lar çıkış kapısı bulunmadığı için


LSTM'den daha az parametreye sahiptirler. Bu kapılar, eğitimde kullanılan verilerden hangilerinin saklanması veya atılmasının önemli olduğunu öğrenebilirler. Bu sayede, tahminlerde bulunmak için ilgili bilgileri uzun dizi zincirinden geçirebilirler.

RNN'lere dayalı hemen hemen tüm son teknoloji sonuçlar bu iki ağ ile elde edilmektedir. LSTM'ler ve GRU'lar, konuşma tanıma, konuşma sentezi ve metin oluşturma gibi alanlarda kullanılabilirler ve hatta videolar için altyazı oluşturma amacıyla da kullanılabilirler (Phi, 2018). (Weiss, Goldberg, & Yahav, 2018) yaptıkları çalışmada LSTM'in GRU'dan daha iyi sonuçlar verdiğini göstermişlerdir. Bunun nedenini ise LSTM'lerin kolayca sınırsız sayma yapabilmesi, ancak GRU'nun bunu yapamaması olarak açıklamışlardır. Bu nedenle GRU, LSTM tarafından öğrenilebilen bazı basit dilleri öğrenmekte başarısız olmaktadır. Ancak, (Gruber & Jockisch, 2020) yaptıkları çalışmada GRU'ların daha küçük ve daha seyrek veri kümelerinde daha iyi performans sergilediğini göstermişlerdir.

GRU'lar, standart tekrarlayan sinir ağlarının geliştirilmiş bir versiyonudur. Standart bir RNN'nin kaybolan gradyan problemini çözmek için GRU kullanılmaktadır. Bunu, “güncelleme kapısı (update gate)” ve “sıfırlama kapısı (reset gate)” vektörleri ile gerçekleştirir. Temel olarak, bu iki vektör hangi bilgilerin çıktıya aktarılması gerektiğine karar verir. Bu vektörlerin özel kılan şey, tahminle ilgili verileri temizlemeden bellekte uzun süre tutabilmesi ve modelin eğitiminde kullanmasıdır. Bu sayede, model hem kısa vadeli hem de uzun vadeli bağımlılıkları öğrenebilir.

3.7. Modelin Eğitim ve Test Metodolojisi

Sinir ağlarının en önemli özelliklerinden biri, öğrenme yeteneğine sahip olmalarıdır. Derin öğrenme modellerinde kullanılan sinir ağlarında, modelin başarılı bir şekilde eğitilmesi için veriler ağırlıklandırılır. Model eğitimi sürecinde, başlangıçta bağlantılara rastgele ağırlık değerleri atanır. Eğer bu bağlantılar istenilen sonuçları vermezse, ağırlık değerleri değiştirilir ve gereksiz bağlantılar elimine edilir. Eğitim sürecinde elde edilen bu ağırlıklar, sinir hücreleri arasındaki bağlantıların ağırlıkları olarak kaydedilir ve modelin öğrenme kapasitesini belirler.



Şekil 3. 16. Yapay Zeka Modelinde Veri Analizi İşleyiş Akış Şeması

Bu çalışmada, her bir kripto paranın tahminlerini yapmadan önce, veri seti eğitim ve test setleri olarak ikiye ayrılmıştır. Veri setinin %80'i modelin öğrenme süreci için eğitim seti olarak kullanılmış, geri kalan %20'si ise modelin doğruluğunu ve genelleme yeteneğini değerlendirmek için test seti olarak ayrılmıştır. Eğitim seti, modelin geçmiş fiyat verilerinden öğrenmesini sağlarken, test seti modelin yeni ve görülmemiş verilere karşı performansını ölçer. Bu eğitim setleri üzerinde, birim sayıları (unit), epoch sayıları, batch size ve dropout oranları kullanılarak çeşitli denemeler yapılmıştır. Bu denemeler, modelin hata oranlarının en düşük seviyeye indirilmesi hedeflenerek gerçekleştirilmiştir. Modelin çıkışındaki hata oranlarının minimize edilmesi, ağırlıkların kararlılık kazandığını ve modelin daha güvenilir tahminler yapabileceğini gösterir.

Araştırmada ele alınan kripto paraların başlangıç tarihleri farklı olduğu için, her biri için farklı zaman aralıklarını kapsayan veri setleri oluşturulmuştur. Ethereum kripto parasının fiyat verileri analiz edilerek, eğitim ve test setleri belirlenmiştir. Bu süreçte, en iyi sonuçları veren model parametreleri tespit edilmiştir. Örneğin, LSTM modeli için epoch sayısı, batch size ve dropout oranı üzerinde yapılan denemeler, modelin performansını optimize etmeyi amaçlamıştır. Aynı şekilde, GRU, RNN ve ANN modelleri için de benzer denemeler yapılmış ve en düşük hata oranları elde edilene kadar devam edilmiştir.

Sonuç olarak, model performansını optimize etmek için yapılan bu detaylı çalışmalar, sinir ağlarının eğitiminde kritik öneme sahiptir. Farklı parametrelerin denenmesi ve en iyi sonuçları veren kombinasyonların bulunması, modelin doğruluğunu artırır ve gelecekteki fiyat hareketlerini daha iyi tahmin etmesini sağlar. Bu çalışma, kripto para piyasalarının dinamik yapısını anlamak ve tahminlerde bulunmak için önemli bir adım teşkil etmektedir.

3.8. Tahmin Modellerinin Performans Değerlendirmesi

RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasının kareköküdür. Bu metrik, hata büyüklüğüne karşı hassas olduğundan, büyük hataların daha fazla cezalandırıldığı bir ölçü sağlar. RMSE, büyük hatalara duyarlıdır çünkü hata kareleri alınır. Bu, outlier'ların (aşırı uç değerlerin) performans metriği üzerinde daha büyük bir etkiye sahip olmasına neden olur. Hata değeri pozitif bir değerdir ve modelin doğruluğunu gösterir; daha düşük RMSE değeri, modelin daha iyi performans gösterdiğini gösterir. RMSE, tahminlerin birimiyle aynı birimde ölçülür, bu da fiziksel anlamını korur ve yorumlamayı kolaylaştırır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.5)$$

- n , veri noktalarının sayısını,
- y_i , gerçek değeri,
- $\hat{y}_i$, modelin tahmin ettiği değeri ifade eder.

MSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasıdır. Kare alma işlemi, hataların büyüklüklerine daha fazla ağırlık verilmesini sağlar. MSE, RMSE'nin kare alınmamış halidir. Hem büyük hem de küçük hatalar karelenerek toplandığından, büyük hatalar daha fazla etkilenir. MSE, modelin tahminlerindeki genel hata miktarını ölçmek için yaygın olarak kullanılır. Daha düşük bir MSE, modelin daha iyi bir performans sergilediğini gösterir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.6)$$

- n , veri noktalarının sayısını,
- y_i , gerçek değeri,
- $\hat{y}_i$, modelin tahmin ettiği değeri ifade eder.

MAE, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasıdır. Bu metrik, tahmin doğruluğunu ölçer ve hem büyük hem de küçük hatalara eşit derecede ağırlık verir. MAE, hataların mutlak değerlerini topladığı için outlier'lara karşı daha az duyarlıdır. Hata değeri, gerçek değerlere daha yakındır ve tahmin hatalarının ortalama büyüklüğünü doğrudan gösterir. Bu, MAE'yi yorumlamayı kolaylaştırır. Tahmin hatalarını yorumlamak ve model doğruluğunu değerlendirmek için sıkça kullanılır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.7)$$

- n , veri noktalarının sayısını,
- y_i , gerçek değeri,
- $\hat{y}_i$, modelin tahmin ettiği değeri ifade eder.

MAPE, tahmin edilen değerlerin gerçek değerlere göre ortalama mutlak yüzde hatasını ölçer. Yüzde olarak ifade edilmesi, modelin performansını farklı ölçeklerde karşılaştırmayı kolaylaştırır. MAPE, hata yüzdesi olarak ifade edilir, bu da farklı veri setleri ve problemler arasında karşılaştırma yapmayı kolaylaştırır. Genellikle iş dünyası ve ekonomi gibi uygulamalarda yaygın olarak kullanılır, çünkü sonuçlar kolayca anlaşılır ve yorumlanabilir.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3.8)$$

- n , veri noktalarının sayısını,
- y_i , gerçek değeri,
- $\hat{y}_i$, modelin tahmin ettiği değeri ifade eder.

Bu metriklerin her biri, modellerin performansını ve tahmin doğruluğunu değerlendirmek için belirli avantajlar ve sınırlamalar sunar. Hangi metriğin kullanılacağı, problem türüne, veri setinin yapısına ve analiz edilen spesifik duruma bağlı olarak değişir. MAPE (Ortalama Mutlak Yüzde Hatası) metriği, tahmin hatalarını yüzde cinsinden ifade ederek modellerin performansını kolayca karşılaştırılabilir hale getirir. Özellikle finansal zaman serileri gibi yüzdesel değişimlerin önemli olduğu durumlarda MAPE, tahmin

doğruluğunu daha anlaşılır ve sezgisel kılar. Bu nedenle, model değerlendirmelerinde birden fazla metriği kullanmak, daha kapsamlı ve dengeli bir anlayış sağlar.

3.9. Kullanılan Yazılım ve Yapay Zeka Kütüphaneleri

Bu tez kapsamında gerçekleştirilen çalışmalar ve deneyler sırasında, çeşitli yazılım araçları ve yapay zeka kütüphaneleri kullanılmıştır. Deneylerde kullanılan bilgisayarın özellikleri şunlardır:

- İşlemci: Amd Ryzen 7 7840HS Cores: 8 Threads: 16 Speed: 5.1Ghz
- GPU: Nvidia RTX4060 8GB 128Bit Tensor Cores: 96
- RAM: 16 GB DDR5
- Depolama: 1.5TB SSD

Kullanılan yazılım ve kütüphanelerin seçiminde, veri işleme, modelleme, eğitim, değerlendirme ve görselleştirme gibi farklı adımlarda yüksek performans, esneklik ve kullanıcı dostu arayüzler sunmaları göz önünde bulundurulmuştur. Aşağıda bu çalışmalarda kullanılan başlıca yazılım ve kütüphaneler detaylandırılmaktadır:

Python programlama dili, esnekliği ve geniş kütüphane desteği ile veri bilimi ve makine öğrenimi alanlarında yaygın olarak kullanılmaktadır. Bu çalışma boyunca, Python'un çeşitli paketlerinden yararlanılmıştır.

NumPy (Numerical Python), büyük ve çok boyutlu dizi nesneleri ile çalışmayı sağlayan temel bir bilimsel hesaplama kütüphanesidir. Vektör ve matris operasyonlarının hızlı ve verimli bir şekilde gerçekleştirilmesini sağlamıştır.

Pandas, veri analizi ve manipülasyonu için güçlü veri yapıları sunan bir kütüphanedir. Veri yükleme, temizleme ve dönüştürme işlemlerinde yoğun olarak kullanılmıştır.

Matplotlib ve Seaborn, veri görselleştirme için kullanılan kütüphanelerdir. Bu kütüphaneler, verilerin grafiksel olarak ifade edilmesini ve analiz sonuçlarının görsel olarak sunulmasını sağlamıştır.

Scikit-Learn, makine öğrenimi algoritmaları ve araçları sunan geniş kapsamlı bir kütüphanedir. Model eğitim, değerlendirme ve hiperparametre optimizasyonu gibi adımlarda kullanılmıştır.

TensorFlow ve Keras, derin öğrenme modellerinin oluşturulması ve eğitilmesi için kullanılan güçlü kütüphanelerdir. Bu çalışma kapsamında, LSTM ve GRU gibi tekrarlayan sinir ağı (RNN) modellerinin oluşturulması ve eğitilmesinde kullanılmıştır.



4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, Ethereum kripto parasının gelecekteki fiyatlarını tahmin etmek için kullanılan farklı yapay zeka modellerinin performans sonuçları ve karşılaştırmaları sunulmaktadır. Kullanılan modeller arasında, Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory- LSTM), Geçitli Tekrarlayan Birim (Gated Recurrent Unit- GRU), Tekrarlayan Sinir Ağı (Recurrent Neural Network- RNN) ve Yapay Sinir Ağı (Artificial Neural Network- ANN) yer almaktadır. Her bir modelin tahmin yetenekleri, çeşitli performans metrikleri kullanılarak detaylı bir şekilde analiz edilmiştir. Bu çalışma, farklı modellerin Ethereum fiyat tahminlerindeki etkinliğini değerlendirmeyi amaçlamaktadır.

4.1. Uzun-Kısa Süreli Bellek (LSTM) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi


Anaconda üzerinde Python kullanılarak oluşturulan LSTM modeline öncelikle Keras'ın Sequential modeli eklenmiştir. Ardından, tam bağlı katman olarak da bilinen Dense katmanı eklenmiştir. Son olarak bir deneyde Dropout katmanı eklenerek modelin aşırı öğrenme (overfitting) sorunu önlenmeye çalışılmıştır.

Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.1'de yer verilmektedir.

Tablo 4. 1. LSTM Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı)


Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	68.18	4649.55	56.79	3.02
2	16	50	52.38	2744.66	37.83	1.95
3	16	100	72.67	5280.94	60.50	3.17
4	16	200	48.53	2355.89	33.06	1.70
5	32	10	80.09	6415.32	61.01	3.15
6	32	50	72.84	5307.05	62.82	3.35
7	32	100	49.30	2431.34	33.92	1.75
8	32	200	77.22	5963.99	66.03	3.47

Eğitim ve doğrulama kayıpları Şekil 4.1’de sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 1. LSTM En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.2’de sunulmaktadır.



Şekil 4. 2. LSTM En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları

Tablo 4.1’de yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 200 epoch ve 16 batch size ile elde edildiği görülmektedir. Tablo 4.2’de ise en iyi model için son 30 günde elde edilen tahmin değerlerine yer verilmektedir.

Tablo 4. 2. LSTM En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri


Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2208.658203
2023-12-22	2326.524902	2250.224609
2023-12-23	2309.046387	2341.478760
2023-12-24	2265.692139	2326.142822
2023-12-25	2272.561768	2275.569092
2023-12-26	2231.465332	2278.740234
2023-12-27	2378.739990	2241.004150
2023-12-28	2347.566162	2390.453125
2023-12-29	2300.690674	2369.044189
2023-12-30	2292.065430	2312.602295
2023-12-31	2281.471191	2297.866455
2024-01-01	2352.327881	2290.009521
2024-01-02	2355.836426	2364.201660
2024-01-03	2210.761963	2372.894775
2024-01-04	2269.038086	2222.455322
2024-01-05	2268.647217	2268.458008
2024-01-06	2241.624756	2280.090332
2024-01-07	2222.865967	2253.693604
2024-01-08	2333.032715	2230.722656
2024-01-09	2344.827148	2342.870361
2024-01-10	2582.103516	2363.523926
2024-01-11	2619.619141	2602.997803
2024-01-12	2524.460205	2650.355469
2024-01-13	2576.597900	2547.496826
2024-01-14	2472.241211	2586.645996
2024-01-15	2511.363770	2488.451172
2024-01-16	2587.691162	2522.377686
2024-01-17	2528.369385	2605.281738
2024-01-18	2467.018799	2550.682373
2024-01-19	2489.498535	2480.461670

Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.3'te yer verilmektedir.

Tablo 4. 3. LSTM Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık)


Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	71.54	59.12	59.12	3.17
2	16	50	73.83	5451.39	64.50	3.45
3	16	100	59.31	3518.77	43.91	2.25
4	16	200	64.11	4110.68	53.30	2.82
5	32	10	112.47	12651	99.16	5.33
6	32	50	78.73	6198.55	64.34	3.32
7	32	100	72.13	5202.89	59.37	3.10
8	32	200	70.94	5033.38	56.83	2.92

Eğitim ve doğrulama kayıpları Şekil 4.3'te sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 3. LSTM En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği (Dropout Açık)

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.4'te sunulmaktadır.



Şekil 4. 4. LSTM En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları (Dropout Açık)

Tablo 4.3'te sunulan modellerin performans ölçütleri incelendiğinde, çeşitli parametre kombinasyonları ile elde edilen sonuçlar karşılaştırılmıştır. Yapılan değerlendirmeler sonucunda, 200 epoch ve 16 batch size parametreleriyle eğitilen modelin, diğer parametrelerle eğitilen modellere kıyasla belirli ölçütler çerçevesinde dikkat çekici sonuçlar ürettiği gözlemlenmiştir. Bu parametre seti, modelin öğrenme sürecinde belirli bir performans sergilemiştir. Tablo 4.4'te ise, bu parametrelerle eğitilen model için elde edilen tahmin değerlerine yer verilmiştir. Bu tablodaki değerler, modelin tahmin yeteneğinin incelenmesi amacıyla sunulmuştur ve modelin belirli bir veri kümesi üzerindeki tahmin performansını değerlendirmek için kullanılmaktadır. Bu tahminler, modelin eğitildiği veri kümesine dayalı olarak son 30 gün için öngörülen değerleri içermektedir.

Tablo 4. 4. LSTM En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)

Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2147.724365
2023-12-22	2326.524902	2179.916992
2023-12-23	2309.046387	2254.008301
2023-12-24	2265.692139	2256.744873
2023-12-25	2272.561768	2223.399658
2023-12-26	2231.465332	2220.946533
2023-12-27	2378.739990	2189.000732
2023-12-28	2347.566162	2294.767578
2023-12-29	2300.690674	2294.047607
2023-12-30	2292.065430	2256.916748
2023-12-31	2281.471191	2241.824951
2024-01-01	2352.327881	2230.447998
2024-01-02	2355.836426	2282.309326
2024-01-03	2210.761963	2296.384033
2024-01-04	2269.038086	2188.012207
2024-01-05	2268.647217	2208.033691
2024-01-06	2241.624756	2213.379395
2024-01-07	2222.865967	2193.839111
2024-01-08	2333.032715	2175.254150
2024-01-09	2344.827148	2256.024902
2024-01-10	2582.103516	2283.318604
2024-01-11	2619.619141	2472.310791
2024-01-12	2524.460205	2540.238037
2024-01-13	2576.597900	2479.270752
2024-01-14	2472.241211	2505.765381
2024-01-15	2511.363770	2429.652344
2024-01-16	2587.691162	2442.796875
2024-01-17	2528.369385	2504.207520
2024-01-18	2467.018799	2470.382812
2024-01-19	2489.498535	2415.477051


4.2. Kapalı Tekrarlayan Birim (GRU) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi

GRU modeline öncelikle Keras'ın Sequential modeli eklenmiştir. Ardından, tam bağlı katman olarak da bilinen Dense katmanı eklenmiştir. Son olarak bir deneyde Dropout katmanı eklenerek modelin aşırı öğrenme (overfitting) sorunu önlenmeye çalışılmıştır. Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.5'te yer verilmektedir.

Tablo 4. 5. GRU Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı)


Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	67.20	4516.09	54.00	2.81
2	16	50	48.33	2336.03	32.51	1.67
3	16	100	51.17	2619.37	36.78	1.91
4	16	200	50.26	2526.19	35.43	1.83
5	32	10	112.98	12765.87	103.21	5.43
6	32	50	73.73	5437.17	61.50	3.19
7	32	100	49.55	2456.14	36.45	1.91
8	32	200	56.49	3191.15	44.63	2.35

Eğitim ve doğrulama kayıpları Şekil 4.5'te sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 5. GRU En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.6’da sunulmaktadır.



Şekil 4. 6. GRU En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları

Tablo 4.5’te yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 50 epoch ve 16 batch size ile elde edildiği görülmektedir. Tablo 4.6’da ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 4. 6. GRU En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri
(Dropout Kapalı)


Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2184.679443
2023-12-22	2326.524902	2221.682129
2023-12-23	2309.046387	2305.492432
2023-12-24	2265.692139	2297.704834
2023-12-25	2272.561768	2254.414307
2023-12-26	2231.465332	2254.005859
2023-12-27	2378.739990	2217.371826
2023-12-28	2347.566162	2348.686279
2023-12-29	2300.690674	2335.981201
2023-12-30	2292.065430	2289.516602
2023-12-31	2281.471191	2274.132568
2024-01-01	2352.327881	2263.533691
2024-01-02	2355.836426	2328.428955
2024-01-03	2210.761963	2339.734375
2024-01-04	2269.038086	2207.580566
2024-01-05	2268.647217	2243.904541
2024-01-06	2241.624756	2250.512939
2024-01-07	2222.865967	2228.417480
2024-01-08	2333.032715	2208.488770
2024-01-09	2344.827148	2307.032715
2024-01-10	2582.103516	2329.760498
2024-01-11	2619.619141	2548.193848
2024-01-12	2524.460205	2602.867676
2024-01-13	2576.597900	2515.378418
2024-01-14	2472.241211	2548.183838
2024-01-15	2511.363770	2455.781982
2024-01-16	2587.691162	2482.775635
2024-01-17	2528.369385	2557.691162
2024-01-18	2467.018799	2512.436523
2024-01-19	2489.498535	2449.875732

Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 9'da yer verilmektedir.

Tablo 4. 7. GRU Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık)


Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	59.32	3518.92	48.10	2.54
2	16	50	48.82	2384.28	35.12	1.84
3	16	100	56.35	3176.44	44.13	2.32
4	16	200	72.50	5257.32	72.50	3.15
5	32	10	105.70	11173.73	94.05	4.91
6	32	50	103.19	10650.14	90.79	4.69
7	32	100	55.58	3090.05	44.09	2.34
8	32	200	113.65	12918.24	102.37	5.32

Eğitim ve doğrulama kayıpları Şekil 4.7'de sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 7. GRU En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği (Dropout Açık)

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.8’de sunulmaktadır.



Şekil 4. 8. GRU En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları (Dropout Açık)

Tablo 4.7'de yer alan modellerin performans ölçüt değerleri incelendiğinde, farklı eğitim parametrelerinin modelin çıktıları üzerindeki etkileri detaylı bir şekilde analiz edilmiştir. Bu analizler kapsamında, çeşitli epoch sayıları ve batch size kombinasyonları denenmiş ve modelin bu parametrelerle nasıl bir performans gösterdiği gözlemlenmiştir. Yapılan değerlendirmeler sonucunda, 50 epoch ve 16 batch size parametreleri ile eğitilen modelin, belirli performans ölçütlerine göre diğer kombinasyonlardan daha uygun sonuçlar verdiği tespit edilmiştir. Bu spesifik parametreler, modelin eğitim sürecinde optimizasyonu sağlamak amacıyla kullanılmıştır ve elde edilen sonuçlar bu optimizasyonun etkilerini ortaya koymaktadır.

Tablo 4.8'de ise, bu en iyi model için son 30 gün boyunca elde edilen tahmin değerleri sunulmuştur. Bu tablo, modelin belirli bir zaman diliminde gerçekleştirdiği tahminlerin gerçek verilerle karşılaştırılması amacıyla hazırlanmıştır. Son 30 güne ait tahminlerin incelenmesi, modelin yakın dönem performansını değerlendirmek ve gelecekteki uygulamalar için yol gösterici bilgiler elde etmek açısından önemlidir. Tablo 4.8, modelin çeşitli parametrelerle eğitildikten sonra nasıl bir tahmin doğruluğu sergilediğine dair kapsamlı bir bakış sunmaktadır ve modelin farklı zaman dilimlerinde nasıl çalıştığını gözlemleme imkanı sağlar.

Tablo 4. 8. GRU En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri
(Dropout Açık)

Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2194.370605
2023-12-22	2326.524902	2227.174805
2023-12-23	2309.046387	2302.581787
2023-12-24	2265.692139	2297.872559
2023-12-25	2272.561768	2264.653564
2023-12-26	2231.465332	2268.341064
2023-12-27	2378.739990	2233.559814
2023-12-28	2347.566162	2349.538330
2023-12-29	2300.690674	2334.981201
2023-12-30	2292.065430	2296.910889
2023-12-31	2281.471191	2288.163086
2024-01-01	2352.327881	2277.156738
2024-01-02	2355.836426	2332.572754
2024-01-03	2210.761963	2340.576904
2024-01-04	2269.038086	2223.116211
2024-01-05	2268.647217	2259.451904
2024-01-06	2241.624756	2260.810059
2024-01-07	2222.865967	2236.517090
2024-01-08	2333.032715	2219.274170
2024-01-09	2344.827148	2308.204590
2024-01-10	2582.103516	2327.023926
2024-01-11	2619.619141	2527.553955
2024-01-12	2524.460205	2581.587158
2024-01-13	2576.597900	2514.576660
2024-01-14	2472.241211	2557.146973
2024-01-15	2511.363770	2473.312500
2024-01-16	2587.691162	2494.422607
2024-01-17	2528.369385	2556.719971
2024-01-18	2467.018799	2511.205078
2024-01-19	2489.498535	2457.712646


4.3. Tekrarlayan Sinir Ağları (RNN) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi

RNN modeline öncelikle Keras'ın Sequential modeli eklenmiştir. Ardından, tam bağlı katman olarak da bilinen Dense katmanı eklenmiş. Son olarak bir deneyde Dropout katmanı eklenerek modelin aşırı öğrenme (overfitting) sorunu önlenmeye çalışılmıştır. Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.9'da yer verilmektedir.


Tablo 4. 9. RNN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı)

Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	143.95	20722.94	134.70	7.40
2	16	50	99.16	9832.93	90.45	4.97
3	16	100	64.14	4114.16	52.29	2.83
4	16	200	90.83	8250.98	81.52	4.45
5	32	10	88.97	7915.20	78.93	4.34
6	32	50	75.34	5675.58	64.90	3.52
7	32	100	60.42	3650.99	48.60	2.62
8	32	200	117.38	13779.23	106.92	5.77

Eğitim ve doğrulama kayıpları Şekil 4.9'da sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 9. RNN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği
Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.10'da sunulmaktadır.



Şekil 4. 10. RNN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları

Tablo 4.9'da sunulan modellerin performans ölçüt değerleri ayrıntılı bir şekilde incelendiğinde, modelin eğitim sürecinde kullanılan çeşitli epoch sayıları ve batch size değerlerinin etkileri dikkatle değerlendirilmiştir. Bu analizler kapsamında, modelin farklı eğitim parametreleriyle nasıl bir performans sergilediği detaylı olarak ele alınmıştır. Özellikle 100 epoch ve 32 batch size kombinasyonu ile eğitilen modelin, performans ölçütlerine göre diğer parametre ayarlarına kıyasla daha uygun sonuçlar verdiği tespit edilmiştir. Bu kombinasyon, modelin eğitim sürecinde belirli bir denge ve doğruluk

sağlamak amacıyla seçilmiş ve modelin daha iyi optimize edilmesi için bu parametreler tercih edilmiştir.

Ayrıca, Tablo 4.10'da, bu en iyi model için elde edilen tahmin değerleri sunulmaktadır. Bu tablo, modelin eğitim sonrasında ürettiği tahminlerin, gerçek verilerle karşılaştırılması amacıyla hazırlanmıştır. Tahmin edilen değerler, modelin belirlenen zaman dilimi içerisinde ne kadar isabetli sonuçlar üretebildiğini göstermek açısından önemlidir. Tablo 4.10, modelin eğitim sonrasındaki performansını değerlendirmek, farklı parametrelerle eğitilen modelin çıktıları arasındaki farkları görmek ve gelecekte yapılacak çalışmalar için referans oluşturmak amacıyla kritik bir rol oynar. Bu sonuçlar, modelin belirlenen parametrelerle eğitimden geçtikten sonra, belirli bir zaman diliminde ne kadar başarılı tahminler gerçekleştirdiğine dair kapsamlı bir bakış sunmaktadır.

Tablo 4. 10. RNN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri

Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2242.964600
2023-12-22	2326.524902	2239.681885
2023-12-23	2309.046387	2281.657227
2023-12-24	2265.692139	2366.693359
2023-12-25	2272.561768	2374.219482
2023-12-26	2231.465332	2323.729492
2023-12-27	2378.739990	2324.491699
2023-12-28	2347.566162	2276.318115
2023-12-29	2300.690674	2424.943115
2023-12-30	2292.065430	2399.702393
2023-12-31	2281.471191	2357.064697
2024-01-01	2352.327881	2347.263916
2024-01-02	2355.836426	2316.175537
2024-01-03	2210.761963	2408.758301
2024-01-04	2269.038086	2408.147949
2024-01-05	2268.647217	2271.670410
2024-01-06	2241.624756	2310.453613
2024-01-07	2222.865967	2304.357422
2024-01-08	2333.032715	2296.780518
2024-01-09	2344.827148	2285.742432


2024-01-10	2582.103516	2357.217529
2024-01-11	2619.619141	2393.987061
2024-01-12	2524.460205	2632.236084
2024-01-13	2576.597900	2687.614502
2024-01-14	2472.241211	2597.339600
2024-01-15	2511.363770	2651.530029
2024-01-16	2587.691162	2517.804199
2024-01-17	2528.369385	2574.286377
2024-01-18	2467.018799	2636.899902
2024-01-19	2489.498535	2571.180176

Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.11'de yer verilmektedir.

Tablo 4. 11. RNN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık)


Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	63.78	4067.89	53.04	2.91
2	16	50	60.32	3638.04	49.49	2.69
3	16	100	111.53	12437.97	101.56	5.52
4	16	200	174.37	30404.85	141.35	7.25
5	32	10	88.14	7768.31	72.36	3.81
6	32	50	100.82	10164.45	92.02	5.03
7	32	100	146.28	21398.25	137.42	7.37
8	32	200	90.54	8196.84	78.00	4.14

Eğitim ve doğrulama kayıpları Şekil 4.11'de sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 11. RNN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği (Dropout Açık)

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.12’de sunulmaktadır.



Şekil 4. 12. RNN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları (Dropout Açık)

Tablo 4.11’de yer alan modellerin performans ölçüt değerleri incelendiğinde, modelin eğitim sürecinde kullanılan farklı epoch sayıları ve batch size değerlerinin performans üzerindeki etkisi ayrıntılı bir şekilde ele alınmıştır. Bu kapsamlı inceleme sonucunda, en iyi eğitim modelinin 50 epoch ve 16 batch size kombinasyonu ile elde

edildiği görülmektedir. Bu eğitim parametreleri, modelin öğrenme süreci boyunca optimal sonuçlar üretmesine olanak tanımıştır. Bu parametreler seçilirken, modelin genel doğruluk oranını artırmak, öğrenme sürecini dengeli tutmak ve modelin aşırı öğrenmeden kaçınması için dikkatli bir denge kurulmuştur.

Bunun yanı sıra, Tablo 4.12'de, bu en iyi model için son 30 gün içerisinde elde edilen tahmin değerlerine yer verilmektedir. Bu tablo, modelin eğitim sürecinden sonra belirlenen zaman dilimi boyunca ürettiği tahminlerin performansını göstermek amacıyla hazırlanmıştır. Tablo 4.12'de sunulan veriler, modelin gerçek verilerle karşılaştırıldığında ne kadar isabetli tahminlerde bulunduğunu ortaya koymaktadır. Özellikle son 30 günlük tahmin verileri, modelin kısa vadeli öngörü kabiliyetini ve eğitiminin pratik uygulamalarda nasıl bir performans sergilediğini göstermesi açısından büyük önem taşımaktadır. Bu veriler, modelin performansını değerlendirmek, gelecekte yapılacak geliştirmeler için referans oluşturmak ve modelin kullanım alanlarına dair içgörüler sunmak amacıyla kritik bir kaynak niteliği taşımaktadır.

Tablo 4. 12. RNN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)

Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2237.758301
2023-12-22	2326.524902	2237.170898
2023-12-23	2309.046387	2275.474609
2023-12-24	2265.692139	2364.539795
2023-12-25	2272.561768	2367.812500
2023-12-26	2231.465332	2316.234619
2023-12-27	2378.739990	2319.263916
2023-12-28	2347.566162	2272.607178
2023-12-29	2300.690674	2410.868896
2023-12-30	2292.065430	2384.100098
2023-12-31	2281.471191	2342.034424
2024-01-01	2352.327881	2336.346191
2024-01-02	2355.836426	2322.602051
2024-01-03	2210.761963	2396.270264
2024-01-04	2269.038086	2395.288330
2024-01-05	2268.647217	2261.500488

2024-01-06	2241.624756	2301.581543
2024-01-07	2222.865967	2311.803223
2024-01-08	2333.032715	2290.891357
2024-01-09	2344.827148	2272.599854
2024-01-10	2582.103516	2360.141113
2024-01-11	2619.619141	2387.199707
2024-01-12	2524.460205	2621.064209
2024-01-13	2576.597900	2674.779053
2024-01-14	2472.241211	2576.664551
2024-01-15	2511.363770	2628.041016
2024-01-16	2587.691162	2511.586426
2024-01-17	2528.369385	2543.253418
2024-01-18	2467.018799	2603.874023
2024-01-19	2489.498535	2551.875488

4.4. Yapay Sinir Ağları (ANN) Modeli Kullanılarak Tahmin Verisinin Elde Edilmesi


ANN modeline öncelikle Keras'ın Sequential modeli eklenmiştir. Ardından, tam bağlı katman olarak da bilinen Dense katmanı eklenmiş. Son olarak bir deneyde Dropout katmanı eklenerek modelin aşırı öğrenme (overfitting) sorunu önlenmeye çalışılmıştır. Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.13'te yer verilmektedir.

Tablo 4. 13. ANN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Kapalı)

Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	110.72	12261.05	94.93	5.02
2	16	50	189.60	35949.60	182.68	9.79
3	16	100	114.04	13007.04	103.97	5.50
4	16	200	142.56	20324.51	134.21	7.13
5	32	10	186.68	34852.67	173.86	9.33


6	32	50	122.51	15008.96	113.67	6.08
7	32	100	98.84	9770.87	86.92	4.58
8	32	200	151.36	22910.25	142.69	7.55

Eğitim ve doğrulama kayıpları Şekil 4.13'te sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 13. ANN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.14'te sunulmaktadır.



Şekil 4. 14. ANN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları

Tablo 4.13'te yer alan modellerin performans ölçüt değerleri incelendiğinde en iyi eğitim modelinin 100 epoch ve 32 batch size ile elde edildiği görülmektedir. Tablo 4.14'te ise en iyi model için elde edilen tahmin değerlerine yer verilmektedir.

Tablo 4. 14. ANN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri

Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2283.419922
2023-12-22	2326.524902	2320.674805
2023-12-23	2309.046387	2398.877441
2023-12-24	2265.692139	2405.909180
2023-12-25	2272.561768	2387.975098
2023-12-26	2231.465332	2383.587158
2023-12-27	2378.739990	2344.081787
2023-12-28	2347.566162	2445.367188
2023-12-29	2300.690674	2462.333496
2023-12-30	2292.065430	2426.455322
2023-12-31	2281.471191	2412.937500
2024-01-01	2352.327881	2394.423828
2024-01-02	2355.836426	2448.190430
2024-01-03	2210.761963	2455.056885
2024-01-04	2269.038086	2390.994141
2024-01-05	2268.647217	2372.848145
2024-01-06	2241.624756	2359.513672
2024-01-07	2222.865967	2335.124023
2024-01-08	2333.032715	2306.090820
2024-01-09	2344.827148	2365.731445
2024-01-10	2582.103516	2409.293945
2024-01-11	2619.619141	2601.531006
2024-01-12	2524.460205	2706.711182
2024-01-13	2576.597900	2674.853760
2024-01-14	2472.241211	2697.978271


2024-01-15	2511.363770	2617.376953
2024-01-16	2587.691162	2631.885254
2024-01-17	2528.369385	2717.669678
2024-01-18	2467.018799	2691.233643
2024-01-19	2489.498535	2644.489990

Bu deneyde, veri setinin %80'i eğitim, %20'si ise test verisi olarak ayrılmıştır. Tahmin edilen değerler ve gerçek değerler arasındaki MAE, MSE, RMSE ve MAPE değerleri hesaplanmıştır. Analizi gerçekleştirirken kullanılan batch size, epoch ve dropout değerleri için performans ölçütlerine Tablo 4.15'te yer verilmektedir.

Tablo 4. 15. ANN Modelinde Ethereum Veri Setinin Performans Değerlendirme Değerleri (Dropout Açık)


Deney	Batch Size	Epochs	RMSE	MSE	MAE	MAPE
1	16	10	386.78	149605.97	376.75	19.74
2	16	50	198.21	22437.58	137.44	7.19
3	16	100	111.53	39288.62	159.17	7.84
4	16	200	210.38	44262.35	179.44	8.98
5	32	10	226.51	51309.70	200.11	10.11
6	32	50	194.02	37644.15	165.61	8.29
7	32	100	238.38	56826.22	210.48	10.62
8	32	200	242.35	58738.02	217.66	11.04

Eğitim ve doğrulama kayıpları Şekil 4.15'te sunulmaktadır. Bu grafik, modelin eğitim ve doğrulama setleri üzerindeki hata (kayıp) oranını epoch sayısına göre gösterir.



Şekil 4. 15. ANN En İyi Modelinin Ethereum Veri Setindeki Eğitim ve Doğrulama Kayıp Grafiği

Test verilerinden elde edilen gerçek ve tahmin edilen değerlerin karşılaştırılması, Şekil 4.16’da sunulmaktadır.



Şekil 4. 16. ANN En İyi Modelinin Ethereum Veri Setindeki Gerçek Değerler ve Tahmin Kayıpları

Tablo 4.15’te yer alan modellerin performans ölçüt değerleri incelendiğinde, farklı epoch ve batch size kombinasyonlarının modelin öğrenme süreci üzerindeki etkileri detaylı olarak incelenmiştir. Bu analizler sonucunda, en iyi eğitim modelinin 50 epoch ve

16 batch size parametreleriyle elde edildiği belirlenmiştir. Bu kombinasyon, modelin öğrenme kapasitesini optimize ederken, aynı zamanda eğitim süresini ve kaynak kullanımını da verimli bir şekilde dengelemektedir. Modelin bu parametrelerle eğitilmesi, hem daha tutarlı hem de daha doğru tahminler üretebilmesi için kritik bir rol oynamıştır.

Tablo 4.16’da ise, bu en iyi modelin elde ettiği tahmin değerlerine yer verilmektedir. Bu tabloda sunulan tahminler, modelin eğitim sürecini takiben gerçek verilerle karşılaştırılarak değerlendirilmiştir. Tahmin edilen değerlerin, modelin doğruluğunu ve genelleme yeteneğini göstermek amacıyla, özellikle dikkatle analiz edilmiştir. Tablo 4.16’daki veriler, modelin sadece eğitim sürecinde değil, aynı zamanda gerçek veri setleri üzerinde ne kadar başarılı bir performans sergilediğini ortaya koymaktadır. Bu tahminler, modelin pratik uygulamalarda nasıl bir performans sergileyebileceğini anlamak ve gelecekteki iyileştirme çalışmalarına rehberlik etmek için önemli bir referans noktası sunmaktadır.

Tablo 4. 16. ANN En İyi Modelinin Ethereum Veri Setindeki Son 30 Günlük Gerçek ve Tahmin Değerleri (Dropout Açık)

Tarih	Gerçek Değer	Tahmin Edilen Değer
2023-12-21	2239.542480	2009.859375
2023-12-22	2326.524902	2031.623169
2023-12-23	2309.046387	2069.118164
2023-12-24	2265.692139	2101.207764
2023-12-25	2272.561768	2100.670898
2023-12-26	2231.465332	2102.622803
2023-12-27	2378.739990	2090.211914
2023-12-28	2347.566162	2136.974854
2023-12-29	2300.690674	2165.928955
2023-12-30	2292.065430	2153.368164
2023-12-31	2281.471191	2136.566650
2024-01-01	2352.327881	2126.538330
2024-01-02	2355.836426	2149.610107
2024-01-03	2210.761963	2153.193359
2024-01-04	2269.038086	2124.176025
2024-01-05	2268.647217	2101.668701


2024-01-06	2241.624756	2102.610840
2024-01-07	2222.865967	2091.000488
2024-01-08	2333.032715	2063.234619
2024-01-09	2344.827148	2093.199951
2024-01-10	2582.103516	2108.677246
2024-01-11	2619.619141	2195.691162
2024-01-12	2524.460205	2273.139160
2024-01-13	2576.597900	2283.136963
2024-01-14	2472.241211	2307.946045
2024-01-15	2511.363770	2290.641846
2024-01-16	2587.691162	2297.168457
2024-01-17	2528.369385	2331.037354
2024-01-18	2467.018799	2326.114990
2024-01-19	2489.498535	2297.595703

4.5. Genel Sonuçlar ve Genel Değerlendirme

Ethereum kripto para biriminin fiyat tahmini için çeşitli derin öğrenme modelleri kullanılarak performans karşılaştırmaları yapılmıştır. Çalışmada, LSTM (Uzun-Kısa Süreli Bellek), GRU (Kapılı Tekrarlayan Birim), RNN (Tekrarlayan Sinir Ağı) ve ANN (Yapay Sinir Ağı) modelleri incelenmiştir. Bu modeller, zaman serisi verilerinde yaygın olarak kullanılan ve fiyat tahmini gibi görevlerde yüksek performans gösteren yapay sinir ağı türleridir. Çalışmanın temel amacı, bu modellerin Ethereum veri seti üzerindeki performanslarını ortalama mutlak yüzde hatası (MAPE) metriği ile değerlendirerek en başarılı modelin belirlenmesidir.

Tablo 4. 17. Tüm Modellerin En İyi Sonuçlarının MAPE Değerleri (Dropout Kapalı)


Model İsmi	Batch Size	Epoch	MAPE
LSTM	16	200	1.70
GRU	16	50	1.67
ANN	32	100	4.58
RNN	32	100	2.62



Şekil 4. 17. Tüm Modellerin En İyi Sonuçlarının Gerçek ve Tahmin Edilen Değerleri (Dropout Kapalı)

Tablo 4. 18. Tüm Modellerin En İyi Sonuçlarının MAPE Değerleri (Dropout Açık)

Model İsmi	Batch Size	Epoch	MAPE
LSTM	16	100	2.25
GRU	16	50	1.84
ANN	16	50	7.19
RNN	16	50	2.69



Şekil 4. 18. Tüm Modellerin En İyi Sonuçlarının Gerçek ve Tahmin Edilen Değerleri (Dropout Açık)

Modellerin performansı, iki farklı Dropout katmanı (kapalı ve açık) kullanılarak değerlendirilmiştir. Dropout, modelin aşırı öğrenme (overfitting) yapmasını engellemek için kullanılan bir tekniktir ve modelin öğrenme sırasında bazı nöronları rastgele kapatarak genelleme yeteneğini artırmayı hedefler.

Dropout açıldığında, tüm modellerde performansın bir miktar düştüğü gözlemlenmiştir. Bu durum, Dropout'un aşırı kullanıldığında modelin öğrenme kapasitesini sınırlayabileceğini ve bu nedenle genelleme yeteneğini olumsuz etkileyebileceğini göstermektedir. Bu bağlamda, uygun Dropout oranının belirlenmesi, modelin genel performansı üzerinde önemli bir etkiye sahip olduğu söylenebilir.

Sonuçlar, GRU modelinin Dropout kapalı iken en düşük MAPE değerini elde ederek en başarılı model olduğunu göstermektedir. GRU'nun bu başarısı, modelin zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalama kapasitesinin yüksek olduğunu ortaya koymaktadır. LSTM modeli de benzer bir performans göstermiş ancak GRU'nun biraz gerisinde kalmıştır. RNN modeli ise, genellikle kısa vadeli bağımlılıkları öğrenme eğiliminde olup, bu nedenle uzun vadeli bağımlılıkların önemli olduğu zaman serisi verilerinde diğer modellere kıyasla daha yüksek MAPE değerleri vermiştir. ANN modeli, diğer modellere kıyasla en yüksek MAPE değerleri ile en düşük performansı sergilemiştir. Bu, ANN'nin zaman serisi verileri üzerinde daha az etkili olduğunu ve daha karmaşık modellerin (RNN, LSTM, GRU) bu tür veriler için daha uygun olduğunu göstermektedir.

4.6. Çalışmada Elde Edilen Sonuçların Literatürle Karşılaştırılması

Çalışma kapsamında kullanılan veri seti, literatürdeki diğer çalışmalara kıyasla hem daha güncel hem de daha geniş bir tarih aralığını içermektedir. Bu geniş ve güncel veri setinin tercih edilmesi, analizlerin daha kapsamlı ve derinlemesine yapılmasına olanak tanıyarak, elde edilen sonuçların doğruluk ve güvenilirlik açısından daha yüksek olmasını sağlamayı hedeflemiştir. Böylece, modelin farklı piyasa koşulları altında performansını değerlendirme imkanı artmış, veri setinin çeşitliliği ve kapsayıcılığı sayesinde daha genel geçer ve güvenilir tahminler elde edilmiştir.

Elde edilen sonuçlar, literatürde yer alan diğer çalışmalarla karşılaştırıldığında, belirgin farklılıklar ve bazı benzerlikler göstermektedir. Özellikle, çalışmamızda kullanılan LSTM, GRU, RNN ve ANN modellerinin MAPE sonuçları, literatürdeki diğer araştırmaların bulgularıyla kıyaslanarak kapsamlı bir değerlendirmeye tabi tutulmuştur. Bu karşılaştırma, modellerin doğruluk seviyelerini, performanslarını ve genel geçerliliklerini daha iyi anlamak, farklı model yapılandırmalarının etkilerini incelemek ve çalışmamızın literatürdeki yerini belirlemek amacıyla yapılmıştır. Sonuçların bu şekilde karşılaştırılması, çalışmamızın hem literatürdeki mevcut bilgi birikimine katkıda bulunmasını hem de gelecekte yapılacak benzer çalışmalara referans teşkil etmesini sağlamaktadır.

Tablo 4. 19. Literatürde Kullanılan Modeller, MAPE Sonuçları ve Çalışma Sonuçları

Yazar	Kullanılan Veri Seti	Veri Seti Tarih Aralığı	Kullanılan Model	MAPE Sonuç
(Gunarto ve ark., 2023)	Ethereum	08.08.2015-	• LSTM	• 4.58
		06.07.2021	• RNN	• 5.20

(Hansun ve ark., 2022)	Ethereum	01.08.2015-12.10.2021	• LSTM • GRU • Bi-LSTM	• 6.35 • 5.73 • 5.97
(Jagannath, ve ark., 2021)	Ethereum	2016- 2021	• LSTM	• 29.06
(Canitez & Savaş, 2022)	Bitcoin	2012- 2022	• LSTM • ARIMA	• 5 • 0.9
(Demirci & Karaatlı, 2023)	Ethereum	10.08.2015-15.09.2020	• LSTM • GRU	• 6.53 • 7.76
(Akay ve ark., 2021)	Ethereum	1.01.2020-07.05.2021	• YSA	• 4.37
Çalışma Sonuçlarım (Dropout Kapalı)	Ethereum	1.01.2019-19.01.2024	• LSTM • GRU • RNN • ANN	• 1.70 • 1.67 • 2.62 • 4.58
Çalışma Sonuçlarım (Dropout Açık)	Ethereum	1.01.2019-19.01.2024	• LSTM • GRU • RNN • ANN	• 2.25 • 1.84 • 2.69 • 7.19

Tablo 4.19'da gösterilen sonuçlar, literatürde kullanılan modeller ve bu modellerin Ethereum veri seti üzerindeki MAPE (Mean Absolute Percentage Error) sonuçlarını içermektedir. Literatürde yer alan bazı çalışmaların sonuçları şu şekildedir:

- Gunarto, Sa'adah, & Utama (2023) çalışmasında Ethereum veri seti kullanılarak LSTM ve RNN modelleri değerlendirilmiş ve MAPE sonuçları sırasıyla 4.58 ve 5.20 olarak bulunmuştur.
- Hansun, Wicaksana, & Khaliq (2022) çalışmasında yine Ethereum veri seti kullanılarak LSTM, GRU ve Bi-LSTM modelleri değerlendirilmiş ve MAPE sonuçları sırasıyla 6.35, 5.73 ve 5.97 olarak rapor edilmiştir.
- Jagannath ve diğerleri (2021) çalışmasında Ethereum veri seti kullanılarak LSTM modeli ile yapılan tahminlerde MAPE sonucu 29.06 olarak bulunmuştur.

- Canitez & Savaş (2022) çalışmasında Bitcoin veri seti kullanılarak LSTM ve ARIMA modelleri değerlendirilmiş ve MAPE sonuçları sırasıyla 5 ve 0.9 olarak rapor edilmiştir.
- Demirci & Karaatlı (2023) çalışmasında Ethereum veri seti kullanılarak LSTM ve GRU modelleri değerlendirilmiş ve MAPE sonuçları sırasıyla 6.53 ve 7.76 olarak bulunmuştur.
- Akay, Canik, Yeşilyurt, & Günkut (2021) çalışmasında Ethereum veri seti kullanılarak YSA (Yapay Sinir Ağları) modeli değerlendirilmiş ve MAPE sonucu 4.37 olarak rapor edilmiştir.

Çalışmamızda, Ethereum veri seti kullanılarak LSTM, GRU, RNN ve ANN modelleri değerlendirilmiştir. İki farklı dropout oranı kullanılarak yapılan çalışmalarda elde edilen MAPE sonuçları aşağıdaki gibidir:

- Dropout Kapalı:
LSTM: 1.70
GRU: 1.67
RNN: 2.62
ANN: 4.58
- Dropout Açık:
LSTM: 2.25
GRU: 1.84
RNN: 2.69
ANN: 7.19

Elde edilen bu sonuçlar, literatürdeki çalışmalara kıyasla daha düşük MAPE değerleri göstermektedir, bu da modelimizin daha yüksek doğruluk ve performansla tahminler yaptığını ortaya koymaktadır. Özellikle GRU ve LSTM modelleri, dropout kapalı iken en düşük MAPE değerlerini göstermiştir. Dropout açık olduğunda da yine GRU ve LSTM modelleri, düşük MAPE değerleri ile başarılı sonuçlar elde etmiştir. Bu sonuçlar, modelimizin literatürdeki diğer çalışmalara göre daha iyi performans gösterdiğini ve tahmin doğruluğunun yüksek olduğunu göstermektedir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu tez çalışmasında, Ethereum kripto para biriminin fiyat tahmininde çeşitli derin öğrenme modellerinin performansları titizlikle incelenmiş ve karşılaştırılmıştır. Araştırmanın merkezinde, LSTM, GRU, RNN ve ANN gibi günümüzde yaygın olarak kullanılan derin öğrenme mimarilerinin etkinliği yer almaktadır. Bu modellerin etkinliklerini ve doğruluk seviyelerini belirlemek amacıyla, finansal tahminlerde sıkça başvurulmuş bir metrik olan Ortalama Mutlak Yüzde Hatası (MAPE) kullanılmıştır. Modellerin performanslarına dair elde edilen bulgular, literatürdeki benzer çalışmaların sonuçlarıyla karşılaştırılmış, bu sayede çalışmanın literatürdeki konumu ve özgünlüğü ortaya konulmuştur.

Çalışmada kullanılan Ethereum veri seti, geniş ve güncel bir tarih aralığını kapsayarak, analizlerin derinlemesine yapılmasına olanak tanımıştır. Bu veri setiyle yapılan model değerlendirmeleri sonucunda elde edilen bulgular, literatürdeki benzer çalışmalardan elde edilen sonuçlarla kıyaslandığında, genellikle daha düşük MAPE değerleri sunarak üstün bir performans sergilemiştir. Modellerin performansı, farklı Dropout (kapalı ve açık) kullanılarak iki farklı senaryo altında değerlendirilmiş ve bu değerlendirmeler, modellerin dayanıklılığını ve genel doğruluğunu daha net bir şekilde ortaya koymuştur.

Dropout açık olarak belirlendiğinde, GRU modeli 1.67 MAPE değeri ile en iyi performansı sergileyerek diğer modellerin önüne geçmiştir. Bu sonuç, aynı veri seti üzerinde yapılan diğer modellere kıyasla daha yüksek doğruluk seviyesini göstermektedir. GRU modelini 1.70 MAPE değeriyle LSTM, 2.62 MAPE değeriyle RNN ve 4.58 MAPE değeriyle ANN modelleri takip etmiştir. Dropout kapatıldığında ise, GRU modeli yine dikkat çekici bir performans sergileyerek 1.84 MAPE değeri elde etmiş, diğer modellerde ise genel bir performans düşüşü gözlenmiştir. Bu senaryoda da GRU ve LSTM modelleri, daha düşük MAPE değerleri ile öne çıkmıştır, bu da bu modellerin tahmin doğruluğunu ve dayanıklılığını ortaya koymaktadır.

Tezde elde edilen sonuçlar, literatürdeki diğer çalışmaların bulgularıyla karşılaştırıldığında, özellikle GRU ve LSTM modellerinin daha yüksek doğruluk seviyeleri sunduğu ortaya çıkmıştır. Örneğin, Gunarto, Sa'adah, & Utama (2023) tarafından yapılan bir çalışmada, LSTM ve RNN modelleri sırasıyla 4.58 ve 5.20 MAPE

değerleriyle sonuçlanmışken, bu tez çalışmasında aynı modellerle elde edilen MAPE değerleri çok daha düşük seviyelerde kalmıştır. Benzer şekilde, Hansun, Wicaksana, & Khaliq (2022) çalışmasında GRU modelinin 5.73 MAPE değeriyle sonuçlandığı göz önüne alındığında, bu tezde elde edilen 1.67 MAPE değeri oldukça başarılı ve etkileyici bir sonuç olarak değerlendirilebilir. Bu sonuçlar, çalışmanın literatürdeki mevcut bilgi birikimine önemli katkılarda bulunduğunu ve Ethereum fiyat tahmini konusunda derin öğrenme modellerinin potansiyelini ortaya koyduğunu göstermektedir.

5.2 Katkılar ve Öneriler

Bu çalışma, Ethereum fiyat tahmini için derin öğrenme modellerinin performanslarını karşılaştırarak literatüre önemli bir katkı sağlamıştır. Çalışmanın bulguları, GRU ve LSTM gibi gelişmiş RNN modellerinin, zaman serisi verileri üzerinde yüksek doğrulukla tahmin yapma kapasitesine sahip olduğunu göstermiştir. Bununla birlikte, ANN modelinin bu tür verilerde diğer modellere göre daha düşük performans gösterdiği tespit edilmiştir.

Gelecekteki çalışmalar, model performansını daha da artırmak için farklı veri ön işleme teknikleri, hiperparametre optimizasyonu ve daha karmaşık model mimarileri üzerinde durabilir. Ayrıca, diğer kripto para birimlerinin fiyat tahmininde bu modellerin uygulanabilirliği araştırılabilir ve farklı piyasa koşullarının modellere etkisi incelenebilir. Ek olarak, petrol ve altın fiyatları, ABD ve diğer ülke borsaları gibi makroekonomik değişkenlerin, bu tahmin modellerine dahil edilerek fiyat hareketleri üzerindeki etkilerinin analiz edilmesi ve model doğruluğunun artırılması da incelenebilir.

KAYNAKLAR

- Aizenberg, I. N., Aizenberg, N. N., & Vandewalle, J. (2000). Multiple-Valued threshold logic and multi-valued neurons. *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications*, 25-80.
- Akay, M. K., Canik, F., Yeşilyurt, C., & Günkut, M. Ş. (2021). Yapay zeka teknikleri ile kripto para değeri tahmini. *Ekonomi Bilimleri Dergisi*, 14(1), 72-101.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Boyraz, C. (2019). Derin öğrenme ile debi tahmini (Yüksek Lisans Tezi). *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*.
- Bozorg-Haddad, O., & Zolghadr-Asli, B. (. (2022). *Computational Intelligence for Water and Environmental Sciences*. Springer.
- Canitez, M. A., & Savaş, S. (2022). Kripto Para Piyasa Değeri Tahmini için Özellik Tabanlı LSTM ve ARIMA Karşılaştırması. *In 3rd International Conference on Applied Engineering and Natural Sciences* (pp. 1311-1317).
- Chen, A. S., Leung, M. T., & Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers & Operations Research*, 30(6), 901-923.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
- Çoban, Ö. (2016). Metin sınıflandırma teknikleri ile türkçe twitter duygu analizi. *Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü*.
- Demirci, E., & Karaatlı, M. (2023). KRIPTO PARA FİYATLARININ LSTM VE GRU MODELLERİ İLE TAHMİNİ. *Journal of Mehmet Akif Ersoy University Economics and Administrative Sciences Faculty*, 10(1), 134-157.
- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends® in signal processing*, 7(3-4), 197-387.

- Deniz, C. (2023). Modern Computer Tomography with Artificial Intelligence and Deep Learning Applications. *Artificial Intelligence Theory and Applications*, 3(2), 123-136.
- Erözel Durbilmez, S. (2018). Blockchain Teknolojisinin Finans Sektöründeki Yeri ve Uygulamaları, *Yüksek Lisans Tezi. İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı*.
- Eylasov, N., & Çiçek, M. (2024). Kripto Para Fiyatlarının Tahmini: ARIMA-GARCH ve LSTM Yöntemlerinin Karşılaştırılması. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 9(1), 48-62.
- François-Lavet, V., Islam, R., Pineau, J., Henderson, P., & Bellemare, M. (2018). An Introduction to Deep Reinforcement Learning. Boston/Delft: Now the Essence of Knowledge.
- Fukushima, K. (1980). A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol, Cybern*, 36, 193-202.
- Gezer, M., & Saylan, S. (2017). Açık kaynaklı makine öğrenmesi kütüphaneleri., O. Torkul, S. Gülseçen, Y. Uyaroglu, G. Çağıl ve MK Uçar.(Editörler). *Mühendislikte yapay zekâ ve uygulamaları*, 53-58.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
- Gruber, N., & Jockisch, A. (2020). Are GRU cells more specific and LSTM cells more sensitive in motive classification of text? *Frontiers in artificial intelligence*, 3, 40.
- Gunarto, D. M., Sa'adah, S., & Utama, D. Q. (2023). Predicting cryptocurrency price using rnn and lstm method. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 12(1), 1-8.
- Hansun, S., Wicaksana, A., & Khaliq, A. Q. (2022). Multivariate cryptocurrency prediction: comparative analysis of three recurrent neural networks approaches. *Journal of Big Data*, 9(1), 50.

- Hinton, G. E. (2007). Learning multiple layers of representation. *Trends in cognitive sciences*, 11(10), 428-434.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Iansiti, M., & Lakhani, K. R. (2017). The truth about blockchain. *Harvard business review*, 95(1), 118-127.
- Ivakhnenko, A. G., & Lapa, V. G. (1966). Cybernetic predicting devices.
- Jagannath, N., Barbulescu, T., Sallam, K. M., Elgendi, I., Mcgrath, B., Jamalipour, A., . . . Munasinghe, K. (2021). An on-chain analysis-based approach to predict ethereum prices. *IEEE Access*, 9, 167972-167989.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4), 541-551.
- LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W., & Jackel, L. (1989). Handwritten digit recognition with a back-propagation network. *Advances in neural information processing systems*, 2.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (1956). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>.
- Mellit, A., & Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. *Progress in energy and combustion science*, 34(5), 574-632.
- Mockenhaupt, A. (2021). *Maschinelles Lernen.* Digitalisierung und Künstliche Intelligenz. Wiesbaden: Springer Vieweg.
- Monkeylearn. (2024). *An Introduction to Machine Learning*. monkeylearn.com: <https://monkeylearn.com/machine-learning/> adresinden alındı
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized business review*.

- Nilsson, N. J. (2010). *The Quest For Artificial Intelligence*. Stanford University: Cambridge University Press.
- Phi, M. (2018). *Illustrated Guide to LSTM's and GRU's: A Atep by Atep Explanation*. Medium: <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21> adresinden alındı
- SAP. (2021). *Was ist Machine Learning?* SAP: <https://www.sap.com/germany/insights/what-is-machine-learning.html> adresinden alındı
- Song, H. A., & Lee, S. Y. (2013). Hierarchical representation using NMF. In *Neural Information Processing: 20th International Conference, ICONIP 2013, Daegu, Korea, November 3-7, 2013. Proceedings, Part I* 20 (pp. 466-473). Springer Berlin Heidelberg.
- Şenol, D., & Denizhan, B. (2023). Kripto Para Değerinin Yapay Sinir Ağları Ve Regresyon Analizi İle Tahmini. *Journal of Industrial Engineering (Turkish Chamber of Mechanical Engineers)*, 34(1).
- Türkmenoglu, C., & Tantug, A. C. (2014, Haziran). Sentiment analysis in Turkish media. In *International Conference on Machine Learning (ICML)*.
- Usta, A., & Doğantekin, S. (2019). Blockchain 101_V2. Bankalararası Kart Merkezi .
- Weiss, G., Goldberg, Y., & Yahav, E. (2018). On the practical computational power of finite precision RNNs for language recognition. arXiv preprint arXiv:1805.04908.
- Yaga, D., Mell, P., Roby, N., & Scarfone, K. (2019). Blockchain technology overview. arXiv preprint arXiv:1906.11078.
- Zhang, L., Aggarwal, C., & Qi, G. J. (2017). Stock price prediction via discovering multi-frequency trading patterns. In *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 2141-2149).

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mustafa YALÇIN
Uyruğu : Türkiye Cumhuriyeti

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Üniversite	: Batman Üniversitesi, Batman	2019
Yüksek Lisans	: Işık Üniversitesi (İSG, Tezsiz), İstanbul	2022
Yüksek Lisans	: Batman Üniversitesi, Batman	2024
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2021 -2022	AKLED Enerji A.Ş.	Elektrik Elektronik Mühendisi
2022- 2023	Sagtek Biyomedikal Bilişim ve Güvenlik Yenilenebilir Enerji	Ar-Ge Mühendisi
2023- Halen	Burel Elektronik Makine Tekstil Sanayi Tic. Ltd. Şti.	Elektrik Elektronik Mühendisi

YABANCI DİLLER

İngilizce (Orta Seviye)

YAYINLAR