KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DERİN VE HİBRİT DERİN ÖĞRENME TEKNİKLERİYLE KRİPTO PARA FİYAT TAHMİNİ

HASAN KİLİMCİ

KOCAELİ 2023

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DERİN VE HİBRİT DERİN ÖĞRENME TEKNİKLERİYLE KRİPTO PARA FİYAT TAHMİNİ

HASAN KİLİMCİ

Prof. Dr. Mehmet YILDIRIM
Danışman, Kocaeli Üniv. ……

Doç. Dr. Serdar SOLAK
Jüri Üyesi, Kocaeli Üniv. ……

Dr. Öğr. Üyesi Ahmet YILMAZ
Jüri Üyesi, KMÜ ……...……

Tezin Savunulduğu Tarih : 22.06.2023

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmasında,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

[X] Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

[ ] Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler ..... tarafından ..... no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

……..

Hasan KİLİMCİ

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanımı bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan ***"Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge"*** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.
☒ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

……

Hasan KİLİMCİ

ÖNSÖZ VE TEŞEKKÜR

Son yıllarda, kripto para, kriptografi ve blok zinciri teknolojileri ekonomi, bilgisayar bilimi ve finans alanlarında yatırımcılar, araştırmacılar ve analistler için oldukça ilgi çeken bir araştırma alanı haline gelmiştir. Tez çalışması kapsamında, son teknoloji yöntemlerle çeşitli kripto para birimlerinin fiyat tahminlemesi amaçlanmıştır.

Yüksek lisans eğitimim süresince, her türlü konuda benimle bilgi ve birikimlerini paylaşan, yoğun çalışma temposunda, zaman ve mekandan bağımsız olarak çalışmamın tamamlanmasında büyük emeği olan kıymetli danışman hocam Prof. Dr. Mehmet YILDIRIM'a teşekkür ederim. Hocamın örnek kişiliği ile bana kazandırdığı akademik bakış açısı ve gayretle ilerleyebilmeyi diliyorum.

Ayrıca, çalışmam sırasında fikirleri ile bana yol gösteren, yayın çalışmalarında desteğini esirgemeyen hocam Doç. Dr. Zeynep Hilal KİLİMCİ'ye teşekkür ederim.

Son olarak, yüksek lisans eğitimim boyunca tüm destekleri ve gösterdikleri sabır için sevgili eşime ve biricik kızlarıma teşekkürü bir borç bilirim. Bu yolculukta yalnız olmadığımı biliyor ve üzerinde emeği olan herkese teşekkürlerimi sunuyorum.

Mayıs – 2023 Hasan KİLİMCİ

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI ii
ÖNSÖZ VE TEŞEKKÜR iii
İÇİNDEKİLER iv
ŞEKİLLER DİZİNİ v
TABLOLAR DİZİNİ vii
SİMGELER VE KISALTMALAR DİZİNİ viii
ÖZET x
ABSTRACT xi
1. GİRİŞ 1
2. KRİPTO PARA BİRİMLERİ 4
2.1. Kripto Para 4
2.2. Bitcoin 4
2.3. Monero 6
2.4. Stellar 7
3. LİTERATÜR ÇALIŞMALARI 9
3.1. İstatistiksel Yöntemler Kullanarak Yapılan Çalışmalar 9
3.2. Geleneksel Makine Öğrenmesi Yöntemleri ile Yapılan Çalışmalar 12
3.3. Derin Öğrenme Yöntemleriyle Yapılan Çalışmalar 15
4. YÖNTEMLER 20
4.1. Evrişimli Sinir Ağları 20
4.2. Uzun Kısa Dönem Bellek Ağları 21
4.3. Hibrit CNN-LSTM 22
4.4. Hibrit ConvLSTM 23
5. ÖNERİLEN ÇERÇEVE 25
5.1. Veri Kümelerinin Toplanması 25
5.2. Önerilen Model 26
5.2.1. CNN Yöntemi Kullanılarak Oluşturulan Model Mimarisi 27
5.2.2. LSTM Yöntemi Kullanılarak Oluşturulan Model Mimarisi 31
5.2.3. CNN-LSTM Yöntemi Kullanılarak Oluşturulan Model Mimarisi 32
5.2.4. ConvLSTM Yöntemi Kullanılarak Oluşturulan Model Mimarisi 33
6. DENEY SONUÇLARI 35
6.1. Bitcoin Veri Kümesi ile Elde Edilen Sonuçlar 37
6.2. Monero Veri Kümesi ile Elde Edilen Sonuçlar 52
6.3. Stellar Veri Kümesi ile Elde Edilen Sonuçlar 66
7. SONUÇLAR VE ÖNERİLER 81
KAYNAKLAR 83
KİŞİSEL YAYIN VE ESERLER 89
ÖZGEÇMİŞ 90

ŞEKİLLER DİZİNİ

Şekil 2.1. Bitcoin transfer işleminde gerçekleşen süreç 5
Şekil 5.1. Önerilen modelin çerçevesi 26
Şekil 5.2. Bitcoin veri kümesi için CNN mimarisi 27
Şekil 5.3. Monero veri kümesi için CNN mimarisi 28
Şekil 5.4. Stellar veri kümesi için CNN mimarisi 29
Şekil 5.5. Bitcoin veri kümesi için LSTM mimarisi 31
Şekil 5.6. Monero ve Stellar veri kümeleri için LSTM mimarisi 32
Şekil 5.7. Üç veri kümesi için CNN-LSTM mimarisi 33
Şekil 5.8. Üç veri kümesi için ConvLSTM mimarisi 34
Şekil 6.1. Bitcoin veri kümesinde (sıralı) CNN modeliyle fiyat tahmini 39
Şekil 6.2. Bitcoin veri kümesinde (sıralı) CNN modeliyle kayıp ve MAPE 39
Şekil 6.3. Bitcoin veri kümesi (karıştırılmış) CNN modeliyle fiyat tahmini 40
Şekil 6.4. Bitcoin veri kümesinde (karıştırılmış) CNN modeliyle kayıp ve MAPE 41
Şekil 6.5. Bitcoin veri kümesinde (sıralı) LSTM modeliyle fiyat tahmini 42
Şekil 6.6. Bitcoin veri kümesinde (sıralı) LSTM modeliyle kayıp ve MAPE 43
Şekil 6.7. Bitcoin veri kümesinde (karıştırılmış) LSTM modeliyle fiyat tahmini 44
Şekil 6.8. Bitcoin veri kümesinde (karıştırılmış) LSTM modeliyle kayıp ve MAPE 45
Şekil 6.9. Bitcoin veri kümesinde (sıralı) CNN-LSTM modeliyle fiyat tahmini 46
Şekil 6.10. Bitcoin veri kümesinde (sıralı) CNN-LSTM modeliyle kayıp ve MAPE 46
Şekil 6.11. Bitcoin veri kümesinde (karıştırılmış) CNN-LSTM modeliyle fiyat tahmini 47
Şekil 6.12. Bitcoin veri kümesinde (karıştırılmış) CNN-LSTM modeliyle kayıp ve MAPE 48
Şekil 6.13. Bitcoin veri kümesinde (sıralı) ConvLSTM modeliyle fiyat tahmini 49
Şekil 6.14. Bitcoin veri kümesinde (sıralı) ConvLSTM modeliyle kayıp ve MAPE 50
Şekil 6.15. Bitcoin veri kümesinde (karıştırılmış) ConvLSTM modeliyle fiyat tahmini 51
Şekil 6.16. Bitcoin veri kümesinde (karıştırılmış) ConvLSTM modeliyle kayıp ve MAPE 51
Şekil 6.17. Monero veri kümesinde (sıralı) CNN modeliyle fiyat tahmini 54
Şekil 6.18. Monero veri kümesinde (sıralı) CNN modeliyle kayıp ve MAPE 54
Şekil 6.19. Monero veri kümesinde (karıştırılmış) CNN modeliyle fiyat tahmini 55
Şekil 6.20. Monero veri kümesinde (karıştırılmış) CNN modeliyle kayıp ve MAPE 56
Şekil 6.21. Monero veri kümesinde (sıralı) LSTM modeliyle fiyat tahmini 56
Şekil 6.22. Monero veri kümesinde (sıralı) LSTM modeliyle kayıp ve MAPE 57
Şekil 6.23. Monero veri kümesinde (karıştırılmış) LSTM modeliyle fiyat tahmini 58

Şekil 6.24. Monero veri kümesinde (karıştırılmış) LSTM modeliyle kayıp ve MAPE 59
Şekil 6.25. Monero veri kümesinde (sıralı) CNN-LSTM modeliyle fiyat tahmini 60
Şekil 6.26. Monero veri kümesinde (sıralı) CNN-LSTM modeliyle kayıp ve MAPE 61
Şekil 6.27. Monero veri kümesinde (karıştırılmış) CNN-LSTM modeliyle fiyat tahmini 62
Şekil 6.28. Monero veri kümesinde (karıştırılmış) CNN-LSTM modeliyle kayıp ve MAPE..... 63
Şekil 6.29. Monero veri kümesinde (sıralı) ConvLSTM modeliyle fiyat tahmini 63
Şekil 6.30. Monero veri kümesinde (sıralı) ConvLSTM modeliyle kayıp ve MAPE 64
Şekil 6.31. Monero veri kümesinde (karıştırılmış) ConvLSTM modeliyle fiyat tahmini 65
Şekil 6.32. Monero veri kümesinde (karıştırılmış) ConvLSTM modeliyle kayıp ve MAPE 66
Şekil 6.33. Stellar veri kümesinde (sıralı) CNN modeliyle fiyat tahmini..... 68
Şekil 6.34. Stellar veri kümesinde (sıralı) CNN modeliyle fiyat tahmini..... 69
Şekil 6.35. Stellar veri kümesinde (karıştırılmış) CNN modeliyle fiyat tahmini 70
Şekil 6.36. Stellar veri kümesinde (karıştırılmış) CNN modeliyle kayıp ve MAPE 70
Şekil 6.37. Stellar veri kümesinde (sıralı) LSTM modeliyle fiyat tahmini 71
Şekil 6.38. Stellar veri kümesinde (sıralı) LSTM modeliyle kayıp ve MAPE 72
Şekil 6.39. Stellar veri kümesinde (karıştırılmış) LSTM modeliyle fiyat tahmini 73
Şekil 6.40. Stellar veri kümesinde (karıştırılmış) LSTM modeliyle kayıp ve MAPE 73
Şekil 6.41. Stellar veri kümesinde (sıralı) CNN-LSTM modeliyle fiyat tahmini..... 74
Şekil 6.42. Stellar veri kümesinde (sıralı) CNN-LSTM modeliyle kayıp ve MAPE 75
Şekil 6.43. Stellar veri kümesinde (karıştırılmış) CNN-LSTM modeliyle fiyat tahmini 76
Şekil 6.44. Stellar veri kümesinde (karıştırılmış) CNN-LSTM modeliyle kayıp ve MAPE 77
Şekil 6.45. Stellar veri kümesinde (sıralı) ConvLSTM modeliyle fiyat tahmini..... 77
Şekil 6.46. Stellar veri kümesinde (sıralı) ConvLSTM modeliyle kayıp ve MAPE 78
Şekil 6.47. Stellar veri kümesinde (karıştırılmış) ConvLSTM modeliyle fiyat tahmini 79
Şekil 6.48. Stellar veri kümesinde (karıştırılmış) ConvLSTM modeliyle kayıp ve MAPE 80

TABLOLAR DİZİNİ

Tablo 5.1. Veri kümesi özellik açıklaması 25
Tablo 6.1. Bitcoin veri kümesi (sıralı) kullanarak elde edilen model performansları 37
Tablo 6.2. Bitcoin veri kümesi (karıştırılmış) kullanarak elde edilen model performansları 38
Tablo 6.3. Monero veri kümesi (sıralı) kullanarak elde edilen model performansları 52
Tablo 6.4. Monero veri kümesi (karıştırılmış) kullanarak elde edilen model performansları 52
Tablo 6.5. Stellar veri kümesi (sıralı) kullanarak elde edilen model performansları 67
Tablo 6.6. Stellar veri kümesi (karıştırılmış) kullanarak elde edilen model performansları 67

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

ABD : Amerika Birleşik Devletleri
ADAM : Adaptive Moment Estimation (Uyarlamalı Moment Tahmini)
ANFIS : Adaptive Neuro-Fuzzy Inference System (Uyarlamalı Sinir Bulanık Çıkarım Sistemi)
API : Application Programming Interface (Uygulama Programlama Arayüzü)
ARCH : Autoregressive Conditional Heteroskedasticity (Otoregresif Koşullu Değişen Varyans
ARDL : Autoregressive Distributed Lag (Otoregresif Dağıtılmış Gecikme)
ARIMA : Autoregressive Integrated Moving Average (Otoregresif Entegre Hareketli Ortalama)
AR : Autoregressive (Otoregresif)
BB : Bollinger Bands (Bollinger Bantları)
BTC : Bitcoin
BTCUSDT : Bitcoin Tether İkili Opsiyonu
CNN : Convolutional Neural Network (Evrişimli Sinir Ağı)
ConvLSTM : Convolutional Long Short-Term Memory (Evrişimli Uzun Kısa Dönem Bellek)
DNN : Deep Neural Network (Derin Sinir Ağı)
DNDT : Deep Neural Decision Tree (Derin Sinir Karar Ağacı)
DSVR : Deep Support Vector Regression (Derin Destek Vektör Regresyonu)
ETH : Ethereum
GARCH : Generalized Autoregressive Conditional Heteroskedasticity (Genelleştirilmiş Otoregresif Koşullu Değişen Varyans)
GRU : Gated Recurrent Unit (Kapılı Tekrarlayan Birim)
LFW : Labelled Faces in the Wild (Vahşi Doğada Etiketli Yüzler)
LSTM : Long Short-Term Memory (Uzun Kısa Dönem Bellek)
LR : Logistic Regression (Lojistik Regresyon)
LTC : Litecoin
MA : Moving Average (Hareketli Ortalama)
MAE : Mean Absolute Error (Ortalama Mutlak Hata)
MAPE : Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MSE : Mean Squared Error (Ortalama Kare Hata)
NNAR : Neural Network AutoRegressive (Sinir Ağı Otoregresif)
PoS : Proof of Stake (Hisse kanıtı)
PoW : Proof of Work (İş kanıtı)
ReLU : Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
R^2 : R-Squared (R Kare)
RNN : Recurrent Neural Network (Tekrarlayan Sinir Ağı)
RSI : Relative Strength Index (Göreceli Güç Endeksi)
RMSE : Root Mean Squared Error (Kök Ortalama Karesel Hata)
SANN : Self-Adaptive Neural Network (Kendinden Uyarlamalı Sinir Ağı)
SMA : Simple Moving Average (Basit Hareketli Ortalama)
SVM : Support Vector Machine (Destek Vektör Makinesi)

TBATS : Trigonometric Seasonal Decomposition of Time Series (Zaman Serisinin Trigonometrik Mevsimsel Ayrıştırması)
USDT : Tether USD Stablecoin(USD sabitlenmiş kripto para)
XLMUSDT : Stellar Tether İkili Opsiyonu
XMRUSDT : Monero Tether İkili Opsiyonu

DERİN VE HİBRİT DERİN ÖĞRENME TEKNİKLERİYLE KRİPTO PARA FİYAT TAHMİNİ

ÖZET

Kripto para kriptografi ve blok zinciri teknolojisi kullanılarak merkezi bir otorite olmadan bir değişim aracı olması amaçlanan dijital bir para birimidir. Ekonomi bilgisayar bilimi ve finans alanlarında önemli bir etkiye sahiptir. Ayrıca, bir değişim aracı olan bazı kripto para birimleri yatırımcıları, araştırmacıları ve analistleri çeken bir değer saklama aracı haline gelir.

Derin öğrenmenin insanların belirli olaylar hakkında bilgi edinme şeklini taklit ettiği bilinmektedir. Son on yılda, bilgisayarların hesaplama gücünde dikkate değer bir artış gözlemleniştir ve bu da derin öğrenmenin nesne algılama, metin işleme, konuşma tanıma, zaman serileri analizi vb. birçok alanda çok popüler ve uygulanabilir hale gelmesine neden olmuştur.

Bu tezde, günlük alım satım olarak bilinen sık alım satım işlemleri için kripto para birimlerinin son fiyatının dolar cinsinden tahmin edilmesi önerilmiştir. Bu amaçla, evrişimli sinir ağları (CNN), uzun kısa dönem bellek ağları (LSTM), evrişimli uzun kısa dönem bellek ağları (ConvLSTM) ve CNN uzun kısa dönem bellek ağları (CNN-LSTM) olmak üzere toplamda dört farklı derin ve hibrit derin öğrenme yaklaşımı kullanılmıştır. Önerilen modellerin katkısını göstermek için Bitcoin, Stellar ve Monero olmak üzere üç farklı kripto para birimi üzerinde deneyler yapılmıştır. Ayrıca, daha iyi tahmin sonuçları elde etmek için istatistiksel özelliklere ek olarak Bollinger bandı (BB), saat bazlı hareketli ortalama (MA) ve Göreceli Güç Endeksi (RSI) gibi teknik göstergeler üç kripto para birimi için özellik alanına dahil edilmiştir. Deney sonuçları, derin öğrenme tekniklerin kullanılmasının, kripto para fiyatlarının tahmini için dikkate değer sonuçlar elde ettiğini göstermektedir.

Anahtar Kelimeler: Bitcoin, Derin Öğrenme, Kripto Para Fiyat Tahmini, Zaman Serisi Analizi.

CRYPTOCURRENCY PRICE PREDICTION USING DEEP AND HYBRID DEEP LEARNING TECHNIQUES

ABSTRACT

Cryptocurrency is a digital currency that is meant to be a medium of exchange without a central authority using cryptography and blockchain technology. It has a substantial impact on the fields of economics, computer science, and finance. Besides, being a medium of exchange, some of the cryptocurrencies become a medium of storing value which attracts investors, researchers, and analysts.

Deep learning has been known to mimic the way humans gain knowledge of certain events. During the last decade, a remarkable increase in the computational power of computers are observed which led deep learning to become very popular and applicable in many areas such as object detection, text processing, speech recognition, time series analysis, etc.

In this thesis, it is proposed to predict the last price of cryptocurrencies in dollar for frequent trading transactions known as day-trading. For this purpose, four different deep and hybrid deep learning approaches are utilized in total, namely convolutional neural networks (CNNs), long short-term memory networks (LSTMs), convolutional long short-term memory networks (ConvLSTM), and CNN Long Short-Term Memory Network (CNN-LSTM). To demonstrate the contribution of the proposed models, experiments are carried out on three different cryptocurrencies namely, Bitcoin, Stellar, and Monero. Furthermore, technical indicators for three cryptocurrencies such as Bollinger band (BB), hour-based moving average (MA), and Relative Strength Index (RSI) are included in the feature space in addition to the statistical features to achieve better prediction results. Experiment results indicate that the inclusion of deep learning-based frameworks achieves remarkable results for the prediction of cryptocurrency prices.

Keywords: Bitcoin, Deep Learning, Cryptocurrency Price Prediction, Time Series Analysis.

1. GİRİŞ

Para, ekonomide mal ve hizmetlerin alım ve satımında kullanılan kişi veya kurumlar tarafından kabul gören mübadele ve karşılık aracıdır. Bir değer ifade eder. Tarihte ilk para M.Ö. 7. yüzyılda Lidyalılar tarafından Anadolu'da icat edilmiştir. Bakır, gümüş, kalay ve altın gibi madenler paranın fiziksel maddesi olarak kullanılmıştır. Kullanım kolaylığı nedeniyle kâğıt paralar ortaya çıkmıştır. Günümüzde blok zincir ve kriptografi teknolojilerinin sağladığı imkanlar sayesinde kripto paralar popülerlik kazanmıştır. Blok zincir, dağıtık bir veri tabanı teknolojisi olarak kullanılan ve verilerin güvenli ve geriye dönük olarak değiştirilemez şekilde kaydedildiği bir sistemdir. Önceki bloklardaki verilerin özetleriyle birleştirilerek yeni bloklar oluşturur ve bu sayede verilerin bütünlüğü sağlanır (Nakamoto, 2008). Kriptografi ise, iletişimde gizlilik, bütünlük ve kimlik doğrulama gibi hedefleri sağlamak için matematiksel ve hesaplama yöntemlerini kullanan bir disiplindir. Temel amacı, verilerin güvenli bir şekilde iletilmesi ve depolanması için şifreleme ve şifre çözme tekniklerini kullanmaktır (Stallings, 2005).

Kripto paralar bankalardan ve devletlerden tamamen bağımsız olarak gerçekleştirilen ödemeler için tasarlanmış sanal para birimleridir. Kripto para ödemelerinde kullanılan teknik, geleneksel yöntemlerin çok ötesindedir. Bu sayede, kripto para birimleri kullanıcılara geleneksel yöntemlere göre daha yüksek transfer hızı, daha az transfer maliyeti, transfer eden ve alıcının gizliliği vb. birçok avantaj sağlamaktadır. Bu nedenle, kripto para birimleri son zamanlarda dünyadaki çoğu ülke vatandaşları tarafından önemli ölçüde ilgi görmektedir. Bununla birlikte, kullanıcıların tutumu ise, doğrudan yasalar tarafından denetlenmediği için birçok kripto para birimine karşı temkinlidir. Bu durum, kullanıcıların yasalarca korunmamasına, fiyatlarının daha fazla manipüle edilebilmesine, yasaların uygulanmasının zorlaşmasına sebebiyet vermektedir. Bu nedenle, kullanıcılar ve çoğunlukla ülkeler tarafından kabul görmemesine neden olmaktadır. Ancak, artan talep ve merak nedeniyle, kripto para birimleri hem yatırımcılar hem araştırmacılar hem de bilim insanları tarafından yoğun bir talep görmektedir. Diğer bilinen finansal enstrümanlar gibi arz ve talep ilişkisine bağlı olarak bir fiyat oluşmaktadır. Bu fiyat değişimleri neticesinde, kayıp ve kazançlar ortaya çıkmaktadır. Kripto borsalar aracılığı ile kripto para alım, satım işlemleri yapılabilmektedir. Ayrıca, diğer kripto para

birimlerine ya da itibari para birimlerine değişim gerçekleştirilebilmektedir (Gümüş ve Erkuş, 2019).

Bitcoin, ilk kripto para, 2008 yılında Satoshi Nakamoto takma adlı kişi ya da kişiler tarafından bir makale ile gündeme gelmiştir. Bitcoin blok zincir ağının çalışması ise 2009 yılında gerçekleşmiştir. Bitcoin, uçtan uca transfer işlemi yapabilmesi, çift ödeme problemine getirdiği çözüm ve oluşturduğu ağ yapısıyla kripto para teknolojisinin en önemli temsilcisidir (Cengiz, 2018). Bitcoin'in hayatımıza girişi ve kullanımı sonrası, günümüzde sayıları 20.000 üzerinde kripto para birimi oluşturulmuştur. Kripto paraların kendi aralarında belli noktalarda farklılık ve üstünlükleri olabilmektedir. Monero, 2014 yılında piyasaya sürülmüştür. Bitcoin transfer işlemleri gönderen ve alıcı bilgileri anonim olsa bile transfer işlemleri herkese açık ve izlenebilirdir. Ayrıca, transferi gönderen, işlem sonrası alıcının adresine ulaşabildiği için alıcının son bakiyesi ile ilgili bilgiye sahip olabilmektedir. Monero transferleri, tekrar rastgele oluşturulmuş bir adres tarafından alıcıya gönderildiği için izi sürülemez (Li ve diğ., 2019). Yüksek güvenlik ve transfer işlemlerinde tam gizlilik isteyen kullanıcılara hitap etmektedir. Stellar, 2014 yılında kullanıcılarına hızlı ve düşük transfer ücretleri sunan bir yapı ile piyasaya sürülmüştür. Çoğu kripto paranın tasarım aşamasındaki amacı, mevcut finansal sistemden ayrı olmasının yanında, hali hazırdaki finansal enstrümanların ya da sistemlerin yerini almasıdır. Fakat, Stellar tam aksine, mevcut finansal sistemlerin tek bir ağ üstünden birlikte çalışabilmesini amaçlamaktadır. Uluslararası ödeme sistemleriyle bütünleşmiş bir şekilde çalışabilmektedir (Khan ve diğ., 2019). Kripto paraların fiyatları birçok değişken ve karmaşık etmenin etkisi altında değişebilir. Bu nedenle, derin öğrenme, kripto para fiyat tahmini için değerli bir araç olarak görülmekte ve yapılan çalışmalarda yaygın olarak kullanılmaktadır.

Derin öğrenme makine öğrenmesinin bir alt alanıdır. Derin öğrenme veri işlemek ve karar vermek için oluşturduğu kalıplarda insan beyninin işleyişini taklit etmektedir. Makine öğrenmesinde kullanılan bazı veri ön işleme, özellik uzayı çıkarımı gibi adımları elemektedir. Derin öğrenme algoritmaları, kullanılan nöronlar arası ağırlıkları sürekli olarak güncelleyerek maliyeti en aza indirmeyi amaçlamaktadır. Çok boyutlu veri kümelerinde karmaşık yapıları keşfeder ve bu yapıları kullanarak sonuç verir. Bu sayede, en doğru çıktıyı vermeyi hedeflemektedir. Derin öğrenmenin temel uygulamaları;

bilgisayarla görme, doğal dil işleme, görüntü işleme, ses tanıma vb. gibi çeşitli alanları içerir. Derin öğrenme metodolojisi, birçok araştırma alanında hem özellik çıkarma hem de sınıflandırma görevlerini kolaylaştırmıştır (Shinde ve diğ., 2018). Popüler derin öğrenme yöntemleri; tekrarlayan sinir ağları (RNN), evrişimli sinir ağları (CNN), uzun kısa dönem bellek ağları (LSTM), derin sinir ağlarıdır (DNN).

Bu çalışmada, önerilen derin ve hibrit derin öğrenme tekniklerini kullanarak dolar cinsinden üç kripto para biriminin, sırasıyla Bitcoin, Monero, Stellar, kısa vadeli fiyatlarının tahmin edilmesine odaklanılmıştır. Analiz yapılabilmesi için hacim, maksimum, minimum ve ortalama fiyatlar, Bollinger bandı (BB), saat bazlı hareketli ortalama (MA- ing: moving average), göreceli güç endeksi (RSI- ing: relative strenght index) gibi hem istatistiksel hem de teknik göstergeler ile özellik uzayı oluşturulur. Veriler, Mart 2021 ile Mayıs 2021 arasında, Binance kripto para borsası tarafından sunulan ücretsiz bir uygulama yazılım arayüzü kullanılarak, saatlik periyotlar halinde toplanmıştır. Kripto paraların fiyatını tahmin etmek için, derin öğrenme modeli olarak; evrişimli sinir ağları (CNN), uzun kısa dönem bellek ağları (LSTM) kullanılırken, evrişimli uzun kısa dönem bellek ağları (ConvLSTM) ve CNN uzun kısa dönem bellek ağı (CNN-LSTM) yöntemleri ise hibrit derin öğrenme modelleri olarak değerlendirilmiştir. Kapsamlı deneyler, derin öğrenme metodolojisi kullanımının kripto paraların fiyat tahminini önemli ölçüde iyileştirdiğini göstermiştir.

Tez çalışması altı bölümden oluşmaktadır. İkinci bölümde, kripto para birimleri ve değerlerinin nasıl belirlendiği, çalışmada kullanılan kripto paralar ve özellikleri, kripto paralara nasıl yatırım yapıldığı anlatılmıştır. Üçüncü bölümde, çeşitli kripto paralar için fiyat ve yön tahmini yapan literatür çalışmalarının özeti sunulmuştur. Dördüncü bölümde, tez kapsamında kullanılan derin ve hibrit derin öğrenme modellerinin detayları gösterilmiştir. Beşinci bölümde, önerilen yöntemin detayları sunulmuştur. Altıncı bölümde, deney sonuçları ve önerilere yer verilmiştir.

2. KRİPTO PARA BİRİMLERİ

2.1. Kripto Para

Günümüzde teknolojik gelişmelere bağlı olarak, internet üzerinde yapılan ticaret denetlenen ve güvenilir olduğu kabul edilen üçüncü taraf finansal kurumlar aracılığıyla gerçekleşmektedir. Kurumlar güveni sağlamakta yeteri kadar iyi olsa da bu modelin doğal zayıflıkları mevcuttur. Finans kurumlarının arabuluculuk anlaşmaları gereği, anlaşmazlık durumunda yapılan işlemler geri alınabilmektedir. Bu modelde geri dönüşü olmayan işlemleri gerçekleştirmek mümkün olmamaktadır (Nakamoto, 2008). Geri dönüşü mümkün olmayan, değiştirilmesi mümkün olmayan ticari işlem arzusu farklı ödeme sistemleri beklentisini ortaya koymuştur. Son on senede, bu beklentiyi karşılayan en önemli sistem kripto paralardır.

Kripto para, şifrelenmiş para anlamına gelen yeni bir alternatif para birimidir. Şifrelenmiş denmesinin en büyük nedeni, sanal cüzdanlar arası yapılan transferlerin şifreler vasıtasıyla oluşmasıdır. Fiziksel bir maddeden imal edilmemiş, tamamen dijital ve sanaldır. Bunun yanında, itibari paralar gibi takas edilebilmektedir.

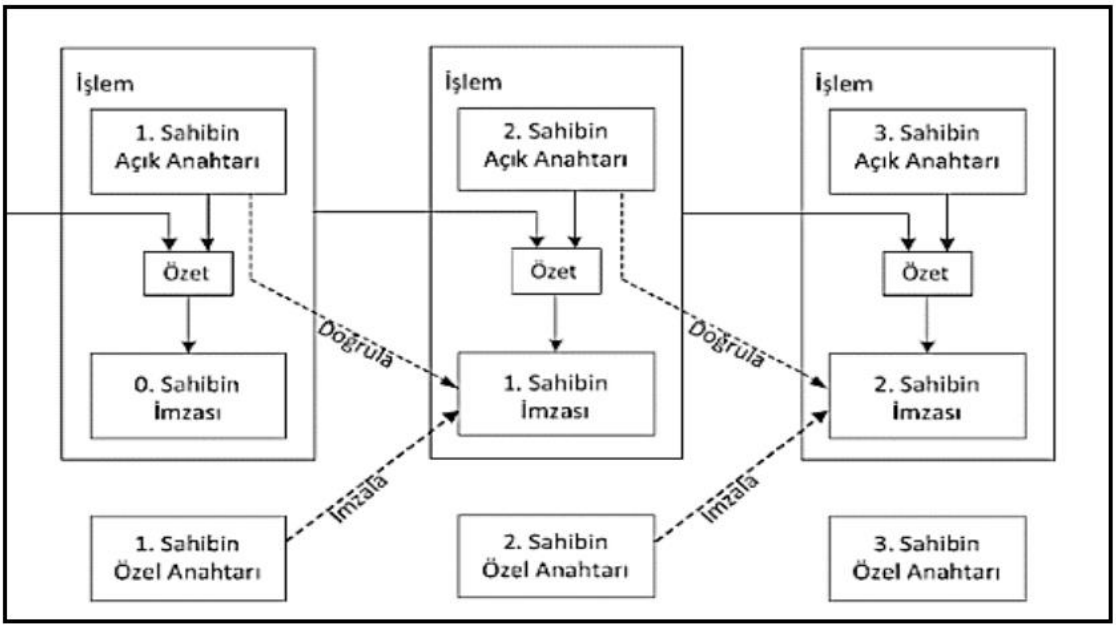
2008 yılında yayınlanan bir makale ile genel hatları belirlenmiştir. Makale, Satoshi Nakamoto adlı yazar tarafından yayınlanmıştır. Satoshi Nakamoto'nun bu sistemi oluşturan kişi ya da kişilerin takma adı olduğu düşünülmektedir. Kripto paralar uzun bir dönem dünyanın ilgisini çekmemiştir. Bu evrede geliştirilmiş ve bir süre gündemde olmamışlardır.

2.2. Bitcoin

Bitcoin kimliği gizemli bir yazar veya yazar grubunun takma adı olan Satoshi Nakamoto tarafından, 2008 yılında tanıtıldı. Bitcoin denilince, akla hem sistem hem de para biriminin adı akla gelmektedir. BTC terimi para birimini ifade etmektedir. Bitcoin madeni para veya banknot gibi fiziki bir maddesi olmayan elektronik, sanal bir para birimidir. Bitcoin sistem olarak, internet üzerinden bitcoin protokolünü kullanarak birbirleriyle iletişim kuran bir kripto para ağıdır. Bitcoin protokolü, açık kaynaklı bir yazılım uygulaması olarak bulunabilmektedir. Kullanıcıların mal ya da hizmet alımı ve satımı için bitcoin saklamasına ve transfer etmesine veya bitcoinleri diğer para birimleriyle

değiştirmesine olanak tanır. Bitcoin ağı, 2009 yılında işleme başlamıştır ve o zamandan beri Bitcoin en popüler kripto para birimi olmuştur (Vranken, 2017). Aralık 2022 itibariyle, toplam kripto para piyasası 865 Milyar Amerikan doları civarında ve Bitcoin'in payı ise %38'dir (URL-1).

Bitcoin madenciliği, finansal bir ödül sunduğu için caziptir. Madenciliği yapılan blok zincirdeki her blok için madenci Bitcoin cinsinden bir blok ödülü ve bloktaki işlemlerin işlem ücretlerini alır. Bitcoin popülerlik kazandıkça, madenciler arasında yüksek bir rekabet başlamıştır. Bitcoin madenciliğinde, başlangıçta, kişisel bilgisayarlar kullanılmıştır. Artan rekabet nedeniyle, yüksek işlem gücü olan bilgisayarlar ile yapılmaktadır (Vranken, 2017). Madencilik ödülü 2022 yılı itibariyle 6,25 Bitcoin'dir. Keşfedilen her 210.000 blok sonrası, ya da ortalama 4 senede, ödül miktarı yarıya düşmektedir. 2009 yılında 50 Bitcoin ile başlayan ödül ilk yarılanmada 25'e, ikinci yarılanmada 12,5'e, üçüncü yarılanmada ise 6,25'e düşmüştür. Bir sonraki yarılanma işleminin 2024 yılında olması beklenmektedir. Yarılanma sonrası madencilik faaliyetlerinin maliyeti arttığı için Bitcoin fiyatları da artma eğiliminde olmaktadır. Bitcoin arzı 21 milyon ile sınırlıdır ve 2040 yılında tamamlanması beklenmektedir (URL-2).



Şekil 2.1. Bitcoin transfer işleminde gerçekleşen süreç

Bitcoin transferleri, Nakamoto (2009) tarafından Şekil 2.1'de gösterildiği üzere bir imza zinciri olarak tanımlanmıştır.

Paranın her sahibi, transfer esnasında önceki işlemin özetini bir sonraki sahibin açık anahtarını ekleyerek dijital olarak imzalar. Bu şekilde alıcı, işlemi doğrulayabilir. Fakat alıcı, gönderilen dijital para jetonunun daha önce harcanıp harcanmadığını bilemez. Aynı para jetonunun birden fazla gönderilmesi durumunu engellemek için, işlemler açıkça ağdaki herkese ilan edilmeli ve işlem sıralamaları ağdakiler tarafından bilinmelidir. Bu şekilde onaylama yapısı çalışmaktadır.

2.3. Monero

Monero gizlilik ve anonimliğe odaklanan bir kripto para birimidir. 2014 yılında piyasaya sürülmüştür. Nisan 2023 itibariyle 2,8 milyar ABD dolarının üzerinde piyasa değerine ulaşmıştır. Bu değer sayesinde, en büyük kripto paralardan biri olmuştur. Monero, alacaklının kimliğini korumak için CryptoNote protokolünü kullanır ve gizli işlemleriyle bilinen RingCT protokolünden yararlanır (Li ve diğ., 2019).

CryptoNote açık kaynak kodlu bir kripto para protokolüdür. Bu protokol gizlilik ve anonimlik özelliklerine önem veren bir kripto para sistemi sağlar. Özellikle Bitcoin'in aksine, CryptoNote protokolü para transferleri sırasında tüm işlemlerin ve hesapların gizliliğini koruyarak anonimliği artırır. Bu özellikler, herhangi bir kişinin hesap bakiyesi veya işlem geçmişi gibi kişisel bilgilerinizi görmesini önler. CryptoNote protokolü, madencilik işlemlerini de özelleştirir. İşlem onaylama işlemi, madencilik havuzları yerine daha küçük gruplar arasında paylaşılır ve bu da ağın daha güvenli ve dayanıklı hale gelmesini sağlar.

Monero, gizlilik odaklı bir kripto para birimidir ve Ring Confidential Transactions (RingCT) adlı bir teknoloji kullanır. RingCT, Monero işlemlerini önceden belirlenmiş bir miktarın üstünde özel hale getirir. RingCT, geleneksel Bitcoin işlemlerindeki gibi açık anahtarlı şifreleme (public-key cryptography) kullanmaz. Bunun yerine, işlemdeki alıcı, herhangi bir kişinin alıcının kimliğini tespit etmesini engellemek için işlemde bir grup oluşturur. Bu grup, alıcının gerçek adresini içerirken, aynı zamanda belirli sayıda sahte adres de içerir.

Daha sonra, işlemi doğrulamak ve onaylamak için, tüm işlem ağında bu sahte adreslerin arasından rastgele seçilen bir adrese rastgele bir rakam eklenir. Bu rakamların toplamı, işlem miktarının doğru olduğunu ve hiçbir Monero'nun çift harcanmadığını kanıtlamak için kullanılır. Bu sayede, RingCT, Monero işlemlerinin gizliliğini korurken, işlemlerin doğruluğunu sağlar.

2.4. Stellar

Stellar, Stellar ağı üzerinde çalışan bir kripto para birimidir. Stellar, merkezi olmayan bir ödeme protokolü ve platformudur ve 2014 yılında Jed McCaleb tarafından kurulmuştur. Stellar, özellikle düşük maliyetli ve hızlı uluslararası para transferleri için tasarlanmıştır. Stellar, "Lumen" olarak da bilinen XLM adı verilen kendi kripto para birimini kullanır. Lumenler, ağda işlem yapmak ve ağın güvenliğini sağlamak için kullanılır. Ayrıca, ağda yeni varlıklar oluşturmak ve bunları Stellar ağı üzerinde kolayca takas etmek de mümkündür.

Stellar'ın bir diğer önemli özelliği, düşük ücretlerdir. Bir Stellar işlemi yalnızca 0,00001 XLM gibi düşük bir ücretle gerçekleştirilebilir. Ayrıca, işlemler saniyeler içinde gerçekleşir ve işlemler arasındaki doğrulama süresi oldukça kısadır.

Stellar; finansal kurumlar, ödeme sağlayıcıları ve para transferi şirketleri tarafından kullanılmaktadır. Örneğin, IBM ve Deloitte gibi şirketler, Stellar ağı üzerindeki uygulamalarını ve projelerini geliştirmekte ve XLM kullanmaktadır.

Stellar ve Bitcoin farklı blok zincir teknolojilerine sahip oldukları için farklı işlem hızlarına sahiptirler. Bitcoin blok zinciri, Proof of Work (PoW) algoritması kullanır. Bu algoritma, madencilik adı verilen işlemler aracılığıyla blok zinciri oluşturur ve işlemlerin doğruluğunu onaylar. Ancak, bu işlem süreci oldukça yavaş ve zaman alıcıdır. Bitcoin işlemleri, ağdaki yoğunluğa ve işlem ücretine bağlı olarak birkaç dakika ile birkaç saat arasında değişen sürelerde tamamlanabilir. Stellar blok zinciri, Proof of Stake (PoS) algoritmasını kullanır. Bu algoritma, blok zincirinin doğruluğunu onaylayan "işlemci" adı verilen belirli bir grup insan tarafından seçilir. Bu işlem süreci daha hızlı ve daha az enerji gerektirir. Stellar işlemleri genellikle birkaç saniye içinde tamamlanır.

Sonuç olarak, Stellar, hızlı, düşük maliyetli ve merkezi olmayan bir ödeme protokolü olan Stellar ağı üzerinde kullanılan bir kripto para birimidir.

3. LİTERATÜR ÇALIŞMALARI

Bu bölümde, farklı kripto para birimlerinin fiyat tahmini için literatürde kullanılan istatistiksel tabanlı yöntemlerin, geleneksel makine öğrenmesi yaklaşımlarının ve derin öğrenme temelli modellerin özeti sunulmaktadır. Tez çalışması kapsamında derin öğrenme yöntemleri olan CNN ve LSTM ile hibrit bir derin öğrenme yöntemi olan CNN-LSTM ve ConvLSTM kullanılarak, saatlik bazda Bitcoin, Monero ve Stellar gibi kripto paraların fiyat tahmini gerçekleştirilmiştir. Yapılan literatür taramasında, aynı yöntem ve kripto paralar üzerine akademik çalışmalara rastlanmamıştır. Bu kapsamda, tez çalışmasının literatüre katkı sağlayacağı öngörülmektedir.

3.1. İstatistiksel Yöntemler Kullanarak Yapılan Çalışmalar

Roy ve diğ. (2018) çalışmalarında, 2013-2017 dönemine ait dört yıllık Bitcoin verileri üzerinde yapılan analizlerde, ardışık 10 gün için Bitcoin fiyatlarını tahmin etme yöntemini, farklı istatistiksel zaman serisi analizleri kullanarak sunmuşlardır. Bu analizler arasında otoregresif (AR), hareketli ortalama (MA) ve Otoregresif Entegre Hareketli Ortalama (ARIMA) modelleri bulunmaktadır. Yapılan analizler sonucunda, MA modelinin %87,58 doğrulukla en düşük performansa sahip olduğu tespit edilirken, ARIMA modelinin ise %90,31 doğruluk oranıyla daha başarılı olduğu belirtilmiştir.

Sorbetov (2018) yaptığı çalışmada, Bitcoin, Ethereum, Dash, Litecoin ve Monero gibi popüler kripto paraların fiyatlarını etkileyen faktörlerin analizini gerçekleştirmiştir. Yazar, otoregresif dağıtılmış gecikme (ARDL) yaklaşımını benimseyip 2010-2018 dönemine ait haftalık verileri kullanmaktadır. En önemli faktörlerin piyasa betası, işlem hacmi ve oynaklık gibi önemli belirleyiciler olduğunu gözlemlemiştir. S&P500 endeksinin Bitcoin, Ethereum ve Litecoin üzerinde zayıf pozitif uzun vadeli etkisi bulunurken, kısa vadede önemini kaybederek negatif yönde bir etki gösterdiği belirtilmiştir. Özellikle Bitcoin için, %10 anlamlılık düzeyinde -0,20'lik bir tahminle negatif yönde bir etki tespit edilmiştir.

Alahmari (2019) çalışmasında, klasik ARIMA modelinin üç önemli kripto para birimi olan Bitcoin, Ripple ve Ethereum'un değerlerinin tahmin edilmesi üzerine odaklanmıştır. Bu bağlamda, günlük, haftalık ve aylık zaman serileri kullanılmıştır. Bu çalışmada elde

edilen bulgular, ARIMA modelinin diğer pek çok yönteme kıyasla daha üstün bir performans sergilediğini ortaya koymuştur. Kripto para birimlerinin değerlerinin günlük zaman serisi temelinde ortalama olarak tahmin edilmesi, mutlak ortalama hata (MAE), ortalama karesel hata (MSE) ve ortalama karesel hatanın kökü (RMSE) kriterleriyle değerlendirilmiştir.

Azari (2019), ARIMA tabanlı Bitcoin fiyat tahmini üzerine kapsamlı bir deneysel çalışma gerçekleştirmiştir. Bu amaçla, verileri işleyerek MSE hatasını en aza indiren ARIMA modelini bulmaya odaklanmış ve (p, q, d) demetlerinin Bitcoin fiyat tahminindeki etkisini araştırmıştır. Deneysel sonuçlar, kapanış fiyat geçmişini kullanan Bitcoin fiyat tahmini modelinin, Bitcoin'in yüksek sıçramalara ve düşüşlere karşı fiyat kırılganlığı nedeniyle büyük MSE değerleri ile sonuçlanabileceğini göstermiştir. Öte yandan, deney sonuçları ARIMA modelinin, zaman aralığının alt dönemlerinde fiyat tahmini için kullanılabileceğini, yani zaman aralığını, veri setinin benzersiz bir eğilime sahip olduğu birkaç zaman aralığına bölerek işlenebileceğini doğrulamıştır. Ayrıca, test zaman penceresinin konumunun ve uzunluğunun, fiyat tahmininde elde edilen MSE üzerindeki etkisi araştırılmıştır. Spesifik olarak, zaman penceresindeki 2'den 9'a artışla, tahmin hatasının ortalama MSE'sinin 118.000'den 16.000'e düşürülebileceği gösterilmiştir.

Hua (2020), iki farklı model olan uzun kısa dönem bellek (LSTM) ağı ve ARIMA modellerini kullanarak dolar cinsinden Bitcoin fiyatını tahmin etmeyi amaçlamıştır. Gerçek zamanlı fiyat verileri, Bitfine'den Pycurl platformu aracılığıyla toplanmıştır. Bu çalışmada kullanılan ARIMA modeli, temel olarak zaman serisi tahmininin klasik bir karşılaştırmasını sunmaktadır. ARIMA modelinin performansının, kısa zaman aralıklarında sınırlı verimli tahmin yapabildiği gösterilmiş ve sonucun zaman dilimine bağlı olduğu ispatlanmıştır. İki modelin Bitcoin fiyat tahmini açısından kıyaslaması yapıldığında, LSTM modelinin ARIMA modeline göre daha üstün bir başarı sergilediği vurgulanmıştır.

Benzekri ve Özütler (2021) tarafından gerçekleştirilen araştırmada, kısa vadeli Bitcoin fiyat hareketlerinin tahmin edilebilirliği ele alınmıştır. Çalışmada, ARIMA modeli kullanılarak Bitcoin fiyatlarının gelecekteki değerlerinin tahminine yönelik bir analiz yapılmıştır. Bu bağlamda, 1 Ocak 2015 ile 31 Mart 2021 tarihleri arasındaki günlük Bitcoin fiyat verileri üzerinde çalışılmıştır. Araştırma sonuçları, ARIMA modelinin

Bitcoin fiyat hareketlerini nispeten başarılı bir şekilde tahmin edebildiğini ortaya koymaktadır. Benzekri ve Özütler (2021) tarafından elde edilen Ortalama Mutlak Yüzde Hata (MAPE ing: Mean Absolute Percentage Error) değeri %4.24 ve Kök Ortalama Kare Hata (RMSE – ing: Root Mean Squared Error) değeri 0.4630 olarak rapor edilmiştir. Bu bulgular, kripto para piyasalarının analizinde ve politika yapımında kısa vadeli tahminler için ARIMA modelinin önemli bir araç olarak değerlendirilebileceğini göstermektedir.

Sadia ve diğ. (2022), blok zincir tabanlı kripto para birimlerinin analizi ve tahmini ile TBATS, NNAR ve ARIMA modellerinin performans değerlendirmesine odaklanmışlardır. Bu amaçla, özellikle Bitcoin (BTC), Ethereum (ETH), Litecoin (LTC), Monero (XMR) ve Cardano (XRP) gibi kripto para birimleri fiyatı için yukarıda bahsedilen üç farklı zaman serisi tahmin yöntemiyle deneyler yapılmış ve performansları değerlendirilmiştir. İlk olarak, zaman serisi verileri toplanmış ve tanımlayıcı istatistikler kullanılarak incelenmiştir. Sonrasında, her bir veri kümesi için özellikler arasındaki korelasyonlar hesaplanıp ARIMA, Trigonometrik, Box-Cox dönüşümü, ARMA hataları, Trend ve Mevsimsel (TBATS) ve Sinir Ağı Otoregresif (NNAR) gibi etkin finansal tahmin modellerini farklı parametre konfigürasyonlarına göre değerlendirilmiştir. Bu modellerin performansları, ortalama karesel hatanın karekökü (RMSE) ve ortalama mutlak yüzde hatası (MAPE) metrikleri kullanılarak değerlendirilmiş ve modellerin performansı, MAPE değerlerinin istatistiksel ortalaması ve standart sapmasına göre sıralanmıştır. NNAR modeli minimum MAPE 2,823 verirken, minimum yakınsama süresi 4,9835s TBATS ile gözlenmiştir. Böylece yazarlar, sinir ağı tabanlı modellerin hem doğrusal olmayan hem de doğrusal finansal veriler üzerinde eşit derecede iyi performans gösterdiğini ve bu nedenle, karar verme sürecinde daha fazla yenilik getiren finansal işlemlerin ve kripto para birimlerinin fiyatının etkisini iyileştirme potansiyeline sahip olduğunu vurgulamışlardır.

Sung ve diğ. (2022), çok değişkenli zaman serisi modeli kullanarak 11 farklı kripto para birimi için günlük getiri fiyat tahmini üzerine bir araştırma yapmışlardır. Bu çalışmada, başlıca kripto para birimlerinin günlük getiri fiyatını tahmin etmek için çeşitli kripto para birimi verileri özellik olarak kullanılmıştır. Bu çalışmanın orijinal katkısı, otoregresif koşullu heteroskedastisite (ARCH) ve genelleştirilmiş otoregresif koşullu heteroskedastisite (GARCH) modellerinden türetilen kripto para biriminin oynaklık

özelliklerini kullanarak her kripto para birimi için en etkili ana özelliklerin seçilmesidir. Ek olarak, çeşitli zaman serisi modellerini uygulayarak kripto para birimlerinin günlük getiri fiyatını tahmin edilmeye çalışılmıştır. Seçilen ana özelliklere dayanarak, kripto para biriminin günlük getiri fiyatı, ARIMA zaman serisi tahmin modeli ve yapay sinir ağı tabanlı zaman serisi tahmin modeli aracılığıyla tahmin edilmiştir. Dahası, geleneksel modellerin performansları, sinir ağı tabanlı zaman serisi tahmin modellerinin performanslarıyla karşılaştırılmış ve geleneksel zaman serisi tahmin modellerine kıyasla sinir ağı tabanlı zaman serisi tahmin modellerinin daha başarılı bir tahmin yeteneğine sahip olduğu bildirilmiştir.

3.2. Geleneksel Makine Öğrenmesi Yöntemleri ile Yapılan Çalışmalar

Atsalakis ve diğ. (2019) çalışmalarında, iki Adaptif Nöro-Bulanık Çıkarım Sistemi (ANFIS) alt sistemi içeren, özellikle PATSOS adlı hibrit bir nöro-bulanık denetleyici sistemi kullanıldığı belirtilmektedir. Modelin tahmin yetenekleri, tek bir ANFIS ile geliştirilmiş olan daha basit bir model, yapay sinir ağları (ANN) kullanılarak geliştirilmiş olan bir başka model ve basit bir al-ve-tut yaklaşımı olan modellerle karşılaştırılmıştır. Bulgular, PATSOS nöro-bulanık modelinin, potansiyel bir yatırımcı için hem ANFIS hem de ANN modellerine göre daha yüksek getiri sağladığını göstererek üstün olduğunu ortaya koymaktadır. Ethereum, Litecoin ve Ripple gibi alternatif üç kripto para biriminin 2011 ile 2017 seneleri arasındaki günlük verileri üzerinde doğrulanmıştır.

Rathan ve diğ. (2019), karar ağacı ve regresyon tekniklerini kullanarak kripto para birimi fiyat tahminine odaklanmışlardır. Bitcoin için açılış, kapanış, en yüksek, en düşük fiyatları, hacim gibi değerler veri kümesinin özelliklerini oluşturmuştur. Sonrasında, karar ağacı ve doğrusal regresyon modelleriyle Bitcoin fiyatı tahminlenmiştir. Deney sonuçları, karar ağaçları ile %95,88 doğruluk değeri elde edilirken regresyon modelinin %97,59 doğruluk değeri ile en iyi tahmin modeli olduğu belirtilmiştir.

Hitam ve diğ. (2019), 6 farklı kripto para tahmini için Parçacık Sürü Optimizasyonuna (PSO) dayalı optimize edilmiş destek vektör makinesi (SVM) modelini tanıtmışlardır. Bitcoin için SVM algoritması %78,90 doğruluk sağlarken SVM-PSO ile %90,4 doğruluk skoru elde edilmiştir. Ethereum için SVM algoritması %95,50 doğruluk sağlarken SVM-PSO ile %97 doğruluk elde edilmiştir. Litecoin için SVM algoritması %82,40 doğruluk

sağlarken SVM-PSO ile %92,1 doğruluk elde edilmiştir. Nem için SVM algoritması %47,70 doğruluk sağlarken SVM-PSO ile %57,8 doğruluk elde edilmiştir. Ripple için SVM algoritması %70 doğruluk sağlarken SVM-PSO ile %82,8 doğruluk elde edilmiştir. Stellar için SVM algoritması %58,70 doğruluk sağlarken SVM-PSO ile %64,5 doğruluk elde edilmiştir. Sonuç olarak, optimize edilmiş bir SVM-PSO algoritmasının, kripto para biriminin gelecekteki fiyatını etkili bir şekilde tahmin edebildiğini ve dolayısıyla orijinal SVM algoritmalarından daha iyi performans gösterdiğini bildirmişlerdir.

Aggarwal ve diğ. (2020), Bitcoin fiyatlarını tahmin etmek için tam ampirik topluluk modu ayrışımı ve destek vektör makinesi tabanlı yaklaşım önermişlerdir. Bu sayede, Bitcoin'in fiyat davranışını tam ampirik topluluk modu ayrıştırmasını (CEEMD – ing: complete empirical ensemble mode decomposition) kullanarak analiz etmeyi ve tahmini için destek vektör makinesi (SVM) algoritmasını makine öğrenmesi tekniği olarak uygulamayı amaçlamışlardır. CEEMD, 2012'den 2018'e kadar günlük Bitcoin fiyatları, Bitcoin fiyat serisindeki kısa vadeli, orta vadeli ve uzun vadeli eğilimi belirlemek için kullanılmıştır. Deney sonuçları, SVM'nin kısa vadeli, orta vadeli, uzun vadeli ve genel Bitcoin fiyat seviyesi için Bitcoin fiyatlarını beş adım önceden tahmin ettiğini göstermiştir.

Mudassir ve diğ. (2020) gerçekleştirdikleri çalışmada, kısa ve orta vadeli Bitcoin fiyat dalgalanmaları ve değerlemelerin tahmininde yüksek performanslı makine öğrenimi tabanlı sınıflandırma ve regresyon modellerinin dikkate değer performans sergilediğini ifade etmişlerdir. Çalışmada bir, yedi, otuz ve doksan günlük aralıklı periyotlar ele alınarak yapay sinir ağı (ANN), yığınlı yapay sinir ağı (SANN), destek vektör makineleri (SVM) ve LSTM modellerini kullanılmıştır. Geliştirilen modeller, önemli ölçüde etkinlik ve yüksek performans seviyeleri sergilemekte olup, sınıflandırma modelleri, bir sonraki gün için tahminlerde %65'e kadar doğruluk sağlamakta ve yedinci ile doksanıncı gün aralığındaki tahminlerde %62 ile %64 doğruluk elde etmektedir. Günlük fiyat tahminleri için hata yüzdesi, dikkate değer derecede düşük olan %1,44'te kalırken, yedi ila doksan gün arasındaki süreler için %2,88 ile %4,10 arasında dalgalanmaktadır.

Poongodi ve diğ. (2020) yaptıkları çalışmada, günlük Ethereum kripto para kapanış fiyatlarından oluşan bir zaman serisi kullanılarak, doğrusal regresyon (LR) ve destek vektör makinesi (SVM) olmak üzere iki farklı makine öğrenimi yöntemi ile fiyat tahminleri gerçekleştirmişlerdir. Çalışmada, Ethereum kripto para fiyat tahminlerinde,

farklı ağırlık katsayılarına sahip filtreler kullanılarak çeşitli periyot uzunlukları uygulanmaktadır. Eğitim aşamasında, veri kümesinden bağımsız yüksek performanslı bir model oluşturmak için çapraz doğrulama tekniği kullanılmaktadır. Önerilen çerçeve, bahsedilen makine öğrenimi yöntemleri kullanılarak uygulanmaktadır. Uygulandığında, SVM yöntemi %85,46, LR tekniği ise %96,06 oranında bir doğruluk sergilemiştir.

Chen ve diğ. (2020) çalışmalarında, makine öğrenimi teknikleri kullanarak Bitcoin fiyatlarını farklı frekanslarda tahmin etmek amacıyla, öncelikle Bitcoin fiyatını günlük fiyat ve yüksek frekanslı fiyat kriterlerine göre sınıflandırmışlardır. Bitcoin'in günlük fiyat tahmini için, emlak endeksi, ticaret ve piyasa endeksleri, altın spot fiyatı gibi yüksek boyutlu özellikler kullanılırken; 5 dakikalık aralıklı fiyat tahmini için bir kripto para borsasından elde edilen temel özelliklere başvurulmaktadır. Yüksek boyutlu özelliklere sahip Bitcoin günlük fiyat tahminlerinde Lojistik Regresyon ve Doğrusal Ayrım Analizi gibi istatistiksel yöntemler, %66'lık doğruluk payı ile karmaşık makine öğrenimi algoritmalarından daha başarılı sonuçlar elde etmektedir. Günlük fiyat tahminleri için kıyaslama sonuçlarıyla karşılaştırıldığında, istatistiksel yöntemler ve makine öğrenimi algoritmalarının sırasıyla %66 ve %65,3'lük en yüksek doğruluk değerleri ile daha etkili bir performans sergilediği görülmüştür. Random Forest, XGBoost, Quadratic Discriminant Analysis, Support Vector Machine gibi Bitcoin'in 5 dakikalık aralıklı fiyat tahminlerinde makine öğrenimi modelleri, %67,2'lik doğruluk oranıyla istatistiksel yöntemlere kıyasla üstün sonuçlar sunduğu ifade edilmiştir.

Akyildirim ve diğ. (2021) yaptıkları çalışmalarında, en hacimli on iki kripto paranın günlük ve dakikalık düzeydeki tahmini için, destek vektör makineleri, lojistik regresyon, yapay sinir ağları ve rastgele ormanlar gibi makine öğrenimi sınıflandırma algoritmaları kullanarak, geçmiş fiyat bilgileri ve teknik göstergeler model özellikleri olarak ele alınarak incelemişlerdir. Veri seti 2013-2018 yıllarını içermektedir. Dört algoritmanın ortalama sınıflandırma doğruluğu, tüm kripto paralar ve incelenen tüm zaman ölçekleri için tutarlı bir şekilde %50 eşiğinin üzerinde seyretmekte olup, bu durum kripto para piyasalarında fiyat eğilimlerinde belirli bir ölçüde öngörülebilirliği olduğunu göstermektedir. Makine öğrenimi sınıflandırma algoritmaları, günlük veya dakikalık düzeydeki frekanslarda ortalama olarak yaklaşık %55-65 tahmin doğruluğuna ulaşırken, destek vektör makineleri, lojistik regresyon, yapay sinir ağları ve rastgele orman

sınıflandırma algoritmalarına kıyasla tahmin doğruluğu açısından en iyi ve tutarlı sonuçları sergilediği belirtilmiştir.

Haryadi ve diğ. (2022), Polkadot kripto para biriminin fiyat tahmini için destek vektörü regresyonunu uygulamışlardır. Destek Vektörü Regresyon algoritmasını kullanan Polkadot kripto para birimi fiyat tahmini analizi, Polkadot günlük kapanış fiyatı verileri de dahil olmak üzere iyi bir tahmin doğruluğu değerine sahiptir. Bu çalışmada, destek vektör makinesi algoritmasının farklı çekirdek modellerinde ve maliyet parametrelerine göre performansı da değerlendirilmiştir. En başarılı deney sonuçları, çekirdek fonksiyonu olarak radyal temel fonksiyonu ve maliyet parametreleri sırasıyla c ve gamma için sırasıyla 1000 ve 0,001 olarak ayarlandığında %90 doğruluk değeri ve 5,28 MAPE değeri olarak gözlenmiştir.

3.3. Derin Öğrenme Yöntemleriyle Yapılan Çalışmalar

Wu ve diğ. (2018), iki farklı uzun kısa dönem bellek (LSTM) modeli (geleneksel LSTM modeli ve AR(2) modeli ile LSTM) ile Bitcoin günlük fiyatını tahmin etmek için yeni bir fiyat tahmin modeli önermişlerdir. Önerilen modellerin performansı, toplam 208 kayıtta 01.01.2018 ile 28.07.2018 arasındaki günlük Bitcoin fiyat verileri kullanılarak değerlendirilmiştir. Deney sonuçları, önerilen AR(2) temelli LSTM modelinin geleneksel LSTM modelinden daha iyi performansa sahip olduğunu göstermiştir. Bu çalışmayla, LSTM'de girdi değişkenleri seçimi sorununun üstesinden gelebilecek ve iyileştirebilecek, Bitcoin fiyat tahmini için yeni bir tahmin çerçevesi sağlandığı vurgulanmıştır. Yazarlar, önerilen modelin çeşitli kripto para tahminlerinde, tıbbi veriler veya finansal zaman serisi verileri gibi endüstri örneklerinde olası uygulanabilirliğini ortaya koyduğunu bildirmişlerdir.

Ji ve diğ. (2019), çeşitli derin öğrenme tekniklerini kullanarak Bitcoin fiyat tahmini üzerine kapsamlı bir deneysel çalışma sunmuşlardır. Bu amaçla, derin sinir ağı (DNN), uzun kısa dönem bellek (LSTM) modeli, evrişimli sinir ağı, derin artık ağ gibi çeşitli derin öğrenme yöntemleri, bu modellerin kombinasyonları modellenmiş ve performansları karşılaştırılmıştır. Deneysel sonuçların, LSTM tabanlı tahmin modellerinin Bitcoin fiyat tahmini (gerileme) için diğer tahmin modellerinden biraz daha iyi performans göstermesine rağmen, DNN tabanlı modellerin fiyat artışları ve düşüşleri tahmini

(sınıflandırma) için en iyi performansı gösterdiğini vurgulamışlardır. Ayrıca, basit bir karlılık analizi, algoritmik ticaret için sınıflandırma modellerinin regresyon modellerinden daha etkili olduğunu göstermişlerdir.

Rizwan ve diğ. (2019), Bitcoin fiyat tahmini için RNN, LSTM ve GRU modellerinin performanslarını değerlendirmişlerdir. Kullanılan modellerin performanslarını değerlendirmek amacıyla 19 Ağustos 2013 ve 19 Temmuz 2016 yılları arasında Bitcoin fiyat değerlerini veri kümesi olarak kullanmışlardır. Deney sonuçları %94,7 doğruluk değeri ile GRU modelinin Bitcoin fiyatını tahminlemede en iyi performans sergileyen model olduğunu göstermiştir. GRU modelini, %92,30 ile LSTM ve %85,40 ile RNN modeli takip etmiştir.

Aggarwal ve diğ. (2019), sosyoekonomik faktörlerin Bitcoin fiyat tahmini üzerindeki etkisini belirlemeye yönelik bir derin öğrenme yaklaşımı sunmuşlardır. Yazarlar, Bitcoin fiyat tahminini etkileyen çeşitli parametreler üzerinde çeşitli derin öğrenme modellerinin RMSE değerleri temelinde karşılaştırmalı bir analizini de yapmışlardır. Sonuçlar, çeşitli derin öğrenme modellerinin Bitcoin fiyatının tahmini için açıkça etkili olduğunu göstermiştir. LSTM, fiyat tahmini için Bitcoin parametreleri dikkate alındığında en düşük RMSE değerini vermiştir. Öte yandan, Bitcoin fiyat tahmini için altın fiyatı parametre olarak kullanıldığında, LSTM altın fiyatı ile Bitcoin fiyatı arasında pozitif bir ilişki göstermemiştir. Ayrıca, Twitter aracılığıyla duygu analizi yapılarak Bitcoin fiyat tahmininin sonuçlarının pozitif bir korelasyon gösterdiği vurgulanmıştır.

Dutta ve diğ. (2020), günlük Bitcoin fiyatlarını tahmin etmek için sabit bir dizi dışsal ve içsel faktör içeren derin öğrenme tabanlı bir çerçeve önermişlerdir. Kök ortalama karesel hatasını (RMSE) değerlendirme metriği olarak kullanarak farklı yaklaşımların performansları karşılaştırılmıştır. Deneysel sonuçların, kapılı yinelenen birim (GRU) modelinin 0,016 RMSE değeriyle 15 günlük fiyat tahmininde mevcut popüler modellerden daha iyi performans gösterdiğini vurgulamışlardır. Ayrıca, önerilen GRU modeliyle basit ticaret stratejilerinin finansal kazanç sağlayabileceğini de belirtmişlerdir.

Patel ve diğ. (2020), finansal kurumlar için derin öğrenme tabanlı kripto para birimi fiyat tahmin planı sunmuşlardır. Bu çalışmada, Litecoin ve Monero kripto para birimlerine odaklanan, LSTM ve GRU tabanlı hibrit bir kripto para birimi tahmin şeması önerilmiştir.

Sonuçlar, önerilen şemanın, fiyatları yüksek doğrulukla tahmin ettiğini ve şemanın çeşitli kripto para fiyat tahminlerinde uygulanabileceğini ortaya koymuştur.

Lamothe-Fernandez ve diğ. (2020), Bitcoin fiyatını tahmin etmek için derin öğrenme metotlarının bir karşılaştırmasını sunmuşlardır. 2011 ve 2019 yılları arasında toplanan Bitcoin verileri, derin tekrarlayan evrişimli sinir ağı (DRCNN), derin sinir karar ağaçları (DNDT) ve derin destek vektör makineleri (DSVR) yöntemleriyle Bitcoin fiyat tahmininde yüksek doğruluk değeri elde etmek için karşılaştırılmıştır. Karşılaştırılan modeller arasında, DRCNN modelinin yaklaşık %96 doğruluk değeri ile en başarılı model olduğu bildirilmiştir. DRCNN modelini, %95 doğruluk değeri ile DNDT, %93 doğruluk değeri ile DSVR modellerinin takip ettiği belirtilmiştir.

Tanwar ve diğ. (2021), Litecoin ve Zcash'in fiyatını ana kripto paranın karşılıklı bağımlılığı ile tahmin etmek için derin öğrenmeye dayalı GRU ve LSTM modellerinin hibrit bir versiyonunu çerçeve olarak önermişlerdir. Önerilen modelin Litecoin için 1 günlük ve 3 günlük MSE değerleri sırasıyla 0,02038 ve 0,02103 olurken Zcash için sırasıyla 0,00461 ve 0,00483 olarak bildirilmiştir. 7 gün ve 30 gün tahminleri için önerilen model, Litecoin için doğru fiyatları tahmin edebilme yeteneğine sahipken Zcash için stokastik bir yapıya sahip olduğunu vurgulamışlardır.

Hamayel ve Owda (2021), GRU, LSTM ve Bi-LSTM derin öğrenme algoritmalarını kullanarak Bitcoin (BTC), Litecoin (LTC) ve Ethereum (ETH) olmak üzere üç tür kripto para biriminin fiyatlarını tahmin eden bir model önermişlerdir. Modellerin performansını değerlendirmek amacıyla ortalama mutlak yüzde hatası (MAPE), değerlendirme metriği olarak kullanılmıştır. Bu modellerden elde edilen sonuçlar, kapılı tekrarlayan birimin (GRU), uzun kısa dönem bellek (LSTM) ve çift yönlü LSTM (bi-LSTM) modellerinden tüm kripto para türleri için tahminde daha iyi performansa sahip olduğunu göstermiştir. GRU, BTC, ETH ve LTC için sırasıyla %0,2454, %0,8267 ve %0,2116 MAPE yüzdeleriyle LTC için en doğru tahmini sunmuştur. MAPE yüzdeleri BTC, ETH ve LTC için sırasıyla %5,990, %6,85 ve %2,332 olduğundan, bi-LSTM algoritması diğer iki algoritmaya kıyasla en düşük tahmin sonucunu sunmuştur.

Kim ve diğ. (2022), baskın bir kripto para birimi olan Bitcoin'in fiyatını tahmin eden derin öğrenme tabanlı yeni bir çerçeve önermişlerdir. Görünmeyen fiyat aralığında istikrarlı

tahmin performansı için değişim noktası tespit tekniği kullanılmıştır. Ek olarak, kripto para birimlerinin doğasında bulunan blok zincirinde listelenen benzersiz kayıtlar olan zincir üstü veriler toplanmış ve fiyatları tahmin etmek için girdi değişkenleri olarak kullanılmıştır. Bu çalışmada, zincir üstü değişken grupları için çoklu LSTM modüllerinden ve tahmin modeli için dikkat mekanizmasından oluşan öz-dikkat temelli çoklu uzun kısa dönem belleği (SAM-LSTM) önerilmiştir. Gerçek dünya BTC fiyat verileri ve çeşitli yöntem kurulumları ile yapılan deneyler, önerilen çerçevenin BTC fiyat tahminindeki etkinliğini kanıtlamıştır. Sırasıyla 0,3462, 0,5035, 0,2536 ve 1,3251 olan en yüksek MAE, RMSE, MSE ve MAPE değerleri ile sonuçlar elde edildiği bildirilmiştir.

Zhang ve diğ. (2022), derin öğrenme entegrasyon yöntemine (SDAE-B) dayalı Bitcoin fiyat tahmininin deneysel analizini sunmuşlardır. Bu yöntemle iki yaklaşım birleştirilmiştir. Biri, istifleme gürültü giderici otomatik kodlayıcılar (SDAE) olarak adlandırılan gelişmiş bir derin sinir ağı modelidir. SDAE yöntemi, Bitcoin fiyatı ile onu etkileyen faktörler arasındaki doğrusal olmayan karmaşık ilişkiyi simüle etmek için kullanılmıştır. Diğeri, bir dizi temel modeli (SDAES) eğitmek için birden çok veri kümesi oluşturan, önyükleme toplaması (Bagging) adı verilen güçlü bir tümleştirme yöntemidir. Deneylerde, Bitcoin'in fiyat dizisi karşılaştırılmış ve blok boyutunu, hash oranını, madencilik zorluğunu, işlem sayısını, piyasa değerini, Baidu ve Google arama hacmini, altın fiyatını, dolar endeksini ve ilgili önemli olaylar değişken olarak belirlenmiştir. Önerilen modelin etkinliğini göstermek amacıyla SDAE-B yöntemi, LSSVM ve BP modelleri kıyaslanmıştır. SDAE-B modeli ile 0,016 MAPE skoru, 131,643 RMSE değeri elde edilmiştir. Diğer iki yöntemle karşılaştırıldığında, daha yüksek doğruluk ve daha düşük hataya sahip olduğu vurgulanmıştır.

Ammer ve Aldhyani (2022), kripto para birimi dalgalanma fiyatlarını tahmin etmek için derin öğrenme tabanlı bir çerçeve önermişlerdir. Bu çalışmada, AMP, Ethereum, Elektro-Optik Sistem ve XRP olmak üzere dört farklı kripto para biriminin değerlerini tahmin eden uzun kısa dönem bellek (LSTM) algoritması kullanılmıştır. LSTM modelinin performansını değerlendirmek için MSE, RMSE ve normalize kök ortalama karesel hata (NRMSE) metrikleri kullanılmıştır. Deney sonuçları, LSTM algoritmasının tüm kripto para birimlerinin fiyatlarını tahmin etmede üstün performansa sahip olduğunu göstermiştir. Model, 180 günlük bir süre boyunca kripto para birimlerinin gelecekteki

kapanış fiyatlarını tahmin etmek için uygulanmıştır. Eğitim ve test süreçlerinde tahmin ve hedef değerler arasındaki korelasyonu değerlendirmek için Pearson korelasyon metriği uygulanmıştır. LSTM algoritmasının, XRP fiyatlarını tahmin etmede eğitimde (R = %96,73) ve testte (%96,09) en yüksek korelasyon değerlerine ulaştığı bildirilmiştir.

Seabe ve diğ. (2023), LSTM, GRU ve çift yönlü LSTM kullanarak Bitcoin (BTC), Ethereum (ETH) ve Litecoin (LTC) kripto para birimlerinin fiyatlarını tahmin etmek için derin bir öğrenme yaklaşımına odaklanmışlardır. RMSE ve MAPE değerlendirme metrikleri kullanılarak bu üç modelin performansları değerlendirilmiştir. Bi-LSTM, BTC, LTC ve ETH için sırasıyla 0,036, 0,041 ve 0,124 MAPE değerleri ile GRU ve LSTM'ye kıyasla en doğru tahminlerin elde edildiği bildirilmiştir.

Zhong ve diğ. (2023), bireysel kripto para birimi özelliklerinin ve kripto para birimi ilişkilerinin dikkate alındığı, uzun kısa dönem bellek (LSTM) ve ilişkisel grafik dikkat ağı (ReGAT) kullanarak fiyat eğilimi tahmini için yeni bir uçtan uca model önermişlerdir. Özellikle, kripto para birimleri arasında paylaşılan özellikler kullanılarak bir kripto para birimi ağı oluşturulmuştur. Ayrıca LSTM, bireysel kripto para birimi özelliklerinin sıralı modellerini modellemek için kullanılmıştır. Ağ özelliklerini tam olarak ayıklamak için ReGAT, farklı ilişki türleri tarafından iletilen bilgileri bir araya getirirken bunların önemini otomatik olarak ayırt etmek için tasarlanmıştır. Son olarak, fiyat eğilimini tahmin etmek için geleneksel özellikler ve ağ özellikleri birleştirilmiştir. LSTM-ReGAT'ın etkinliği, gerçek dünya kripto para piyasası verileri kullanılarak doğrulanmıştır.

4. YÖNTEMLER

Bu bölümde, tez çalışması kapsamında kullanılan evrişimli sinir ağları (CNN), uzun kısa dönem bellek ağları (LSTM), hibrit CNN-LSTM ve hibrit ConvLSTM modelleri tanıtılmaktadır.

4.1. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (CNN), özellikle görüntüler veya videolar gibi ızgara benzeri topolojisi olan verileri işlemek için uygun olan bir sinir ağı türüdür. İlk kez 1980'lerde tanıtılmış olsalar da, 2010'lu yılların başlarında çeşitli bilgisayarlı görü işleme görevlerindeki başarıları nedeniyle geniş popülerlik kazandılar (Kiranyaz ve diğ., 2021).

CNN'lerin temel fikri, girdi verilerinden yararlı özellikler çıkarabilen bir dizi filtreyi öğrenmektir. Bu filtreler, genellikle küçüktür ve girdi verilerine kaydırılan bir pencere tarzında uygulanır. Her filtre çıktısı, girdinin belirli bir özelliğine karşılık gelir. Çok katmanlı filtreler, her katmanın giderek daha karmaşık ve soyut özellikler öğrenmesiyle birbirine eklenir. CNN'ler genellikle, ağı hesaplama açısından daha verimli hale getirmek ve özellik haritalarının uzamsal boyutunu azaltmak için havuzlama katmanları kullanır. Yaygın havuzlama işlemleri arasında, her bir yerel bölgenin maksimum değerini alan maksimum havuzlama ve ortalama değeri alan ortalama havuzlama bulunur. CNN'ler, geriye yayılım kullanarak eğitilir. Bu, ağın parametreleri ile kayıp fonksiyonunun gradyanlarını hesaplayıp parametreleri gradyan inişi veya onun bir türevi ile güncelleyerek yapılır. Aşırı uydurmayı önlemek için bırakma (dropout) ve ağırlık azaltma gibi çeşitli düzenleme teknikleri kullanılabilir (Alzubaidi ve diğ., 2021).

CNN'ler görüntü sınıflandırma, nesne tanıma, piksel bazlı görüntü etiketleme, yüz tanıma, video analizi ve doğal dil işleme gibi birçok bilgisayar görüşü görevinde başarılı bir şekilde kullanılmıştır. He ve arkadaşları (2016), görüntü sınıflandırmada ImageNet gibi literatürde yaygın kullanılan veri setlerinde en iyi performansı CNN'ler ile elde etmişlerdir. Bu veri setleri için hata oranları %5'ten az olduğu belirtilmiştir. Ayrıca, tümör tespiti gibi tıbbi görüntü analizi görevlerinde de kullanılmıştır (Behrmann ve diğ., 2018). CNN'ler, nesnelerin görüntü içindeki konumunu belirlemek için nesne tanıma görevlerinde kullanılmıştır. YOLO ve Faster R-CNN gibi popüler nesne tanıma

çerçeveleri, CNN'ler üzerine kuruludur (Redmon ve diğ., 2016; Ren ve diğ., 2015). CNN'ler, her pikselin belirli bir kategoriye sınıflandırıldığı piksel bazlı görüntü etiketleme görevleri için de kullanılmıştır. Otonom sürüş gibi uygulamalarda CNN'ler, araçlar ve yaya gibi nesneleri tanımlamak ve takip etmek için kullanılır (Cordts ve diğ., 2016). CNN'ler, yüz tanıma görevlerinde kullanılmış ve LFW ve MegaFace gibi literatürde yaygın kullanılan veri setlerinde yüksek doğruluk elde edilmiştir (Schroff ve diğ., 2015; Kemelmacher-Shlizerman ve diğ.,2016). CNN'ler, eylem tanıma gibi çeşitli video analizi görevlerinde videolarda gerçekleştirilen eylemleri sınıflandırmak için kullanılır (Simonyan ve Zisserman, 2014). Ayrıca, CNN'lerin kullanımı, metin sınıflandırma ve duygu analizi gibi doğal dil işleme görevlerinde de popülerlik kazanmıştır (Kim, 2014).

4.2. Uzun Kısa Dönem Bellek Ağları

Uzun kısa dönem bellek ağları (LSTM) ağları, geleneksel tekrarlı sinir ağlarının (RNN) geliştirilmiş bir versiyonu olarak 1997'de Hochreiter ve Schmidhuber tarafından tanıtılmış bir sinir ağı türüdür (Hochreiter ve Schmidhuber, 1997). LSTM'ler, RNN'lerdeki kaybolan gradyan problemini çözmek için tasarlanmıştır. RNN'ler geçmiş zaman adımlarında gittikçe küçülen gradyanlar nedeniyle uzun vadeli bağımlılıkları etkili bir şekilde öğrenmekte zorlanabilmektedir. Ancak LSTM'ler, bu sorunu aşmak için hücre durumu ve kapı mekanizmalarını kullanmaktadır. LSTM'ler, zaman içinde bilgi depolayabilen bir bellek hücresi ve hücreye giren ve çıkan bilginin akışını kontrol eden bir dizi kapı mekanizması kullanarak çalışır. Bellek hücresi, girdi, önceki hücre durumu ve önceki zaman adımının çıktısına dayanarak güncellenir. Kapı mekanizmaları üç kapıdan oluşur: giriş kapısı, çıkış kapısı ve unutma kapısı. Giriş kapısı hangi bilginin hücreye ekleneceğini kontrol eder, unutma kapısı hangi bilginin hücreden kaldırılacağını kontrol eder ve çıkış kapısı hangi bilginin hücrenin çıktısını oluşturmak için kullanılacağını kontrol eder. Giriş kapısı, unutma kapısı ve çıkış kapısı, önceki çıktı ve mevcut girdi gibi girdileri alan ve genellikle sigmoid fonksiyonlardır. Fonksiyon seçimi problemin yapısına ve modelin özelliklerine göre farklılık gösterebilir. Sigmoid fonksiyonlar 0 ile 1 arasında değerler almaktadır. Bu değerler, daha sonra aday değerleriyle çarpılır, aday değerleri hiperbolik tanjant fonksiyonu kullanılarak -1 ile 1 arasında olacak şekilde oluşturulur. Kapılardan gelen çıktılar ve aday değerleri daha sonra

yeni hücre durumunu oluşturmak için birleştirilir ve bir sonraki zaman adımına iletilir (Hochreiter ve Schmidhuber, 1997).

LSTM'ler doğal dil işleme, konuşma tanıma ve görüntü açıklama gibi geniş bir uygulama yelpazesinde kullanılmaktadır. LSTM ağları metin sınıflandırma, duygu analizi, makine çevirisi ve dil modelleme gibi dil görevlerinde yaygın olarak kullanılmaktadır. Örneğin, LSTM ağları spam algılama (Liu ve diğ., 2022) ve haber kategorizasyonu (Cavnar ve Trenkle, 1994) gibi metin sınıflandırma görevleri için kullanılmıştır. Ayrıca, İngilizce-Fransızca çeviri (Sutskever ve diğ., 2014) ve İngilizce-Japonca çeviri (Sutskever ve diğ., 2014) gibi makine çevirisi görevleri için de kullanılmışlardır. LSTM ağları fonem tanıma ve akustik modelleme doğruluğunu artırmak için konuşma tanıma sistemlerinde kullanılmaktadır (Graves ve diğ., 2013). LSTM ağları, eylem tanıma, video alt yazıları ve görsel soru cevaplama gibi görüntü ve video analizi görevlerinde kullanılmıştır. Örneğin, LSTM ağları insan etkinliklerinin videolarında eylem tanıma için uygulanmıştır (Donahue ve diğ., 2015). Ayrıca, verilen bir video için doğal dil açıklaması oluşturulduğu video alt yazıları görevleri için de kullanılmışlardır (Venugopalan ve diğ., 2015). LSTM ağları elektroensefalogram (EEG) analizi, epileptik nöbetlerin tahmini (Li ve diğ., 2019) ve kalp hastalığı teşhisi (Attia ve diğ., 2019) gibi tıbbi uygulamalarda kullanılmıştır.

4.3. Hibrit CNN-LSTM

Evrişimli sinir ağları (CNN'ler) ve uzun kısa dönem bellek ağları (LSTM'ler), sırasıyla görüntü ve ardışık veri işleme için derin öğrenme araştırmalarında yaygın olarak kullanılmaktadır. Ancak, CNN'ler uzun süreli zaman bağımlılıklarını yakalama konusunda, LSTM'ler ise mekansal bağımlılıkları yakalamada sınırlı yeteneğe sahiptir. Bu sınırlamaların üstesinden gelebilmek için hibrit CNN-LSTM ağları, her iki mimarinin güçlü yönlerini birleştirmek amacıyla önerilmiştir. Hibrit CNN-LSTM ağları üzerine erken çalışmalardan biri, Donahue ve diğ. (2015) tarafından video sınıflandırma görevleri için önerilmiştir.

Hibrit CNN-LSTM ağları, CNN'ler ve LSTM'ler gibi hem mekansal hem de zamansal bağımlılıkları olan ardışık verileri etkili bir şekilde işlemek ve analiz etmek için bir araya getirir. Hibrit CNN-LSTM ağları, özellik çıkarma için bir CNN bileşeni ve zamanla ilgili modelleme için bir LSTM bileşeni olmak üzere iki temel bileşenden oluşur. CNN

bileşeni, girdi verilerini (görüntüler veya özellik vektörlerinin sıraları) işler ve anlamlı mekansal özellikleri çıkarmak için kullanılır. CNN bileşeninin çıktısı, daha sonra LSTM bileşenine beslenir, bu bileşen ardışık işleme ile uzun vadeli bağımlılıkları yakalamak için kullanılır. LSTM bileşeni, bellek hücreleri kullanarak zaman içinde bilgiyi seçici olarak saklama ve unutma yeteneğine sahiptir, bu da ağın karmaşık zamansal desenleri öğrenmesine olanak tanır.

Hibrit CNN-LSTM ağları, görüntü ve video analizi, doğal dil işleme ve konuşma tanıma gibi çeşitli alanlarda başarılı bir şekilde uygulanmıştır. Donahue ve diğ. (2015), Venugopalan ve diğ., (2015) hibrit CNN-LSTM ağlarını video sınıflandırması, eylem tanıma ve video yazısı görevleri için kullanmışlardır. Kim ve diğ. (2016), CNN-LSTM ağlarını duygu analizi, dil modellemesi ve makine çevirisi görevleri için kullanmışlardır. Zhang ve diğ. (2017) ise CNN-LSTM ağlarını konuşmadan metne dönüştürme gibi konuşma tanıma görevleri için kullanmışlardır.

4.4. Hibrit Conv-LSTM

Hibrit Conv-LSTM mimarisi, ilk olarak 2015 yılında Shi ve arkadaşları tarafından yağış tahmini için önerilmiştir. Sonrasında, Conv-LSTM ağları video analizinde video sınıflandırması, hareket tanıma, video tahmini görevlerinde (Wang ve diğ., 2015), sahne metni tanımada (Wang ve diğ., 2020), hava tahmini, yağış tahmini (Souto ve diğ., 2018) gibi çeşitli uygulama alanlarında da kullanılmıştır. Hibrit ConvLSTM ağları, evrişimli sinir ağları (CNN) ve uzun kısa dönem bellek (LSTM) ağlarının güçlü yanlarını birleştirir. Bu ağlarda, evrişimli katmanlar girdi verisinden uzaysal özellikleri çıkarırken, LSTM katmanları bu özellikler arasındaki zamansal bağımlılıkları yakalar. Bu kombinasyon video analizi, eylem tanıma ve hava tahmini gibi uzay-zamansal verilerle ilgili görevler için Conv-LSTM ağlarının özellikle etkili olmasını sağlar.

Conv-LSTM ağı evrişimli katmanları takiben LSTM katmanlarından oluşur. Evrişimli katmanlar kenarlar, köşeler ve dokular gibi girdi verisinden uzaysal özellikleri çıkarır. LSTM katmanları ise bu özellikler arasındaki zamansal bağımlılıkları yakalayarak, ağın girdinin zaman içindeki evrimini modellemesini sağlar. LSTM katmanlarının çıktısı, son sınıflandırma veya regresyon için tam bağlantılı katmanlara beslenebilmektedir. CNN-LSTM ve Conv-LSTM ağları, her ikisi de uzun kısa dönem bellek (LSTM) ağları ile

evrişimli sinir ağlarını (CNN'ler) birleştirerek veri dizilerindeki mekansal ve zamansal bilgiyi yakalamak için kullanılır. İki yöntem arasındaki temel fark, CNN ve LSTM katmanlarının nasıl entegre edildiğidir.

CNN-LSTM ağı, CNN katmanı girdi dizisinden mekansal özellikleri çıkarır ve ardından LSTM katmanına verileri geçirerek zamansal bağımlılıkları yakalar. LSTM katmanı, CNN katmanından bir özellik haritası dizisi alır ve her zaman adımında bellek hücresini ve gizli durumu günceller. Bu yaklaşım, görüntü ve video analizi, doğal dil işleme ve konuşma tanıma gibi birçok uygulamada başarılı olmuştur. Conv-LSTM ağı ise konvolüsyon işlemini LSTM katmanına entegre eder ve ağın mekansal ve zamansal bağımlılıkları aynı anda yakalamasına olanak tanır. Başka bir deyişle, Conv-LSTM katmanı her zaman adımında girdi ve gizli durumun üzerinde konvolüsyon işlemi gerçekleştirerek mekansal ve zamansal bağımlılıkları aynı anda işler. Bu yaklaşım yağış tahmini vehareket tanıma gibi çeşitli uygulamalarda önemli iyileştirmeler göstermiştir.

Özetle, CNN-LSTM ve Conv-LSTM ağları, her ikisi de CNN'leri ve LSTM'leri mekansal ve zamansal bilgiyi yakalamak için birleştirirken, Conv-LSTM ağı konvolüsyon işlemini LSTM katmanına entegre ederek mekansal ve zamansal bağımlılıkların aynı anda işlenmesine olanak tanır.

5. ÖNERİLEN ÇERÇEVE

Bu bölümde, çalışmada kullanılan veri kümeleri ve önerilen model mimarileri detaylı olarak sunulmaktadır.

5.1. Veri Kümelerinin Toplanması

Veri kümesi, günümüzde en büyük işlem hacmine sahip kripto para borsası olan Binance.com tarafından sağlanan uygulama programlama arabirimi (API) kullanılarak Bitcoin, Monera ve Stellar kripto birimlerine ait veriler toplanmıştır. Her altmış dakikada, API sunucusuna bir istek gönderilerek Mart 2021 ile Mayıs 2021 tarihleri arasında veri kümelerini oluşturan anlık fiyat, fiyat değişimi, fiyat değişim yüzdesi, ağırlıklı ortalama fiyat, önceki kapanış fiyatı, son fiyat, alış fiyatı, satış fiyatı, açılış fiyatı, en yüksek fiyat, en düşük fiyat, anlık pazar hacmi, yapılan işlem sayısı gibi bilgiler toplanmaktadır. Veri kümelerindeki özellikler ve açıklamaları Tablo 5.1.'de verilmiştir.

Tablo 5.1. Veri kümesi özellik açıklaması (Kilimci ve diğ., 2021).

Özellik	Açıklama
priceChange	Açılış ve kapanış zaman aralığındaki fiyat değişimi
priceChangePercent	Açılış ve kapanış zaman aralığındaki fiyat değişim yüzdesi
weightedAvgPrice	Açılış ve kapanış zaman aralığındaki ağırlıklı ortalama fiyat
prevClosePrice	Önceki zaman aralığında kapanış fiyatı
LastPrice	USDT cinsinden anlık fiyat bilgisi
BidPrice	USDT cinsinden en yüksek alış fiyatı
AskPrice	USDT cinsinden en düşük satış fiyatı
openPrice	Açılış fiyatı
highPrice	Açılış ve kapanış zaman aralığındaki en yüksek fiyat
lowPrice	Açılış ve kapanış zaman aralığındaki en düşük fiyat
quoteVolume	USDT cinsinden anlık hacim
Count	Toplam işlem adeti

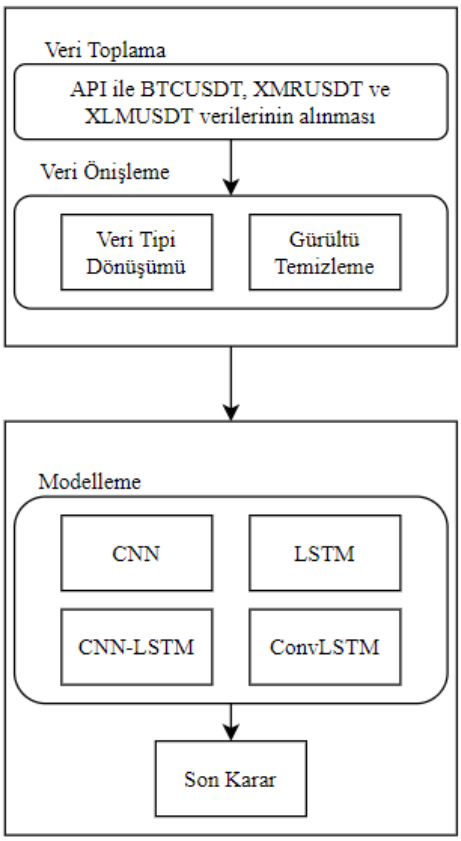
API kullanılarak elde edilen veriler açık erişimli TA-Lib python kütüphanesi kullanılarak, bir saatlik basit hareketli ortalama (SMA), üç saatlik basit hareketli ortalama, beş saatlik basit hareketli ortalama, Bollinger bandı (BB) üst değeri, Bollinger bandı alt değeri, Bollinger bandı orta değeri gibi veriler, momentum göstergesi olarak, göreceli güç indeksi (RSI) hesaplanmış, veri kümelerine eklenmiştir. Böylece, özellik uzayı teknik

göstergelerle zenginleştirilmiştir. Sonuç olarak, her bir veri kümesi 1669 örnek ve 19 adet özellikten oluşmaktadır.

Veri kümelerindeki ham verilerde önişleme yapılmıştır. Öncelikle, tarih ve zaman bilgisi kodlamada kullanılabilir bir veri tipine dönüştürülmüştür. Bu sayede her bir satır, ilgili zaman aralığını temsil etmektedir. Bu işlem sonrası, veri kümelerindeki veri kaynağından gelen gürültülü veriler, deneyler sırasında performansa etki etmemesi için bulunduğu özellik uzayının ortalama değerleri ile değiştirilmiştir.

5.2. Önerilen Model

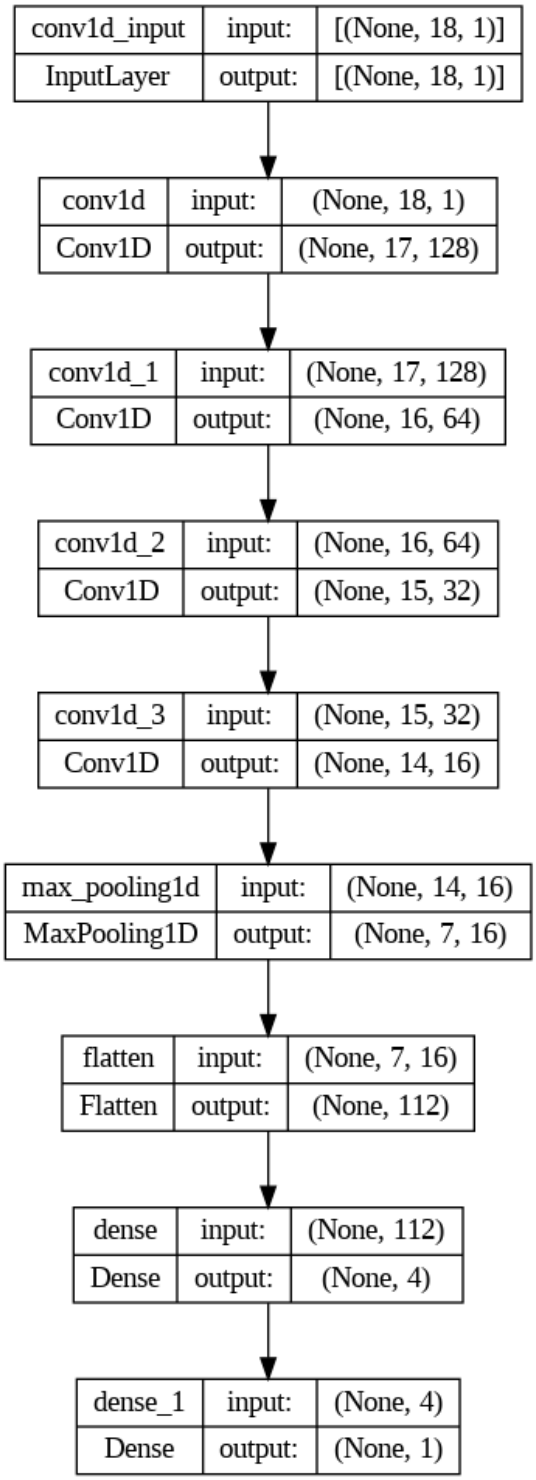
Veri kümeleri oluşturulduktan sonra, evrişimli sinir ağları (CNN), uzun kısa dönem bellek ağları (LSTM) derin öğrenme teknikleri olarak değerlendirilirken evrişimli uzun kısa dönem bellek ağı (ConvLSTM), CNN uzun kısa dönem bellek ağı (CNN-LSTM) hibrit derin öğrenme modelleri olarak kısa vadeli fiyat tahmin etmek amacıyla kullanılmıştır. Önerilen modelin çerçevesi Şekil 5.1'de gösterilmektedir.



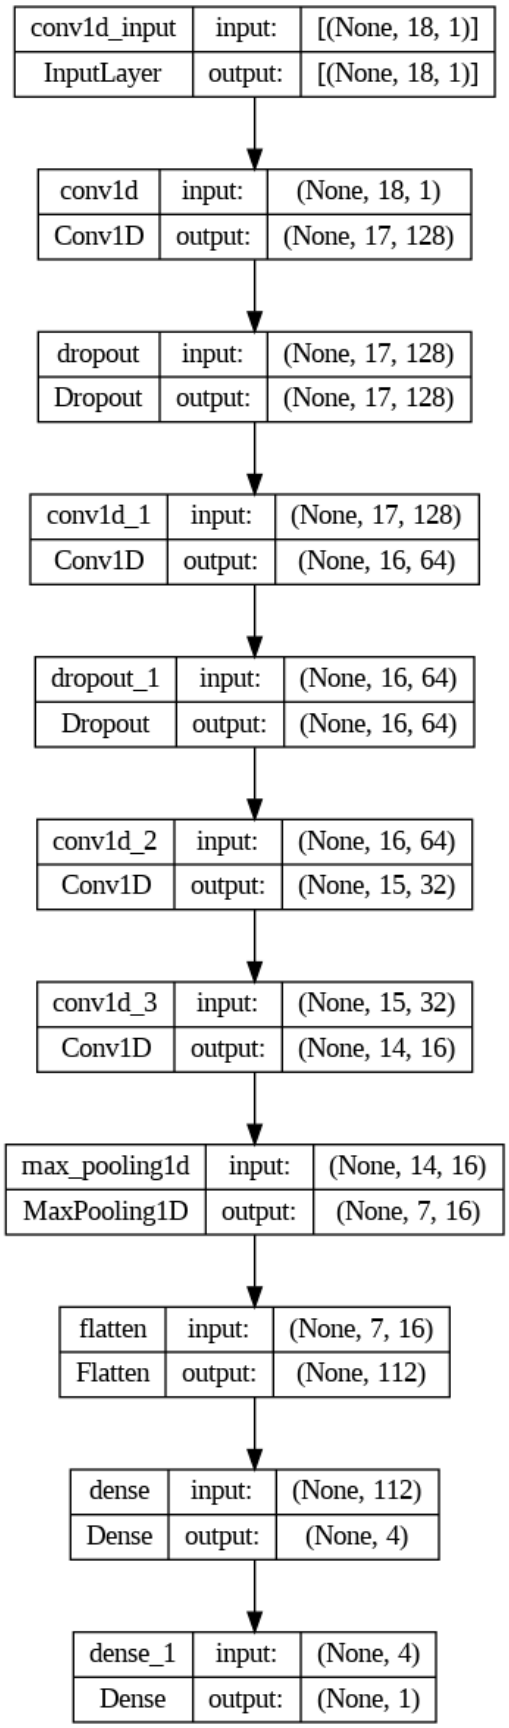
Şekil 5.1. Önerilen modelin çerçevesi

5.2.1. CNN Yöntemi Kullanılarak Oluşturulan Model Mimarisi

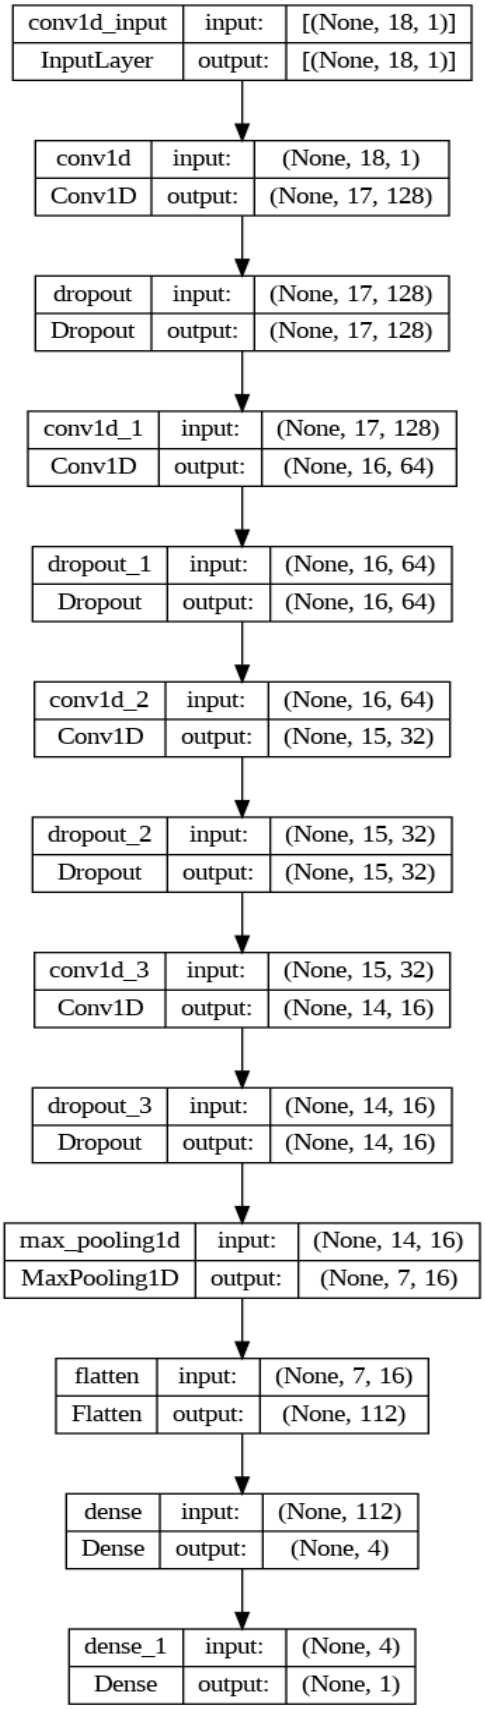
CNN mimarisi, 3 farklı veri kümesi için ayrı ayrı inşa edilmiştir. Şekil 5.2'de Bitcoin veri kümesi için yapılandırılan CNN mimarisi sunulmaktadır.



Şekil 5.2. Bitcoin veri kümesi için CNN mimarisi



Şekil 5.3. Monero veri kümesi için CNN mimarisi



Şekil 5.4. Stellar veri kümesi için CNN mimarisi

Şekil 5.2'den de görüldüğü üzere, Bitcoin veri kümesi için CNN mimarisi 4 evrişim katmanı, global maksimum türünde havuzlama katmanı, düzleştirme katmanı, tam bağlantılı katman ve çıktı katmanıyla oluşturulmuştur. Birinci evrişim katmanı 128 filtreden oluşmaktadır. İkinci katmanda 64 filtre, üçüncü katmanda 32 filtre ve dördüncü katmanda 16 filtre bulunmaktadır. Çekirdek boyutu 2'ye ayarlanmış ve doğrultulmuş doğrusal birim (ReLU) aktivasyon fonksiyonu olarak atanmıştır. Son evrişim katmanından sonra, havuzlama katmanı global maksimum olarak kullanılmış ve boyutu 2'ye ayarlanmıştır. Düzleştirme katmanının ardından, 4 nöronlu ve ReLU aktivasyon fonksiyonlu tam bağlantılı katman gelmektedir. Ezberleme sorununu engellemek için, bırakma katmanı kullanılmış, kayıp değeri MSE olarak belirlenmiştir. Ayrıca, yığın boyutu 8 ve deneme sayısı 50 olarak belirlenmiştir.

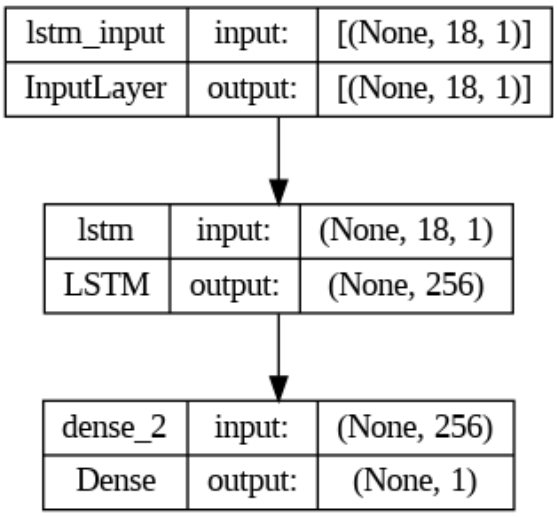
Monero veri kümesi için CNN mimarisi, Şekil 5.3' te sunulmaktadır. Mimari 1 evrişim katmanı, 1 düğüm bırakma katmanı, 1 evrişim katmanı, 1 düğüm bırakma katmanı, 2 evrişim katmanı, global maksimum türünde havuzlama katmanı, düzleştirme katmanı, tam bağlantılı katman ve çıktı katmanıyla oluşturulmuştur. Birinci evrişim katmanı 128 filtre ve aktivasyon fonksiyonu olarak hiperbolik tanjant (tanh) kullanılmıştır. İkinci katmanda 64 filtre ve tanh aktivasyon fonksiyonu, üçüncü katmanda 32 filtre ve tanh aktivasyon fonksiyonu bulunmaktadır. Dördüncü katmanda 16 filtre ve ReLU aktivasyon fonksiyonu kullanılmıştır. Çekirdek boyutu 2'ye ayarlanmıştır. Son evrişim katmanından sonra, havuzlama katmanı global maksimum olarak kullanılmış ve boyutu 2'ye ayarlanmıştır. Düzleştirme katmanının ardından, 4 nöronlu ve ReLU aktivasyon fonksiyonlu tam bağlantılı katman gelmektedir. Bu katman üzerinde düzenleyici olarak L2 çekirdek düzenleyici ve sapma düzenleyicisi vardır. Ezberleme sorununu engellemek çin, bırakma katmanı kullanılmış, kayıp değeri MSE olarak belirlenmiştir. Ayrıca, yığın boyutu 8 ve deneme sayısı 50 olarak belirlenmiştir.

Stellar veri kümesi için CNN mimarisi, Şekil 5.4' te sunulmaktadır. Bu mimaride 1 evrişim katmanı, 1 düğüm bırakma katmanı, 1 evrişim katmanı, 1 düğüm bırakma katmanı, 1 evrişim katmanı, 1 düğüm bırakma katmanı, 1 evrişim katmanı, 1 düğüm bırakma katmanı, global maksimum türünde havuzlama katmanı, düzleştirme katmanı, tam bağlantılı katman ve çıktı katmanıyla oluşturulmuştur. Birinci evrişim katmanında 128 filtre ve aktivasyon fonksiyonu olarak tanh kullanılmıştır. İkinci katmanda 64 filtre

ve tanh aktivasyon fonksiyonu, üçüncü katmanda 32 filtre ve tanh aktivasyon fonksiyonu bulunmaktadır. Dördüncü katmanda 16 filtre ve doğrultulmuş doğrusal birim (ReLU) aktivasyon fonksiyonu kullanılmıştır. Çekirdek boyutu 2'ye ayarlanmıştır. Son evrişim katmanından sonra, havuzlama katmanı global maksimum olarak kullanılmış ve boyutu 2'ye ayarlanmıştır. Düzleştirme katmanının ardından, 4 nöronlu ve ReLU aktivasyon fonksiyonlu tam bağlantılı katman gelmektedir. Bu katman üzerinde düzenleyici olarak L2 çekirdek düzenleyicisi ve sapma düzenleyicisinde yararlanılmıştır. Ezberleme sorununu engellemek için bırakma katmanı kullanılmış, kayıp değeri MSE olarak belirlenmiştir. Ayrıca, yığın boyutu 8 ve deneme sayısı 50 olacak şekilde kurgulanmıştır.

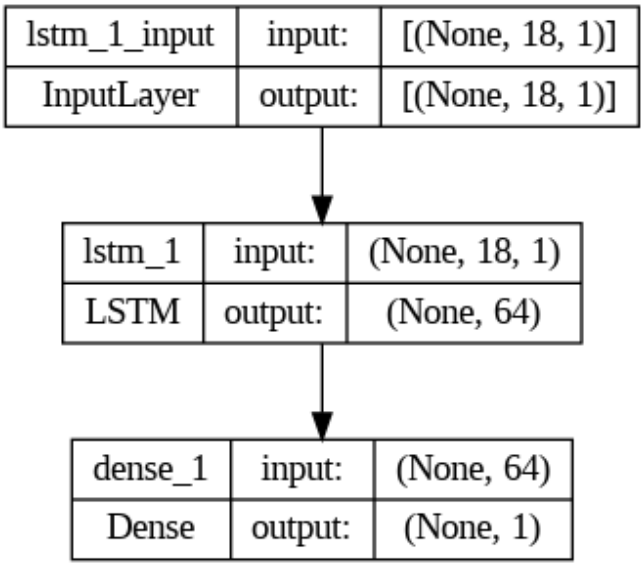
5.2.2.LSTM Yöntemi Kullanılarak Oluşturulan Model Mimarisi

LSTM mimarisi Bitcoin veri kümesi için farklı, diğer iki veri kümesi Monero ve Stellar için farklı olarak ele alınmıştır. Şekil 5.5'te Bitcoin veri kümesi için yapılandırılan LSTM mimarisinin detayları aktarılmaktadır.



Şekil 5.5. Bitcoin veri kümesi için LSTM mimarisi

Bitcoin veri kümesi için tasarlanan LSTM mimarisi 256 nörondan oluşan, ReLU aktivasyon fonksiyonu kullanan bir LSTM katmanı ve çıkış katmanından oluşmaktadır. Ezberleme sorununu engellemek için bırakma katmanı kullanılmış, kayıp değeri MSE olarak belirlenmiştir. Ayrıca, yığın boyutu 8 ve deneme sayısı 50 olacak şekilde kurgulanmıştır.



Şekil 5.6. Monero ve Stellar veri kümeleri için LSTM mimarisi

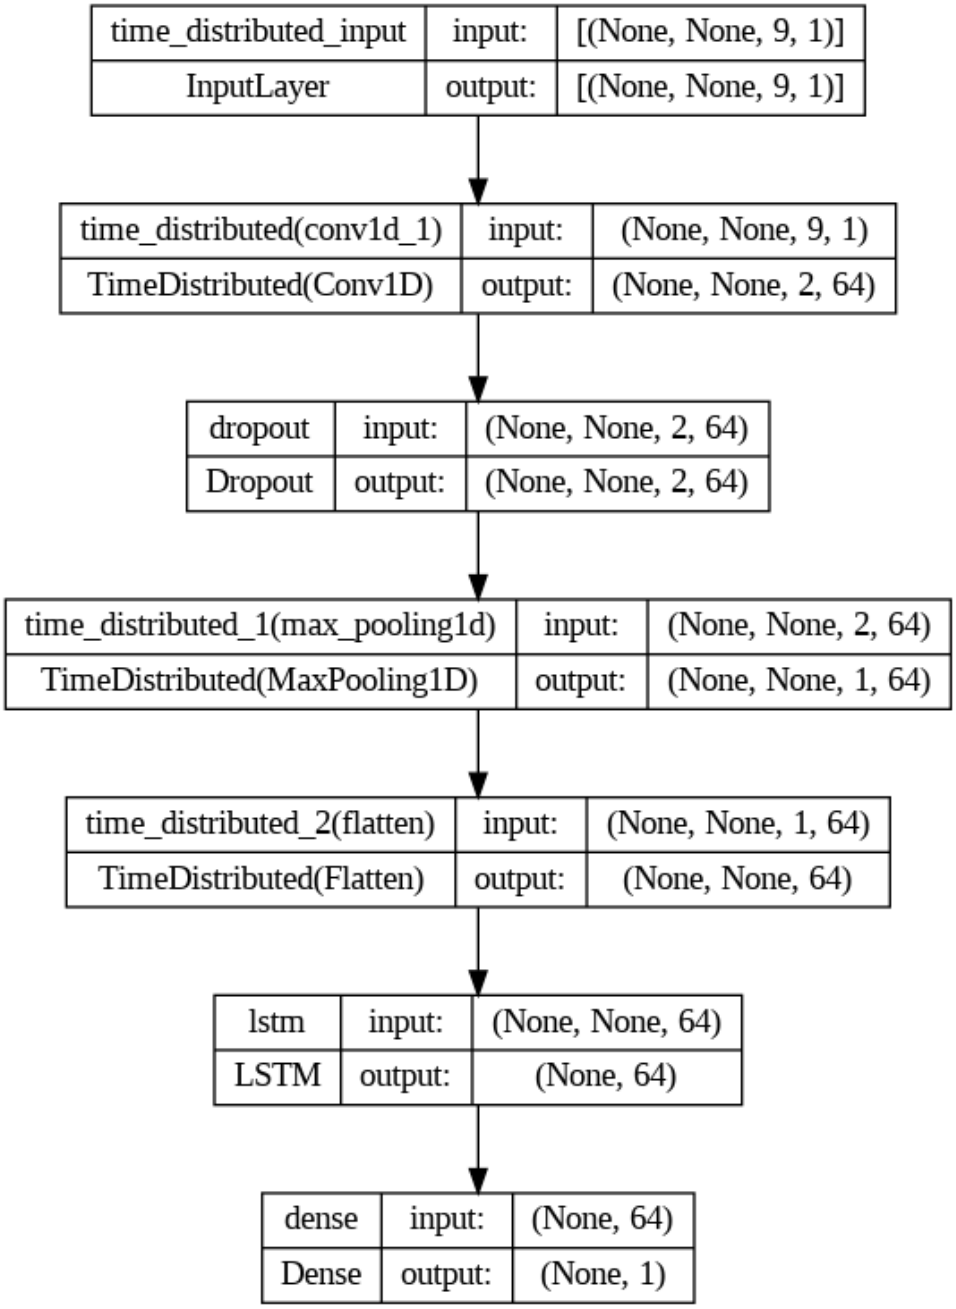
Şekil 5.6'da verilen Monero ve Stellar için tasarlanan modelde 64 nörondan oluşan ve ReLU aktivasyon fonksiyonunu kullanan 1 LSTM katmanı ve çıkış katmanı bulunmaktadır. LSTM katmanı içinde 0,1 bırakma değeri ve düzenleyici olarak çekirdek düzenleyici, tekrarlayan düzenleyici ve sapma düzenleyici işletilmiş ve değer olarak her değer 0,1 olarak atanmıştır. Ezberleme sorununu engellemek için bırakma katmanı kullanılmış, kayıp değeri MSE olarak belirlenmiştir. Ayrıca, yığın boyutu 8 ve deneme sayısı 50 olacak şekilde tasarlanmıştır.

5.2.3. CNN-LSTM Yöntemi Kullanılarak Oluşturulan Model Mimarisi

CNN-LSTM mimarisi, üç veri kümesi için de aynı şekilde tasarlanmıştır. Şekil 5.7'de veri kümeleri için yapılandırılan CNN-LSTM mimarisinin detayları aktarılmaktadır.

CNN-LSTM modelinin inşasında sırasıyla bir evrişim katmanı, bir bırakma katmanı, global maksimum tipi bir havuzlama katmanı, bir düzleştirme katmanı ve tam bağlantılı bir katman kullanılır. Evrişim katmanında filtre sayısı 64, çekirdek boyutu 8 ve aktivasyon fonksiyonu olarak ReLU seçilmiştir. Bunun ardından, global maksimum havuzlama katmanının boyutu 2 olarak belirlenir. Ayrıca, evrişim, havuzlama ve düzleştirme katmanlarına katman sarıcı olarak zamanla dağıtılmış (TimeDistributed) şekilde uygulanır. 64 nöron ve ReLU aktivasyon fonksiyonu, düzenleyicisi ADAM olan

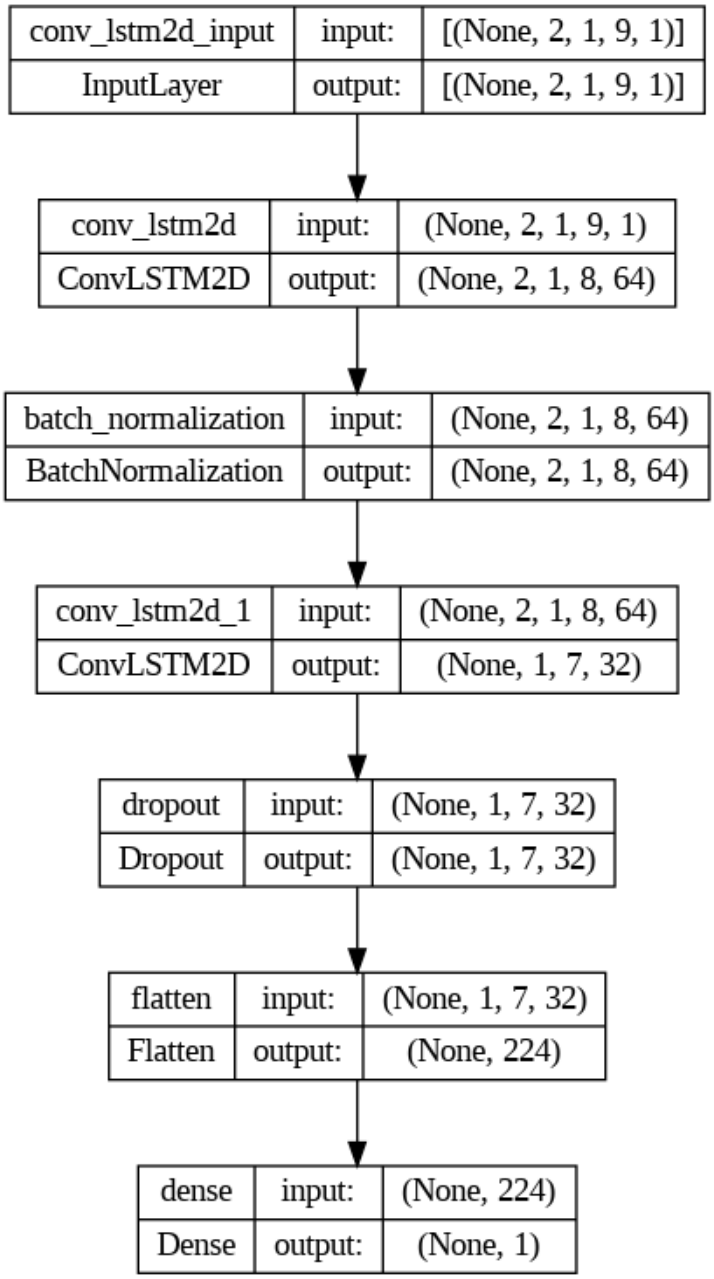
LSTM katmanı ile CNN-LSTM modelinin çıktı katmanında tanımlanır. Ayrıca, yığın boyutu 32 olarak ayarlanır ve yineleme değeri 50 olarak belirlenir.



Şekil 5.7. Üç veri kümesi için CNN-LSTM mimarisi

5.2.4.ConvLSTM Yöntemi Kullanılarak Oluşturulan Model Mimarisi

ConvLSTM mimarisi, üç veri kümesi için de aynı şekilde tasarlanmıştır. Şekil 5.8'de veri kümeleri için yapılandırılan ConvLSTM mimarisinin detayları aktarılmaktadır.



Şekil 5.8. Üç veri kümesi için ConvLSTM mimarisi

ConvLSTM modeli iki ConvLSTM katmanı, ardından bir düzleştirme katmanı ve bir çıktı katmanı ile oluşturulmuştur. İlk ConvLSTM katmanında, filtre sayısı 64 ve çekirdek boyutu 1'dir. İkinci katmanda 32 katman kullanılır ve çekirdek boyutu 2 olarak ayarlanır. Aktivasyon fonksiyonu ReLU olarak atanır ve düzenleyici ADAM'dır. Yığın boyutu ve yineleme sayısı, CNN-LSTM modeliyle aynıdır.

6. DENEY SONUÇLARI

Tezin bu bölümünde, kripto para fiyat tahmini için derin ve hibrit derin öğrenme modellerinin performansları sunulmaktadır. Bu bağlamda, CNN ve LSTM modelleri derin öğrenme modelleri olarak, CNN-LSTM ve ConvLSTM teknikleri ise hibrit derin öğrenme modelleri olarak kullanılmıştır. Modellerin başarısını göstermek amacıyla MAPE, MAE, (MSE, R kare puanı (R^2) değerlendirme metrikleri kullanılarak Bitcoin, Monero, Stellar veri kümeleri üzerinde fiyat tahmini yapılmaktadır. Denklem (6.1), Denklem (6.2), Denklem (6.3) ve Denklem (6.4)'te değerlendirme ölçütlerinin matematiksel formülleri sunulmuştur. Deneylerde her bir veri kümesi %80 eğitim kalan kısım ise test kümesi olarak ayrılmıştır. Ayrıca, eğitim ve test verilerinin dağılımının modeller üzerindeki etkisini göstermek amacıyla deneylerde, eğitim ve test veri kümeleri sıralı (sequential) ve karıştırılmış (shuffled) olmak üzere iki farklı durumda modellerin performansları gözlemlenmiştir.

$$\mathrm{MAPE} = \frac{1}{\mathrm{n}} \sum_{\mathrm{i}=1}^{\mathrm{n}} \left| \frac{\mathrm{y_i} - \hat{\mathrm{y}}_\mathrm{i}}{\mathrm{y_i}} \right| \times 100 \tag{6.1}$$

$$\mathrm{MAE} = \frac{1}{\mathrm{n}} \sum_{\mathrm{i}=1}^{\mathrm{n}} |\mathrm{y_i} - \hat{\mathrm{y}}_\mathrm{i}| \tag{6.2}$$

$$\mathrm{MSE} = \frac{1}{\mathrm{n}} \sum_{\mathrm{i}=1}^{\mathrm{n}} (\mathrm{y_i} - \hat{\mathrm{y}}_\mathrm{i})^2 \tag{6.3}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n} (y_i - y_i)^2}{\sum_{i=1}^{n} (y_i - \bar{y})^2} \tag{6.4}$$

MAPE gerçek değerlere oranla tahminlerin ne kadar hatalı olduğunu yüzdesel olarak göstermektedir. Her bir tahminle gerçek değer arasındaki mutlak yüzde hataların ortalaması alınarak hesaplanmaktadır. MAPE değerinin düşük olması genellikle daha iyi bir model performansı anlamına gelmektedir. Bu bağlamda, düşük MAPE değerleri tahmin edilen değerlerin gerçek değerlere daha yakın olduğunu ifade etmektedir. Yüksek bir MAPE değeri, model ile elde edilen tahminlerin gerçek değerlerden önemli ölçüde

farklı olduğunu göstermektedir. Bu nedenle, genellikle bir modeli eğitirken veya modelin başarısını test ederken MAPE değerinin minimize edilmesi amaçlanmaktadır. Bir diğer deyişle, düşük MAPE değerleri modelin tahmin etmedeki başarısını göstermektedir. Bunun yanında, MAPE metriğinin sınırlamaları da mevcuttur. Özellikle, gerçek değerlerin sıfıra yakın olduğu durumlarda, paydada sıfır değeri problem oluşturmakta ve sonuç sonsuz hata oranlarına yol açmaktadır. Denklem (6.1)'de n örnek sayısını, y_i gerçek değeri, $\hat{y}_i$ ise model tarafından tahmin edilen değeri temsil etmektedir.

MAE, tahmin hatalarının mutlak değerinin ortalaması anlamına gelmektedir. Gerçek değerler ile tahminler arasındaki mutlak hataların ortalamasıdır. Bir başka deyişle, tahminlerin gerçek değerlere ne kadar yakın olduğunu ölçmektedir. Her bir tahminle gerçek değer arasındaki mutlak farkın ortalaması alınarak hesaplanmaktadır. Denklem (6.2)'de n örnek sayısını, y_i gerçek değeri, $\hat{y}_i$ ise model tarafından tahmin edilen değeri temsil etmektedir. MAE sonucunun düşük olması daha iyi bir model performansını anlamına gelmektedir. Bu bakış açısıyla, düşük MAE sonuçları, model tahmininin gerçek değerlere daha yakın olduğunu ifade etmektedir. Yüksek bir MAE sonucu, modelin tahminlerinin gerçek değerlerden önemli ölçüde farklı olduğu anlamına gelmektedir. Modelin hatalarını yansıtırken bu hataların büyüklüğünü dikkate almaktadır. Fakat, hataların yönünü göz ardı etmektedir. Ayrıca, büyük hataların etkisini küçük hatalarla aynı şekilde değerlendirmektedir.

Denklem (6.3)'te sunulan MSE metriği, tahmin hatalarının karelerinin ortalamasını temsil etmektedir. Büyük hataların daha fazla önem kazandığı durumlarda kullanılmaktadır. MSE, gerçek değerler ile tahmin edilen değerler arasındaki farkların karesinin ortalaması alınarak hesaplanmaktadır. Tahmin edilen değerlerin, gerçek değerlere ne kadar yakın olduğunu ölçmektedir. MSE sonucunun düşük olması daha iyi bir model performansı anlamına gelmektedir. Başka bir deyişle, düşük bir MSE sonucu, modelin tahmin ettiği değerlerin gerçek değerlere daha yakın olduğunu ifade etmektedir. Yüksek bir MSE değeri ise, modelin tahmin ettiği değerlerin, gerçek değerlerden önemli ölçüde farklı olduğunu göstermektedir. MSE modelin hatalarını yansıtırken, bu hataların karesini alır. Bu nedenle, büyük hatalar daha fazla ağırlıklıdır ve modelin performansını daha fazla etkiler. Denklem (6.3)'te n örnek sayısını, y_i gerçek değeri, $\hat{y}_i$ ise model tarafından tahminlenen değeri temsil etmektedir.

R^2 değerlendirme metriği, bir regresyon modelinin performansını değerlendirmek için kullanılan istatistiksel bir araçtır. Bu ölçüt, bağımlı değişkendeki varyansın ne kadarının bağımsız değişkenler tarafından açıklandığını belirtmektedir. R^2 değeri, hedef değişkendeki toplam varyansın tahmin edilen değerlerle ne ölçüde ilişkili olduğunu ifade etmektedir. Dolayısıyla, bir modelin verileri ne kadar doğru bir şekilde tahmin ettiğini göstermektedir. R^2 metriği, genellikle 0 ile 1 arasında çıktılar üretmektedir. Bire yakın sonuçlar, modelin yüksek bir uyum gösterdiğini ve verilerin varyansının büyük bir kısmını açıkladığını ifade etmektedir. Sıfıra yakın değerler ise, modelin verilerin varyansını açıklamakta başarılı olamadığını ve tahminlerin gerçek değerlerden farklı olduğunu belirtmektedir. Denklem (6.4)'te n örnek sayısını, y_i gerçek değeri, $\hat{y}_i$ model tarafından tahmin edilen değeri, $\bar{y}$ ise gerçek değerlerin ortalamasını temsil etmektedir.

6.1. Bitcoin Veri Kümesi ile Elde Edilen Sonuçlar

Bu bölümde, Bitcoin veri kümesinin sıralı ve karıştırılmış versiyonları kullanılarak CNN, LSTM, CNN-LSTM ve ConvLSTM modellerinin performansları MAPE, MAE, MSE, R^2 değerlendirme metrikleri ile sunulmaktadır.

Tablo 6.1. Bitcoin veri kümesi (sıralı) kullanarak elde edilen model performansları

	CNN	**LSTM**	**CNN-LSTM**	**ConvLSTM**
MAPE	1,5409	3,5502	4,7003	3,2175
MAE	0,0776	0,1695	0,2389	0,1621
MSE	0,1372	0,7351	0,8970	0,3852
R^2	0,9469	0,7158	0,6532	0,8510

Tablo 6.1'de Bitcoin veri kümesinin sıralı versiyonu üzerinde yukarıda bahsedilen modellerin performansları verilmiştir. Bu tablodaki sonuçlar incelendiğinde en düşük ortalama mutlak hata yüzdesi 1,5409 değeri ile CNN modeliyle elde edilmiştir. Bu bağlamda, en iyi tahmin performansını CNN modeli sağlamıştır. MAPE değerleri değerlendirildiğinde CNN modelinin performansını sırasıyla 3,2175 ile ConvLSTM, 3,5502 ile LSTM ve 4,7003 değeriyle CNN-LSTM modeli takip etmektedir. CNN-LSTM modeli, Bitcoin veri kümesi (sıralı) için fiyat tahmininde diğer modellerin performanslarına kıyasla tahmin başarımı en düşük modeldir. CNN-LSTM ile ConvLSTM modellerinin performansları MAPE değerleri açışından karşılaştırıldığında

ConvLSTM modeli 1,48 oranında, CNN-LSTM ile LSTM modeli karşılaştırıldığında ise LSTM modeli 1,15 oranında iyileşme göstermiştir. ConvLSTM ve LSTM modellerinin tahmin sonuçları MAPE değerleri değerlendirildiğinde ise ConvLSTM modeli, 0,33 oranında bir performans artışı sağlamıştır. Tablo 6.1'de sunulan MAPE değerleri değerlendirildiğinde her bir derin öğrenme modelinin tahmin performansı şu şekilde sıralanmaktadır: CNN>ConvLSTM> LSTM>CNN-LSTM. MAPE sonuçları değerlendirildiğinde elde edilen benzer model performans sıralaması MSE, MAE ve R^2 değerlendirme metrikleri için de geçerlidir.

Tablo 6.2. Bitcoin veri kümesi (karıştırılmış) kullanarak elde edilen model performansları

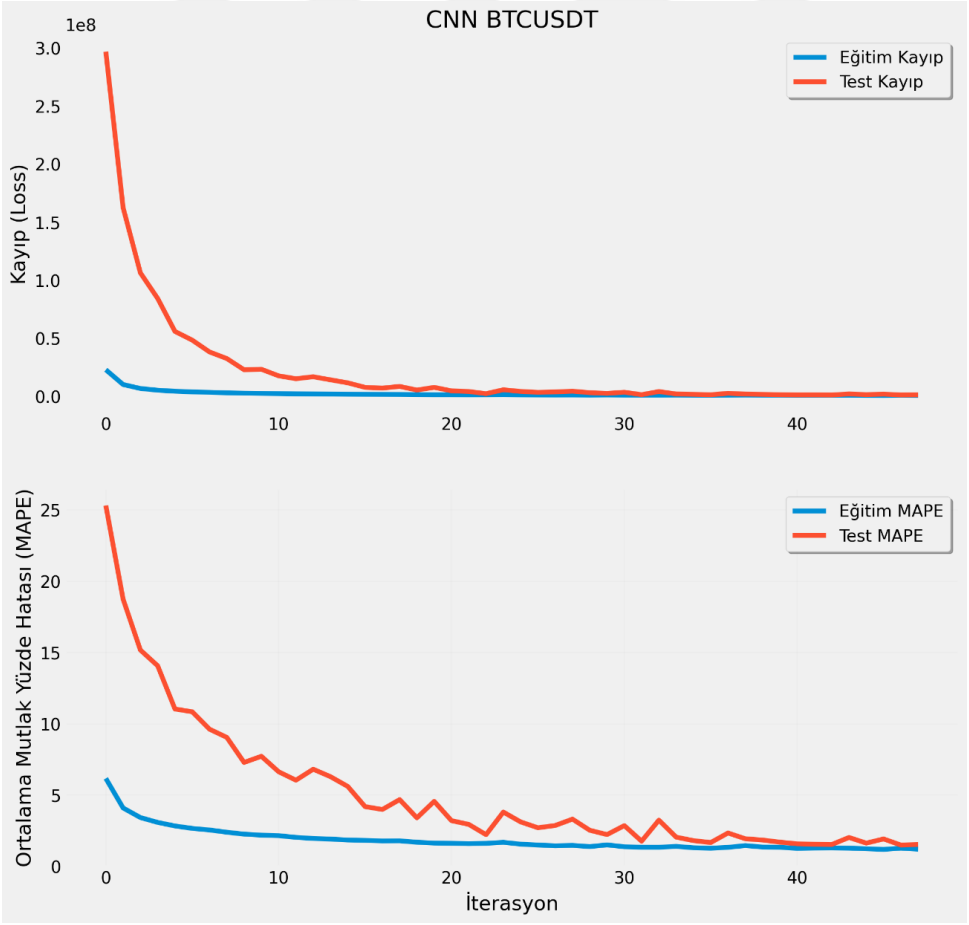
	CNN	**LSTM**	**CNN-LSTM**	**ConvLSTM**
MAPE	4,3365	6,8177	3,0908	4,2963
MAE	0,2477	0,3816	0,1727	0,2437
MSE	0,6960	1,6916	0,5659	0,7246
R^2	0,5218	0,3239	0,5728	0,5145

Tablo 6.2'de Bitcoin veri kümesinin karıştırılmış versiyonu üzerinde derin ve hibrit derin öğrenme modelleriyle elde edilen performansları verilmiştir. Tablo 6.2'deki sonuçlar incelendiğinde en düşük ortalama mutlak hata yüzdesi 3,0908 değeri ile CNN-LSTM modeliyle elde edilmiştir. Bu bağlamda, en iyi tahmin performansını CNN-LSTM modeli sağlamıştır. MAPE değerleri değerlendirildiğinde CNN-LSTM modelinin performansını sırasıyla 4,2963 ile ConvLSTM, 4,3365 ile CNN ve 6,8177 değeriyle LSTM modeli takip etmektedir. LSTM modeli, Bitcoin veri kümesi (karıştırılmış) için fiyat tahmininde diğer modellerin performanslarına kıyasla tahmin başarımı en düşük modeldir. LSTM ve ConvLSTM modellerinin performansları MAPE değerleri açışından karşılaştırıldığında ConvLSTM modeli 2,52 oranında, LSTM ile CNN modeli karşılaştırıldığında ise CNN modeli 1,48 oranında iyileşme göstermiştir. ConvLSTM ve CNN modellerinin tahmin sonuçları MAPE değerleri değerlendirildiğinde ise ConvLSTM modeli, 0,02 oranında bir performans artışı sağlamıştır. Tablo 6.2'de sunulan MAPE değerleri değerlendirildiğinde her bir derin öğrenme modelinin tahmin performansı şu şekilde sıralanmaktadır: CNN-LSTM>ConvLSTM>CNN>LSTM. MAPE sonuçları değerlendirildiğinde elde edilen benzer model performans sıralaması MSE, MAE ve R^2 değerlendirme metrikleri için de geçerlidir.

Şekil 6.1'de Bitcoin veri kümesinin sıralı versiyonu kullanılarak CNN modeli ile yapılan fiyat tahmini sunulmuştur. Veri kümesi, 10 Mart 2021 ve 19 Mayıs 2021 tarihleri arasını kapsamaktadır. Yaklaşık iki haftalık gerçek BTCUSDT değeri, CNN modeliyle elde edilen tahmin değeriyle örtüşebildiği ve BTCUSDT'nin fiyat tahmininde yönünü belirlemede başarılı olduğu görülmektedir.



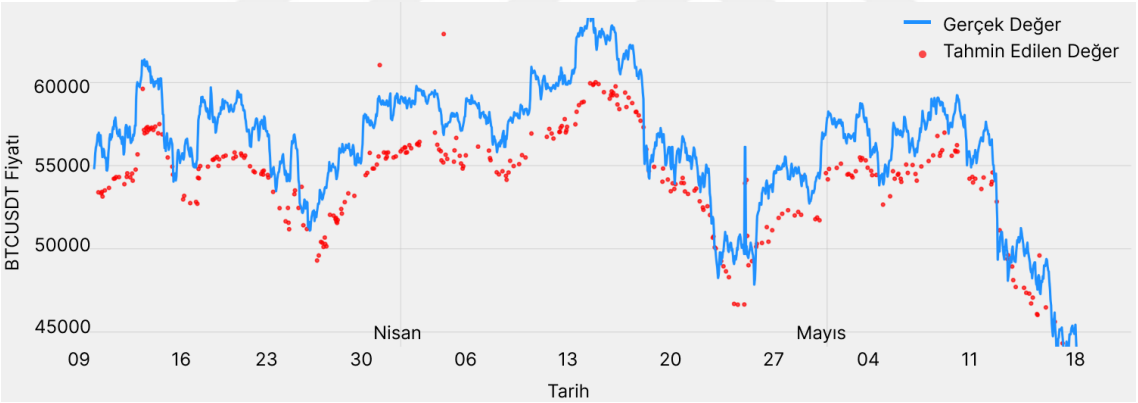
Şekil 6.1. Bitcoin veri kümesinde (sıralı) CNN modeliyle fiyat tahmini



Şekil 6.2. Bitcoin veri kümesinde (sıralı) CNN modeliyle kayıp ve MAPE

Şekil 6.2'de Bitcoin veri kümesinin sıralı versiyonu üzerinde CNN modeli ile yapılan fiyat tahmininde iterasyon boyunca gözlemlenen kayıp ve MAPE değeri gösterilmiştir. Şekil 6.2 incelendiğinde hem eğitim kayıp hem de test kayıp değerinin iterasyon boyunca azaldığı görülmektedir. Bu durum modelin, Bitcoin veri kümesi (sıralı) hem iyi öğrendiğini hem de iyi bir fiyat tahmini yaptığını göstermektedir. MAPE değerlerinin gösterimi ise bu olguyu doğrulamaktadır. Ortalama mutlak yüzde hatası iterasyon boyunca düşüş eğilimindedir. Eğitim MAPE ve test MAPE çıktıları birbirine oldukça yakınsamaktadır.

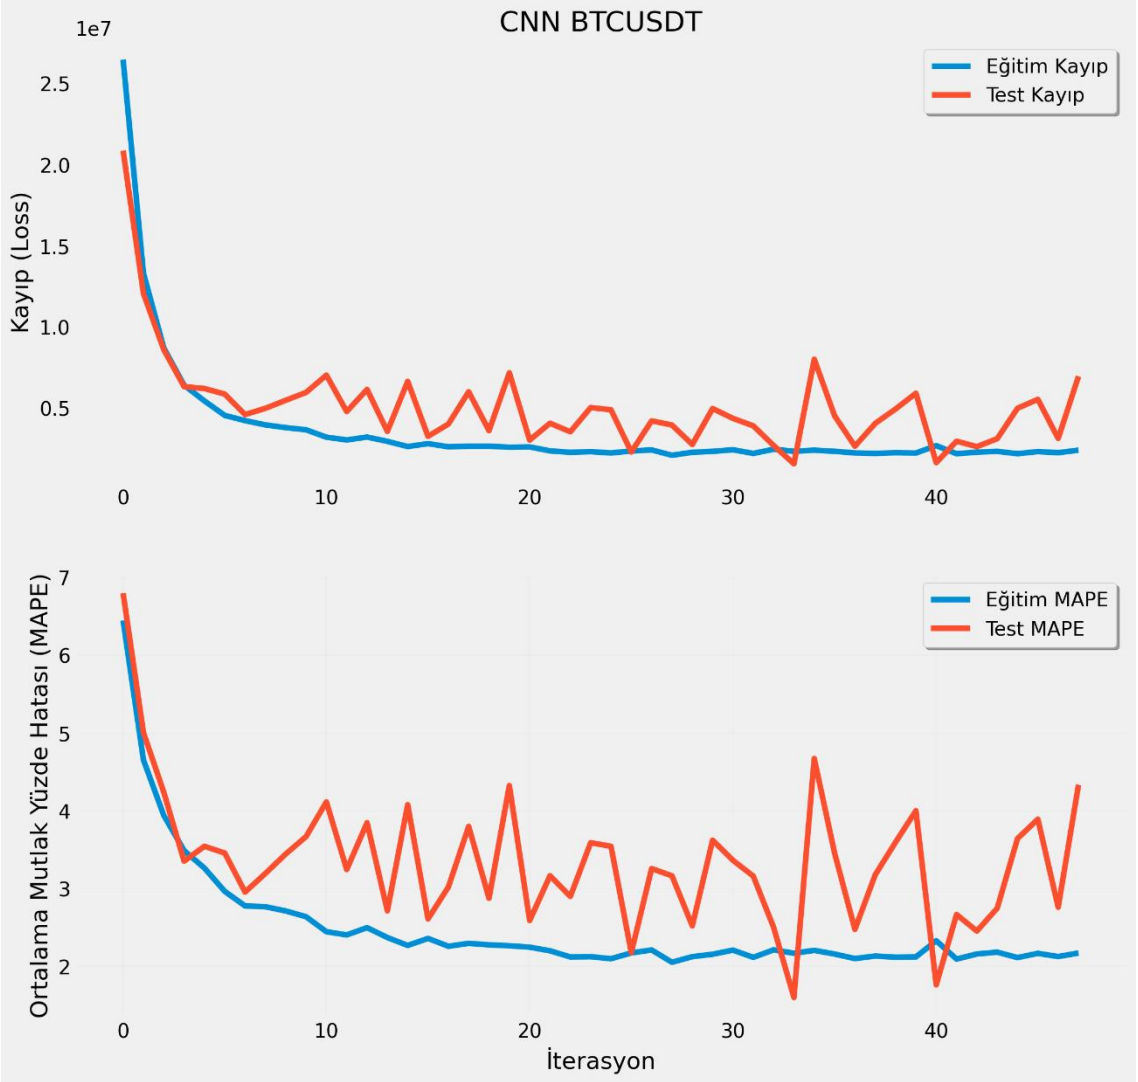
Şekil 6.3'te Bitcoin veri kümesinin karıştırılmış versiyonu kullanılarak CNN modeli ile yapılan fiyat tahmini yer almaktadır. Tahmin edilen değerler, tüm veri kümesinin %20 oranında ve saatlik bazda herhangi bir zaman aralığını ele alıp fiyat tahmini yapmaktadır. CNN modeliyle tahmin edilen değerler, gerçek BTCUSDT değerini örtüşebildiği görülmektedir. Ayrıca, CNN modelinin, BTCUSDT'nin fiyat tahmininde yönünü belirlemede başarılı olduğu gözlemlenmektedir.



Şekil 6.3. Bitcoin veri kümesi (karıştırılmış) CNN modeliyle fiyat tahmini

Şekil 6.4'te Bitcoin veri kümesinin karıştırılmış versiyonu üzerinde CNN modeli ile yapılan fiyat tahmininde iterasyon boyunca gözlemlenen kayıp ve MAPE değeri sunulmuştur. Şekil 6.4 incelendiğinde hem eğitim kayıp hem de test kayıp değerinin iterasyon boyunca oldukça azaldığı görülmektedir. Bu durum modelin, Bitcoin veri kümesi (karıştırılmış) hem iyi öğrendiğini hem de iyi bir fiyat tahmini yaptığını göstermektedir. MAPE değerlerinin de azaldığının görülmesi kayıp değerlerinden yola çıkarak yapılan yorumu doğrulamaktadır. Ortalama mutlak yüzde hatası iterasyon boyunca düşüş eğilimindedir. Verinin karıştırılarak verilmesi sonucu olarak iterasyon

boyunca dalgalı kayıp ve MAPE değerleri olsa da eğitim MAPE ve test MAPE çıktıları birbirine oldukça yakınsamaktadır. Bu bağlamda CNN modelinin fiyat tahmin ve fiyat yön belirleme de oldukça başarılı olduğu görülmektedir.



Şekil 6.4. Bitcoin veri kümesinde (karıştırılmış) CNN modeliyle kayıp ve MAPE

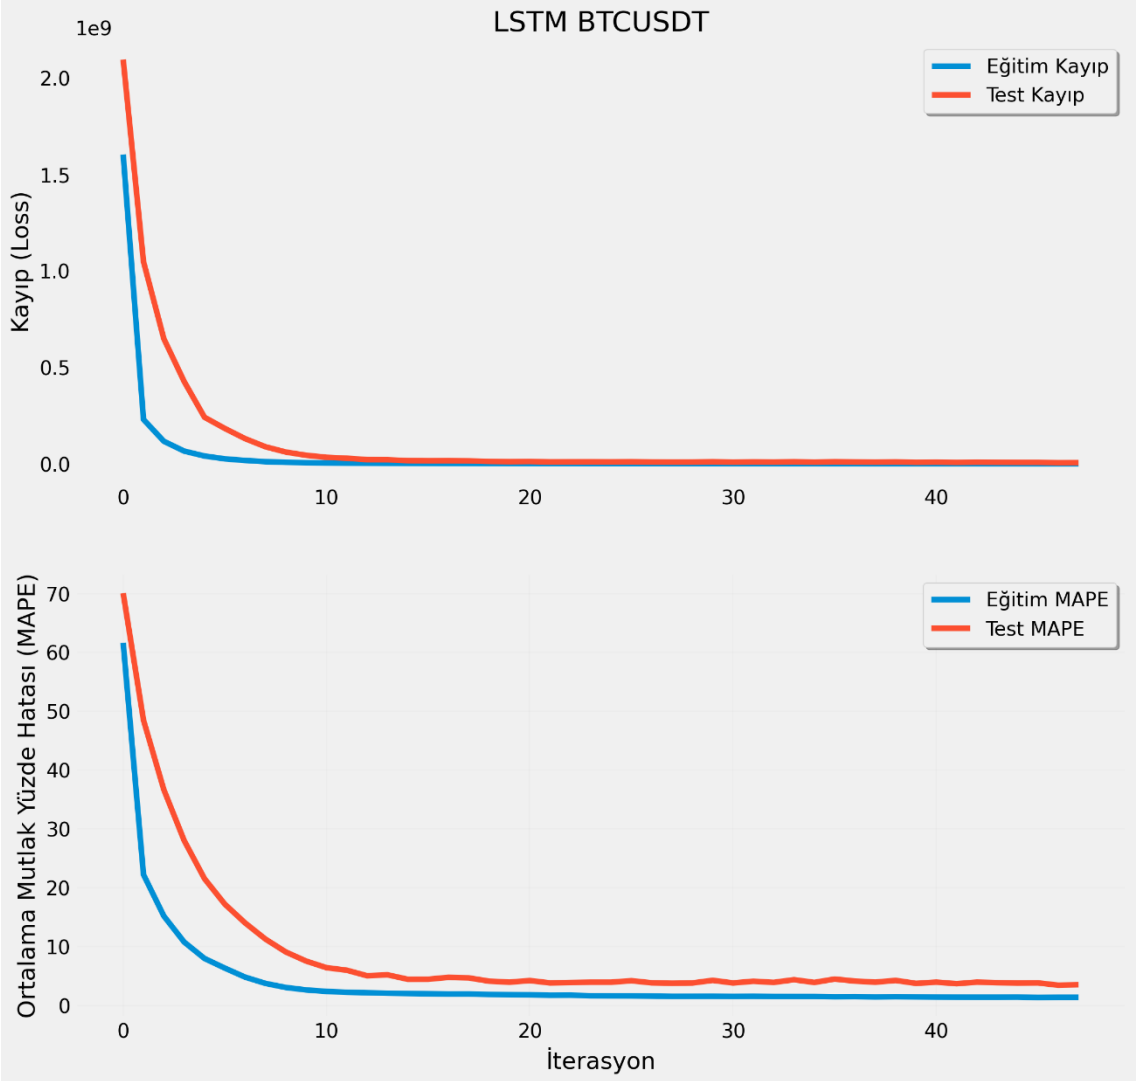
Şekil 6.5'te Bitcoin veri kümesinin sıralı versiyonu kullanılarak LSTM modeli ile yapılan fiyat tahmini sunulmuştur. LSTM modeli ile yapılan tahminler CNN modeli ile yapılan fiyat tahminleri kadar başarılı olmamasına rağmen oldukça başarılıdır. Gerçek fiyat oynaklığının az olduğu noktalarda gerçek fiyatlara çok yakın fiyat tahmini sağlamıştır. Fakat, fiyat oynaklığının görece yüksek olduğu bölgelerde gerçek fiyatlara göre çok daha yüksek ya da çok daha düşük sonuçlar vermekte, fiyat yönü tahmininde ise gerçek fiyat yönüne ters hareket ettiği bölgeler olabilmektedir. Bu nedenle LSTM modelinin durağan

zaman aralıklarında başarım oranı daha iyi iken oynaklığın yüksek olduğu zaman aralıklarında başarım oranının düştüğü gözlemlenmektedir.



Şekil 6.5. Bitcoin veri kümesinde (sıralı) LSTM modeliyle fiyat tahmini

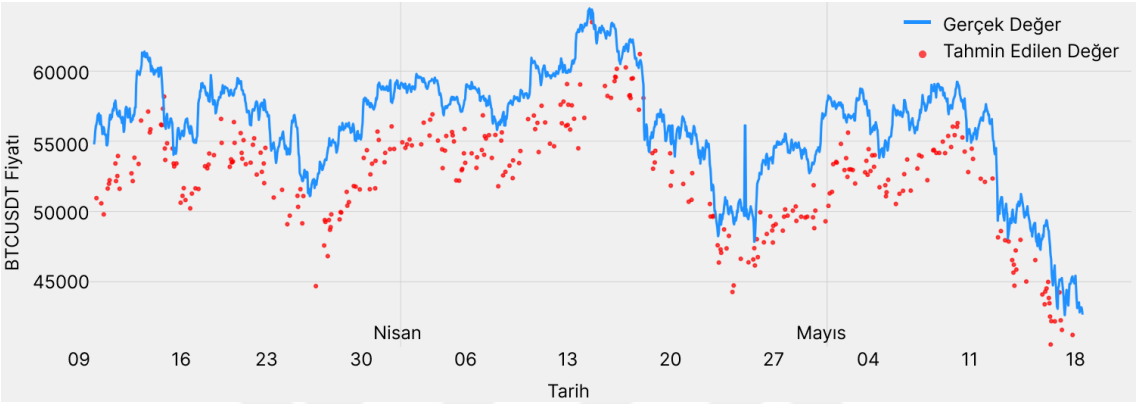
Şekil 6.6, LSTM modelinin sıralı Bitcoin veri kümesi üzerinde uyguladığı fiyat tahmininin iterasyon süresince kayıp ve MAPE değerlerini detaylı bir biçimde sunulmaktadır. Bu figür, özellikle modelin öğrenme süreci boyunca nasıl geliştiğini ve hedef metriğin nasıl evrildiğini gözler önüne sermekte ve bu sayede modelin genel performansını değerlendirmek için kritik bir araç oluşturmaktadır. Detaylı inceleme hem eğitim hem de test kayıp değerlerinin iterasyon boyunca belirgin bir düşüş trendi gösterdiğini açığa çıkarmaktadır. Bu, modelin öğrenme sürecinin istikrarlı bir biçimde geliştiğini ve hedeflenen sonuçlara doğru ilerlediğini gösterir. Bu durum, LSTM modelinin sıralı Bitcoin veri kümesini etkin bir biçimde öğrendiği ve doğru bir fiyat tahmini yapabildiği sonucunu desteklemektedir. MAPE değerlerinin sunumu, bu durumu daha da güçlendirmektedir. Şekil 6.6'deki MAPE değerlerinin düşüşü, modelin tahminlerinin giderek daha doğru hale geldiğini ve böylece tahmin performansının sürekli olarak iyileştiğini gösterir. Ortalama mutlak yüzde hata, iterasyon süresince genel bir düşüş eğilimi sergilemektedir. Bu, modelin hem öğrenme sürecinde hem de tahmin performansında istikrarlı bir gelişme gösterdiğini teyit eder. Son olarak, hem eğitim hem de test MAPE çıktıları, birbirine oldukça yakın bir konverjansı belirtmektedir. Bu, modelin performansının eğitim ve test veri kümeleri arasında tutarlı olduğunu ve bu nedenle genelleme yeteneğinin güçlü olduğunu gösterir. Bu sonuçlar, LSTM modelinin Bitcoin veri kümesi(sıralı) üzerinde fiyat tahmininde oldukça başarılı olduğunu belirtmektedir.



Şekil 6.6. Bitcoin veri kümesinde (sıralı) LSTM modeliyle kayıp ve MAPE

Şekil 6.7, LSTM modelinin karıştırılmış Bitcoin veri kümesi üzerinde uygulanan fiyat tahminlerini göstermektedir. Bu figür, özellikle modelin veri kümesinin %20'si üzerinde saatlik bazda rasgele zaman aralıklarını alarak nasıl bir fiyat tahmini yapabileceğini detaylı olarak sunmaktadır. LSTM modeli tarafından tahmin edilen değerlerin, gerçek BTCUSDT değerleri ile önemli ölçüde uyum gösterdiği görülmektedir. Bu, modelin öğrenme sürecinin etkin olduğunu ve tahmin yeteneğinin yüksek olduğunu göstermektedir. Bu durum, modelin hem genel veri özelliklerini öğrendiğini hem de bu özellikler üzerinden doğru fiyat tahminleri yapabildiğini belirtmektedir. Ayrıca, LSTM modelinin BTCUSDT'nin fiyat yönünü belirleme yeteneğinin oldukça başarılı olduğu gözlemlenmektedir. Fiyat yönünün doğru bir şekilde tahmin edilmesi, özellikle finansal piyasalarda işlem yapanlar için kritik bir öneme sahiptir. Bu, modelin sadece fiyatları

tahmin etmekle kalmayıp, aynı zamanda fiyat hareketlerinin genel yönünü de etkili bir şekilde belirleyebildiğini gösterir. Bu sonuçlar, LSTM modelinin karıştırılmış Bitcoin veri kümesi üzerinde fiyat tahminlerinde etkin bir performans gösterdiğini belirtmektedir. Bu, genellikle karışık veri setleri üzerinde modelin genelleme yeteneğinin güçlü olduğunu ve bu nedenle gerçek dünya uygulamalarında kullanım için uygun olduğunu gösterir.

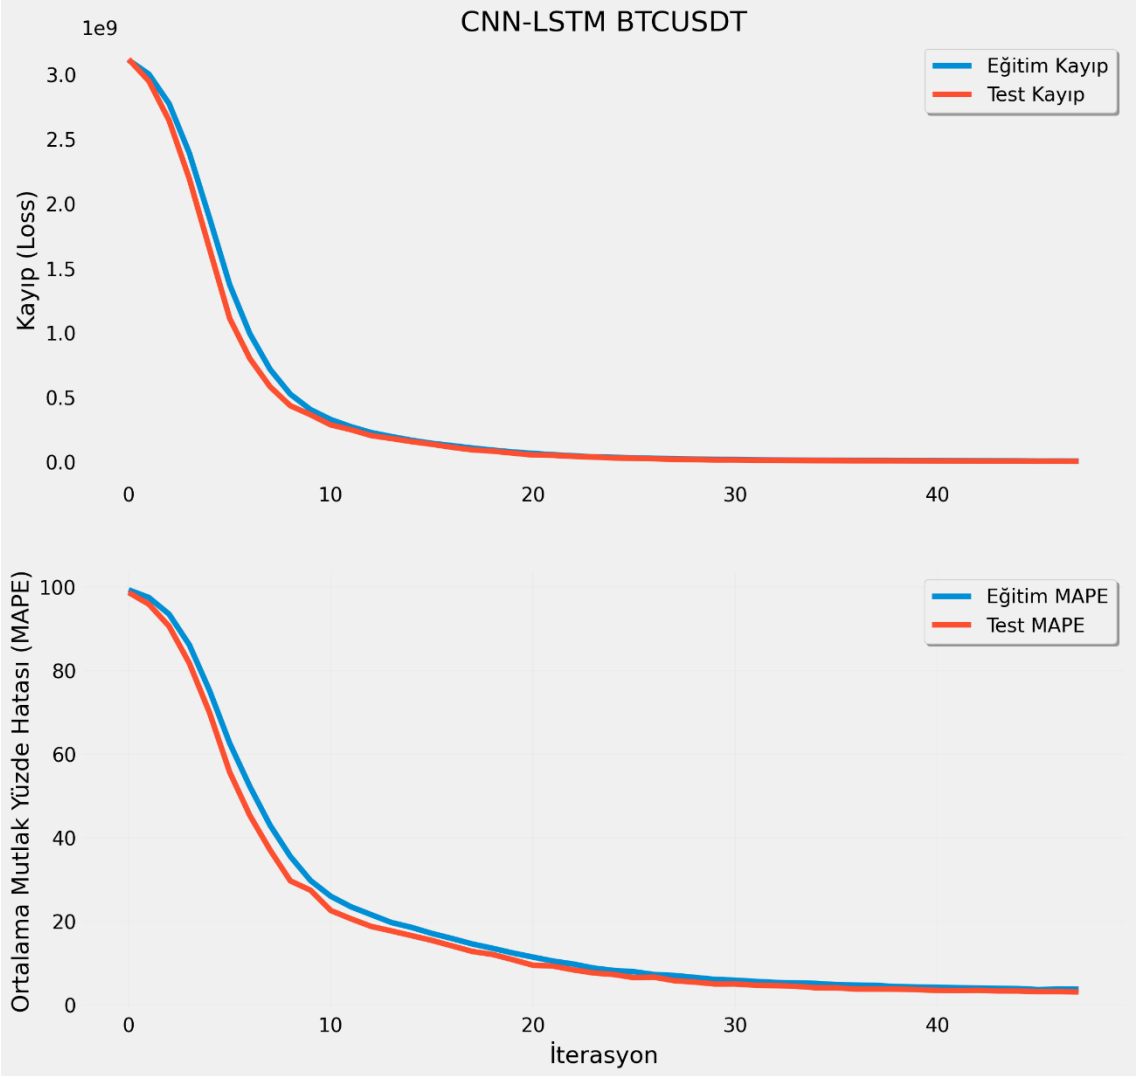


Şekil 6.7. Bitcoin veri kümesinde (karıştırılmış) LSTM modeliyle fiyat tahmini

Şekil 6.8, LSTM modelinin karıştırılmış Bitcoin veri kümesi üzerinde gerçekleştirdiği fiyat tahmin sonuçlarının iterasyonla birlikte nasıl değiştiğini göstermektedir. Bu figür, eğitim ve test sürecindeki kayıp değerlerinin yanı sıra MAPE değerlerinin de dinamiklerini göstermektedir. Şekil incelendiğinde, eğitim ve test aşamasında kayıp değerlerinin iterasyonla birlikte azaldığı belirlenmiştir. Bu durum, LSTM modelinin karıştırılmış Bitcoin veri kümesi üzerinde başarılı bir öğrenme süreci gerçekleştirdiğini ve etkili bir şekilde fiyat tahminleri yaptığını göstermektedir. Bu gözlem, modelin özellikle karıştırılmış veri setlerinde bile genelleme yeteneğinin güçlü olduğunu ve etkin bir şekilde öğrendiğini belirtir. Bunun yanında, MAPE değerlerinin de iterasyon boyunca düşüş eğiliminde olduğu görülmektedir. Bu, modelin tahmin hatalarını azaltmayı başardığını ve tahminlerin gerçek değerlere yaklaştığını gösterir. Bu gözlem, eğitim ve test aşamasındaki kayıp değerlerinin azalmasını doğrular niteliktedir. Karıştırılmış veri kümesi kullanılarak yapılan bu analizde, modelin genelleme kabiliyetinin güçlü olduğunu ve verinin karıştırılmasına rağmen tahminlerin tutarlı olduğunu göstermektedir.

Şekil 6.9, CNN-LSTM modeli ile yapılan fiyat tahminlerini, Bitcoin veri kümesinin sıralı versiyonu üzerinde göstermektedir. Bu modelin performansını değerlendirdiğimizde,

CNN modeli ile yapılan tahminlere kıyasla başarı oranının daha düşük olduğu görülmektedir. Diğer modellerle yapılan karşılaştırmalarda da CNN-LSTM modelinin performansının daha az tatmin edici olduğunu doğrulamaktadır. Özellikle, fiyatların yoğun oynaklık gösterdiği zaman dilimlerinde, modelin tahminlerinin gerçek değerlere kıyasla çok daha yüksek ya da çok daha düşük olduğu belirlenmiştir. Bu durum, modelin fiyat hareketlerini doğru bir şekilde tahmin etme yeteneğinde belirgin bir zayıflık olduğunu gösterir. Dahası, belirli bölgelerde, modelin tahmin ettiği fiyat yönünün gerçek fiyat yönüne ters hareket ettiği tespit edilmiştir.



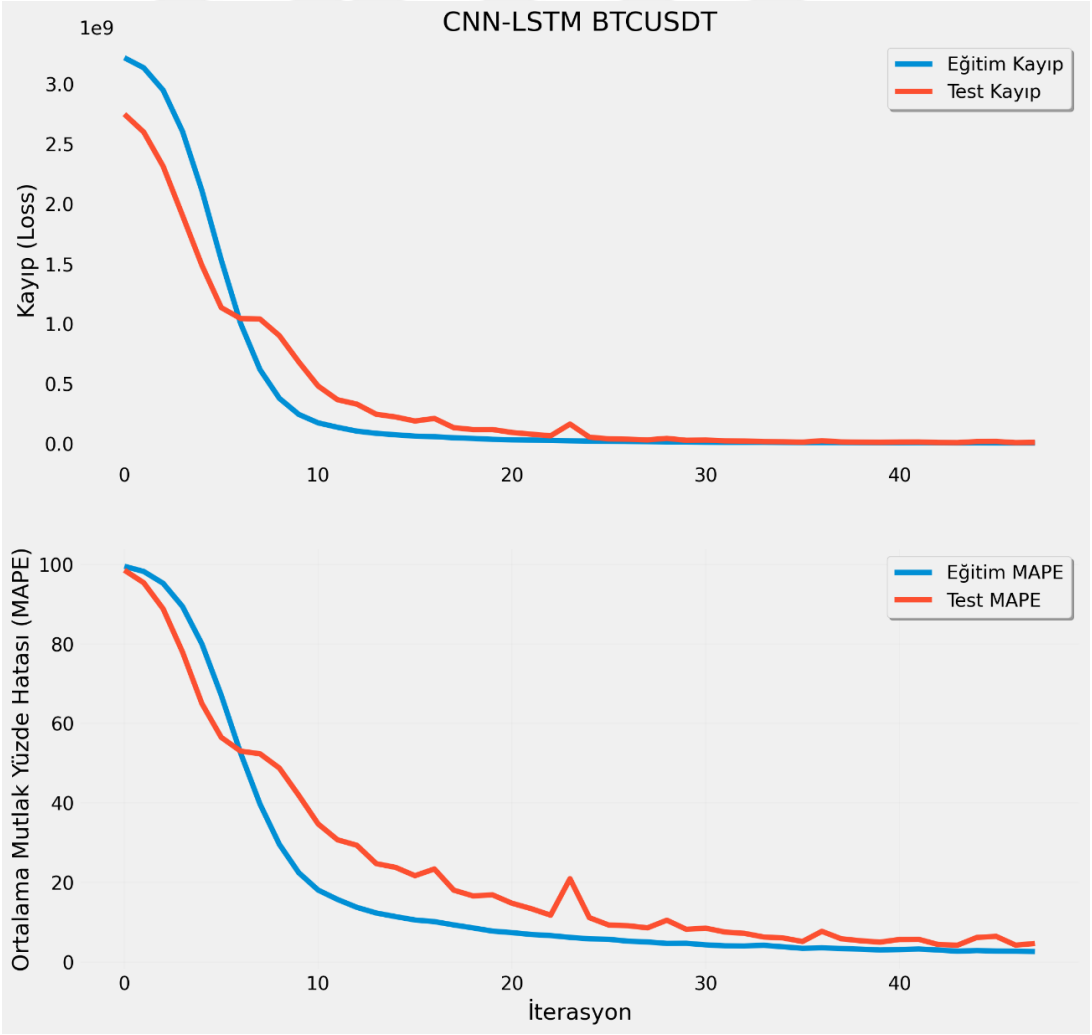
Şekil 6.8. Bitcoin veri kümesinde (karıştırılmış) LSTM modeliyle kayıp ve MAPE

Bu sonuçlar, CNN-LSTM modelinin başarı oranının, fiyatların nispeten durağan olduğu zaman dilimlerinde daha yüksek olduğunu, ancak fiyat oynaklığının arttığı dönemlerde

performansının düştüğünü göstermektedir. Böylece, modelin oynaklıkla başa çıkma yeteneğinin belirli bir sınırlama olduğunu ve bu tür durumlar altında daha az etkili olduğunu işaret etmektedir.



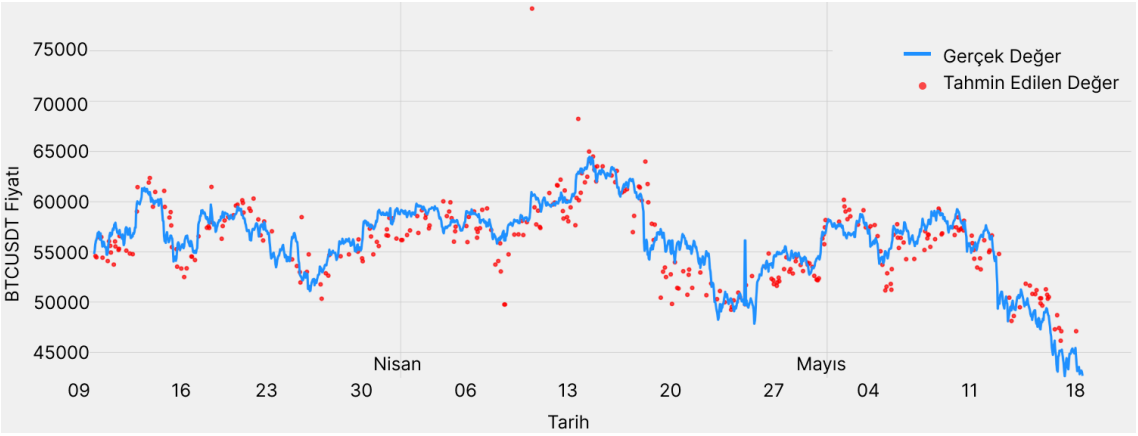
Şekil 6.9. Bitcoin veri kümesinde (sıralı) CNN-LSTM modeliyle fiyat tahmini



Şekil 6.10. Bitcoin veri kümesinde (sıralı) CNN-LSTM modeliyle kayıp ve MAPE

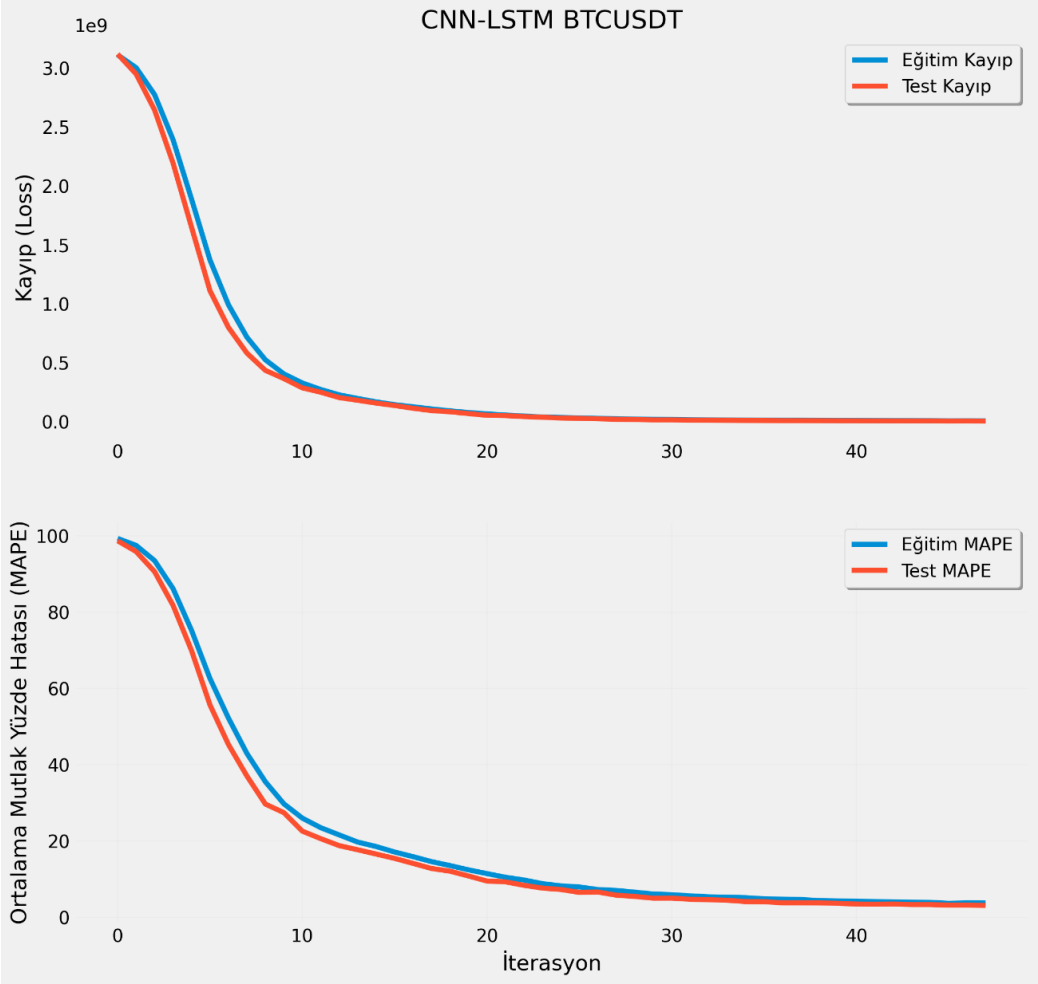
Şekil 6.10’da sunulan kayıp ve MAPE değerleri, eğitim kayıp ve test kayıp değerlerinin iterasyon boyunca düştüğünü göstermektedir. Aynı, şekilde eğitim MAPE ve test MAPE değerleri de düşme eğilimdedir. Şekil 6.10’da eğitim kayıp ve test kayıp değerleri 6 ve 8’inci iterasyon aralığında birebiriyle kesişmekte ve farklı yönde hareket ettiği görülmektedir. Bu durum, CNN-LSTM modelinin eğitim verilerine aşırı derecede uyum sağladığı ve bu nedenle genelleme kabiliyetinin azaldığını ifade etmektedir. Bu kesişme, CNN-LSTM modelinin daha önce görmediği verileri, yani test setini doğru bir şekilde tahmin etme yeteneğinin azaldığı noktadır. Bu noktadan itibaren, eğitim hatası azalırken, test hatası artmaktadır. Bu, CNN-LSTM modelinin eğitim verilerini aşırı derecede iyi bir şekilde öğrendiğini, ancak bu bilginin yeni verilere uygulanmasında zorlandığını göstermektedir.

Şekil 6.11'de yer alan görselde, Bitcoin veri kümesinin karıştırılmış bir versiyonu işlenerek CNN-LSTM modeli kullanılarak gerçekleştirilen fiyat tahmini sunulmaktadır. CNN-LSTM modeli aracılığıyla tahmin edilen değerler, veri kümesinin toplamının %20'sini temsil eden, saatlik bazda belirli bir zaman aralığını ele alarak fiyat tahminleri yapmaktadır. CNN-LSTM modeliyle tahmin edilen değerlerin gerçek BTCUSDT değerlerine ne derece uyum sağladığına dair bir değerlendirme yapılmaktadır. Bu çerçevede, CNN-LSTM modelinin BTCUSDT'nin fiyatının yönünü belirleme yeteneğinin etkin bir şekilde gözlemlendiği söylenebilir. Bu durum, CNN-LSTM modelinin karmaşıklığının ve tahmin yeteneğinin, özellikle fiyat yönü tahmini konusunda, etkili bir biçimde kullanılabildiğini göstermektedir.



Şekil 6.11. Bitcoin veri kümesinde (karıştırılmış) CNN-LSTM modeliyle fiyat tahmini

Şekil 6.12'de, Bitcoin veri kümesinin karışık bir versiyonu üzerinde CNN-LSTM modeli kullanılarak gerçekleştirilen fiyat tahmininde, iterasyonlar boyunca kaydedilen kayıp ve MAPE değerleri gösterilmektedir. İncelendiğinde, hem eğitim kaybının hem de test kaybının iterasyonlar boyunca belirgin bir şekilde azaldığı görülmekte olup, bu durum, CNN-LSTM modelinin Bitcoin veri kümesini (karışık) etkili bir biçimde öğrendiğini ve hassas fiyat tahminleri gerçekleştirdiğini işaret etmektedir. Kayıp değerlerinin azalmış olması, MAPE değerlerinin de benzer bir eğilim gösterdiğini doğrulamaktadır. Ortalama mutlak yüzde hata, iterasyonlar boyunca genel bir düşüş trendi sergilemektedir. Verinin karıştırılarak sunulması nedeniyle, sıralı veri kümesinde iyi performans veremeyen CNN-LSTM modeli, karıştırılmış veri kümesinde daha iyi sonuçlar üretmektedir. Bu gözlemler ışığında, CNN-LSTM modelinin aşırı uyuma düşmediği durumlarda hem fiyat tahmini hem de fiyat yön belirleme konularında önemli bir başarı sergilediği sonucuna varılmaktadır.



Şekil 6.12. Bitcoin veri kümesinde (karıştırılmış) CNN-LSTM modeliyle kayıp ve MAPE

Şekil 6.13'te, Bitcoin veri kümesinin sıralı bir versiyonu üzerinde ConvLSTM modeli kullanılarak gerçekleştirilen fiyat tahmini sunulmaktadır. Koyu mavi renk ile gösterilen gerçek değerler, koyu turuncu renk ile gösterilen değerler tahmin edilen fiyatı temsil etmektedir. Tahmin edilen değerler, yaklaşık iki haftalık gerçek BTCUSDT değeriyle karşılaştırıldığında, ConvLSTM modeliyle elde edilen tahminlerin gerçek değerleriyle uyum içinde olduğu görülmektedir. Ayrıca, ConvLSTM modelinin, BTCUSDT'nin fiyat tahmini ve fiyat yönünün belirlenmesinde etkili olduğu gözlemlenmektedir.

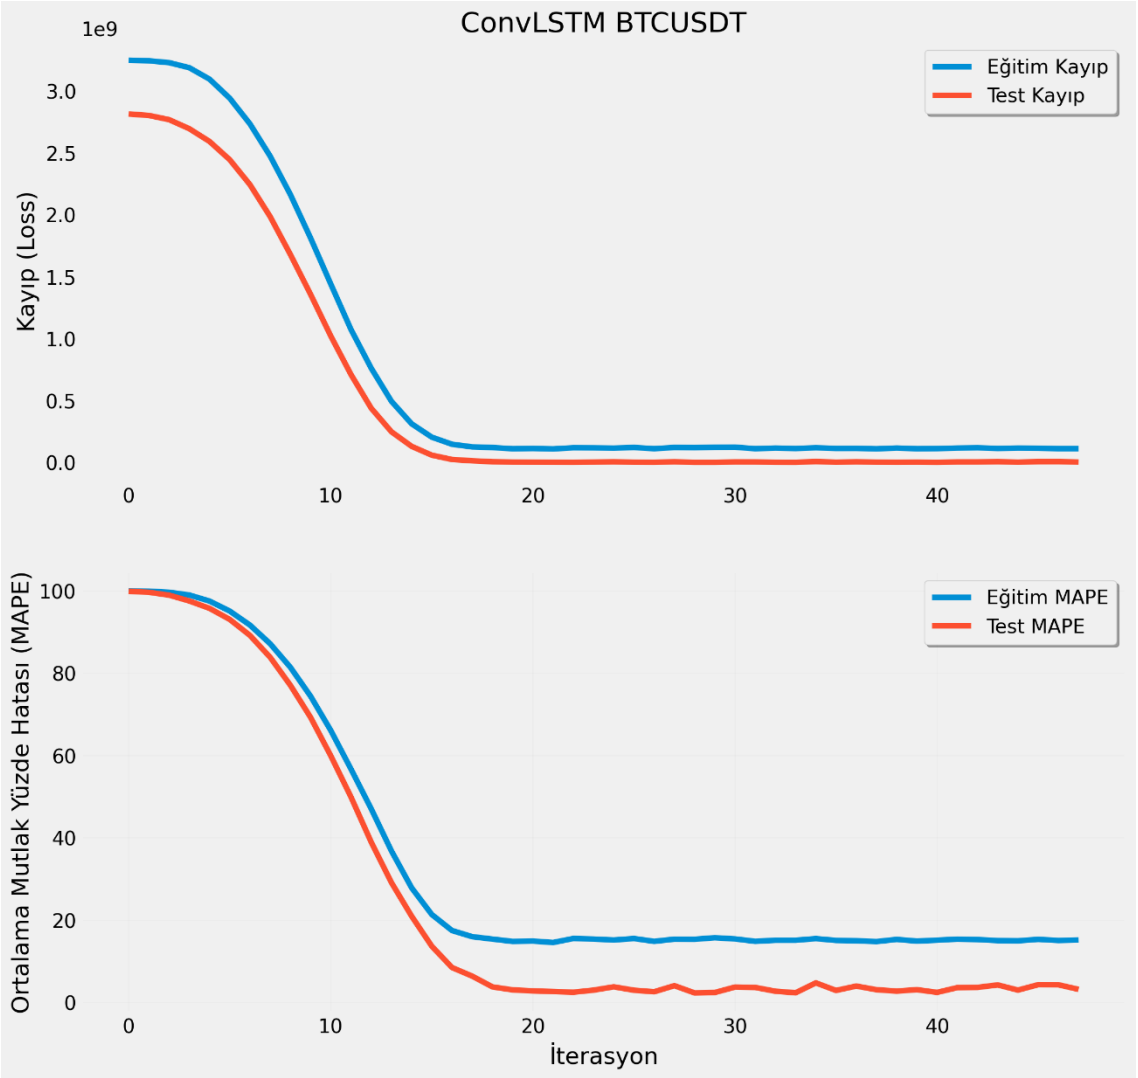


Şekil 6.13. Bitcoin veri kümesinde (sıralı) ConvLSTM modeliyle fiyat tahmini

Şekil 6.14'te, Bitcoin veri kümesinin sıralı biçimi kullanılarak ConvLSTM modeli ile elde edilen fiyat tahmin sonuçları ve bu süreçte iterasyon bazında takip edilen kayıp ve MAPE değerleri aktarılmaktadır. Şekil 6.14'ün detaylı analizi hem eğitim setindeki kayıp hem de test setindeki kayıp değerlerinin iterasyon süresince kademeli olarak azaldığını göstermektedir. Bu gözlem, ConvLSTM modelinin, Bitcoin veri kümesini (sıralı) başarılı bir şekilde öğrendiğini ve etkili bir fiyat tahmini yaptığını ortaya koymaktadır. Bu durumu doğrulayan bir diğer faktör ise, MAPE değerlerinin iterasyon süresince düşüş trendi göstermesidir. Bu trend, eğitim ve test MAPE çıktılarının birbirine yakınlaşma eğiliminde olduğunu da göstermektedir. Bu bulguların ışığında, ConvLSTM modelinin, Bitcoin veri kümesi üzerinde fiyat tahmini ve fiyat yönünün belirlenmesi konularında önemli bir başarı sağladığı çıkarımı yapılabilmektedir.

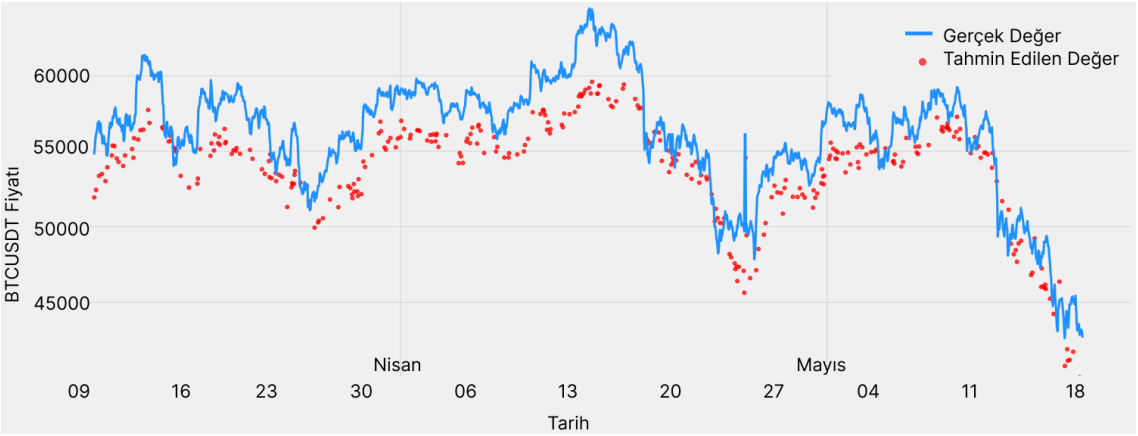
Şekil 6.15, ConvLSTM modelinin kullanıldığı, Bitcoin veri kümesinin karıştırılmış versiyonuna dayalı fiyat tahminlerini sergilemektedir. Tahmin sürecinde, veri kümesinin %20'si ele alınarak, saatlik dilimlerde rasgele seçilmiş bir zaman aralığına odaklanılmıştır. ConvLSTM modeli tarafından tahmin edilen değerlerin, gerçek

BTCUSDT değerleriyle büyük ölçüde örtüştüğü gözlemlenmektedir. Ek olarak, ConvLSTM modelinin, BTCUSDT'nin fiyat yönünün tahmin edilmesinde başarı sergilediği belirgin hale gelmektedir.

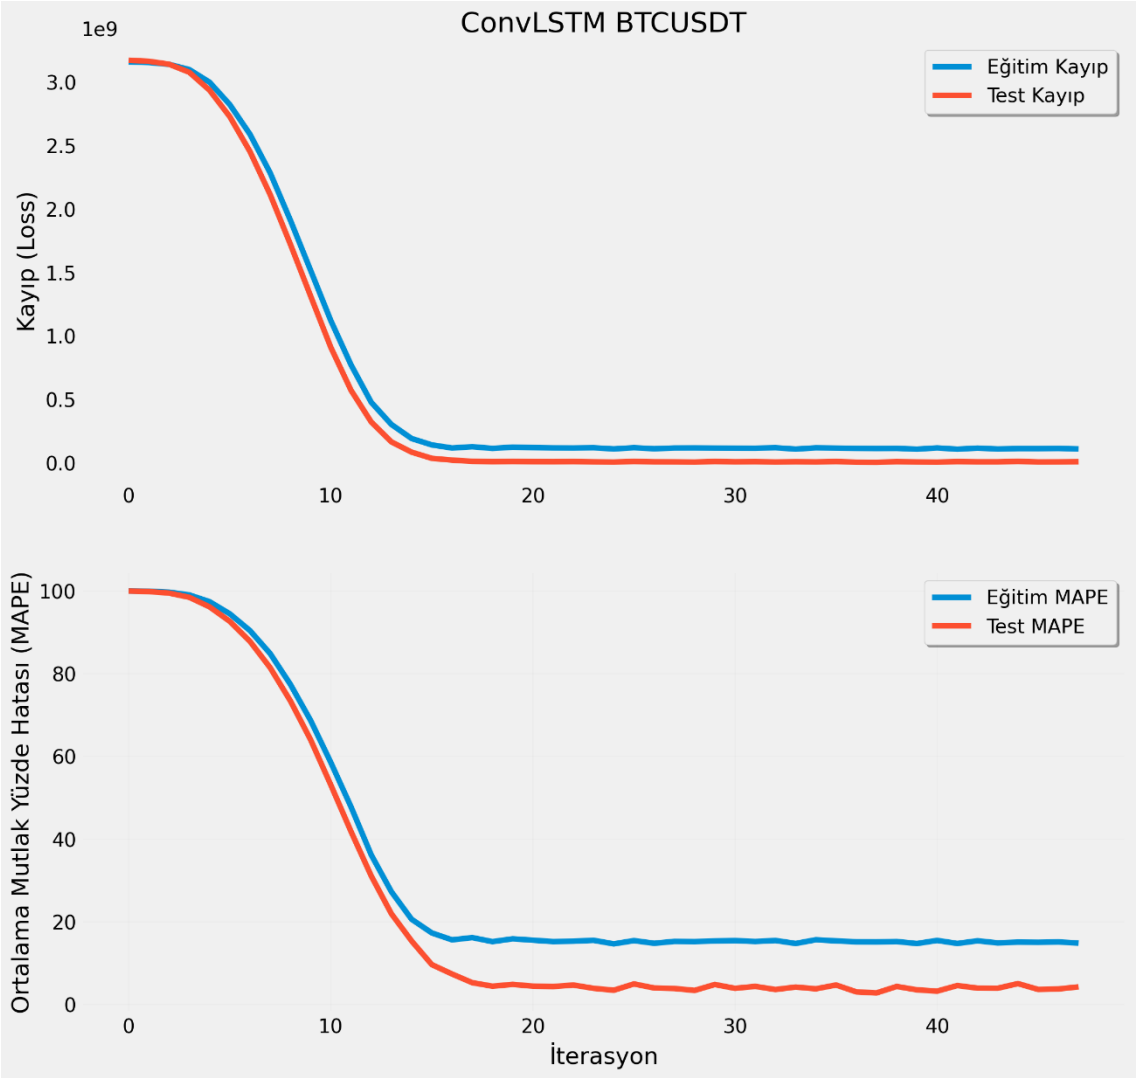


Şekil 6.14. Bitcoin veri kümesinde (sıralı) ConvLSTM modeliyle kayıp ve MAPE

Şekil 6.16'da ConvLSTM modeliyle Bitcoin veri kümesinin karıştırılmış versiyonunda gerçekleştirilen ve Şekil 6.15'te verilen fiyat tahmin grafiğinin deney boyunca gözlemlenen kayıp ve MAPE değerleri sunulmaktadır. Model, yaklaşık 15'inci iterasyona kadar etkin bir şekilde öğrenmiş ve fiyat tahmini yapmıştır. Hem kayıp değerlerinin gösterimi hem de MAPE değerlerinin sunumu bulguları doğrulamaktadır.



Şekil 6.15. Bitcoin veri kümesinde (karıştırılmış) ConvLSTM modeliyle fiyat tahmini



Şekil 6.16. Bitcoin veri kümesinde (karıştırılmış) ConvLSTM modeliyle kayıp ve MAPE

6.2. Monero Veri Kümesi ile Elde Edilen Sonuçlar

Bu bölümde, Monero veri setinin hem sıralı hem de karıştırılmış versiyonları, CNN, LSTM, CNN-LSTM ve ConvLSTM modelleri aracılığıyla değerlendirilmiştir. Performanslar, MAPE, MAE, MSE ve R2 metrikleri kullanılarak analiz edilmiştir.

Tablo 6.3. Monero veri kümesi (sıralı) kullanarak elde edilen model performansları

	CNN	**LSTM**	**CNN-LSTM**	**ConvLSTM**
MAPE	4,8986	10,5940	7,3046	4,0685
MAE	0,2110	0,4627	0,3164	0,1712
MSE	0,0677	0,2734	0,1231	0,0393
R^2	0,6197	0,2369	0,3082	0,7790

Tablo 6.3'teki performans değerlerine göre, ConvLSTM modeli, ortalama mutlak yüzde hata değeri 4,0685 ile en düşük olan model olarak göze çarpmaktadır. Bu durum, ConvLSTM modelinin Monero veri kümesinin sıralı versiyonu üzerinde en etkili tahmin performansını gösterdiğini ifade eder. CNN, CNN-LSTM ve LSTM modelleri, sırasıyla MAPE değerleri 4,8986, 7,3046 ve 10,5940 ile ConvLSTM modelini takip etmektedir. LSTM modeli, tahmin doğruluğu açısından diğer modellere kıyasla en düşük performansa sahiptir.

Tablo 6.4. Monero veri kümesi (karıştırılmış) kullanarak elde edilen model performansları

	CNN	**LSTM**	**CNN-LSTM**	**ConvLSTM**
MAPE	3,7645	4,4122	7,1469	3,4603
MAE	0,1179	0,1352	0,2333	0,1126
MSE	0,0196	0,0354	0,0696	0,0205
R^2	0,9723	0,9435	0,9005	0,9704

Tablo 6.4'te karıştırılmış versiyonun incelenmesi durumunda ise, ConvLSTM modeli yine ortalama mutlak yüzde hata metriği bakımından en düşük değeri 3,4603 ile elde etmiştir ve bu durum yine en iyi tahmin performansının ConvLSTM modelinden geldiğini göstermektedir. Bu modeli, sırasıyla, CNN 3,7645 değeri, LSTM 4,4122 değeri ve CNN-LSTM 7,1469 değeri ile takip etmektedir. Her iki tablonun detaylı analizi, ConvLSTM modelinin hem sıralı hem de karışık versiyonlarda en iyi performansı sergilediğini

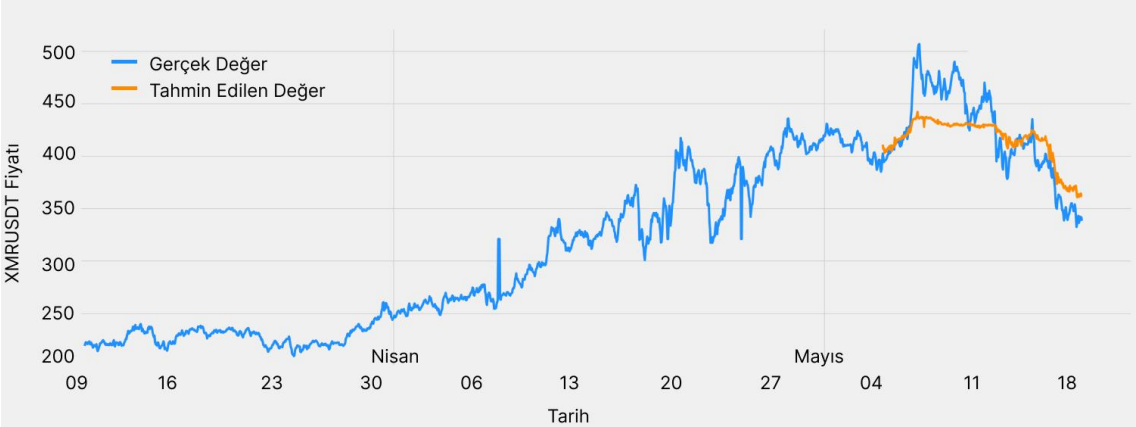
göstermektedir. Bu sonuç, tüm değerlendirme metriklerinde (MAPE, MAE, MSE, R2) tutarlı bir şekilde gözlemlenmektedir. Bu bulgular, ConvLSTM modelinin, Monero veri setinin tahmini için en uygun derin öğrenme modeli olduğunu göstermektedir. Bu analizin devamında, diğer modellerin performansları arasındaki farklar da önemlidir. Örneğin, sıralı veri seti için LSTM modeli, MAPE değeri 10,5940 ile en düşük performansı gösterirken, karışık veri kümesi için CNN-LSTM modeli MAPE değeri 7,1469 ile en düşük performansı sergilemiştir. Bu, veri kümesinin yapısının ve sıralamasının, model performansı üzerinde önemli bir etkisi olabileceğini göstermektedir. Diğer bir önemli nokta, MAPE değerlerine bakıldığında LSTM ve CNN-LSTM modellerinin performanslarının, ConvLSTM modeline kıyasla önemli ölçüde daha düşük olduğudur. Örneğin, sıralı veri kümesi için LSTM modeli, ConvLSTM modeline kıyasla %1,48 daha düşük bir performans sergilemiştir. Karışık veri kümesi için ise CNN-LSTM modeli, ConvLSTM modeline kıyasla %1,10 daha düşük bir performans göstermiştir. Bu, ConvLSTM modelinin, LSTM ve CNN-LSTM modellerine kıyasla önemli bir performans avantajı sağladığını göstermektedir. Son olarak, her bir değerlendirme metriği için modellerin performans sıralaması da tutarlıdır. Hem sıralı hem de karışık veri setleri için, performans sıralaması şu şekildedir: ConvLSTM>CNN>CNN-LSTM>LSTM. Bu sonuç, ConvLSTM modelinin, Monero veri kümesinin tahmininde diğer derin öğrenme modellerine göre daha iyi bir performans sergilediğini doğrulamaktadır.

Bu sonuçlar, Monero veri setinin tahmini için ConvLSTM modelinin en uygun seçim olduğunu doğrulamaktadır. Ancak, veri setinin yapısı ve modelin uygulanma şekli gibi faktörlerin model performansı üzerinde önemli bir etkisi olduğunu da unutmamak gerekir.

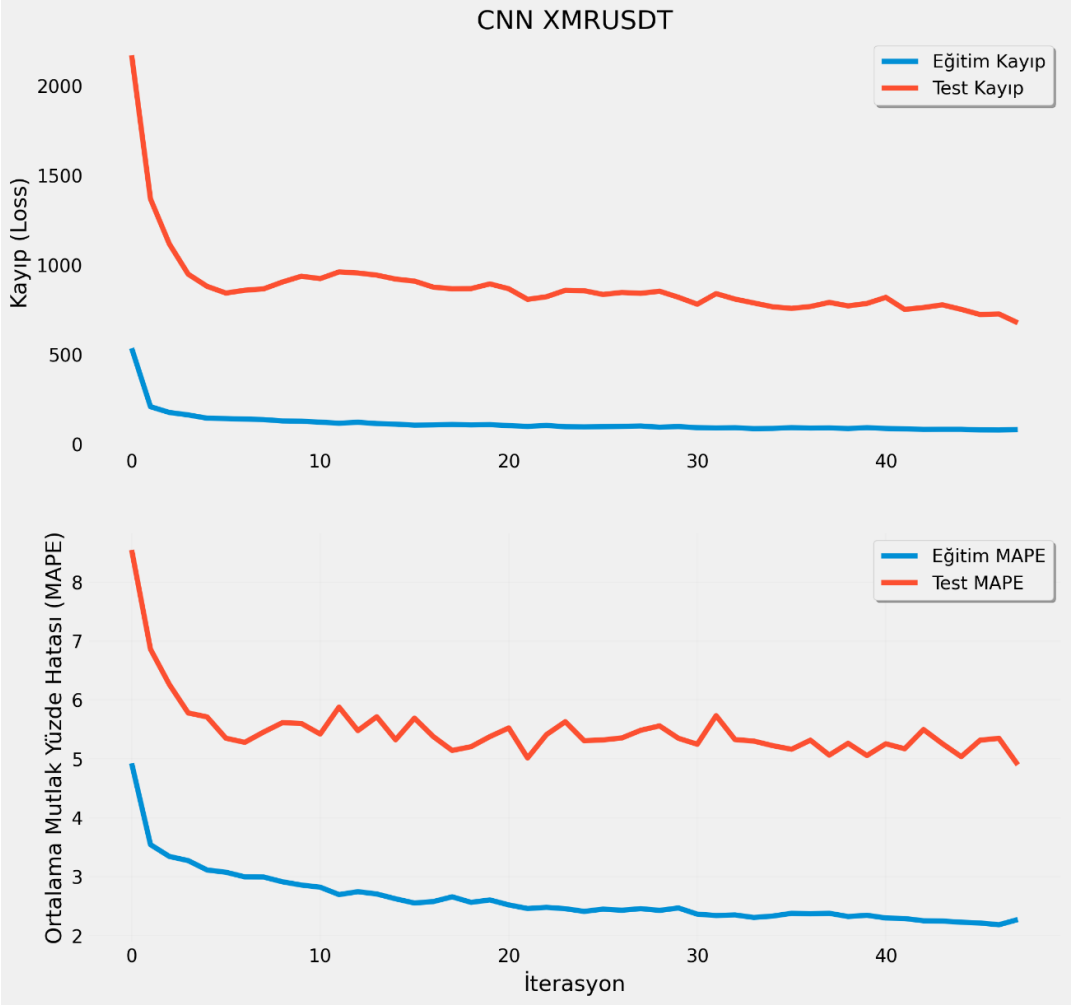
Şekil 6.17, CNN modelinin Monero veri setinin sıralı versiyonunu kullanarak yapılan fiyat tahminlerini görselleştirmektedir. Bu veri seti, 10 Mart 2021 ile 19 Mayıs 2021 tarihleri arasındaki süreyi kapsar.

Şekil 6.18'de Monero veri kümesinin sıralı versiyonu üzerinde CNN modeli ile yapılan fiyat tahmininde deney boyunca gözlemlenen kayıp ve MAPE değeri gösterilmiştir. Şekil 6.18 detaylı incelendiğinde, eğitim kayıp oranı etkin bir şekilde azalırken test kayıp değerinin azalsa da aynı etkinlikte azalmadığı görülmektedir. Bu durum modelin, Bitcoin veri kümesini (sıralı) iyi öğrendiğini fakat aynı oranda iyi bir fiyat tahmini yapamadığını

göstermektedir. MAPE değerlerinin gösterimi ise bu olguyu doğrulamaktadır. Aynı şekilde, Şekil 6.17'de bu yorumu desteklemektedir. Ortalama mutlak yüzde hatası iterasyon boyunca az da olsa düşüş eğilimindedir.

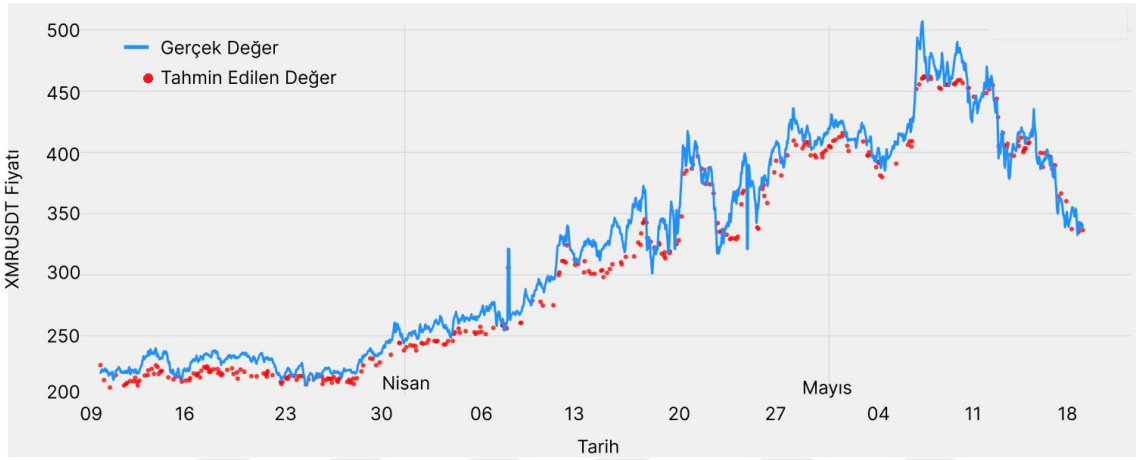


Şekil 6.17. Monero veri kümesinde (sıralı) CNN modeliyle fiyat tahmini



Şekil 6.18. Monero veri kümesinde (sıralı) CNN modeliyle kayıp ve MAPE

Şekil 6.19, CNN modelinin kullanıldığı, Monero veri kümesinin karıştırılmış versiyonuna dayalı fiyat tahminlerini sergilemektedir. Rastgele seçilmiş zaman aralıklarında CNN modeli tarafından tahmin edilen değerlerin, gerçek XMRUSDT değerleriyle ciddi bir şekilde örtüştüğü gözlemlenmektedir. Özellikle, oynaklığın arttığı, fiyat tahmininin zorlaştığı bölgelerde dahi ConvLSTM modelinin, BTCUSDT'nin gerçek fiyat değerlerine yakın tahmin değerleri sağladığı açıkça görülmektedir. Bu bağlamda, yükselen ya da düşen trendlerde de fiyat tahminde oldukça başarılı sonuçlar verdiği söylenebilir.



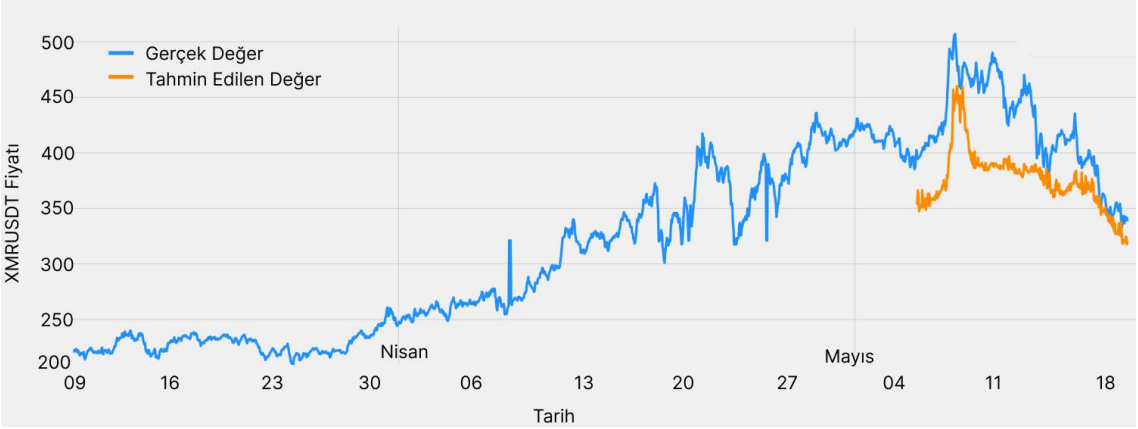
Şekil 6.19. Monero veri kümesinde (karıştırılmış) CNN modeliyle fiyat tahmini

Şekil 6.20, CNN modelinin Monero veri kümesinin karıştırılmış versiyonunda uygulanan fiyat tahminlemesinin, iterasyonlar boyunca deneyimlediği hata MAPE değerlerini sunmaktadır. Detaylı bir inceleme sonucunda hem eğitim setindeki hem de test setindeki hata miktarının iterasyonlar süresince anlamlı bir azalma trendi gösterdiği belirlenmiştir. Bu gözlem, modelin, Monero veri setini (karıştırılmış) etkili bir şekilde öğrendiğini ve güçlü bir fiyat tahminleme kabiliyeti geliştirdiğini kanıtlar niteliktedir. Aynı zamanda, MAPE değerlerinin de iterasyonlar boyunca dalgalı olsa bile azalış gösterdiği görülmektedir. Bu bulgu, hata değerlerine dayanarak yapılan analizlerin doğruluğunu destekler niteliktedir. Ortalama mutlak yüzde hata, iterasyon sürecinde genel bir düşüş trendi sergilemektedir. Verinin karıştırılmasının bir sonucu olarak, iterasyon boyunca belirli bir dalgalanma gösteren hata ve MAPE değerlerine rağmen, eğitim ve test MAPE çıktıları birbirine doğru yakınsamaktadır. Bu, modelin fiyat tahminlemesi ve fiyat yönünün belirlenmesi konusunda oldukça başarılı olduğunu ortaya koyar. Şekil 6.20'nin analizi, CNN modelinin karışık veri setini kullanarak fiyat tahmini yapma ve fiyat trendini belirleme konularında önemli bir yetenek sergilediğini onaylamaktadır.

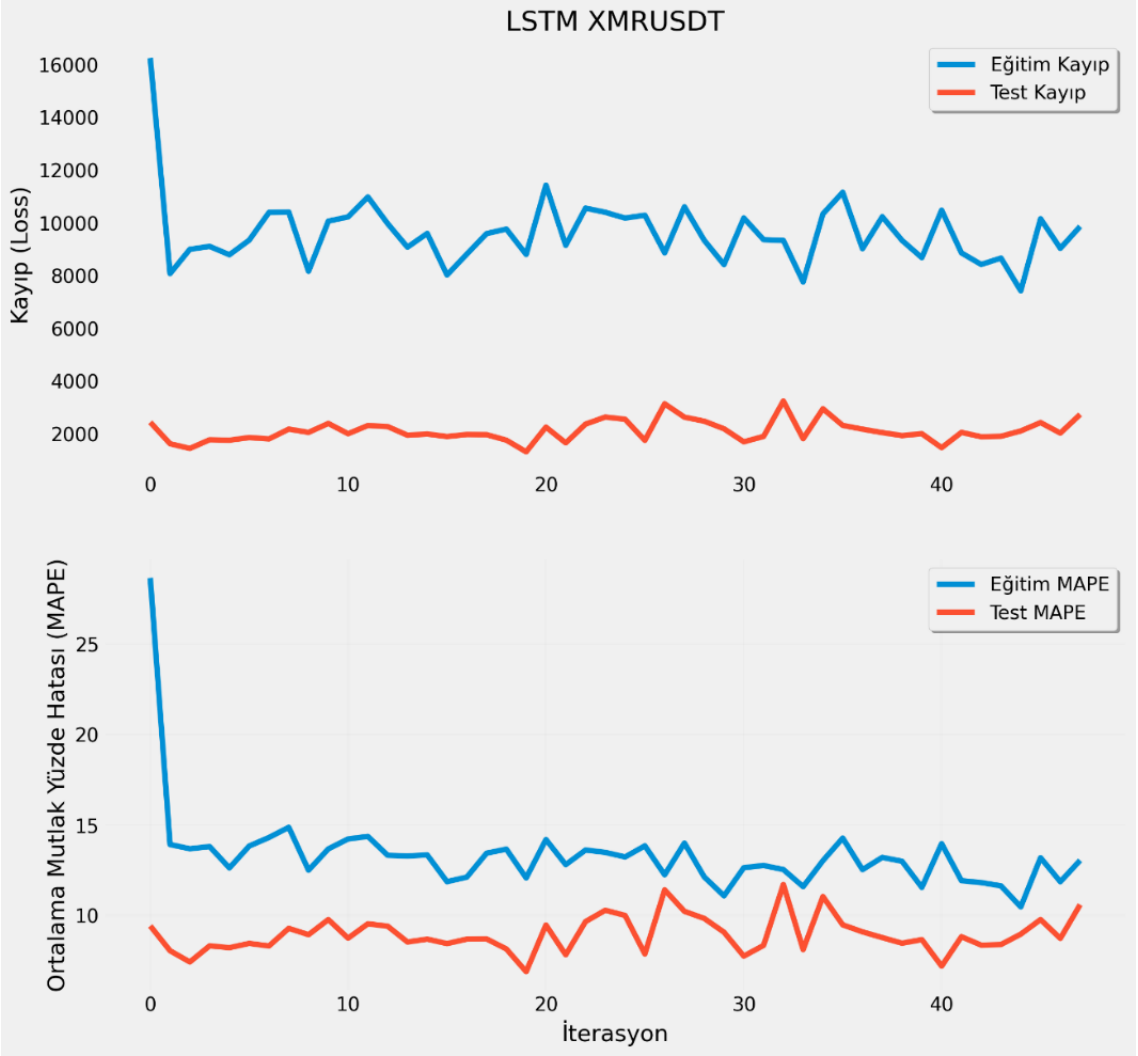
Şekil 6.21'de Bitcoin veri kümesinin sıralı versiyonu kullanılarak LSTM modeli ile yapılan fiyat tahmini sunulmuştur. LSTM modeli ile yapılan tahminler gerçek fiyatı yakalamakta gerektiği kadar başarılı olamamıştır. Fakat yön tahmini konusunda fiyat tahminine göre daha başarılıdır.



Şekil 6.20. Monero veri kümesinde (karıştırılmış) CNN modeliyle kayıp ve MAPE



Şekil 6.21. Monero veri kümesinde (sıralı) LSTM modeliyle fiyat tahmini



Şekil 6.22. Monero veri kümesinde (sıralı) LSTM modeliyle kayıp ve MAPE

Şekil 6.22, LSTM modelinin sıralı Monero veri kümesi üzerinde uyguladığı fiyat tahmininin iterasyon süresince kayıp ve MAPE değerlerini detaylı bir biçimde sunulmaktadır. LSTM modeli öğrenme süreci boyunca gerekli gelişmeyi gösterememiştir. Bu nedenle, test kayıp ve test MAPE değerleri diğer modellere göre yüksek sonuçlar üretmiştir. Bu bağlamda, LSTM modeli, Monero veri kümesi sıralı versiyonunda diğer modellere göre düşük performans göstermiştir. İnceleme sonrası hem eğitim hem de test kayıp değerlerinin iterasyon boyunca yeterli bir düşüş trendi gösteremediğini vurgulamaktadır. Sonuç olarak, model öğrenme sürecinin istikrarlı bir şekilde sürdürememiş ve hedeflenen sonuçlara tam manasıyla ulaşamamıştır.

Şekil 6.23, LSTM modelinin, karıştırılmış Monero veri seti üzerinde gerçekleştirilen fiyat tahminlemelerini sergilemektedir. LSTM modeli tarafından oluşturulan tahminler, gerçek

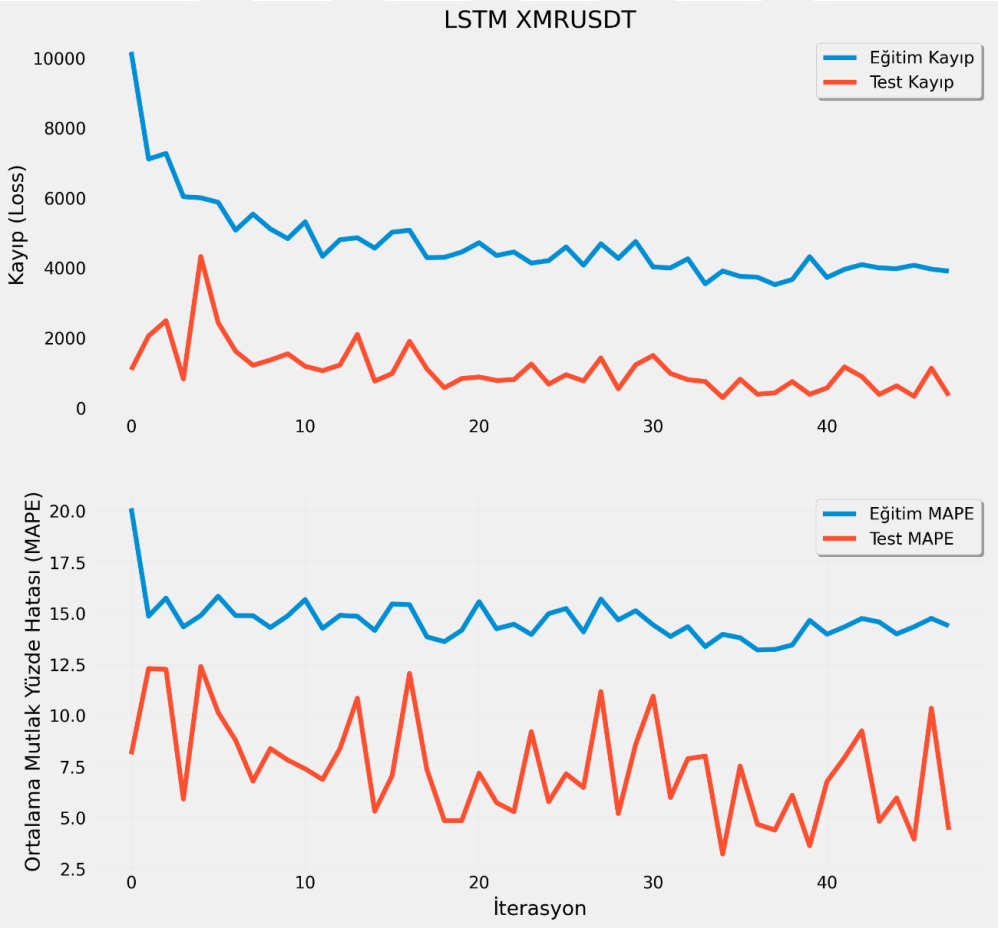
XMRUSDT değerleri ile ciddi bir uyum sergilemektedir. Ancak, uygun bir tahminleme trendi olsa da bazı aykırı değerlerin olduğu gözlenmektedir. Bu, modelin genel eğilimleri öğrendiği, ancak aşırı değerlerin tahmininde bazı zorluklar yaşadığı anlamına gelebilir. Modelin öğrenme sürecinin etkili bir biçimde ilerlediğini ve genel olarak fiyat tahmin kapasitesinin oldukça gelişmiş olduğunu ifade etmektedir. Bu sonuç, modelin genel veri özelliklerini öğrenmeyi başardığını ve bu özellikler üzerinden doğru fiyat tahminleri yapabildiğini ispatlar niteliktedir. Ek olarak, LSTM modelinin XMRUSDT'nin fiyat yönünü belirleme kabiliyeti oldukça başarılı bir performans göstermektedir. Fiyat yönünün doğru bir biçimde tahmin edilmesi, finansal piyasalarda faaliyet gösteren aktörler açısından hayati öneme sahip bir faktördür. Bu durum, modelin sadece fiyatları tahmin etme yeteneğine sahip olmadığını, aynı zamanda fiyat hareketlerinin genel yönünü de etkin bir biçimde belirleme kapasitesine sahip olduğunu ifade etmektedir. Bu bulgular, LSTM modelinin karıştırılmış Monero veri kümesi üzerinde fiyat tahmini konusunda etkileyici bir performans sergilediğini teyit etmektedir. Ancak, modelin karışık veri setleri üzerindeki genelleme yeteneği ve aşırı değerlerin tahminindeki zorluklar da dikkate alınmalıdır. Sonuç olarak, modelin genel olarak gerçek dünya uygulamalarında kullanım için uygun olduğunu, ancak aşırı değerlerin tahmininde daha fazla iyileştirme gerektirebileceğini göstermektedir.



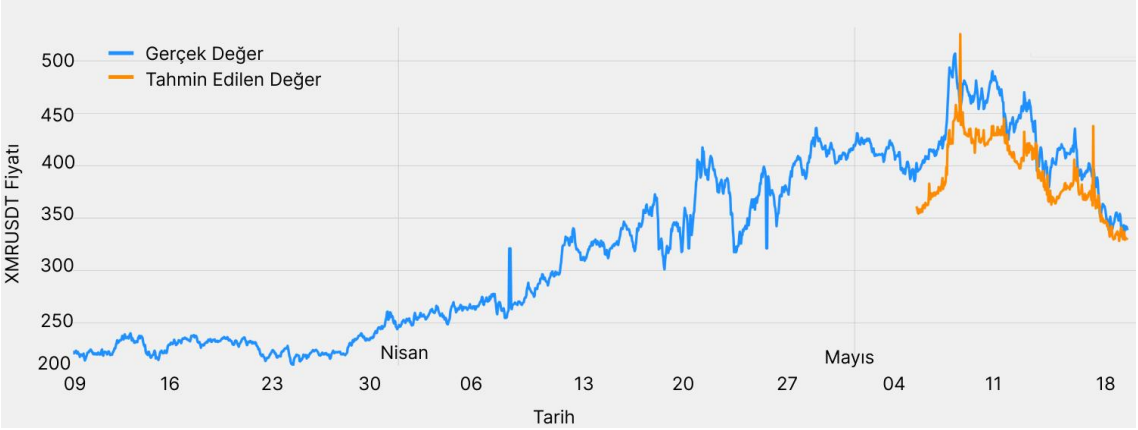
Şekil 6.23. Monero veri kümesinde (karıştırılmış) LSTM modeliyle fiyat tahmini

Şekil 6.24, LSTM modelinin, karıştırılmış Monero veri seti üzerinde yapılan fiyat tahminlerinin iterasyon boyunca nasıl bir değişim sergilediğini görsel olarak sunmaktadır. Bu görsel materyal, eğitim ve doğrulama süreçlerindeki kayıp değerlerinin yanı sıra Ortalama Mutlak Yüzde Hata değerlerinin evrimini de detaylı bir biçimde ortaya

koymaktadır. Grafiğin incelenmesi sonucunda hem eğitim hem de doğrulama aşamalarında kayıp değerlerinin iterasyon sürecinde özellikle 35'inci iterasyona kadar azalmaya meyilli olduğu tespit edilmiştir. Bu gözlem, LSTM modelinin karıştırılmış Monero veri seti üzerinde verimli bir öğrenme süreci yürüttüğünü ve fiyat tahminlemelerinde etkin bir performans sergilediğini göstermektedir. Modelin karışık veri setleri üzerinde bile genelleme kapasitesinin sağlam olduğunu ve veri özelliklerini etkili bir biçimde öğrendiğini ifade etmektedir. Ayrıca, MAPE değerlerinin de iterasyon süreci boyunca düşüş eğiliminde olduğu belirlenmiştir. Bu durum, modelin tahmin hatalarını başarıyla minimize ettiğini ve fiyat tahmin sonuçlarının gerçek XMRUSDT değerlerine giderek daha yakın hale geldiğini göstermektedir. Bu bulgular, eğitim ve doğrulama aşamalarında kayıp değerlerinin azalmasının doğruluğunu teyit etmektedir. Karışık veri seti kullanılarak yapılan bu analiz, modelin genelleme yeteneğinin güçlü olduğunu ve verinin karıştırılmasına rağmen tahminlerin tutarlı bir doğrulukta olduğunu ifade etmektedir.



Şekil 6.24. Monero veri kümesinde (karıştırılmış) LSTM modeliyle kayıp ve MAPE

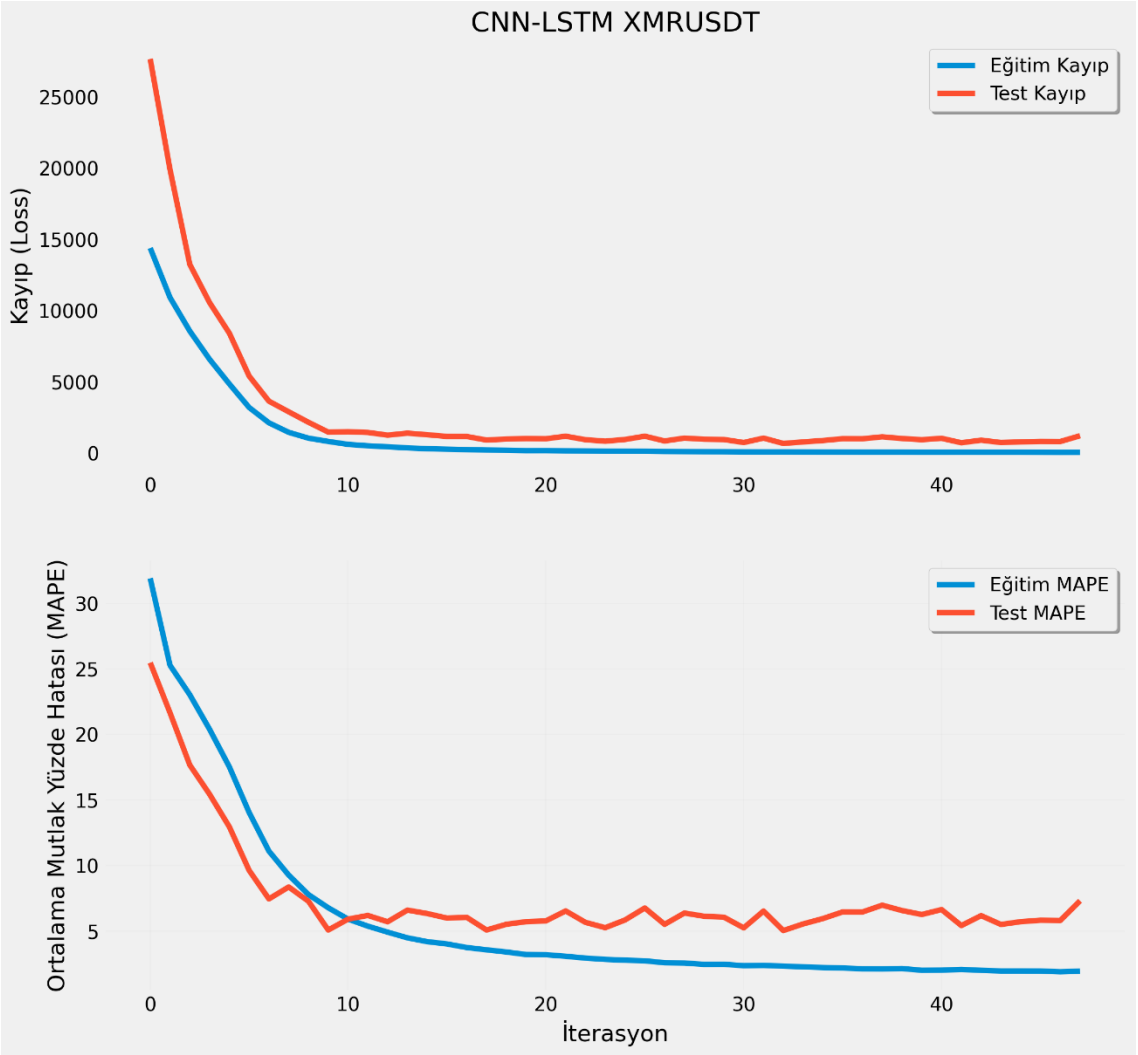


Şekil 6.25. Monero veri kümesinde (sıralı) CNN-LSTM modeliyle fiyat tahmini

Şekil 6.25'te, CNN-LSTM modeli ile gerçekleştirilen fiyat tahminlerinin, Monero veri setinin sıralı versiyonu üzerindeki performansını görsel olarak sunmaktadır. Bu hibrit modelin sonuçları analiz edildiğinde, CNN ve ConvLSTM modelinin sağladığı tahmin sonuçlarına göre başarı seviyesinin nispeten daha az olduğu tespit edilmiştir. Özellikle, fiyatların tepe yapıp büyük bir düşüş eğilimi sergilediği zaman dilimlerinde, bu modelin tahminlerinin gerçek değerlerden önemli ölçüde yüksek olduğu belirlenmiştir. Bu durum, modelin fiyat hareketlerini etkin bir şekilde tahmin etme kapasitesinde belirli bölgelerde zayıflıklar olduğunu göstermektedir. Modelin yüksek volatiliteli düşüş trendlerini etkili bir şekilde yönetme kapasitesinin belirli bir sınırlamaya sahip olduğunu ve bu tür durumlarda tahmin etme kabiliyetinin daha az güvenilir olduğunu belirtmektedir. Bu, özellikle yüksek oynaklık dönemlerinde, modelin fiyat tahmininde daha dikkatli bir yaklaşım gerektirdiğini göstermektedir.

Şekil 6.26'da Monero veri kümesinin sıralı biçimi kullanılarak CNN-LSTM modeli ile elde edilen fiyat tahmin sonuçları ve bu süreçte iterasyon bazında takip edilen kayıp ve MAPE değerleri aktarılmaktadır. Şekil 6.26'nın detaylı analizi hem eğitim setindeki kayıp hem de test setindeki kayıp değerlerinin özellikle 10'uncu iterasyona kadar, kademeli olarak azaldığını göstermektedir. Bu gözlem, CNN-LSTM modelinin, Monero veri kümesini (sıralı) başarılı bir şekilde öğrendiğini ve kabul edilebilir bir fiyat tahmini yaptığını ortaya koymaktadır. Bu durumu doğrulayan bir diğer faktör ise, MAPE değerlerinin 10'uncu iterasyona kadar kayıp değerine paralel bir düşüş trendi göstermesidir. Bu trend, eğitim ve test MAPE çıktılarının birbirine yakınlaşma eğiliminde olduğunu da göstermektedir. Bu bulguların ışığında, CNN-LSTM modelinin, Monero

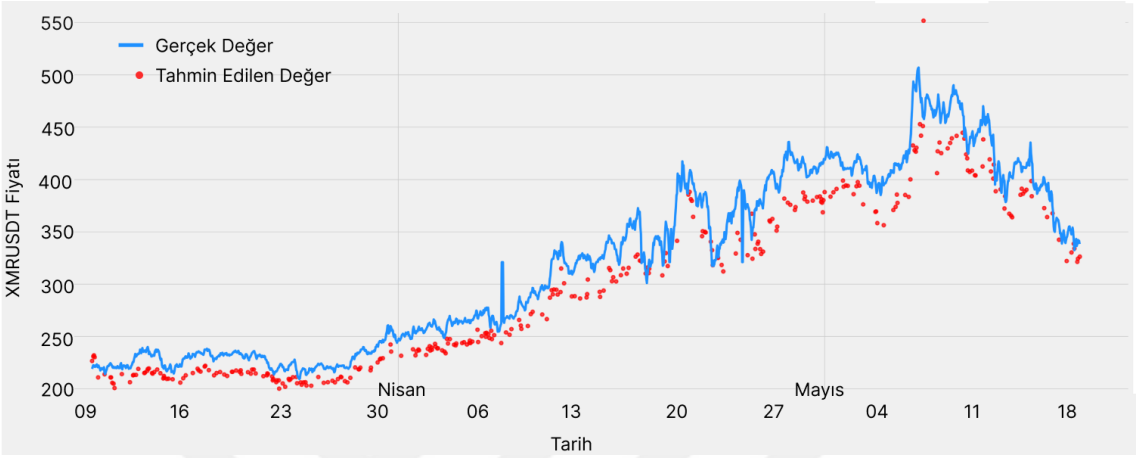
veri kümesi üzerinde fiyat tahmini ve fiyat yönünün belirlenmesi konularında kabul edilebilir bir başarı sağladığı çıkarımı yapılabilmektedir.



Şekil 6.26. Monero veri kümesinde (sıralı) CNN-LSTM modeliyle kayıp ve MAPE

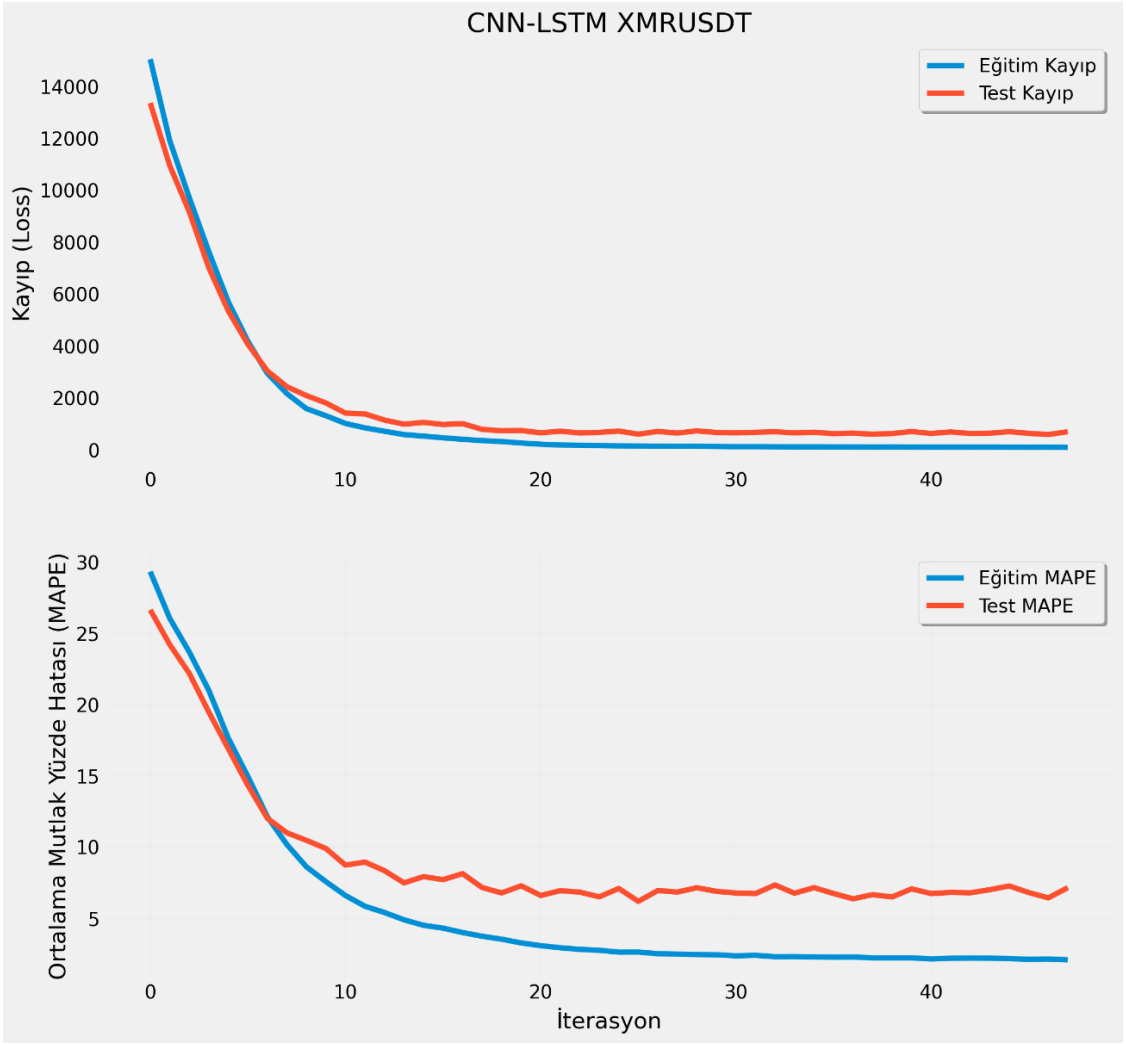
Şekil 6.27, CNN-LSTM modeli kullanılarak gerçekleştirilen fiyat tahminlerinin, karıştırılmış Monero veri seti üzerindeki uygulama sonuçlarını sunmaktadır. CNN-LSTM modeli tarafından üretilen tahminler, gerçek XMRUSDT değerleri ile karşılaştırıldığında, diğer model tahminlerine nazaran daha az uyum gösteren bir trend oluşturmaktadır. Genel olarak, modelin fiyat hareket yönünü belirleme yeteneği kısmen etkin gibi görünse de bazı bölümlerde aykırı değerlerin varlığı belirgin olarak dikkat çekmektedir. Bu, modelin genel piyasa trendlerini etkin bir şekilde öğrenip modellemeye yetkin olduğunu, fakat yükselişlerin fazla olduğu bölümlerde çok daha yüksek aykırı fiyat tahmininde bulunabilmektedir. Bu durum, modelin karıştırılmış veri setleri üzerindeki genelleme

kabiliyetinin, özellikle aşırı değerlerin tahmininde, sınırlamaları olduğunu belirtmektedir. Sonuç olarak, volatilitenin yüksel olduğu finansal piyasalar gibi aşırı değerlerin sıkça gözlendiği alanlarda, modelin performansının ve güvenilirliğinin doğru bir şekilde değerlendirilmesi gerekmektedir.

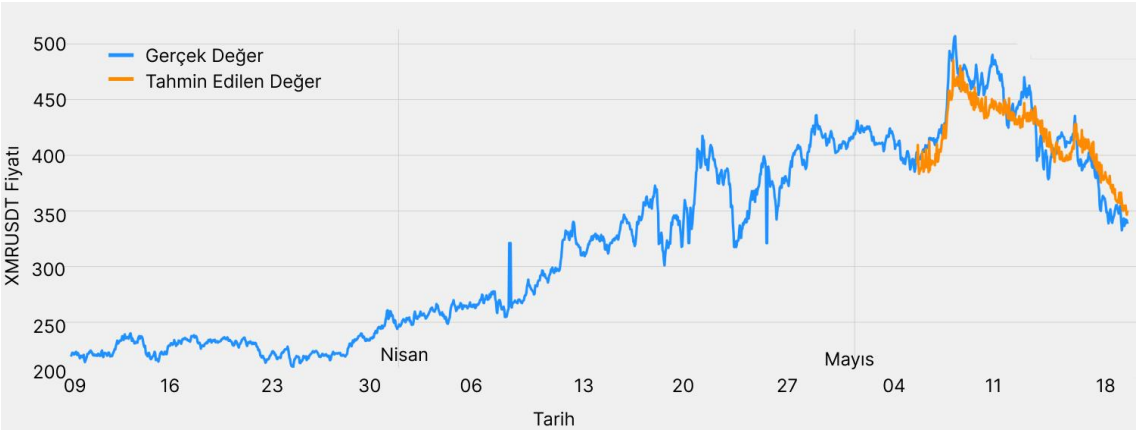


Şekil 6.27. Monero veri kümesinde (karıştırılmış) CNN-LSTM modeliyle fiyat tahmini

Şekil 6.28'de, CNN-LSTM modelinin karışık Monero veri kümesi üzerinde uyguladığı fiyat tahmininin iterasyon süresince kayıp ve MAPE değerlerini detaylı bir biçimde sunulmuştur. Detaylı inceleme sonucunda, hem eğitim hem de test kayıp değerlerinin 8'inci iterasyona kadar belirgin bir düşüş trendi gösterdiğini açığa çıkmaktadır. Bu, modelin öğrenme sürecinin 8'inci iterasyona kadar istikrarlı bir biçimde geliştiği ve hedeflenen sonuçlara doğru ilerlediği gösterilmektedir. Fakat, ilerleyen iterasyonlar boyunca, CNN-LSTM modelinin karışık Monero veri kümesini etkin bir biçimde öğrenemediği ve hedeflene tam olarak doğru bir fiyat tahmini yapamadığı sonucu görülmüştür. MAPE değerlerinin sunumu, bu durumu daha da güçlendirmektedir. Şekil 6.28'deki MAPE değerlerinin özellikle 10'uncu iterasyon sonraki istenen ölçüde düşüş göstermemesi, modelin tahminlerinde 10'uncu iterasyon sonrası kayda değer bir gelişme olmadığını teyit etmektedir. Son olarak, eğitim MAPE değerleri iterasyon boyunca düşse de test MAPE değerleri arzulanan ölçüde düşmemiştir. Böylece modelin tahmin performansının uygulanan iterasyon boyunca tam anlamıyla eğitim MAPE değerlerine yakınsayamadığını göstermektedir.



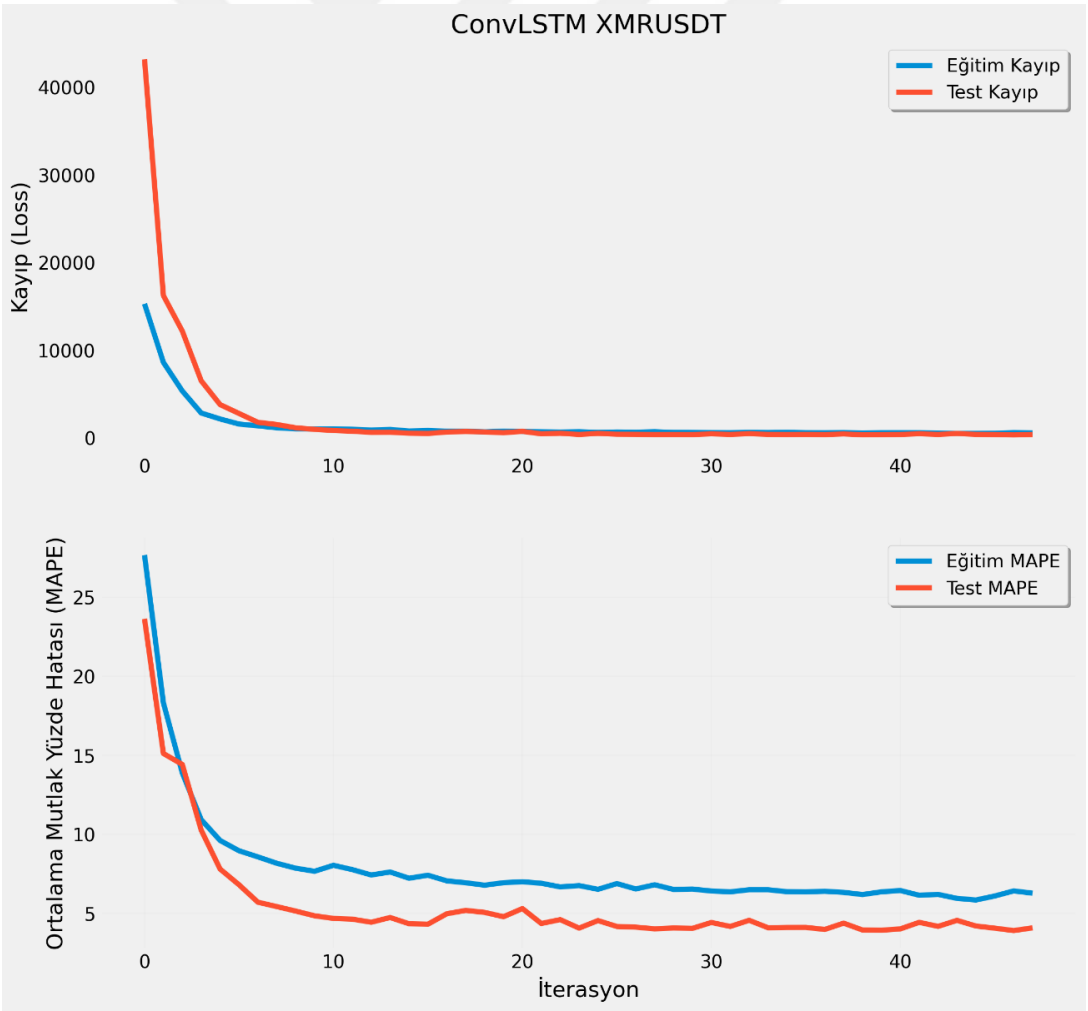
Şekil 6.28. Monero veri kümesinde (karıştırılmış) CNN-LSTM modeliyle kayıp ve MAPE



Şekil 6.29. Monero veri kümesinde (sıralı) ConvLSTM modeliyle fiyat tahmini

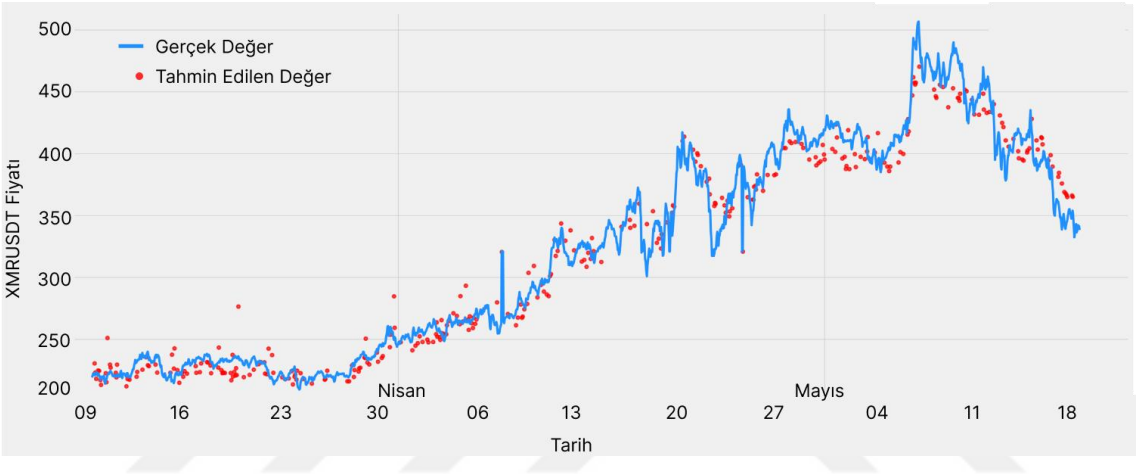
Şekil 6.29'da Monero veri kümesinin sıralı versiyonu kullanılarak ConvLSTM modeli ile yapılan fiyat tahmini sunulmuştur. Modelin tahmin ettiği değerler, gerçek XMRUSDT değeri ile karşılaştırıldığında değerlerin örtüşebildiği görülmüştür. Ayrıca, yapılan değerlendirmede modelin tahmin ettiği XMRUSDT fiyatlarının özellikle ana trend yönünü göstermede çok başarılı olduğu gözlemlenmektedir. ConvLSTM modeliyle yapılan fiyat tahminlerinin performansı Monero sıralı veri kümesinde yapılan deneylerde en iyi sonuçları üretmiştir.

Şekil 6.30'da ConvLSTM modelinin Monero veri kümesinin sıralı versiyonu üzerinde yapılan fiyat tahminlerinin iterasyon bazında kayıp ve MAPE değerleri gösterilmiştir. Eğitim ve test veri kümesi için hem kayıp hem de MAPE değerleri hedeflenen seviyelerde düşmüş ve birbirine yakınsamıştır. Bu bağlamda, ConvLSTM modeli eğitim süresince iyi öğrenmiş ve test aşamasında iyi fiyat tahminleri üretmiştir.



Şekil 6.30. Monero veri kümesinde (sıralı) ConvLSTM modeliyle kayıp ve MAPE

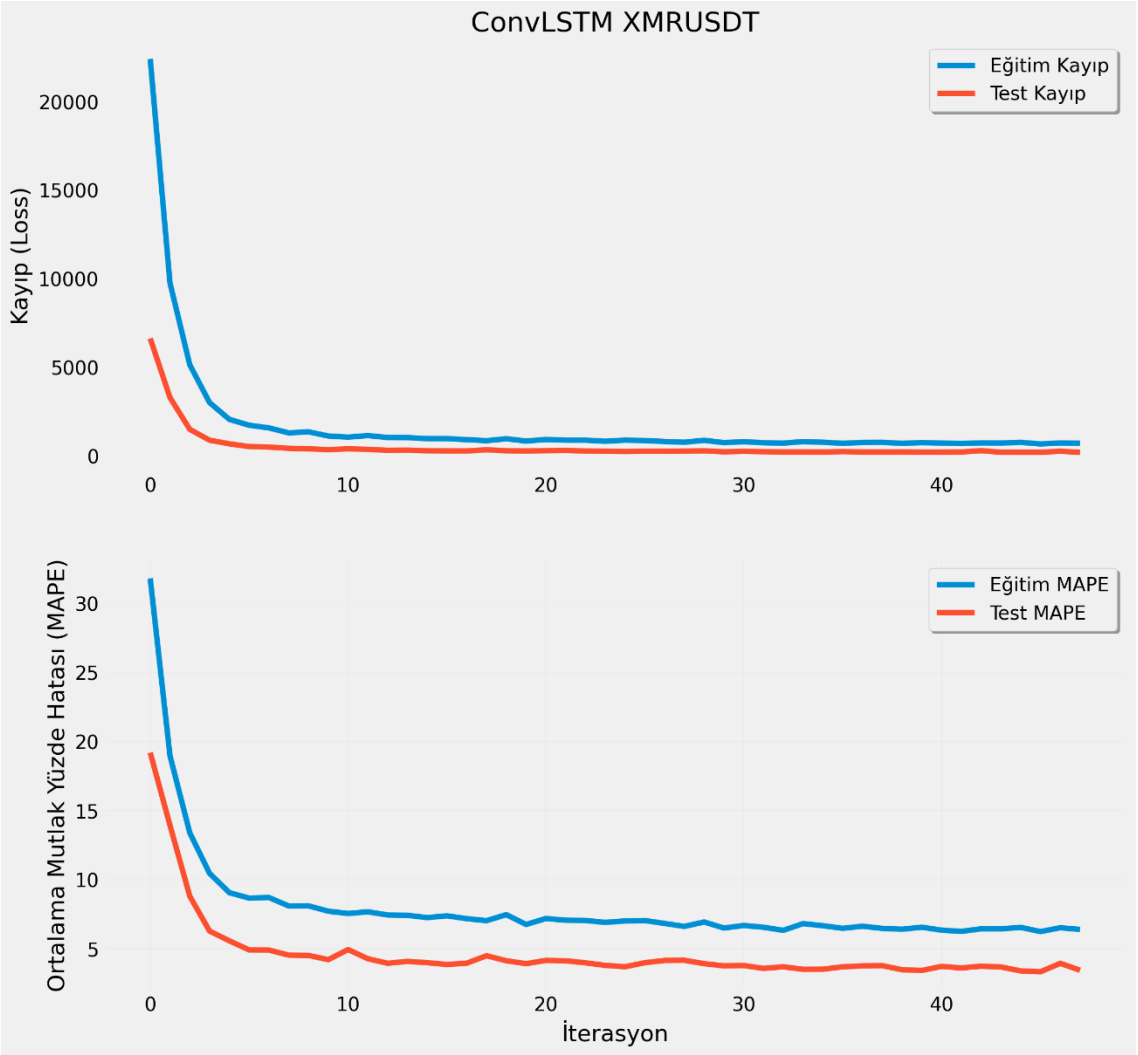
Şekil 6.31’de, ConvLSTM modeliyle Monero veri kümesinde (karıştırılmış) XMRUSDT’nin gerçek değeri ve model tarafından çıktı olarak verilen XMRUSDT fiyat tahminleri sunulmaktadır. Bu grafik incelendiğinde, ConvLSTM modelinin tahmin ettiği fiyat değerlerinin gerçek fiyat değerlerle başarılı bir uyum içinde olduğu gözlemlenmektedir. Hem oynaklığın az olduğu hem de oynaklığın fazla olduğu bölgelerdeki fiyat tahmin performansı oldukça kuvvetlidir. Yükseliş ve düşüş trendlerinde de başarım oranı yüksektir. Bu bağlamda, fiyatların yönünü tayin etmede de ciddi bir başarı sağlamıştır



Şekil 6.31. Monero veri kümesinde (karıştırılmış) ConvLSTM modeliyle fiyat tahmini

Şekil 6.32, ConvLSTM modelinin, Monero veri setinin karıştırılmış versiyonu üzerinde yapılan fiyat tahminleme sürecinde, hata miktarı ve MAPE değerlerinin iterasyonlar boyunca nasıl değiştiğini detaylı bir şekilde sunmaktadır. Hem eğitim setindeki hem de test setindeki hata oranlarının, iterasyonlar ilerledikçe belirgin bir azalma trendi sergilediği dikkat çekmektedir. Bu durum, ConvLSTM modelinin Monero veri setinin karıştırılmış versiyonunu etkin bir biçimde öğrendiğini ve güçlü bir fiyat tahminleme yeteneği geliştirdiğini belirgin bir şekilde göstermektedir. Ayrıca, MAPE değerlerinin de iterasyonlar boyunca sürekli bir azalış eğilimi gösterdiği görülmektedir. Bu gözlem, hata değerlerinin analizi temelinde yapılan değerlendirmelerin doğruluğunu teyit eder niteliktedir. Bu, modelin fiyat tahminleme sürecindeki hatalarını sürekli olarak azaltmayı başardığını ve dolayısıyla tahminlerinin gerçek değerlere daha yakın hale geldiğini göstermektedir. Ortalama mutlak yüzde hata, genel anlamda iterasyon sürecinde bir düşüş eğilimi sergilemektedir. Bu durum, modelin fiyat tahmini ve fiyat yönünün belirlenmesi konusunda önemli bir başarı oranı elde ettiğini gösterir. Bu analiz sonuçları, ConvLSTM

modelinin, karıştırılmış veri setini kullanarak fiyat tahminleme ve fiyat trendini belirleme konularında belirgin bir yetenek sergilediğini net bir şekilde ortaya koymaktadır.



Şekil 6.32. Monero veri kümesinde (karıştırılmış) ConvLSTM modeliyle kayıp ve MAPE

6.3.Stellar Veri Kümesi ile Elde Edilen Sonuçlar

Bu bölümde, Stellar'ın saatlik fiyat hareketlerinin sıralı ve karışık versiyonlarına dayalı olarak CNN, LSTM, CNN-LSTM ve ConvLSTM modellerinin performansları incelenmiştir. Bu değerlendirmeler, MAPE, MAE, MSE ve R2 metrikleri kullanılarak gerçekleştirilmiştir.

Tablo 6.5'te, Stellar veri kümesi üzerinde (sıralı) uygulanan model performanslarına tablo sunulmuştur.

Tablo 6.5. Stellar veri kümesi (sıralı) kullanarak elde edilen model performansları

	CNN	**LSTM**	**CNN-LSTM**	**ConvLSTM**
MAPE	6,3493	6,0916	8,5584	1,6220
MAE	0,4197	0,4121	0,5632	0,1080
MSE	0,1959	0,2532	0,3692	0,0204
R^2	0,6807	0,6885	0,5325	0,9043

Tablo 6.5'te yer alan sonuçlar incelendiğinde, en düşük MAPE değerinin 1,6220 ile ConvLSTM modeli tarafından sağlandığı belirlenmiştir. Bu bulgu, tahmin performansı açısından en üstün modelin ConvLSTM olduğunu ortaya koymaktadır. MAPE değerlerine bakıldığında, ConvLSTM modelinin performansını sırasıyla 6,0916 ile LSTM, 6,3493 ile CNN ve 8,5584 ile CNN-LSTM modelleri izlemektedir. CNN-LSTM modeli, Stellar veri kümesi (sıralı) için fiyat tahmininde en düşük performansı sergileyen model olarak belirlenmiştir. ConvLSTM modeli, MAPE, MSE ve MAE metrikleri dikkate alındığında, diğer modellere göre en belirgin iyileşmeyi sağlamıştır. Tablo 6.5.'te sunulan MAPE değerlerine dayanarak, tahmin performansı bakımından her bir derin öğrenme modeli şu şekilde sıralanabilir: ConvLSTM>LSTM> CNN>CNN-LSTM. Bu sıralama MSE, MAE ve R2 metriklerini kullanarak da doğrulanabilmektedir.

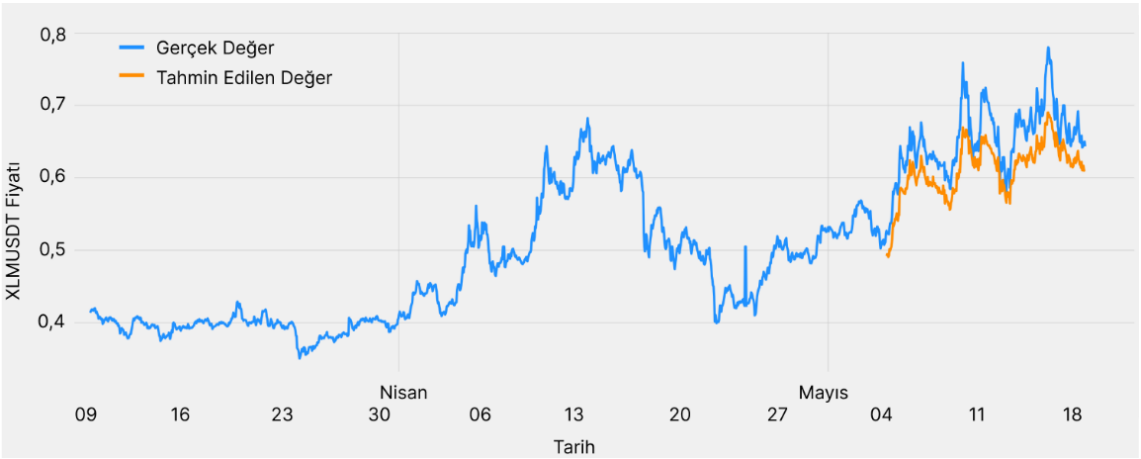
Tablo 6.6. Stellar veri kümesi (karıştırılmış) kullanarak elde edilen model performansları

	CNN	**LSTM**	**CNN-LSTM**	**ConvLSTM**
MAPE	4,6147	4,4437	3,1149	1,4741
MAE	0,2400	0,2161	0,1696	0,0789
MSE	0,0813	0,0711	0,0521	0,0128
R^2	0,9231	0,9340	0,9517	0,9893

Tablo 6.6'daki sonuçlar incelendiğinde, en düşük MAPE değerinin 1,4741 ile ConvLSTM modeli tarafından sağlandığı belirlenmiştir. Bu bulgu, ConvLSTM modelinin karıştırılmış veri setinde en üstün tahmin performansını sunduğunu göstermektedir. MAPE değerlerine bakıldığında, ConvLSTM modelinin performansını sırasıyla 3,1149 ile CNN-LSTM, 4,4437 ile LSTM ve 4,6147 ile CNN modellerinin takip ettiği görülmektedir. CNN modeli, Stellar veri kümesi (karıştırılmış) üzerinde fiyat tahmininde en düşük performansı sergileyen model olarak ortaya çıkmıştır. CNN-LSTM ve ConvLSTM modellerinin performansları, MAPE değerleri açısından karşılaştırıldığında,

ConvLSTM modeli belirgin bir iyileşme göstermiştir. Bu iyileşme, CNN-LSTM modeline göre %58 oranında bir performans artışı olarak ifade edilebilir. Ayrıca, LSTM modeli ile ConvLSTM modelinin performansı karşılaştırıldığında, ConvLSTM modeli %66 oranında bir performans artışı sağlamıştır. CNN ve ConvLSTM modellerinin tahmin sonuçları MAPE değerlerine bakıldığında ise ConvLSTM modeli, %68 oranında bir performans artışı sağlamıştır. Tablo 6.6'da sunulan MAPE değerlerine dayanarak, tahmin performansı bakımından her bir derin öğrenme modeli şu şekilde sıralanabilir: ConvLSTM>CNN-LSTM>LSTM>CNN. Bu sıralama, MSE, MAE ve R2 metrikleri kullanılarak da doğrulanabilir. Sonuç olarak, bu analiz, sıralı ve karıştırılmış Stellar veri kümesi üzerinde CNN, LSTM, CNN-LSTM ve ConvLSTM modellerinin performanslarını karşılaştırmıştır. Genel olarak, ConvLSTM modeli, diğer üç modelin performansını her iki veri seti üzerinde de aşmıştır. Bu bulgular, gelecekteki çalışmalar için ConvLSTM modelinin Stellar fiyat tahminlerinde özellikle kullanışlı olabileceğini göstermektedir.

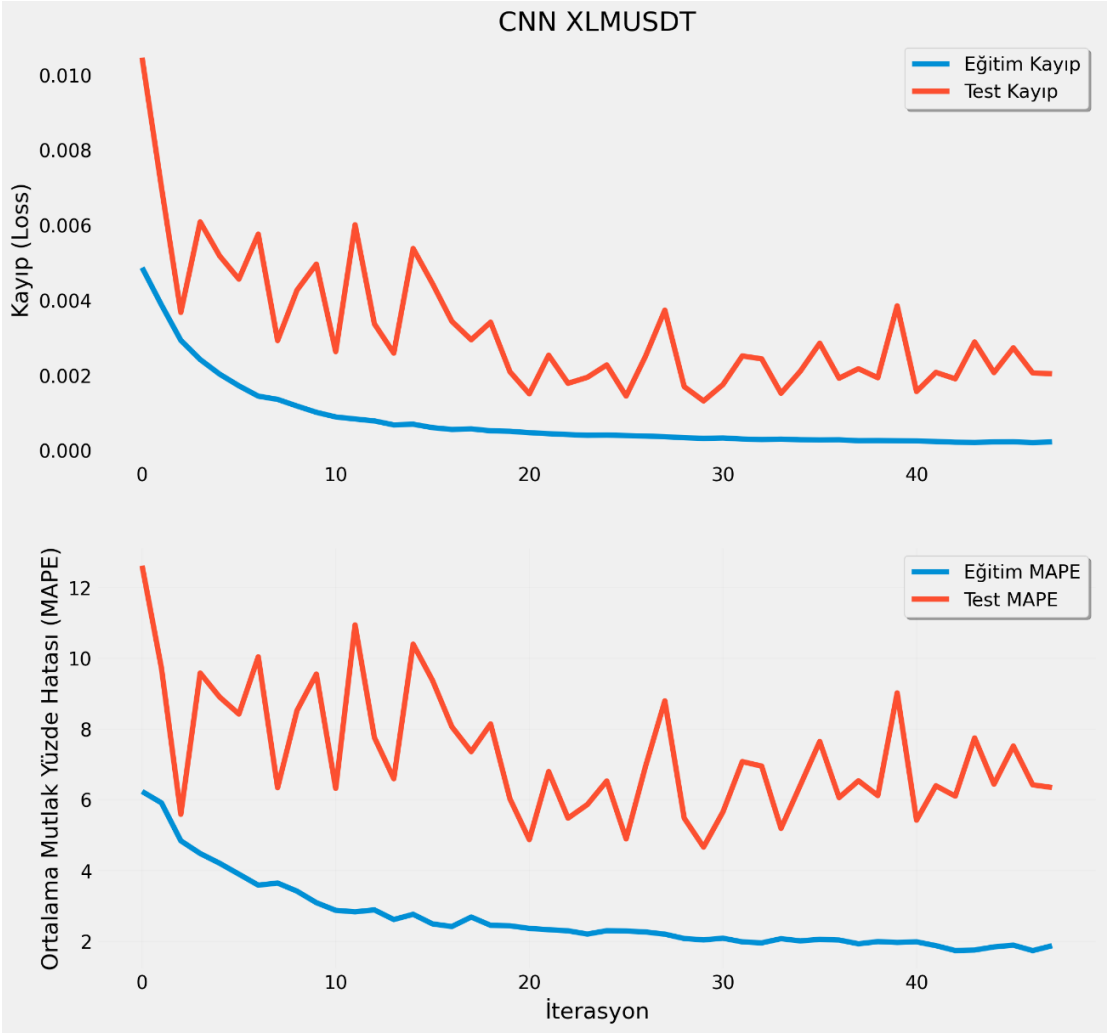
Şekil 6.33'te Stellar veri kümesinin sıralı versiyonu kullanılarak CNN modeli ile yapılan fiyat tahmini sunulmuştur. Yaklaşık iki haftalık gerçek XLMUSDT değeri, CNN modeliyle elde edilen tahmin değeriyle örtüşebildiği ve XLMUSDT'nin fiyat tahmininde yönünü belirlemede başarılı olduğu görülmektedir.



Şekil 6.33. Stellar veri kümesinde (sıralı) CNN modeliyle fiyat tahmini

Şekil 6.33 incelendiğinde hem eğitim kayıp hem de test kayıp değerinin iterasyon boyunca azaldığı görülmektedir. Bu durum modelin, Stellar veri kümesi (sıralı) hem iyi

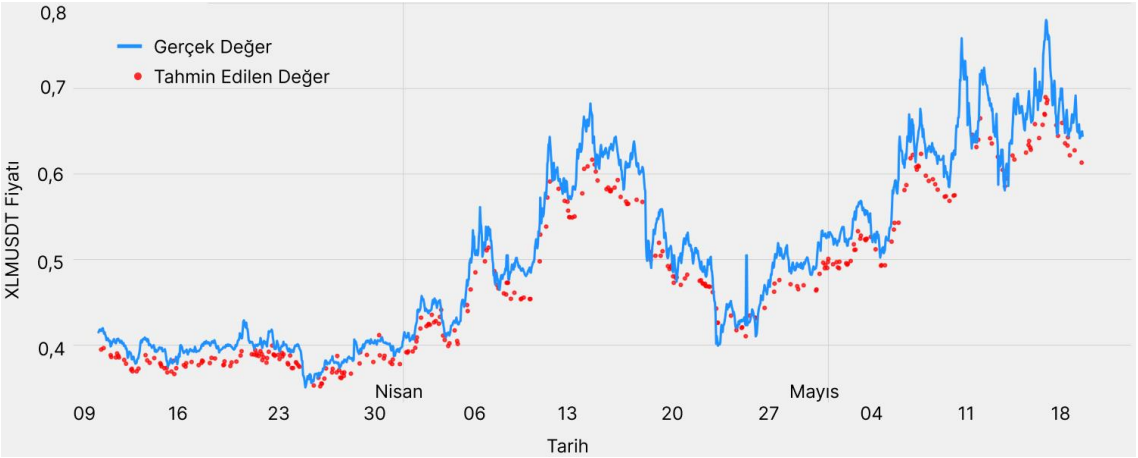
öğrendiğini hem de iyi bir fiyat tahmini yaptığını göstermektedir. MAPE değerlerinin gösterimi ise bu olguyu doğrulamaktadır. MAPE iterasyon boyunca düşüş eğilimindedir.



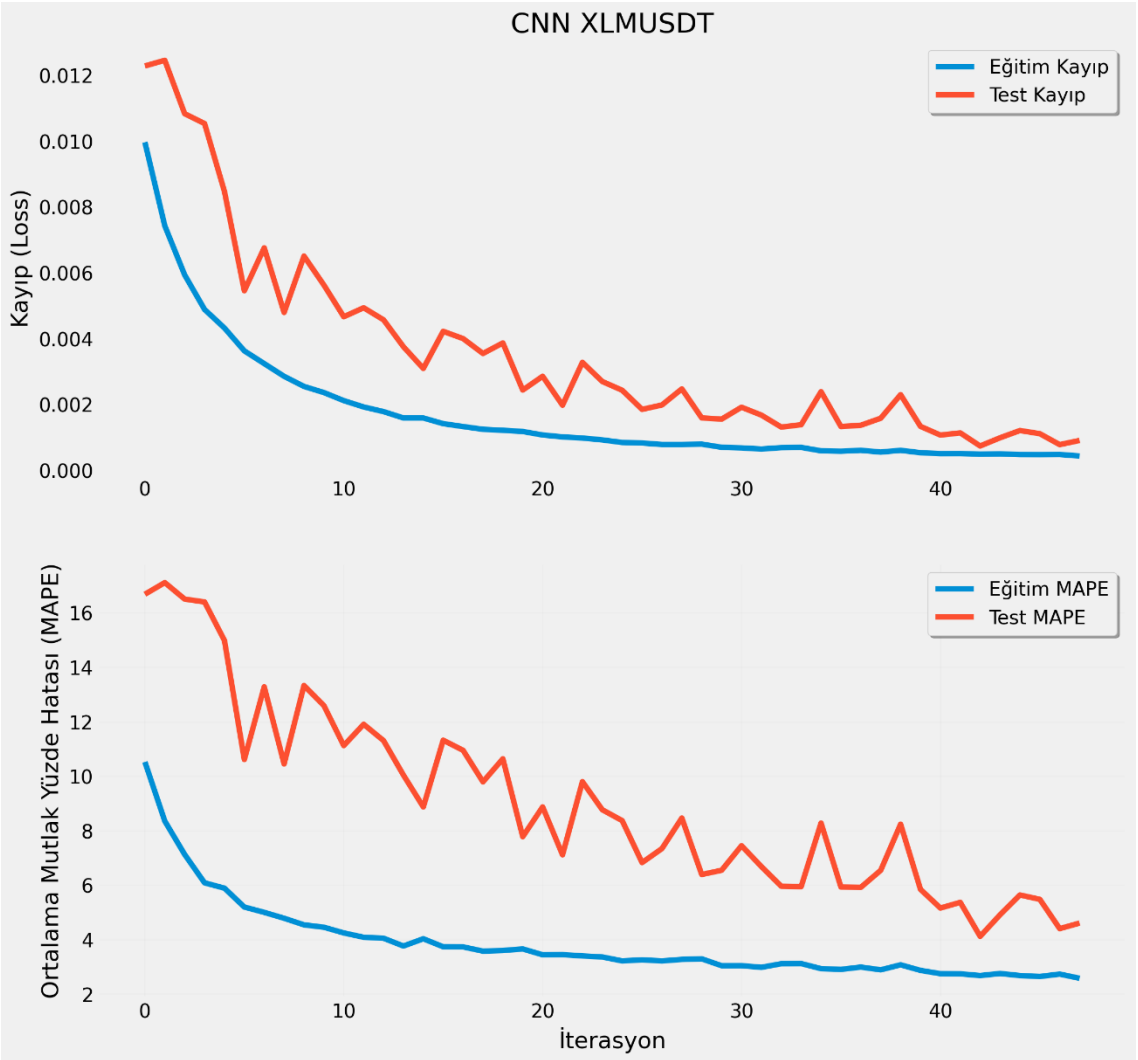
Şekil 6.34. Stellar veri kümesinde (sıralı) CNN modeliyle fiyat tahmini

Şekil 6.34'te Stellar veri kümesinin sıralı versiyonu üzerinde CNN modeli ile yapılan fiyat tahmininde iterasyon boyunca gözlemlenen kayıp ve MAPE değeri gösterilmiştir. Genel olarak test süresince iterasyonlar boyunca hem kayıp hem de MAPE değerleri dalgalanma göstermiştir. Kayıp ve MAPE değerlerindeki düşüş trendi gözlemlenebilmektedir.

Şekil 6.35.'te, CNN modelinin kullanıldığı, Stellar veri kümesinin karıştırılmış versiyonuna üzerindeki fiyat tahminlerini sergilemektedir. Rastgele seçilmiş zaman aralıklarında CNN modeli tarafından tahmin edilen değerlerin, gerçek XLMUSDT değerleriyle ciddi bir şekilde örtüştüğü gözlemlenmektedir.



Şekil 6.35. Stellar veri kümesinde (karıştırılmış) CNN modeliyle fiyat tahmini



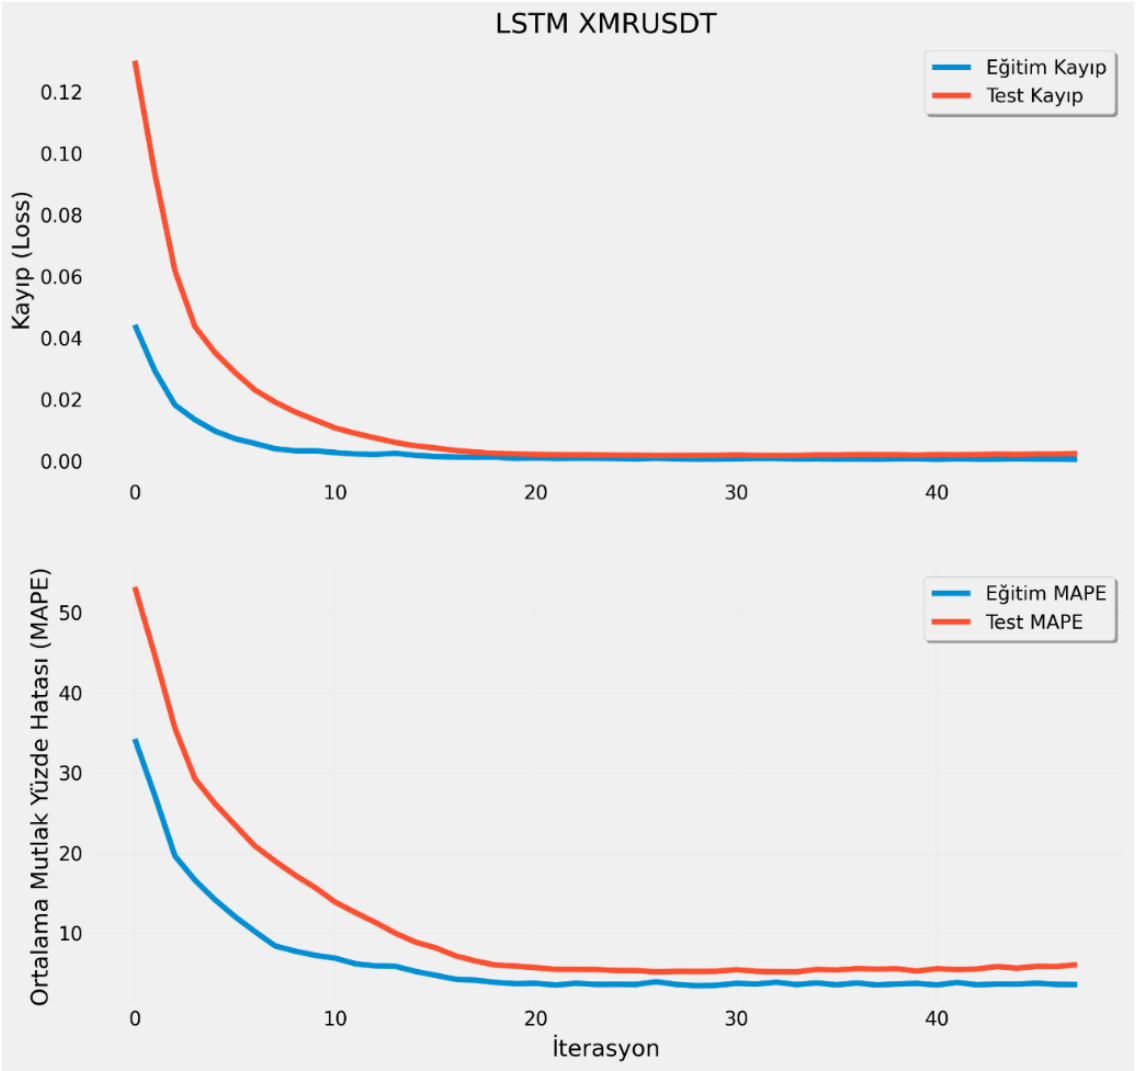
Şekil 6.36. Stellar veri kümesinde (karıştırılmış) CNN modeliyle kayıp ve MAPE

Şekil 6.36, Stellar veri kümesinin karıştırılmış versiyonunu kullanarak CNN modeli ile gerçekleştirilen fiyat tahmininin, iterasyonlar boyunca süregelen kayıp ve MAPE değerlerini göstermektedir. Bu şekil incelendiğinde hem eğitim hem de test süreçlerinde kayıp değerlerinin sürekli bir şekilde azaldığı gözlemlenmektedir. Bu düşüş eğilimi, modelin Stellar veri kümesi üzerinde etkin bir öğrenme gerçekleştirdiği ve kesin fiyat tahminlerinde bulunduğuna işaret etmektedir. Buna ek olarak, MAPE değerlerinin de azaldığı gözlenmiştir, bu durum kayıp değerlerindeki düşüş trendini teyit eder niteliktedir. MAPE iterasyonlar boyunca genel bir düşüş eğilimi göstermektedir. Kayıp ve MAPE değerleri, iterasyon sürecinde belirli bir dalgalanma gösterse de eğitim MAPE ve test MAPE çıktıları arasında önemli bir yakınsama gözlemlenmiştir. Bu bulgular, CNN modelinin Stellar fiyat tahmini ve fiyat yön belirleme konusunda önemli bir başarı elde ettiğini belirtmektedir. Bu nedenle, CNN modelinin karıştırılmış Stellar veri seti üzerinde etkili bir tahmin performansı sunduğu sonucuna varılabilmektedir.



Şekil 6.37. Stellar veri kümesinde (sıralı) LSTM modeliyle fiyat tahmini

Şekil 6.37'de, LSTM modelinin Stellar veri kümesinin sıralı versiyonunda üzerindeki fiyat tahminleri sergilenmektedir. Tahmin edilen XLMUSDT değerlerinin gerçek XLMUSDT değerleriyle tam bir uyum yakalayamasa da örtüştüğü bölgeler mevcuttur. LSTM modeliyle verilen fiyat tahminleri, gerçek fiyatların hızlı bir yükseliş ya da hızlı bir düşüş gösterdiği bölümlerde daha muhafazakâr kalmıştır. Bu davranış modelin genel performansına negatif yönde etkilemiştir. Bu bağlamda, LSTM modelinin Stellar veri-kümesinin sıralı versiyonu ile eğitildiğinde alınan tahmin değerleri ile yapılacak finansal işlemlerde mümkün olduğunca oynaklığın az olduğu piyasalar tercih edilmelidir.

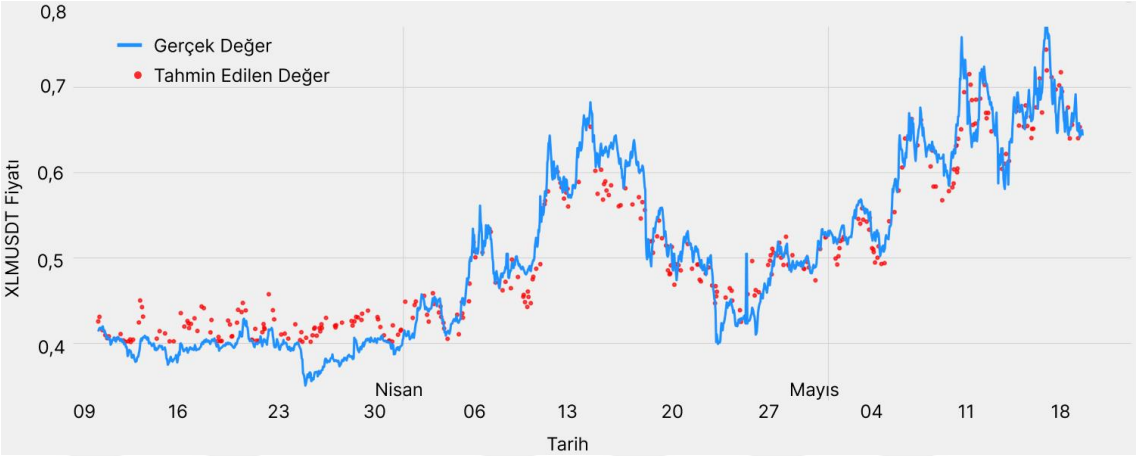


Şekil 6.38. Stellar veri kümesinde (sıralı) LSTM modeliyle kayıp ve MAPE

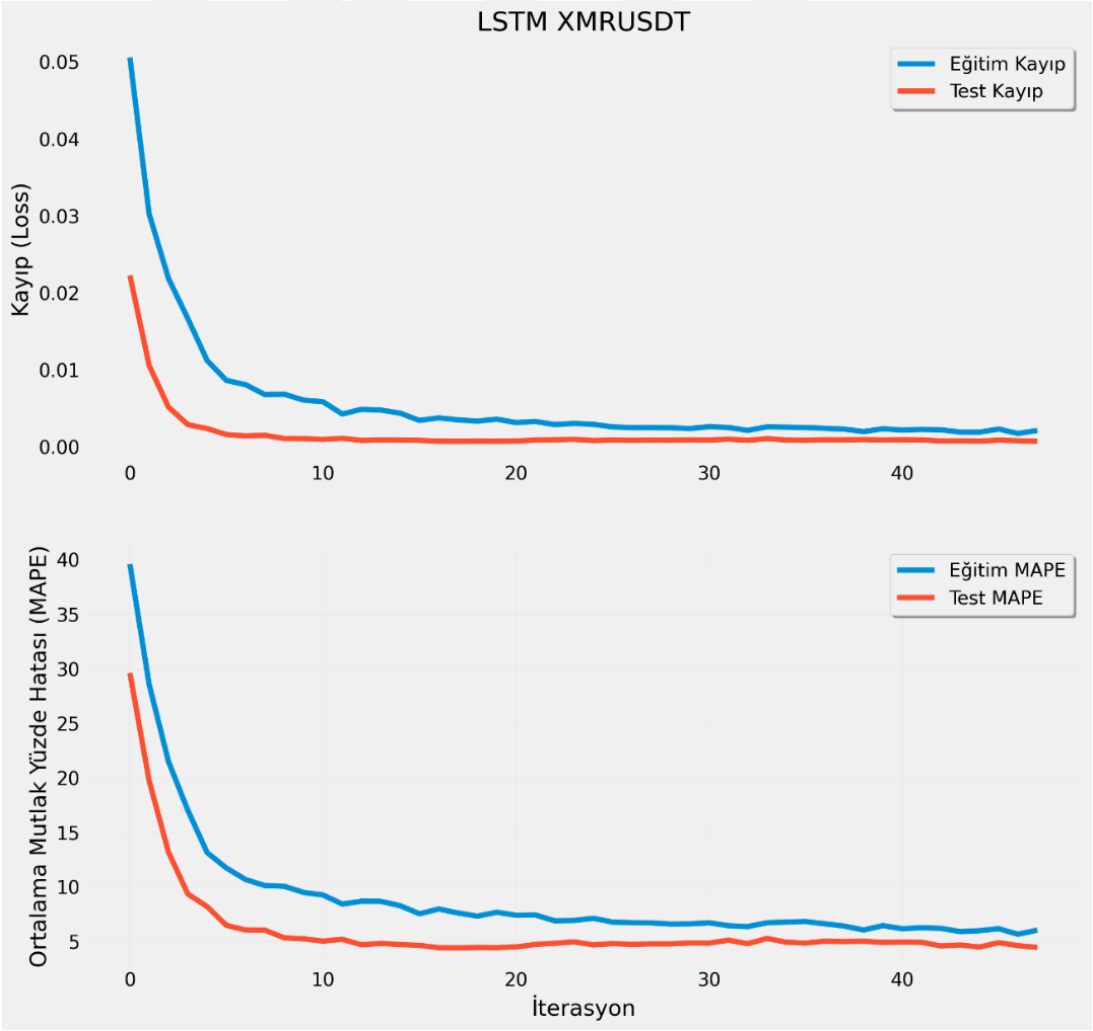
Şekil 6.38'de, Stellar veri kümesinin sıralı versiyonu üzerinde LSTM modeli ile yapılan fiyat tahmininde iterasyon boyunca gözlemlenen kayıp ve MAPE değeri sunulmuştur. Detaylı incelendiğinde hem eğitim kayıp hem de test kayıp değerinin iterasyon boyunca, özellikle 20'nci iterasyona kadar, azaldığı görülmektedir. Bu durum modelin, Stellar veri kümesinde (sıralı) hem iyi öğrendiğini hem de iyi bir fiyat tahmini yaptığını göstermektedir. MAPE değerlerinin gösterimi ise bu yorumu tamamlamaktadır. MAPE iterasyon boyunca düşüş eğilimindedir.

Şekil 6.39'da Stellar veri kümesinin karıştırılmış versiyonu ele alınarak LSTM modeliyle yapılan fiyat tahminlerini gösterilmektedir. Rastgele seçilmiş zaman aralıklarında LSTM

modeli tarafından tahmin edilen değerlerin, gerçek XLMUSDT değerleriyle örtüşebildiği gözlemlenmektedir.

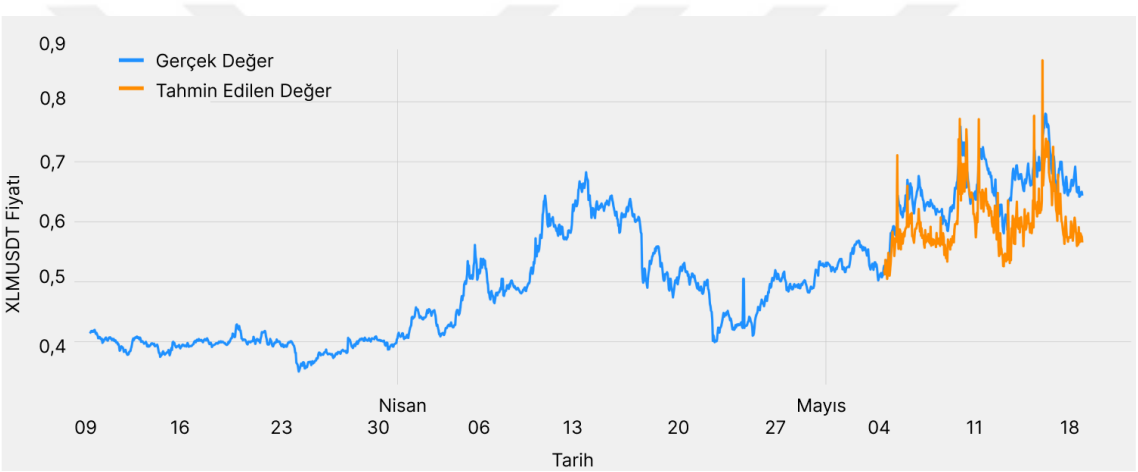


Şekil 6.39. Stellar veri kümesinde (karıştırılmış) LSTM modeliyle fiyat tahmini



Şekil 6.40. Stellar veri kümesinde (karıştırılmış) LSTM modeliyle kayıp ve MAPE

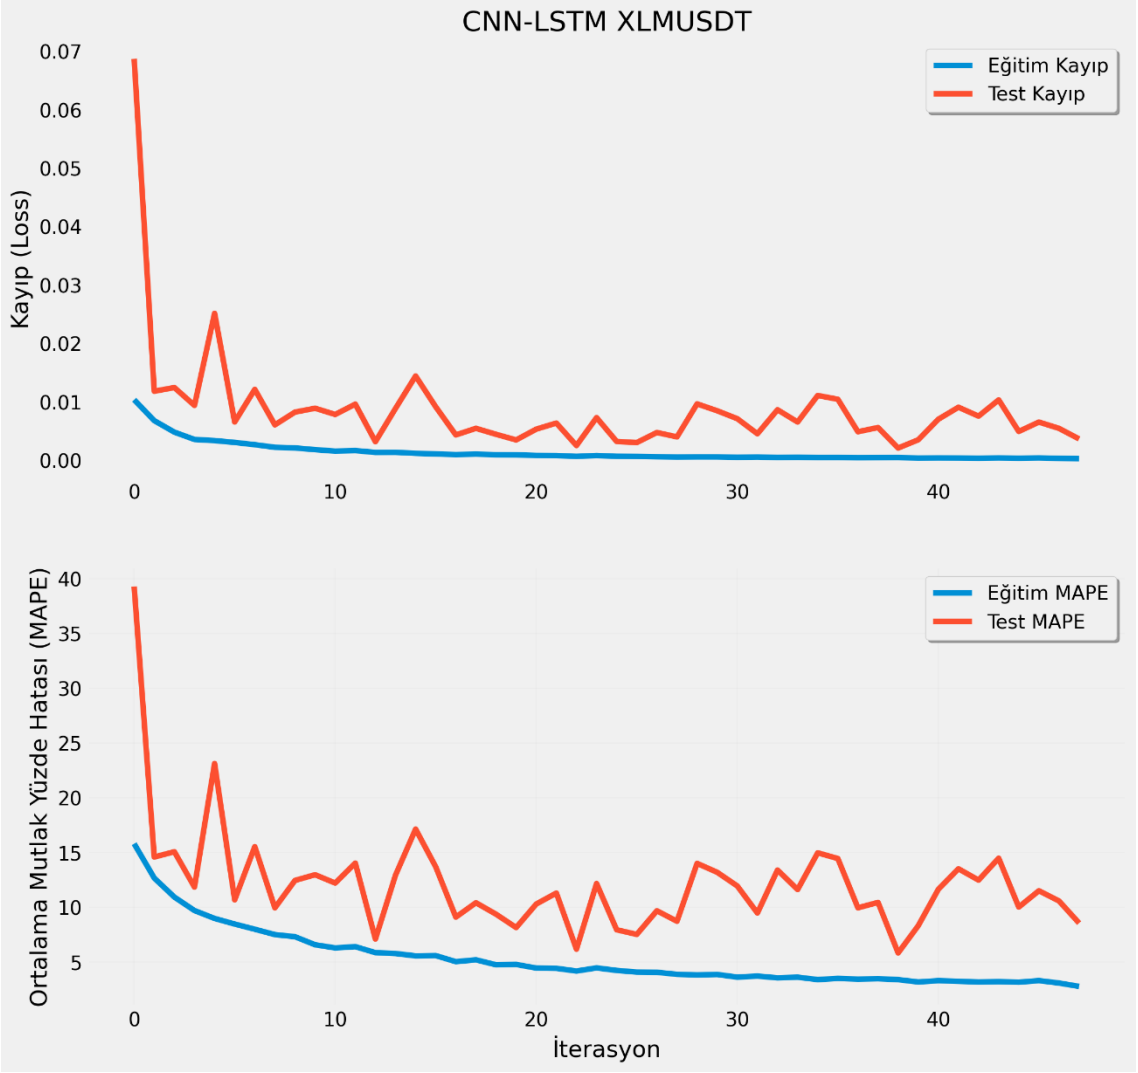
Şekil 6.40, Stellar veri setinin karıştırılmış versiyonunu kullanarak LSTM modeli ile gerçekleştirilen fiyat tahminlerinin, iterasyonlar boyunca kayıp ve MAPE değerlerini göstermektedir. Dikkatli bir analiz hem eğitim hem de test kayıplarının, iterasyon düzlemi boyunca sürekli bir azalma trendi sergilediğini ortaya koymaktadır. Bu azalmalar, modelin karıştırılmış Stellar veri kümesinde sağlıklı bir öğrenme süreci gerçekleştirdiğini ve doğru fiyat tahminleri oluşturabildiğini göstermektedir. MAPE değerlerinin sunumu, bu analizi daha da desteklemektedir. MAPE iterasyon süreci boyunca genel bir düşüş trendi gösterir. Bu, LSTM modelinin fiyat tahminlerinde giderek daha az hata yaptığını gösterir. Dolayısıyla, bu gözlemler LSTM modelinin karıştırılmış Stellar veri kümesinde sağlam bir fiyat tahmini performansı sergilediğini belirtir.



Şekil 6.41. Stellar veri kümesinde (sıralı) CNN-LSTM modeliyle fiyat tahmini

Şekil 6.41, CNN-LSTM modeli kullanılarak gerçekleştirilen fiyat tahminlerini, Stellar veri kümesinin sıralı versiyonu bağlamında sergilemektedir. Modelin performansının detaylı bir analizi, CNN modeli tarafından yapılan tahminlerle karşılaştırıldığında, bir başarı eksikliği olduğunu göstermektedir. Diğer model performanslarıyla yürütülen karşılaştırmalar da CNN-LSTM modelinin performansının daha az tatmin edici olduğunu doğrulamaktadır. Özellikle, fiyat volatilitenin belirgin olduğu dönemlerde, modelin tahminlerinin gerçek değerlerle karşılaştırıldığında önemli ölçüde daha yüksek veya daha düşük olduğu saptanmıştır. Bu, modelin fiyat hareketlerini doğru bir şekilde tahmin etme yeteneğinde önemli bir eksiklik olduğunu işaret etmektedir. Dahası, belirli zaman dilimlerinde, model tarafından tahmin edilen fiyat yönünün gerçek fiyat yönüne karşıt olduğu gözlemlenmiştir. Bu bulgular, CNN-LSTM modelinin başarı oranının, fiyatların görece durağan olduğu dönemlerde daha yüksek olduğunu, ancak fiyat volatilitenin

yükseldiği dönemlerde performansının azaldığını göstermektedir. Sonuç olarak, modelin volatilitenin arttığı durumlarla başa çıkma kapasitesinin belirgin bir sınırlılık olduğunu ve bu tür koşullar altında daha az verimli olduğunu belirtmektedir.



Şekil 6.42.Stellar veri kümesinde (sıralı) CNN-LSTM modeliyle kayıp ve MAPE

Şekil 6.42.'de sunulan kayıp ve MAPE değerleri, eğitim kayıp ve test kayıp değerlerinin 12'nci iterasyona kadar düştüğünü göstermektedir. Benzer şekilde eğitim MAPE ve test MAPE değerleri zaman zaman dalgalanmalar olsa da düşme eğilimdedir. Test MAPE değerlerinin eğitim MAPE değerleriyle uyumunun bozulduğu 12'nci iterasyondan sonra modelin test MAPE performansında kayda değer bir gelişim olmamıştır. Bu durum, CNN-LSTM modelinin eğitim verilerinden öğrenimi sürdürse de test verilerinde genelleme kabiliyetinin azaldığını ifade etmektedir.

Şekil 6.43, Stellar veri kümesinin karıştırılmış versiyonu üzerinde CNN-LSTM modeli ile yapılan fiyat tahminlerini göstermektedir. Tahmin sürecinde, veri kümesinin yüzde 20'si ele alınmış ve saatlik dilimlerde rastgele seçilmiş bir zaman aralığına odaklanılmıştır. CNN-LSTM modeli tarafından üretilen tahminlerin, reel XLMUSDT değerleriyle büyük bir uyum içinde olduğu belirlenmiştir. Ayrıca, CNN-LSTM modeli tarafından gerçekleştirilen XLMUSDT'nin fiyat yönü tahminlerinde başarının sağlandığı tespit edilmiştir.

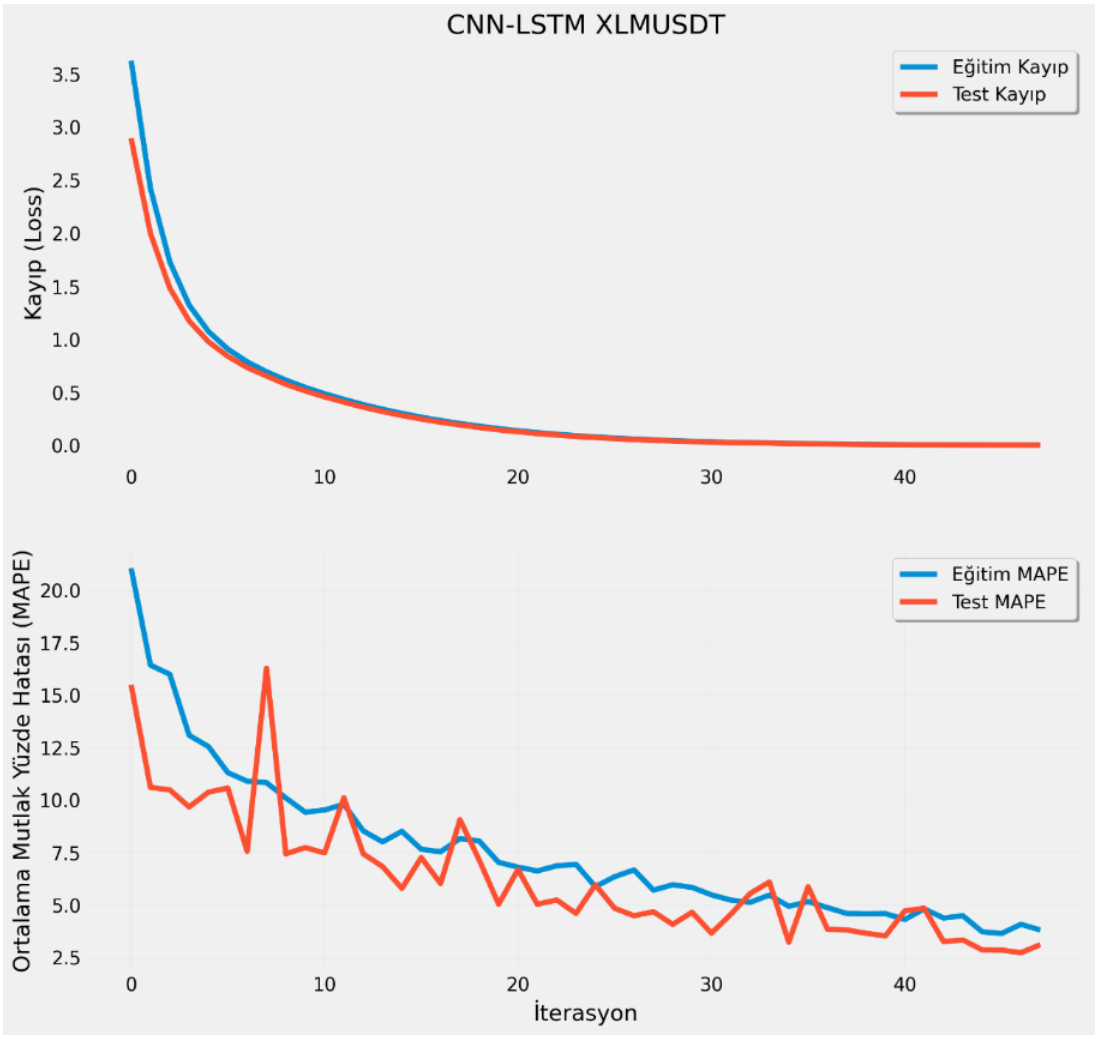


Şekil 6.43. Stellar veri kümesinde (karıştırılmış) CNN-LSTM modeliyle fiyat tahmini

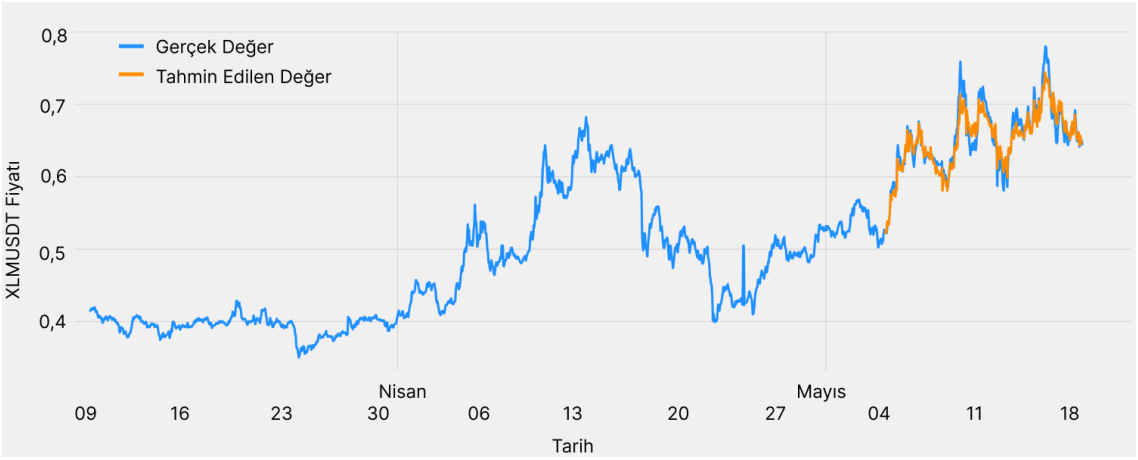
Şekil 6.44, CNN-LSTM modeli kullanılarak Stellar veri kümesinin karıştırılmış versiyonu üzerinde gerçekleştirilen tahminlerle ilgili, deney süresince kaydedilen kayıp ve MAPE değerlerini içermektedir. Bu grafik, aynı zamanda, Şekil 6.43'te sunulan fiyat tahmin grafiğinin başarılı sonuçlarına ışık tutmaktadır. İterasyon süresi boyunca dalgalanmalar göstermesine rağmen, modelin etkili bir öğrenme süreci gerçekleştirdiği ve güvenilir fiyat tahminleri sunduğu belirlenmiştir. Hem kayıp değerlerinin sunumu hem de MAPE değerlerinin gösterimi, bu sonuçları destekleyici niteliktedir.

Şekil 6.45, ConvLSTM modeli kullanılarak Stellar veri kümesinin sıralı versiyonu üzerinde gerçekleştirilen fiyat tahminlerini içermektedir. Model tarafından tahmin edilen değerlerle, gerçek XLMUSDT değerlerinin bir karşılaştırması yapıldığında, değerlerin büyük ölçüde örtüştüğü belirlenmiştir. Ek olarak, modelin XLMUSDT fiyatlarını tahmin etme yeteneğinin, özellikle ana trend yönünü belirleme konusunda, oldukça başarılı olduğu tespit edilmiştir. ConvLSTM modeli ile gerçekleştirilen fiyat tahminlerinin performansı, Stellar sıralı veri kümesi üzerinde yürütülen deneylerde, diğer deneylerden

belirgin bir şekilde öne çıkmıştır. Bu bulgular, ConvLSTM modelinin fiyat tahminleri yapma konusunda oldukça etkin bir yöntem olduğunu göstermektedir.

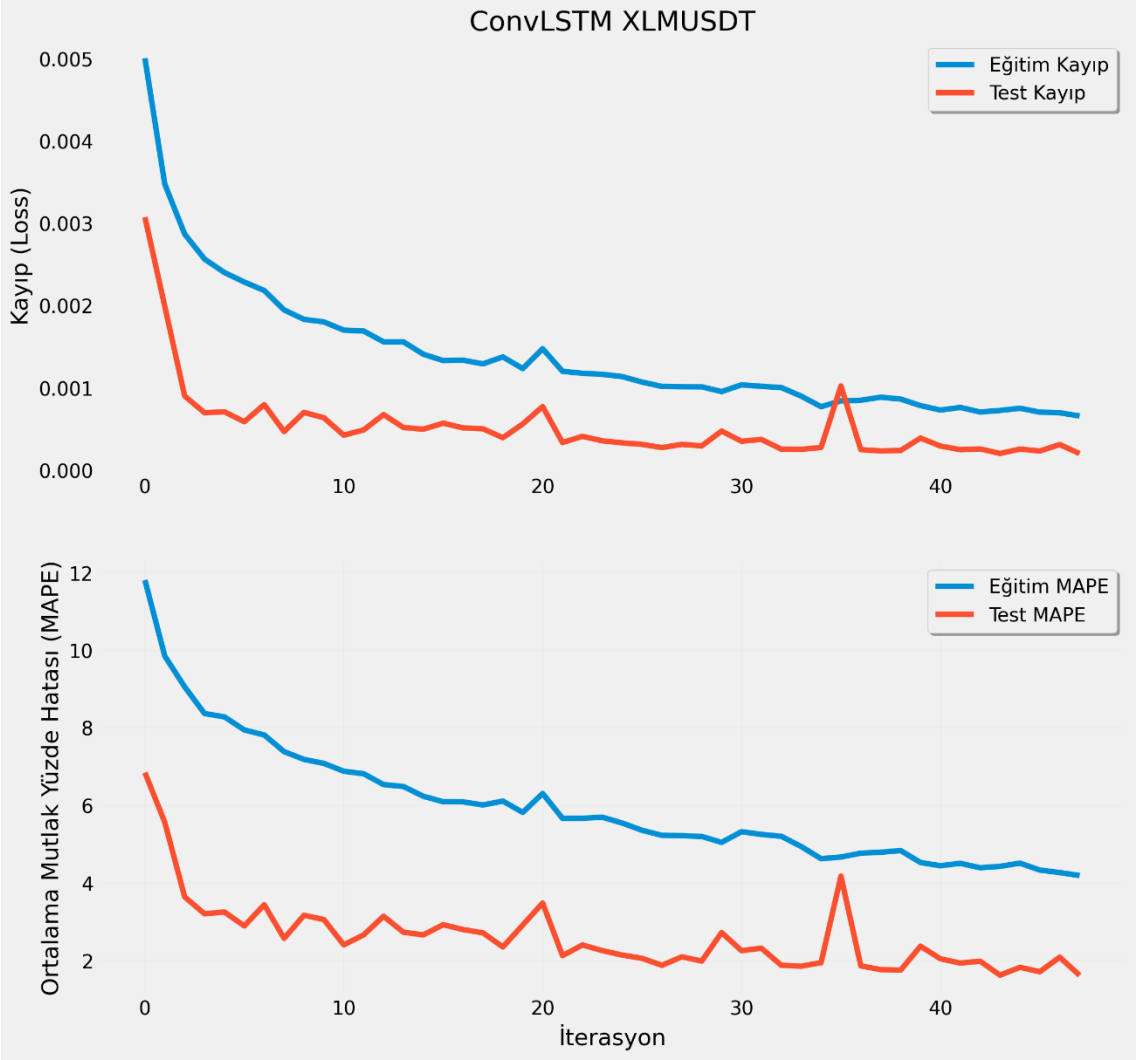


Şekil 6.44. Stellar veri kümesinde (karıştırılmış) CNN-LSTM modeliyle kayıp ve MAPE



Şekil 6.45. Stellar veri kümesinde (sıralı) ConvLSTM modeliyle fiyat tahmini

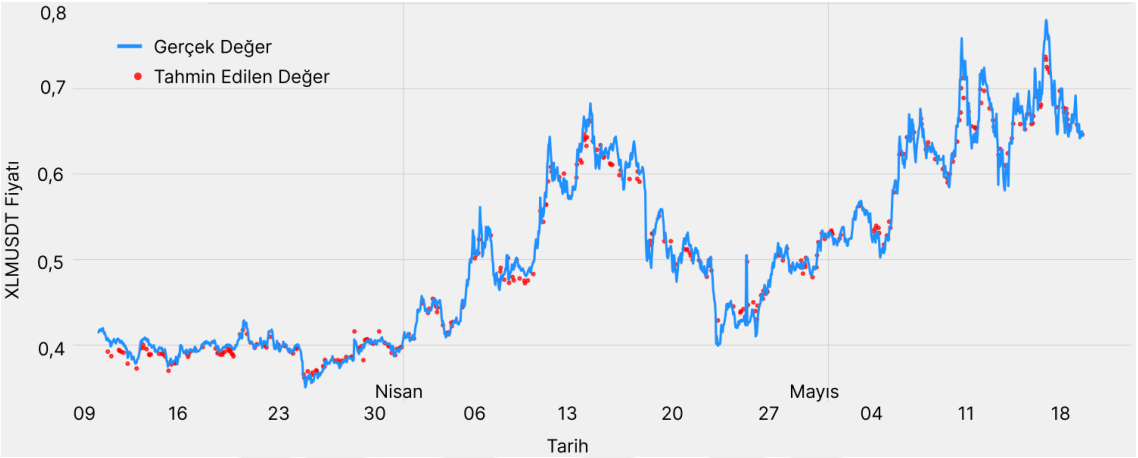
Şekil 6.46, ConvLSTM modelinin Stellar veri kümesinin sıralı versiyonu üzerinde gerçekleştirilen fiyat tahminlerinin iterasyonlara bağlı olarak kayıp ve MAPE değerlerini ifade etmektedir. Hem eğitim hem de test veri kümeleri için, kayıp ve MAPE değerlerinin, hedeflenen seviyelere doğru önemli bir azalma ve yakınsama gösterdiği tespit edilmiştir. Bu bulguların ışığında, ConvLSTM modelinin eğitim süreci boyunca etkin bir şekilde öğrendiği ve test aşamasında doğru fiyat tahminleri ürettiği belirlenmiştir.



Şekil 6.46. Stellar veri kümesinde (sıralı) ConvLSTM modeliyle kayıp ve MAPE

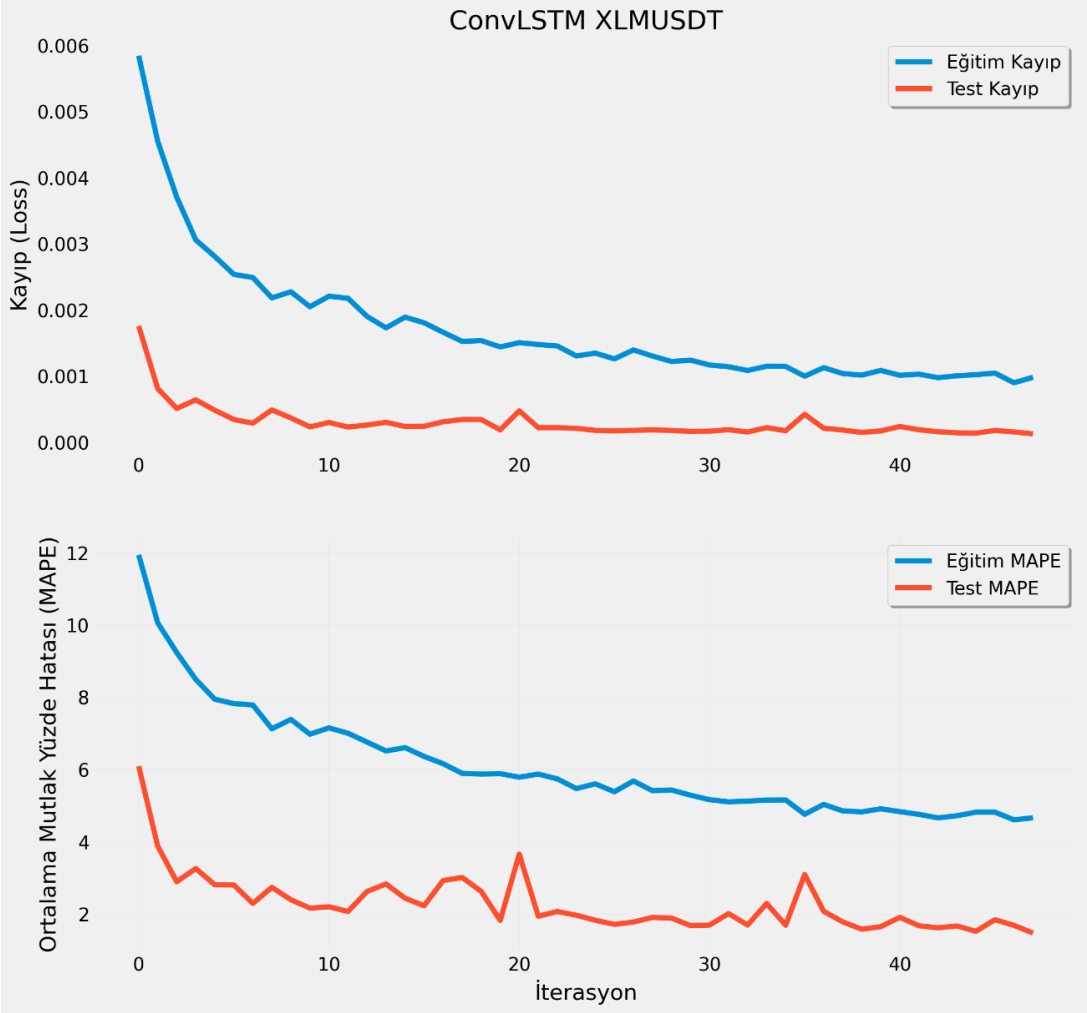
Şekil 6.47'de, ConvLSTM modeli tarafından üretilen tahminlerin Stellar veri kümesindeki (karıştırılmış) XLMUSDT'nin gerçek değerleriyle karşılaştırıldığı bir gösterim sunulmaktadır. Yapılan tahminlerin ve tahminlere karşılık gelen gerçek değerlerin uyumu, geliştirilmiş olan ConvLSTM modelinin fiyat tahminlerinde belirgin bir başarıya işaret etmektedir. Gerçek değerler ve tahmin edilen değerler incelendiğinde

hem düşük oynaklık sergileyen bölgelerde hem de yüksek oynaklık gösteren bölgelerde, modelin fiyat tahmin performansının istikrarlı bir güç sergilediği belirlenmiştir. Ayrıca, hem yükseliş ve hem de düşüş trendlerinde modelin performansı yüksek oranlarda başarı sergilemiştir. Bu sonuçlar ışığında, ConvLSTM modelinin fiyat yönünün belirlenmesinde de önemli bir başarı gösterdiği tespit edilmiştir.



Şekil 6.47. Stellar veri kümesinde (karıştırılmış) ConvLSTM modeliyle fiyat tahmini

Şekil 6.48, ConvLSTM modeli tarafından gerçekleştirilen fiyat tahmini sürecinde, hata oranının ve MAPE değerlerinin, Stellar veri setinin karıştırılmış versiyonu üzerindeki iterasyonlar boyunca nasıl evirildiğini ayrıntılı olarak ortaya koymaktadır. Hem eğitim hem de test setlerinde hata oranlarının, ilerleyen iterasyonlarla birlikte belirgin bir düşüş trendi sergilediği gözlemlenmiştir. Bu gözlem, ConvLSTM modelinin Stellar veri setinin karıştırılmış versiyonunu etkili bir şekilde öğrendiğini ve güçlü bir fiyat tahmin kabiliyeti geliştirdiğini vurgulamaktadır. Ayrıca, MAPE değerlerinin de iterasyonlar süresince sürekli bir azalma eğilimi gösterdiği belirlenmiştir. Bu bulgu, hata analizinin temelinde yatan değerlendirmelerin güvenilirliğini teyit eder niteliktedir ve modelin tahminleme hatalarını sürekli azalttığını, dolayısıyla tahminlerinin gerçek değerlere daha yakın hale geldiğini göstermektedir. MAPE genellikle iterasyon sürecinde bir azalma eğilimi göstermekte olup, bu durum modelin fiyat tahmini ve fiyat yönünün belirlenmesi konusunda önemli bir başarı oranı elde ettiğini işaret etmektedir. Bu analitik sonuçlar, ConvLSTM modeli ile karıştırılmış Stellar veri seti üzerinde yapılan deneylerde fiyat tahmini ve fiyat trendini belirleme konularında belirgin bir yetenek sergilediğini açıkça göstermektedir.



Şekil 6.48.Stellar veri kümesinde (karıştırılmış) ConvLSTM modeliyle kayıp ve MAPE

Bu çalışma kapsamında, derin öğrenme ve hibrit yöntemlerin, özellikle CNN, LSTM, CNN-LSTM ve ConvLSTM'nin, Bitcoin, Monero ve Stellar gibi kripto para birimlerinin saatlik veri kümeleri üzerindeki fiyat tahmin süreçlerinde kullanıldığı gözlemlendi. Bu deneyler, kısa vadeli tahminlerin volatilitenin yüksek olduğu piyasalarda ne kadar zorlu bir görev olabileceğini gözler önüne sermiştir.

7. SONUÇLAR VE ÖNERİLER

Tez çalışması kapsamında derin ve hibrit derin öğrenme yöntemlerinin Bitcoin, Monero ve Stellar kripto para birimlerinin fiyat tahminlemedeki başarımı üzerine odaklanılmıştır. Bu amaçla, veri kümeleri sıralı ve karıştırılmış olarak deneylerde kullanılmış ve veri kümeleri çeşitlendirildiğinde modellerin tahmin performansları da değerlendirilmiştir. Bitcoin sıralı veri kümesinde yapılan deneylerde, en etkili modelin CNN olduğu belirlenirken karıştırılmış veri kümesinde ise en yüksek performansın CNN-LSTM modeli ile elde edildiği saptanmıştır. Monero ve Stellar veri kümeleri üzerinde yapılan deneylerde hem sıralı hem de karıştırılmış veri kümesi versiyonlarında en etkili modelin ConvLSTM olduğu sonucuna varılmıştır. Bu bulgular, özellikle saatlik veri kümeleri için ConvLSTM modelinin kripto para birimi fiyat tahminlerinde güçlü bir araç olabileceğini göstermektedir.

Ancak, tüm bu sonuçlara rağmen, kısa vadeli tahminlerin hassasiyetini artırma ihtiyacı devam etmektedir. Gelecekte yapılacak çalışmalarda, farklı kripto para birimlerinin daha uzun zaman dilimleri ve farklı frekanslardaki veri kümeleri üzerinde bu modellerin performanslarının değerlendirilmesi önerilmektedir. Ayrıca, çeşitli hiper parametre ayarları ve farklı özellik seçim stratejilerinin incelenmesi de değerli olabilmektedir. Bu yaklaşımların uygulanması, özellikle volatil kripto para piyasalarında kısa vadeli fiyat tahmini için daha güçlü ve daha sağlam modellerin geliştirilmesine katkı sağlayabilmektedir.

Ayrıca, dikkate değer bir diğer bulgu, modellerin farklı veri kümelerinde farklı performans sergilediğidir ve bu durum modellerin veri kümesine bağımlı olabileceğini göstermektedir. Örneğin, Bitcoin sıralı veri kümesinde en iyi sonuçların CNN ile elde edildiği, ancak karıştırılmış veri kümesinde CNN-LSTM modelinin daha etkili olduğu görülmüştür. Bu durum, derin öğrenme ve hibrit yöntemlerin farklı veri kümelerinde farklı şekillerde çalışabileceğini ve bu modellerin performansının veri kümelerine bağlı olarak değişebileceğini göstermektedir. Bu nedenle, kripto para birimi fiyat tahminleme konusunda en uygun modeli seçerken, veri kümesinin yapısı ve özellikleri göz önünde bulundurulmalıdır. Gelecekte yapılacak çalışmalarda, daha fazla veri kümesi üzerinde deneyler yapılarak modellerin farklı veri kümelerine adaptasyon yeteneği daha kapsamlı bir şekilde değerlendirilebilir. Bu tür analizler, kripto para birimi fiyat tahminleme

alanında daha geniş bir bakış açısı sunabilir ve daha kapsamlı sonuçlara ulaşmamızı sağlayabilir.

Sonuç olarak, bu çalışma, derin öğrenme ve hibrit yöntemlerin kripto para birimi fiyat tahminindeki potansiyelini, özellikle kısa vadeli ve fiyat oynaklığının fazla olduğu koşullarda, gösteren önemli bir adım olarak kabul edilebilir. Bu alanda daha fazla araştırma yapılması, tespitlerimizi genişletebilir ve daha etkili tahmin araçları oluşturulmasına yardımcı olabilir.

KAYNAKLAR

Aggarwal, A., Gupta, I., Garg, N., Goel, A. (2019). Deep Learning Approach to Determine the Impact of Socio Economic Factors on Bitcoin Price Prediction. *IEEE 2019 Twelfth International Conference on Contemporary Computing IC3*, Noida, Hindistan, 8-10 Ağustos 2019.

Aggarwal, D., Chandrasekaran, S., Annamalai, B. (2020). A Complete Empirical Ensemble Mode Decomposition and Support Vector Machine-based Approach to Predict Bitcoin Prices. *Journal of Behavioral and Experimental Finance, 27*(3), 100335.

Akyildirim, E., Goncu, A., Sensoy, A. (2021). Prediction of Cryptocurrency Returns Using Machine Learning. *Annals of Operations Research, 297*, 3-36.

Alahmari, S. A. (2019). Using Machine Learning ARIMA to Predict the Price of Cryptocurrencies. *ISeCure*, *11*(3), 139-144.

Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Farhan, L. (2021). Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions. *Journal of Big Data*, *8*(54), 1-74.

Ammer, M. A., Aldhyani, T. H. (2022). Deep Learning Algorithm to Predict Cryptocurrency Fluctuation Prices: Increasing Investment Awareness. *Electronics*, *11*(15), 1-22.

Atsalakis, G. S., Atsalaki, I. G., Pasiouras, F., Zopounidis, C. (2019). Bitcoin Price Forecasting with Neuro-fuzzy Techniques. *European Journal of Operational Research, 276*(2), 770-780.

Attia, Z. I., Kapa, S., Lopez-Jimenez, F., McKie, P. M., Ladewig, D. J., Satam, G., Friedman, P. A. (2019). Screening for Cardiac Contractile Dysfunction Using an Artificial Intelligence–enabled Electrocardiogram. *Nature Medicine*, *25*(1), 70-74.

Azari, A. (2019). *Bitcoin Price Prediction: An ARIMA Approach*. ArXiv Preprint, https://arxiv.org/abs/1904.05315 (Ziyaret Tarihi: 22 Mart 2023).

Behrmann, J., Etmann, C., Boskamp, T., Casadonte, R., Kriegsmann, J., Maaβ, P. (2018). Deep Learning for Tumor Classification in Imaging Mass Spectrometry. *Bioinformatics, 34*(7), 1215-1223.

Benzekri, M. K. Özütler, H. Ş. (2021). On the Predictability of Bitcoin Price Movements: A Short-term Price Prediction with ARIMA. *Journal of Economic Policy Researches, 8*(2), 293-309.

Cavnar, W. B., Trenkle, J. M. (1994). N-gram-based Text Categorization. *Third Annual Symposium on Document Analysis and Information Retrieval*, Las Vegas, ABD, 11-13 Nisan 1994.

Cengiz, K. (2018). En popüler kripto para birimi: Bitcoin. *Bandırma Onyedi Eylül Üniversitesi Sosyal Bilimler Araştırmaları Dergisi*, *1*(2), 87-100.

Chen, Z., Li, C., Sun, W. (2020). Bitcoin Price Prediction Using Machine Learning: An Approach to Sample Dimension Engineering. *Journal of Computational and Applied Mathematics*, *365*(C), 112395.

Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., Benenson, R., Schiele, B. (2016). The Cityscapes Dataset for Semantic Urban Scene Understanding. *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, ABD, 27-30 Haziran 2016.

Donahue, J., Anne Hendricks, L., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., Darrell, T. (2015). Long-term Recurrent Convolutional Networks for Visual Recognition and Description. *IEEE Conference on Computer Vision and Pattern Recognition*, Boston, ABD, 7-12 Haziran 2015.

Dutta, A., Kumar, S., Basu, M. (2020). A Gated Recurrent Unit Approach to Bitcoin Price Prediction. *Journal of Risk and Financial Management*, *13*(2), 23.

Graves, A., Mohamed, A. R., Hinton, G. (2013). Speech Recognition With Deep Recurrent Neural Networks. *IEEE International Conference on Acoustics, Speech and Signal Processing*, Vancouver, ABD, 26-31 Mayıs 2013.

Gümüş, A., Erkuş, H. (2019). Blockchain ve kripto paraların kullanımı üzerine bir değerlendirme. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*, *7*(2), 41-49.

Hamayel, M. J., Owda, A. Y. (2021). A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms. *AI*, *2*(4), 477-496.

Haryadi, D., Hakim, A. R., Atmaja, D. M. U., Yutia, S. N. (2022). Implementation of Support Vector Regression for Polkadot Cryptocurrency Price Prediction. *JOIV: International Journal on Informatics Visualization*, *6*(1-2), 201-207.

He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, ABD, 27-30 Haziran 2016.

Hitam, N. A., Ismail, A. R., Saeed, F. (2019). An Optimized Support Vector Machine (SVM) Based on Particle Swarm Optimization (PSO) for Cryptocurrency Forecasting. *Procedia Computer Science*, *163*, 427-433.

Hochreiter, S., Schmidhuber, J. (1997). Long Short-term Memory. *Neural Computation*, *9*(8), 1735-1780.

Hua, Y. (2020). Bitcoin Price Prediction Using ARIMA and LSTM. *International Symposium on Energy, Environmental Science and Engineering*, Chongqing, Çin, 20-22 Kasım 2020.

Ji, S., Kim, J., Im, H. (2019). A Comparative Study of Bitcoin Price Prediction Using Deep Learning. *Mathematics, 7*(10), 898.

Khan, N., Ahmad, T., State, R. (2019). Feasibility of Stellar as a Blockchain-Based Micropayment System. *International Conference on Smart Blockchain*, Birmingham, İngiltere, 11-13 Ekim 2019.

Kemelmacher-Shlizerman, I., Seitz, S. M., Miller, D., Brossard, E. (2016). The Megaface Benchmark: 1 Million Faces for Recognition at Scale. *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, ABD, 27-30 Haziran 2016.

Kesebir, M., Günceler, B. (2019). Kripto Para Birimlerinin Parlak Geleceği. *Iğdır Üniversitesi Sosyal Bilimler Dergisi*, (17), 605-626.

Kilimci, H., Yıldırım, M., Kilimci, Z. H. (2021). The Prediction of Short-Term Bitcoin Dollar Rate (BTC/USDT) Using Deep and Hybrid Deep Learning Techniques. *5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Türkiye, 21-23 Ekim 2021.

Kim, G., Shin, D. H., Choi, J. G., Lim, S. (2022). A Deep Learning-Based Cryptocurrency Price Prediction Model That Uses On-Chain Data. *IEEE Access, 10*, 56232-56248.

Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *Conference on Empirical Methods in Natural Language Processing*, Doha, Qatar, 25-29 Ekim 2014.

Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., Inman, D. J. (2021). 1D Convolutional Neural Networks and Applications: A Survey. *Mechanical Systems and Signal Processing*, *151*, 107398.

Lamothe-Fernández, P., Alaminos, D., Lamothe-López, P., Fernández-Gámez, M. A. (2020). Deep Learning Methods for Modeling Bitcoin Price. *Mathematics, 8*(8), 1245.

Li, Y., Cui, W. G., Huang, H., Guo, Y. Z., Li, K., Tan, T. (2019). Epileptic Seizure Detection in EEG Signals Using Sparse Multiscale Radial Basis Function Networks and the Fisher Vector Approach. *Knowledge-Based Systems*, *164*, 96-106.

Li, Y., Yang, G., Susilo, W., Yu, Y., Au, M. H., Liu, D. (2019). Traceable Monero: Anonymous Cryptocurrency with Enhanced Accountability. *IEEE Transactions on Dependable and Secure Computing*, *18*(2), 679-691.

Liu, Y., Wang, L., Shi, T., Li, J. (2022). Detection of Spam Reviews through a Hierarchical Attention Architecture with N-gram CNN and Bi-LSTM. *Information Systems*, *103*, 101865.

Mudassir, M., Bennbaia, S., Unal, D., Hammoudeh, M. (2020). Time-series Forecasting of Bitcoin Prices Using High-dimensional Features: a Machine Learning Approach. *Neural Computing and Applications*, 1-15.

Patel, M. M., Tanwar, S., Gupta, R., Kumar, N. (2020). A Deep Learning-based Cryptocurrency Price Prediction Scheme for Financial Institutions. *Journal of Information Security and Applications, 55*, 102583.

Poongodi, M., Sharma, A., Vijayakumar, V., Bhardwaj, V., Sharma, A. P., Iqbal, R., Kumar, R. (2020). Prediction of the Price of Ethereum Blockchain Cryptocurrency in an Industrial Finance System. *Computers & Electrical Engineering*, *81*, 106527.

Rathan, K., Sai, S. V., Manikanta, T. S. (2019). Crypto-currency Price Prediction Using Decision Tree and Regression Techniques. *3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, Hindistan, 23-25 Nisan 2019.

Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2016). You Only Look Once: Unified, Real-time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, ABD, 27-30 Haziran 2016.

Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster r-cnn: Towards Real-time Object Detection with Region Proposal Networks. *Advances in Neural Information Processing Systems*, *28*(1), 91-95.

Rizwan, M., Narejo, S., Javed, M. (2019). Bitcoin Price Prediction Using Deep Learning Algorithm. *13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS)*, Karachi, Pakistan, 14-15 Aralık 2019.

Roy, S., Nanjiba, S., Chakrabarty, A. (2018). Bitcoin Price Forecasting Using Time Series Analysis. *21st International Conference of Computer and Information Technology (ICCIT)*, Dhaka, Bangladeş, 21-23 Aralık 2018.

Sadia, I., Mahmood, A., Kiah, L. B. M., Azzuhri, S. R. (2022). Analysis and Forecasting of Blockchain-based Cryptocurrencies and Performance Evaluation of TBATS, NNAR and ARIMA. *IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET)*, Kota Kinabalu, Malezya, 13-15 Eylül 2022.

Schroff, F., Kalenichenko, D., Philbin, J. (2015). Facenet: A Unified Embedding for Face Recognition and Clustering. *IEEE Conference on Computer Vision and Pattern Recognition*, Boston, ABD, 7-12 Haziran 2015.

Seabe, P. L., Moutsinga, C. R. B., Pindza, E. (2023). Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-directional LSTM: A Deep Learning Approach. *Fractal and Fractional*, *7*(2), 203.

Shi, X., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., Woo, W. C. (2015). Convolutional LSTM network: A Machine Learning Approach for Precipitation Nowcasting. *Advances in Neural Information Processing Systems*, *28*, 1-9.

Shinde, P. P., Shah, S. (2018). A review of machine learning and deep learning applications. *IEEE 4th International Conference on Computing Communication Control and Automation (ICCUBEA)*, Pune, Hindistan, 16-18 Ağustos 2018.

Simonyan, K., & Zisserman, A. (2014). Two-stream Convolutional Networks for Action Recognition in Videos. *Advances in Neural Information Processing Systems*, *27*, 1-9.

Souto, Y. M., Porto, F., Moura, A. M., Bezerra, E. (2018). A Spatiotemporal Ensemble Approach to Rainfall Forecasting. *International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro, Brezilya, 8-13 Temmuz 2018.

Sovbetov, Y. (2018). Factors Influencing Cryptocurrency Prices: Evidence from Bitcoin, Ethereum, Dash, Litcoin, and Monero. *Journal of Economics and Financial Analysis*, *2*(2), 1-27.

Stallings, W. (2005). *Cryptography and Network Security: Principles and Practice* (3rd ed.). Prentice Hall, Upper Saddle River, NJ.

Sung, S. H., Kim, J. M., Park, B. K., Kim, S. (2022). A Study on Cryptocurrency Log-Return Price Prediction Using Multivariate Time-Series Model. *Axioms*, *11*(9), 448.

Sutskever, I., Vinyals, O., Le, Q. V. (2014). Sequence to Sequence Learning with Neural Networks. *Advances in Neural Information Processing Systems*, *27*, 2394-2403.

Tanwar, S., Patel, N. P., Patel, S. N., Patel, J. R., Sharma, G., Davidson, I. E. (2021). Deep learning-based Cryptocurrency Price Prediction Scheme with Inter-dependent Relations. *IEEE Access*, *9*, 138633-138646.

URL-1: https://coinmarketcap.com/tr/charts/, (Ziyaret tarihi: 2 Aralık 2022).

URL-2: https://www.investopedia.com/bitcoin-halving-4843769, (Ziyaret tarihi: 25 Kasım 2022).

Venugopalan, S., Rohrbach, M., Donahue, J., Mooney, R., Darrell, T., Saenko, K. (2015). Sequence to Sequence-video to Text. *IEEE International Conference on Computer Vision*, Santiago, Şili, 7-13 Aralık 2015.

Vranken, H. (2017). Sustainability of Bitcoin and Blockchains. *Current Opinion in Environmental Sustainability*, *28*, 1-9.

Wang, L., Xiong, Y., Wang, Z., Qiao, Y. (2015). *Towards Good Practices for Very Deep Two-stream Convnets*. ArXiv Preprint, https://arxiv.org/abs/1507.02159 (Ziyaret Tarihi: 17 Mart 2023).

Wang, Q., Huang, Y., Jia, W., He, X., Blumenstein, M., Lyu, S., Lu, Y. (2020). FACLSTM: ConvLSTM with Focused Attention for Scene Text Recognition. *Science China Information Sciences*, *63*, 1-14.

Wu, C. H., Lu, C. C., Ma, Y. F., Lu, R. S. (2018). A New Forecasting Framework for Bitcoin Price with LSTM. *IEEE International Conference on Data Mining Workshops (ICDMW)*, Singapur, 17-20 Kasım 2018.

Zhang, S., Li, M., Yan, C. (2022). The Empirical Analysis of Bitcoin Price Prediction Based on Deep Learning Integration Method. *Computational Intelligence and Neuroscience*, *2022*, 1-9.

Zhong, C., Du, W., Xu, W., Huang, Q., Zhao, Y., Wang, M. (2023). LSTM-ReGAT: A Network-centric Approach for Cryptocurrency Price Trend Prediction. *Decision Support Systems*, *169*, 113955.

KİŞİSEL YAYIN VE ESERLER

Kilimci, H., Kilimci, Z. H., & Yıldırım, M. (2021). Deep Learning-based Decision Integration Strategy for the Price Prediction of Istanbul Stock Exchange (BIST100). *13th International Conference on Electrical and Electronics Engineering (ELECO)*, Bursa, Türkiye, 25-27 Kasım 2021.

Kilimci, H., Yıldırım, M., Kilimci, Z. H. (2021). The Prediction of Short-Term Bitcoin Dollar Rate (BTC/USDT) Using Deep and Hybrid Deep Learning Techniques. *5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Türkiye, 21-23 Ekim 2021.

ÖZGEÇMİŞ

Lise öğrenimini İzmir'de tamamladı. 2009 yılında İstanbul Teknik Üniversitesi Bilişim Sistemleri Mühendisliği çift diploma programı kapsamında, İTÜ Bilişim Sistemleri Mühendisliği ve SUNY-Binghamton Üniversitesi Information Systems Engineering bölümlerinden lisans derecelerini aldı. 2020 yılında Kocaeli Üniversitesi Bilişim Sistemleri Mühendisliği bölümünde yüksek lisans eğitimine başladı. Yüksek lisans eğitiminde Makine Öğrenmesi ve Derin Öğrenme ile finansal araçlar üzerinde fiyat tahmini konularında çalışmaları bulunmaktadır.

2011-2021 yılları Netaş Telekomünikasyon A.Ş şirketinde GPS mühendisi olarak çalıştı. 2021 yılından beri Orion Innovation Türkiye şirketinde çalışmalarına devam etmektedir.