

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OPTUNA TABANLI MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE BİTCOİN FİYAT
TAHMİNLEME YAKLAŞIMLARI

Berkay YILDIRIM

YÜKSEK LİSANS TEZİ
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Elektronik Programı

Danışman
Dr. Öğr. Üyesi Murat TAŞKIRAN

Mayıs, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OPTUNA TABANLI MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE BİTCOİN FİYAT TAHMİNLEME
YAKLAŞIMLARI

Berkay YILDIRIM tarafından hazırlanan tez çalışması 28.05.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Murat TAŞKIRAN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Murat TAŞKIRAN, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Bülent BOLAT, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Nurullah ÇALIK, Üye
İstanbul Medeniyet Üniversitesi

Danışmanım Dr. Öğr. Üyesi Murat TAŞKIRAN sorumluluğunda tarafımca hazırlanan Optuna Tabanlı Makine Öğrenmesi Yöntemleriyle Bitcoin Fiyat Tahminleme Yaklaşımları başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Berkay YILDIRIM

İmza

*Aileme ve dostlarıma
ithaf edilmiştir.*



TEŞEKKÜR

Bu tezin yürütülmesi sırasında bilgi ve deneyimleriyle her zaman yanımda olan danışman hocam Dr. Öğr. Üyesi Murat TAŞKIRAN'a teşekkür ederim. Bana verdiği değerli önerilerle bu çalışmanın şekillenmesinde büyük rol oynamıştır.

Araştırmam sırasında bana rehberlik eden ve destek olan tüm bölüm hocalarıma ve çalışma arkadaşlarıma minnettarım. Özellikle, lisansüstü eğitimim boyunca desteklerinden dolayı Arş. Gör. Emin AKPINAR'a ve finansal analiz konusunda destek veren Mustafa Tamer YAZ'a teşekkür ederim.

Ayrıca, bu süreçte bana moral ve motivasyon kaynağı olan aileme ve dostlarıma teşekkür ediyorum.

Berkay YILDIRIM

İÇİNDEKİLER

KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	x
ÖZET	xi
ABSTRACT	xiii
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	4
1.3 Hipotez	5
2 BİTCOİN FİYATI TAHMİNLEME SİSTEMLERİ	6
2.1 Zaman Serisi Yaklaşımı	7
2.1.1 Kripto Para Piyasasında Zaman Serisi Modelleri	7
2.2 Teknik Analiz Yaklaşımı	11
2.2.1 Teknik Analiz Sonuçlarının Yapay Zeka ile Değerlendirilmesi	12
2.2.2 Teknik İndikatörler	12
2.2.3 Teknik Analiz Modelleri	18
2.3 Topluluk Modelleme Yaklaşımı	19
2.3.1 Ortalama Alma Yöntemi	20
2.3.2 Ağırlıklı Ortalama Alma Yöntemi	20
2.3.3 Meta Öğrenme Yöntemi	20
2.4 Zaman Serisi Modellerinin Veri Seti	20
2.5 Teknik İndikatör Modellerinin Veri Seti	21
2.5.1 Teknik İndikatörlerin Yorumlanması	21
2.5.2 Hedef Değişken Tanımlanması	22
2.5.3 Özellik Mühendisliği	22
2.6 Optimizasyon	24
2.6.1 Optuna	25

2.7	Değerlendirme Metrikleri	25
3	UYGULAMA	27
3.1	Veri Seti	27
3.2	Zaman Serisi Yaklaşımı	27
3.2.1	ARIMA ve ARIMAX	27
3.2.2	XGBoost	28
3.2.3	RNN, LSTM ve ANN	28
3.2.4	TCN	28
3.2.5	Transformer	28
3.2.6	Zaman Serisi Yaklaşımı Sonuçları	29
3.3	Teknik Analiz Yaklaşımı	30
3.3.1	Model Seçimi	32
3.3.2	Başarılı Modellerin Optimizasyonu	33
3.3.3	Teknik Analiz Yaklaşımı Sonuçları	34
3.4	Topluluk Modelleme Yaklaşımı	34
3.4.1	Ortalama Alma Yöntemi	35
3.4.2	Ağırlıklı Ortalama Alma Yöntemi	35
3.4.3	Meta Öğrenme Yöntemi	35
3.4.4	Topluluk Modelleme Yaklaşımı Sonuçları	36
4	SONUÇ	38
	KAYNAKÇA	40
	TEZDEN ÜRETİLMİŞ YAYINLAR	43

KISALTMA LİSTESİ

ABC	Yapay Arı Kolonisi
ADX	Ortalama Yön Endeksi
ANN	Yapay Sinir Ağı
AO	Müthiş Osilatör
API	Uygulama Programlama Arabirimi
AR	Otokorelasyon
ARIMA	Otoregresif Entegre Hareketli Ortalama
ARIMAX	Dışsal Değişkenlerle Otoregresif Entegre Hareketli Ortalama
ATR	Ortalama Gerçek Aralık
BBAND	Bollinger Bant
BBP	Boğa-Ayı Gücü
BiLSTM	İki Yönlü Uzun Kısa Süreli Bellek
BTC	Bitcoin
CCI	Emtia Kanalı Endeksi
CMF	Chaikin Para Akışı
CNN	Evrişimli Sinir Ağı
DMN	Negatif Yönlü Hareket
DMP	Pozitif Yönlü Hareket
EMA	Üssel Hareketli Ortalama
ETH	Ethereum
GA	Genetik Algoritma
GRU	Kapılı Tekrarlayan Birimler
KC	Keltner Kanalı

LGBM	Hafif Gradyan Artırma Makinesi
LSTM	Uzun Kısa Süreli Bellek
MA	Hareketli Ortalama
MAE	Ortalama Mutlak Hata
MACD	Hareketli Ortalamaların Yakınsaması/İraksaması
MLP	Çok Katmanlı Algılayıcı
OBV	Denge Hacmi
OHE	Tek Sıcak Kodlama
PSAR	Parabolik Durdurma ve Geri Alma
RNN	Yinelemeli Sinir Ağı
RMSE	Kök Ortalama Kare Hatası
RSI	Göreceli Güç Endeksi
SMA	Basit Hareketli Ortalama
STOCH	Stokastik Osilatör
TAY	Teknik Analiz Yaklaşımı
TCN	Zamansal Evrişimsel Ağ
TİMT	Teknik İndikatör Model Tahmini
TPE	Ağaç Tabanlı Parzen Tahminleyici
UO	Nihai Osilatör
WR	Williams %R
XGBoost	Aşırı Gradyan Artırma
XRP	Ripple
ZSMT	Zaman Serisi Model Tahmini
ZSY	Zaman Serisi Yaklaşımı

ŞEKİL LİSTESİ

Şekil 2.1	Transformer mimarisi.	11
Şekil 2.2	Bitcoin kapanış fiyatlarının görselleştirilmesi.	21
Şekil 3.1	6 zaman adımı ve (0.7-0.3) eğitim-test bölünme oranı için Transformer'ın tahminleri.	30
Şekil 3.2	Teknik analiz yaklaşımıyla XGBoost modelinin tahminleri.	34
Şekil 3.3	6 zaman adımı ve (0.7-0.3) eğitim-test bölünme oranı için Ağırlıklı Ortalama Alma Yöntemi'nin tahminleri.	37

TABLO LİSTESİ

Tablo 2.1	Teknik indikatörler ve tipleri.	13
Tablo 3.1	Zaman serisi yaklaşımı modellerinin performans karşılaştırması. .	29
Tablo 3.2	Zaman serisi yaklaşımı modellerinin genel performans karşılaştırması.	29
Tablo 3.3	Teknik indikatör parametreleri.	32
Tablo 3.4	Teknik indikatör yorumlaması.	33
Tablo 3.5	Teknik analiz yaklaşımında LazyPredict modellerinin performans karşılaştırması.	33
Tablo 3.6	Teknik analiz yaklaşımı modellerinin performans karşılaştırması.	34
Tablo 3.7	Topluluk modelleme yaklaşımlarının performans karşılaştırması.	36

Optuna Tabanlı Makine Öğrenmesi Yöntemleriyle Bitcoin Fiyat Tahminleme Yaklaşımları

Berkay YILDIRIM

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Murat TAŞKIRAN

Kripto piyasaları, yüksek volatiliteleri ve öngörülemez yapıları nedeniyle finansal zaman serisi tahminlerinde önemli zorluklar sunmaktadır. Bu çalışmanın amacı, literatürde var olan yapay zeka modellerini ve finansal teknik indikatörleri kullanarak, Bitcoin'in ABD doları karşısındaki dört saatlik fiyatını tahmin edebilmektir.

Çalışmada zaman serisi yaklaşımı olarak Otoregresif Entegre Hareketli Ortalama (ARIMA), Aşırı Gradyan Artırma (XGBoost), Yinelemeli Sinir Ağı (RNN), Uzun Kısa Süreli Bellek (LSTM), Zamansal Evrimsel Ağ (TCN) ve Transformer modelleri kullanılmıştır. Teknik analiz yaklaşımı olarak, veri seti teknik indikatörlerle birlikte özellik mühendisliği süreçlerinden geçirilip geleneksel makine öğrenmesi algoritmaları uygulanmıştır. Modellerin en iyi performansı gösterebilmesi için hiperparametreleri Optuna ile optimize edilmiştir. Farklı yaklaşımlardaki en iyi performans gösteren modellerin sonuçları, topluluk yöntemi yaklaşımı olarak belirlenen üç farklı yöntemle birleştirilerek değerlendirilmiştir. Modellerin ve yöntemlerin performansları, Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Hata (MAE) metrikleriyle karşılaştırılmıştır.

Sonuçlar, zaman serisi yaklaşımında Transformer modelinin MAE değeri 280.07 ve RMSE değeri 431.71 ile öne çıktığını göstermektedir. Ayrıca yüzdesel olarak hedef değişken belirlemenin, doğrudan fiyatın hedef değişken olarak kullanılmasından daha iyi performans gösterdiği belirlenmiştir. Topluluk yöntemi olarak en iyi performans gösteren Ağırlıklı Ortalama Yöntemini MAE değeri 149.1490 ve

RMSE değeri 247.3687 ile öne çıkmaktadır. Bu bulgular, önerilen yaklaşımların kripto pazarı tahmininde önemli bir potansiyele sahip olduğunu ve gelecekteki çalışmalarda daha ayrıntılı olarak incelenmesi gerektiğini ortaya koymaktadır.

Anahtar Kelimeler: Transformer, bitcoin fiyat tahmini, Optuna, zaman serisi tahmini, teknik indikatörler.



ABSTRACT

Bitcoin Price Forecasting Approaches With Optuna-Based Machine Learning Methods

Berkay YILDIRIM

Department of Electronics and Communications Engineering
Master of Science Thesis

Supervisor: Asst. Prof. Murat TAŞKIRAN

Crypto markets present significant challenges in financial time series forecasting with their high volatility and unpredictable nature. The aim of this study is to forecasting the 4-hour price of Bitcoin against the US dollar by using artificial intelligence models and financial technical indicators existing in the literature.

Autoregressive Integrated Moving Average (ARIMA), Extreme Gradient Boosting (XGBoost), Recurrent Neural Network (RNN), Long Short Term Memory (LSTM), Temporal Convolutional Network (TCN) and Transformer models were used as time series approaches in the study. As a technical analysis approach, the data set was subjected to feature engineering processes along with technical indicators and traditional machine learning algorithms were applied. In order for the models to show the best performance, their hyperparameters are optimized with Optuna. The results of the best performing models in different approaches were evaluated by combining three different methods designated as the ensemble approach. The performances of the models and methods were compared with the Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) metrics.

The results show that in the time series approach, the Transformer model stands out with its MAE value of 280.07 and RMSE value of 431.71. It has also been determined that setting a target variable as a percentage performs better than using the price directly as a target variable. As an ensemble method, the best performing Weighted Average Method stands out with its MAE value of 149.1490 and its RMSE value of 247.3687. These findings reveal that the proposed approaches have

significant potential in crypto market forecasting and should be examined in more detail in future studies.

Keywords: Transformer, bitcoin price forecasting, Optuna, time series forecasting, technical indicators.



1.1 Literatür Özeti

Kripto para piyasası, dijital para birimleri olarak adlandırılan kripto paraların alım satımının gerçekleştiği, merkeziyetsiz bir pazardır. Geleneksel finansal piyasalardan farklı olarak, bu piyasa herhangi bir aracı veya otorite olmaksızın, doğrudan internet üzerinden işlem yapılmasına olanak tanır. Kripto para borsaları, kripto cüzdanları, kripto para birimleri ve kripto teknolojileri gibi unsurları içerir; bu özellikler onu finansal yatırımcılar için popüler bir yatırım alanı yapmaktadır. Profesyonel yatırımcılar, piyasada yapacakları yatırımların miktarını, pozisyonunu ve süresini, çeşitli göstergelere dayanarak belirlemektedirler. En sık başvurulan yöntemler arasında, haberler ve güncel gelişmelere dayalı temel analiz, seçilen enstrümanın geçmiş fiyat hareketlerinden türetilen teknik indikatörler ve piyasanın temelini oluşturan makroekonomik göstergeler yer almaktadır. Ayrıca, son zamanlarda zaman serisi verileri üzerine kurulu yapay zeka modellerinin kullanımı da artmıştır. Bu çalışmada, teknik indikatörlerin yapay zeka ve veri bilimi teknikleri kullanılarak analiz edilmesi, geçmiş fiyat verileri üzerine yapılan ve son yıllarda popülerlik kazanan derin öğrenme modelleri ile zaman serisi analizinin gerçekleştirilmesi ele alınmaktadır. Son olarak, bu iki farklı metodolojinin bir araya getirilerek topluluk öğrenme yaklaşımı altında elde edilen sonuçlar incelenmiştir. Bu kısımda başlangıç olarak zaman serisi analizi üzerine yoğunlaşmış çalışmalar incelenip ne tarz çalışmalar yapıldığı ve bu çalışmaların sonuçları hakkında bilgiler verilmiştir.

Zaman serisi analizi üzerine geçmiş zamanlarda yapılan çalışmalar incelendiğinde, uzun süredir bu alanda popüler olan Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli gibi geleneksel yöntemlerin yanı sıra, son yıllarda yapay sinir ağları ve özellikle derin öğrenme tabanlı modeller [1–6], zaman serisi tahmininde önemli başarılar elde etmiştir. Literatürdeki zaman serisi tahmin modelleri üzerine yapılan çalışmalar, çeşitli yöntemlerin potansiyellerini ve sınırlamalarını ortaya koymaktadır. Poongodi ve arkadaşlarının [7] 2020 yılında yaptığı çalışma, ARIMA

modelinin Bitcoin'in saatlik olarak fiyat tahmininde nasıl kullanılabileceğini detaylı bir şekilde incelemiştir. Bu çalışmada, yazarlar tarihsel Bitcoin'in saatlik olarak kapanış fiyat verileri üzerinde ARIMA modelinin uygulanışını ve modelin tahmin başarısını yapay sinir ağı modeline karşı tartışmışlardır. Sonuç olarak da her iki modelin benzer sonuçlar elde ettiği görülmüştür. Dışsal Değişkenlerle Otoregresif Entegre Hareketli Ortalama (ARIMAX) ve Aşırı Gradyan Artırma (XGBoost) modelleri gibi makine öğrenimi tekniklerinin etkinliğide bu konuda hala merak edilen çalışmalardandır. Bu bağlamda, Iqbal ve arkadaşları [8] 2021 yılında, kripto para piyasalarında ARIMAX ve XGBoost modellerinin uygulanabilirliği ve performansını detaylı bir şekilde incelemiştir. Yazarlar, bu iki modelin çeşitli kripto paraların fiyat hareketlerini tahmin etmedeki başarısını analiz etmiş ve özellikle belirli piyasa koşullarında ARIMAX modelinin daha iyi performans gösterdiğini belirtmişlerdir. Zaman serisi tahmininde derin öğrenme tekniklerinin uygulanabilirliği üzerine yapılan çalışmalar, bu modellerin finans piyasalarındaki karmaşıklıkları modelleme potansiyelini göstermektedir. Bu bağlamda, Pai ve arkadaşları [9] 2022 yılında ve Saraswathi ve arkadaşları [10] BTC, ETH, XRP gibi kripto paraların fiyat tahmininde Uzun Kısa Süreli Bellek (LSTM) ağlarının nasıl kullanılabileceğini derinlemesine incelemiştir. Çalışma, piyasa verilerinin zaman serilerini analiz ederek gelecekteki fiyat hareketlerini yüksek doğruluk oranları ile tahmin edebilecek LSTM modelinin başarısını ortaya koymuştur. Seabe ve arkadaşları [11] 2023 yılında, zaman serisi tahminlerinde LSTM, Kapılı Tekrarlayan Birimler (GRU) ve İki Yönlü LSTM (BiLSTM) modellerinin etkinliğine vurgu yaptı. Çalışma, özellikle geçmiş ve gelecek verileri eş zamanlı olarak işleyebilme yeteneği sayesinde BiLSTM modelinin diğerlerine göre kripto para fiyat tahmininde üstün olduğunu gösterdi. Bu çalışmadaki bulgular, kendi araştırmamızda BiLSTM modelini ve LSTM modelini değerlendirip karşılaştırmak için sağlam bir temel sağlar. Fajou ve arkadaşları [12] tarafından 2021 yılında yapılan çalışma, kendi çalışmamız için önemli bir ölçüt sunar. Odak noktamız Bitcoin fiyat tahmini olsa da, Zamansal Evrişimsel Ağ (TCN) modelinin finans piyasalarındaki farklı varlıklar üzerindeki uygulanabilirliğini ve tahmin başarısını gösterir. Çalışma sonucunda, TCN modelinin LSTM, ARIMA ve Evrişimli Sinir Ağları (CNN) gibi modellere göre daha başarılı sonuçlar verdiği gösterilmiştir. Bu, TCN modelinin Bitcoin fiyat tahmininde de uygulanabileceğini ve benzer başarılar elde edebileceğini önermektedir. Sridhar ve arkadaşları [13] tarafından 2021 yılında yapılan çalışma, kendi çalışmamızda Transformer modelinin Bitcoin fiyat tahmini için uygulanabilirliğini araştırmak için değerli bir referanstır. Çalışmanın bulguları, Transformer modelinin kripto para piyasalarında geniş uygulanabilirlik potansiyeline sahip olduğunu göstermektedir. Bu, modelin Bitcoin gibi farklı bir kripto para üzerinde çalışılırken nasıl uyarlanabileceği ve optimize edilebileceği

konusunda bize rehberlik etmektedir. Özellikle bu çalışmanın farklı bir kripto para birimi olan Dogecoin üzerine odaklanması, Transformer modelinin farklı piyasa koşullarına ve kripto paraların özgün dinamiklerine nasıl uyum sağlayabileceğini göstermektedir.

Literatürde teknik indikatörler ve makine öğrenmesi tekniklerini kullanan çalışmalar incelendiğinde, kullanılan yöntemlerden biri doğal dil işleme yöntemleriyle birlikte teknik indikatörlerinin ortak şekilde kullanılması olduğu gözlemlenmiştir. Bu bağlamda yapılan çalışmada [14], teknik indikatörler ve metin verileri üzerinde duygu analizi kullanılarak Bitcoin fiyat trendleri tahmin edilmeye çalışılmıştır. Çalışmada kullanılan teknik indikatörler arasında Basit Hareketli Ortalama (SMA), Üssel Hareketli Ortalama (EMA), Göreceli Güç Endeksi (RSI), Hareketli Ortalamaların Yakınsaması/İraksaması (MACD) ve Stokastik RSI bulunmaktadır. Ayrıca, metin verilerinden yapılan duygu durum tespitlerinin Bitcoin fiyatı üzerindeki etkileri de incelenmiştir. Elde edilen duygu durumları ile teknik indikatör sonuçları birleştirilerek geleneksel makine öğrenme modelleri ile Bitcoin fiyat trendi tahmin edilmiştir. Çalışmanın sonucu olarak, gradyan artırma tabanlı makine öğrenmesi modelleri çok daha iyi performans göstermiştir. Farklı kripto paralar üzerinde de teknik indikatör modelleri için çalışmalar incelenmiştir. Bu bağlamda yapılan bir çalışmada [15], Bitcoin, Ethereum ve Litecoin gibi çeşitli kripto paraların günlük ve saatlik kapanış fiyatları için RSI, hareketli ortalamalar ve Bollinger Bantları gibi momentum, hareketlilik ve trend indikatörleri kullanılmıştır. Elde edilen sonuçlar, yapay sinir ağı modelleri ile değerlendirilerek, literatürdeki önceki yöntemlerle karşılaştırılmıştır. Karşılaştırılan önceki yöntemlere göre “Performer ve BiLSTM” yöntemi çok daha başarılı sonuçlar elde etmiştir. Bir diğer çalışmada [16], farklı kripto paraların dakikalık verileri için evrişim tabanlı ve diğer çeşitli derin öğrenme modelleri geliştirilmiş, hareketli ortalamalar gibi teknik indikatörler hesaplanmış ve sonuçlar çeşitli derin öğrenme modellerinde kullanılmıştır. Evrişim tabanlı modellerin sonuçlarının, diğer derin öğrenme yöntemlerine göre başarısı belirtilmiştir. Bu çalışmanın önemi, farklı kripto paralar üzerinde yapılan incelemelerde, her bir para birimi için başarılı performansın elde edilip edilmediğinin gösterilmesidir. Teknik indikatör haricinde belirli ekonomik göstergeler de yatırımcılar tarafından kullanılan ve takip edilen yatırım stratejilerinden biridir. Bu bağlamda yapılan çalışmada [17], hareketli ortalama ve momentum gibi teknik indikatörlerin yanı sıra S&P 500 gibi borsa endeksleri, global riskler ve emtia piyasalarının durumları gibi makroekonomik göstergeler de dikkate alınmıştır. Model olarak ElasticNet ve Lasso gibi regresyon modelleri kullanılmış ve teknik indikatörlerin ve makroekonomik göstergelerin Bitcoin fiyatını belirlemedeki başarısı ortaya konmuştur. Farklı zaman aralıklarında

da çeşitli çalışmalar yapılmaktadır. Genelde bir günlük kapanış fiyatları üzerine çalışmalar olsa da çok daha kısa süreler için de çalışmalar yapılmıştır. Bu bağlamda yapılan çalışmada [18], bir dakikalık veriler üzerinden teknik indikatörler ve Varyasyonel Mod Ayrışımı yöntemi ile fiyat tahminleri yapılmıştır. Elde edilen teknik indikatör verileri üzerinde korele olmuş özelliklerin çıkartılmasında Boruta yöntemi kullanılmış ve sonrasında Destek Vektör Makinesi modeli uygulanmıştır. Yapılan bu çalışmalar, teknik indikatörlerin ve özellik mühendisliği yöntemlerinin etkin kullanımını göstermiştir. Sonuç olarak, teknik indikatörlerle Varyasyonel Mod Ayrışımı yönteminin entegre edilmesi, bu yöntemlerin bireysel uygulamalarına kıyasla daha üstün performans sergilemiştir.

Yapılan çalışmada, literatüre benzer şekilde teknik indikatörler kullanılıp, bunlar makine öğrenmesi ve derin öğrenme tabanlı modeller eğitilmiştir. Literatürdeki çalışmalardan farklı olarak teknik indikatör sonuçları ham nümerik halde kullanılmamıştır. Her bir teknik indikatör için farklı bir şekilde sonuçlar kategoriklendirilmeye çalışılmıştır. Bunun dışında literatürdeki çalışmalar az sayıda teknik indikatörü incelemiştir. Bu çalışmada ise birbirinden farklı yirmi teknik indikatör kullanılıp bunlardan otuz civarı özellik çıkarılmıştır. Bu çıkarılan özellikler de yorumlanıp, elde edilen sonuçlar çeşitli özellik mühendisliği yöntemlerinden geçirilmiştir.

1.2 Tezin Amacı

Zaman serisi tahmini, finansal piyasalardan hava durumu tahminine kadar geniş bir uygulama yelpazesi sunar ve bu alandaki gelişmeler hem teorik hem de pratik olarak büyük önem taşır. Kripto para piyasaları gibi yüksek volatilité ve belirsizliğe sahip finansal piyasalarda, etkili zaman serisi tahmin yöntemleri büyük değér taşır. Bu çalışmanın temel amaçlarından biri, Bitcoin'in ABD doları karşısındaki kapanış fiyatını, dört saatlik zaman aralığına göre bir sonraki dört saatlik kapanışında oluşacak fiyatı tahmin edebilmeye çalışmaktır. Çalışmada, literatürde oldukça fazla kullanılan zaman serisi modellerini farklı zaman adımlarına ve farklı eğitim test bölünmesine göre bu modellerin özellikle Transformer modelinin performansları incelenmiştir.

Ayrıca, finansal piyasalarda yaygın olarak kullanılan teknik indikatörler de farklı modellere ayrı birer girdi olarak eklenmiştir. Bu indikatörler, yatırımcıların piyasada pozisyon alırken başvurduğu önemli araçlardır. Çalışmada, bu teknik indikatörler ile geleneksel makine öğrenmesi modellerinin bir arada kullanılması ve bu modellerin performanslarının kıyaslanması amaçlanmaktadır. Son olarak,

elde ettiğimiz bu iki farklı tip modelin sonuçlarını ortaklaşa bir şekilde kullanarak, performans kıyaslaması yapmaktır. Tüm modelleme süreçlerinde en iyi performansı elde edebilmek için de Optuna hiperparametre optimizasyon aracı kullanılmıştır. Yapılan analizler sonucunda, bu modellerin hangi koşullar altında daha iyi performans gösterdikleri ve hangi ölçütlerin tahmin başarısını etkilediği incelenecektir.

1.3 Hipotez

Bu çalışmanın temel hipotezi, zaman serisi analizi ve teknik indikatörler kullanılarak oluşturulan bireysel ve topluluk modellerin performanslarının karşılaştırılmasına dayanmaktadır. Çalışma, bu modellerin Bitcoin'in ABD doları karşısındaki dört saatlik kapanış fiyatının tahminlemesi üzerindeki performansını değerlendirerek, hangi yaklaşımların daha doğru tahminler sağladığını belirlemeyi amaçlamaktadır. Bireysel modellerin performansları ile topluluk modellerin performansları detaylı bir şekilde incelenecek, ve bu modellerin her biri için elde edilen sonuçlar kapsamlı analizlerle değerlendirilecektir. Ayrıca, Transformer gibi çeşitli konularda başarısını kanıtlamış modelin, geleneksel yapay sinir ağı modellerine ve klasik yöntemlere kıyasla Bitcoin kapanış fiyat tahminlerinde nasıl bir performans sergilediği özellikle incelenecektir. Ayrıca, zaman serisi verilerinin yüzdesel değişim hesaplamaları ile işlenmesinin, modelin tahmin başarısını nasıl etkilediği de sorgulanacaktır. Sonuç olarak, bu hipotezler, araştırmanın ilerleyen bölümlerinde deneysel metodolojiler ve çeşitli değerlendirme metrikleri kullanılarak test edilecektir.

BİTCOİN FİYATI TAHMİNLEME SİSTEMLERİ

Bitcoin [19], 2009 yılında ortaya çıkan ve kısa sürede finansal piyasalarda önemli bir yer edinen dijital bir para birimidir. Bitcoin'in fiyatı, çeşitli ekonomik faktörler, piyasa dinamikleri ve yatırımcı psikolojisi gibi bir dizi karmaşık değişkene bağlı olarak dalgalanmaktadır. Bu dalgalanmalar, Bitcoin yatırımcıları ve piyasa spekülörleri için hem fırsatlar hem de riskler oluşturmakta, bu nedenle Bitcoin fiyatının doğru bir şekilde tahmin edilmesi büyük bir önem arz etmektedir.

Genel olarak Bitcoin fiyat tahminleme sistemleri, genellikle finansal piyasalarda kullanılan geleneksel tahmin yöntemlerine benzer teknikler kullanır, fakat Bitcoin'in yüksek volatilitesi ve tahmin edilemez piyasa davranışları bu sistemlerin başarısını olumsuz etkiler ve sistemlerin geliştirilmesini zorunlu kılar. Bu sistemlerin başarısı, doğru veri toplama, etkili özellik seçimi ve güçlü algoritmaların uygun şekilde uygulanmasına bağlıdır.

Bitcoin fiyatını tahmin etmeye yönelik yaklaşımlar arasında zaman serisi analizi, makine öğrenmesi teknikleri ve derin öğrenme modelleri bulunmaktadır. Bu metodolojiler, geçmiş fiyat hareketlerinden yararlanarak gelecekteki fiyat değişikliklerini tahmin etmeye çalışır. Ancak, piyasadaki ani değişiklikler, global ekonomik olaylar veya düzenleyici müdahaleler gibi dış faktörler bu tahminlerin doğruluğunu olumlu yada olumsuz etkileyebilir.

Bu bölümde, Bitcoin fiyat tahminleme sistemlerinin temel prensipleri ve uygulamaları incelenecek, zaman serisi modelleri ve teknik analizlerle entegre edilen yapay zeka yöntemlerinin detaylarına değinilecektir. Ayrıca, bu sistemlerin etkinliğini değerlendirmek için kullanılan veri setleri, veri setlerinin nasıl işlendiği, kullanılan modellerin nasıl optimize edildiği ve ölçüm metrikleri incelenecektir.

2.1 Zaman Serisi Yaklaşımı

Zaman serisi tahmini, finansal piyasalar ve hava tahmini gibi çeşitli alanlarda uzun süredir karşılaşılan ve incelenen kritik bir problemdir. Geçmişte bu problemi çözmek için önce ARIMA gibi istatistiksel modeller kullanılmış, ardından karar ağacı, rastgele orman ve gradyan artırma gibi makine öğrenimi algoritmaları kullanılmıştır. Daha sonraki dönemde, sıralı verilerin özelliklerini yakalama konusunda güçlü olan RNN, LSTM ve GRU gibi derin öğrenme modelleri öne çıkmıştır. Günümüzde, bu modeller karmaşık sıralı ilişkileri öğrenme konusunda umut verici sonuçlar sunduğu için zaman serisi tahmininde Transformer modellerin potansiyeline odaklanılmaktadır. Çalışmada kullanılan modellere ilişkin kısa açıklamalar ilerleyen bölümlerde verilmiştir.

2.1.1 Kripto Para Piyasasında Zaman Serisi Modelleri

Kripto para borsaları gibi karmaşık yapıları olan ve tahminleri zorlayan alanlarda, yapay zeka teknolojilerinin katkısı büyük önem taşımaktadır. Bu bağlamda, özellikle finansal piyasaların analizi için geliştirilmiş olan zaman serisi modelleri, geniş bir kullanım alanına sahiptir. Kripto para piyasaları, yoğun volatiliteye ve öngörülemez fiyat ve hacim değişikliklerine sahne olmaktadır; bu nedenle, zaman serisi analizi yöntemleri, bu tür finansal piyasalarda karar verme süreçlerinde kritik bir rol oynamaktadır. Zaman serisi modelleri, geçmiş veriler üzerinden gelecekteki trendleri tahmin etme yeteneği sayesinde, kripto para piyasasının dinamiklerinin anlaşılmasında ve yatırım kararlarının şekillendirilmesinde etkili bir araç olarak değerlendirilmektedir. Çalışmada kullanılan zaman serisi modelleri hakkında bilgiler aşağıdaki başlıklarda verilmiştir.

Otoregresif Entegre Hareketli Ortalama (ARIMA) [20]

ARIMA, zaman serisi verilerini analiz etmek için kullanılan istatistiksel modelleme tekniklerinden biridir. Bu teknik, özellikle doğrusal zaman serisi verilerinin gelecekte ulaşacağı noktaları tahmin etmek için kullanılır. ARIMA modeli, finans, meteoroloji, ekoloji ve ekonomi gibi birçok alanda geçmiş verileri kullanarak, gelecekteki değerleri tahmin etmek için kullanılır. ARIMA modelinin bileşenlerini, Otokorelasyon (AR), Entegre (I) ve Hareketli Ortalama (MA) oluşturmaktadır. AR bileşeni, geçmiş değerlerin gelecekteki değerler üzerindeki etkisini temsil eder. I bileşeni, zaman serisinin durağan olmayan yapısını ele alır. MA bileşeni, hareketli ortalamaya göre geçmiş değerlerin hata terimleriyle ilişkisini ele alır.

Dışsal Değişkenlerle Otoregresif Entegre Hareketli Ortalama (ARIMAX)

ARIMA modelinin genişletilmiş bir versiyonudur. Bu model, ARIMA'nın temel

özelliklerinin yanı sıra dışsal değişkenlerin modellenmesine de izin verir. Bu dışsal değişkenler, zaman serisinin dışından gelen ve zaman serisinin gelecekteki değerlerini tahmin etmek için potansiyel olarak fayda sağlayabilecek değişkenlerdir. ARIMAX modelinde, ARIMA'ya göre AR, I ve MA bileşenleri bulunup, ekstra olarak da Dışsal Değişkenler (X) bulunmaktadır.

Aşırı Gradyan Artırma (XGBoost) [21]

XGBoost, yapılandırılmış veri setlerinde yüksek performans sağlayan ölçeklenebilir ve esnek bir gradyan artırma algoritmasıdır. Karar ağaçlarına dayanan bu model, hem sınıflandırma hem de regresyon problemlerinde etkilidir. XGBoost, özellikle karmaşık veri kümelerinde yüksek tahmin başarısı göstermesiyle bilinir. Birçok makine öğrenmesi alanında tercih edilen etkili bir modeldir. XGBoost, gradyan artırma tekniğini kullanarak bir dizi karar ağacını eğitir. Her bir iterasyonda, bir sonraki ağaç önceki ağaçların hatalarını düzeltmeye odaklanır, bu sayede modelin genel tahmin yeteneği artar. Gradyan artırma tekniği ise, birden fazla zayıf öğreniciyi bir araya getirip daha güçlü bir öğrenici oluşturmayı amaçlar.

Yapay Sinir Ağı (ANN)

ANN'ler, insan beyninin sinir ağlarından esinlenilmiş yapay sinir ağlarıdır, karmaşık desenleri tanıma ve öğrenme yeteneğine sahiptir. Bu yapay sinir ağları, nöronlardan oluşan bir giriş katmanı, çeşitli sayıda gizli katman ve bir çıkış katmanından oluşmaktadır. Her bir nöron, bir önceki katmandan aldığı ağırlıklandırılmış çıkışları toplar ve buna belirlenmiş aktivasyon fonksiyonunu uygular ardından elde edilen sonucu bir sonraki sırada bulunan katmana aktarır. Bu süreç çıkış katmanına kadar devam eder. İlk iterasyon sonucunda tahmin edilen değer ile gerçek değer arasında bir kayıp fonksiyonu hesaplanır. Ardından geriye yayılım algoritması ile birlikte ağırlıklar güncellenir. Daha sonra güncellenmiş ağırlıklar ile yeni bir iterasyon başlar. Bu süreç iterasyon sayısı bitene kadar bu şekilde devam eder.

Yinelemeli Sinir Ağı (RNN) [6]

RNN, özellikle ardışık zaman serisi verileri ile çalışmak için tasarlanmış bir yapay sinir ağı türüdür. RNN'ler, bir önceki adımdan bilgi akışını sürdürme yeteneği ile dikkat çekerler, böylece zaman içinde bilgiyi koruyabilir ve her adımda bu bilgiyi kullanabilirler. RNN tek yönlü ileri beslemeli sinir ağının aksine, çift yönlü bir yapay sinir ağıdır, yani bazı düğümlerden gelen çıktıların aynı düğümlere sonraki girdileri etkilemesine izin verir. ANN'den farklı olarak gizli katman, RNN'nin bellek bölümünü temsil eder. Her bir iterasyonda, gizli katmanın durumu h_t , bir önceki durum h_{t-1} ve mevcut girdi x_t ile güncellenir. Denklem şu şekildedir:

$$h_t = \sigma(W_{hh}h_{t-1} + W_{xh}x_t + b_h) \quad (2.1)$$

Burada W_{hh} ve W_{xh} ağırlık matrisleri, b_h bias terimi ve σ aktivasyon fonksiyonudur.

RNN için kaybolan ve patlayan gradyan problemi bulunmaktadır. RNN eğitimi sırasında, geriye yayılım yapıldığında, gradyanlar zamanla azalabilir veya aşırı büyüyebilir. Bu durum, modelin uzun süreli bağımlılıkları öğrenmesini zorlaştırır.

Uzun Kısa Süreli Bellek (LSTM) [5]

LSTM, zaman serisi verilerindeki uzun vadeli bağımlılıkları ve desenleri etkili bir şekilde modelleyen bir RNN türüdür. RNN'lerin karşılaştığı gradyan problemine çözüm getirmek için tasarlanmıştır. LSTM'ler, her bir hücrede bilgiyi uzun süreli olarak saklamak ve gerektiğinde bu bilgiyi unutmak veya güncellemek için kapı mekanizmalarını kullanır. Bir LSTM ünitesi bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısından oluşmaktadır. Hücre, belirsiz zaman aralıklarında değerleri hatırlar, ayrıca üç kapı, hücrenin içine ve dışına bilgi akışını düzenler. Unutma kapısı, hücrenin eski bilgileri unutmasını kontrol eder.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.2)$$

Burada W_f unutma kapısının ağırlıklarını, b_f bias, σ sigmoid aktivasyon fonksiyonunu, h_{t-1} önceki gizli durumu ve x_t mevcut girdiyi ifade eder.

Giriş kapısı, yeni bilginin hücre durumuna ne kadar ekleneceğini belirler.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.3)$$

Burada W_i , W_c ağırlıklar ve b_i , b_C bias terimlerini ifade eder. Ayrıca h_{t-1} önceki gizli durumu, $\tilde{C}_t$ aday hücre durumunu ve x_t mevcut girdiyi ifade eder.

Hücre durumu, uzun vadeli bilgileri saklar ve her adımda güncellenir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.4)$$

Burada C_t mevcut hücre durumunu, f_t unutma kapısını, i_t giriş kapısını, $\tilde{C}_t$ aday hücre durumunu ve $*$ eleman bazında çarpımı ifade eder.

Çıkış kapısı, hangi bilginin sonraki katmana aktarılacağını belirler.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)h_t = o_t * \tanh(C_t) \quad (2.5)$$

Burada W_0 çıkış kapısının ağırlıklarıdır ve b_0 bias terimidir. Ayrıca C_t mevcut hücre durumunu, h_t gizli durumu, x_t mevcut girdiyi ve o_t çıkış kapısını ifade eder.

LSTM için farklı varyasyonlar olarak yığın LSTM ve İki Yönlü LSTM (BiLSTM) [3] de kullanılmıştır. Yığın LSTM, birden fazla LSTM katmanını içeren bir yapıdır. Her katman, ardışık verilerdeki uzun vadeli bağımlılıkları ve karmaşık özellikleri yakalamaya katkıda bulunur. BiLSTM, hem geçmiş hem de gelecek zaman adımlarındaki bilgileri dikkate alarak daha kapsamlı bir zaman serisi analizi sunar. İki yönlü yapı, verilerin her iki yönünde de bağlamı öğrenir.


Zamansal Evrişimsel Ağ (TCN) [1]

TCN'ler, özellikle zaman serisi verileri için tasarlanmış bir tür evrişimsel sinir ağıdır. Bu modeller, uzun vadeli bağımlılıkları etkili bir şekilde ele alabilir ve zaman serisi verilerinde karmaşık desenleri tanıyabilir. TCN'ler, girdi verisinin zaman boyutu boyunca bir dizi bir boyutlu evrişim katmanını kullanılır. Temel mimaride, katmanlar arası evrişim kernel'leri artımlı olarak genişletilir. Bu sayede, her katman bir önceki katmandan daha geniş zaman penceresini odaklanabilir.

Transformer [4]

Doğal dil işleme alanında devrim yaratan Transformer, ardışık verilerdeki bağlamı, dikkat mekanizmalarını kullanarak anlar. Transformer modelleri, verilerin ardışık yapısını korurken her bir eleman arasındaki ilişkileri daha etkili bir şekilde modelleyebilir. Transformer modelinin genel blok diyagramı Şekil 2.1'de verilmiştir. Transformer modeli, kodlayıcı ve dekoder olarak iki ana bileşenden oluşur. Her iki bileşen de birden fazla katmandan oluşur. Her katman çoklu başlık dikkat mekanizması ve pozisyonel tam bağlantılı katmanları içerir.

Çoklu başlık dikkat mekanizması katmanı, dikkat mekanizmasını paralel olarak birden çok sefer uygular. Her başlık farklı dikkat ağırlıkları kullanarak girdilerden farklı bilgiler çıkarır ve bu bilgiler daha sonra birleştirilir. Pozisyonel tam bağlantı katmanı, her pozisyonadaki değerleri bağımsız olarak işleyen iki adet lineer dönüşümden oluşur. Normalizasyon katmanında, her alt katmanın çıktısı, girdiye eklenmeden önce katman normalizasyonundan geçer. Bu öğrenme sürecini daha kararlı hale getirir. Dekoder bileşeninde, ekstra olarak maske çoklu başlık dikkat mekanizması içerir. Bu sayede, bu katman, gelecekteki konumlarda bilgilere bakmamayı sağlayarak, oto regresif tahminde bulunur.



Şekil 2.1 Transformer mimarisi.

Dikkat mekanizması, Transformer’da kullanılan anahtar, sorgu ve değer olmak üzere üç ana bileşen üzerinden işlev gören dikkat mekanizması, veri içerisindeki elemanlar arası etkileşimleri ölçer. Bu mekanizma denklem 2.6’de verilmiştir.

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (2.6)$$

Burada Q , K ve V sırasıyla sorgu, anahtar ve değer matrisleridir. d_k anahtarların boyutudur.

2.2 Teknik Analiz Yaklaşımı

Finansal piyasalarda teknik analizler, sıklıkla başvurulanan ve piyasa fiyat hareketlerinin gelecekteki yönünü kestirmek amacıyla kullanılan yöntemler arasında yer almaktadır. Bu yöntemler, piyasanın volatilitesi, momentumu, trendleri ve hacim değişiklikleri gibi ölçütleri tahmin etmek için de kullanılmaktadır. Temelde, teknik analizler, geçmişteki fiyat hareketlerini inceleyerek, gelecekte oluşabilecek fiyat hareketlerini tahmin etmeyi amaçlar. Temel analizlerden farklı

olarak, teknik analizler daha çok rasyonel ve niceliksel verilere dayanır, bu sebeple yatırımcılar için genellikle daha güvenilir sonuçlar sunduğu kabul edilir. Teknik analizler genelde bir finansal varlığın açılış, kapanış, en yüksek, en düşük fiyatları ve işlem hacmi gibi temel verilerine dayanarak hesaplanır. Ancak, piyasa spekülasyonları nedeniyle aşırı derecede manipüle edilen durumlarda, teknik analizin başarısı önemli ölçüde azalabilir.

2.2.1 Teknik Analiz Sonuçlarının Yapay Zeka ile Değerlendirilmesi

Piyasalarda teknik analizler tek başlarına çoğu zaman yeterli bilgi sağlamazlar. Bu nedenle, analistler genellikle birden fazla teknik indikatörü bir arada kullanmayı tercih ederler. Ancak, birden fazla indikatörün eş zamanlı kullanımı, yorumlama sürecini karmaşık hale getirebilir. Bu durumu çözmek için, hesaplanan tüm teknik indikatörlerin sonuçlarının sistematik bir şekilde değerlendirilmesi ve bu sonuçların çeşitli yapay zeka modellerine beslenmesi önerilmektedir. Böylece, geçmişten günümüze uzanan veriler üzerinden bir eğitim süreci gerçekleştirilerek, teknik analiz sonuçlarının daha mantıklı ve etkin bir şekilde ele alınması sağlanabilir. Bu süreçte, teknik indikatörlerin çıktılarının yapay zeka modelleri tarafından etkin bir şekilde işlenebilmesi için uygun formata dönüştürülmesi büyük önem taşır.

2.2.2 Teknik İndikatörler

Finansal piyasalarda en çok kullanılan teknik indikatörler çalışmada tercih edilmiştir. Teknik indikatörlerin isimlerinin, tiplerinin ve çıkartılan özellik sayılarının yer aldığı bilgiler Tablo 2.1’de verilmiştir. Kullanılan teknik indikatörler ile alakalı kısa bilgiler aşağıda verilmiştir.

Göreceli Güç Endeksi (RSI)

RSI, J. Welles Wilder tarafından 1978’de geliştirilen ve teknik analizde sıklıkla kullanılan momentum indikatörlerinden biridir. RSI, bir yatırım enstrümanının fiyat hareketlerinin hızını ve değişimini ölçer. RSI değeri 0 ile 100 arasında bir değer almaktadır.

İndikatör yorumlamasında, RSI değeri 70’in üzerindeyse ‘aşırı alım’ sinyali, 30’un altındaysa ‘aşırı satım’ sinyali ve 30 ile 70 arasındaki değerlerin ise ‘nötr’ sinyali olarak değerlendirilmiştir.

Stokastik Osilatör (STOCH)

STOCH, 1950’lerde Dr. George Lane tarafından geliştirilen bir momentum indikatörlerinden biridir. Bu indikatör, bir varlığın kapanış fiyatını belirli bir

Tablo 2.1 Teknik indikatörler ve tipleri.

İndikatör	Tipi	Özellik Sayısı
RSI	Momentum	1
WR	Momentum	1
CCI	Momentum	1
UO	Momentum	1
STOCH	Momentum	1
STOCHRSI	Momentum	1
MACD	Momentum	1
KDJ	Momentum	1
BBP	Momentum	1
CMF	Hacim	1
AO	Momentum	1
BBAND	Trend	2
KC	Oynaklık	1
Hareketli Ortalama	Trend	4
PSAR	Trend	1
OBV	Hacim	1
SuperTrend	Trend	1
ADX	Trend	1
Pivot Noktaları	Destek/Direnç	4
ATR	Oynaklık	1

zaman aralığındaki fiyat aralığının en yüksek ve en düşük noktalarıyla karşılaştırır. STOCH, fiyatların bir trendin içindeki yönünü ve gücünü ölçmek için kullanılır ve 0 ile 100 arasında bir değer alır.

İndikatör yorumlamasında, hesaplanan K ve D değerleri 20'nin altına düştüğünde ve K değeri, D değerini alttan üste doğru keserse, bu bir 'al' sinyali olarak değerlendirilmiştir. Öte yandan, K ve D değerleri 80'in üzerine çıktığında ve K değeri, D değerini üstten alta doğru keserse, bu bir 'sat' sinyali olarak kabul edilmiştir. Ayrıca, K değeri D değerinden büyük olduğunda bu durum 'boğa momentumu'; K değeri D değerinden küçük olduğunda ise 'ayı momentumu' olarak değerlendirilmiştir.

Stokastik Göreceli Güç Endeksi (STOCHRSI)

STOCHRSI aslında bir indikatörün indikatörüdür. Teknik analizde RSI indikatörü üzerinde stokastik bir hesaplama yapılarak kullanılır. Bu indikatör, belirtilen periyot boyunca RSI değerlerinin kendi en yüksek ve en düşük değerleri arasındaki dalgalanmaları ölçer.

İndikatör yorumlamasında, hesaplanan K ve D değerleri 20'nin altına düştüğünde ve K değeri, D değerini alttan üste doğru keserse, bu bir 'al' sinyali olarak

değerlendirilmiştir. Öte yandan, K ve D değerleri 80'in üzerine çıktığında ve K değeri, D değerini üstten alta doğru keserse, bu bir 'sat' sinyali olarak kabul edilmiştir. Ayrıca, K değeri D değerinden büyük olduğunda bu durum 'boğa momentumu'; K değeri D değerinden küçük olduğunda ise 'ayı momentumu' olarak değerlendirilmiştir.

Hareketli Ortalamaların Yakınsaması/İraksaması (MACD)

MACD, fiyatın iki farklı hareketli ortalamasının arasındaki ilişkiyi yorumlayarak, piyasa hakkında trend takibi yapmaya yarayan bir momentum indikatörüdür. MACD indikatörü 1970'li yıllarda Gerald Appel tarafından geliştirilmiştir.

Hesaplanan MACD değeri, sinyal çizgisini yukarı yönlü kesiyorsa 'al' sinyali olarak, aşağı yönlü kesiyorsa 'sat' sinyali olarak yorumlanmaktadır. Bunun dışında, MACD değeri sinyal çizgisinden yüksekse 'boğa momentumu', düşükse 'ayı momentumu' olarak değerlendirilmiştir.

Bollinger Bantları (BBAND)

BBAND, John Bollinger tarafından 1980'lerde geliştirilen ve finansal piyasalarda volatilitiyi ölçmeye yarayan ve fiyatın alt üst sınırlarını belirlemeye yardımcı olan teknik indikatörlerden biridir. Üç çizgiden oluşmaktadır; Orta çizgi, üst bant ve alt bant. Basit hareketli ortalama (SMA) kullanılarak orta çizgi hesaplanır. Standart sapma kullanılarak da üst ve alt bant hesaplanır.

Hesaplanan değer, üst bandın yukarısına çıkıyorsa 'boğa trendi' sinyali, alt bandın aşağısına iniyorsa 'ayı trendi' sinyali olarak yorumlanmıştır. Hesaplanan değer, alt bandı yukarı yönlü kestiye 'al' sinyali, üst bandı aşağı doğru kestiye 'sat' sinyali olarak yorumlanmıştır. Hesaplanan değer eğer orta noktayı kestiye de 'stabil' sinyali ve bunların dışındaki durumlar ise 'nötr' sinyali olarak yorumlanmıştır. Hesaplanan bant genişliği değeri ise nümerik özellik olarak eklenmiştir.

Ortalama Yön Endeksi (ADX)

Welles Wilder tarafından geliştirilen ADX, teknik analizde kullanılan ve trendin gücünü ölçmeye yardımcı bir indikatördür. Özetle, fiyat hareketlerini inceleyerek trendin gücünü belirlemek için kullanılan bir araçlardan biridir.

Yorumlama için ilk olarak bir güç eşik değeri belirlenir. Eğer hesaplanan Pozitif Yönlü Hareket (DMP) değeri Negatif Yönlü Hareket (DMN)'den büyük ve ADX değeri güç eşik değerinden büyük ise 'al' sinyali, DMN değeri DMP'den büyük ve ADX değeri güç eşik değerinden büyük ise 'sat' sinyali olarak yorumlanmıştır. Ayrıca bu durumlar dışında DMP değeri DMN'den büyük ve ADX değeri güç eşik değerinden küçük ise 'nötr al' sinyali, DMN değeri DMP'den büyük ve ADX

değeri güç eşik değerinden küçük ise 'nötr sat' sinyali olarak yorumlanmıştır.

Williams %R (WR)

WR indikatörü, bir finansal varlığın aşırı alım veya aşırı satım koşullarını belirlemek için kullanılan bir momentum indikatörüdür. Larry Williams tarafından geliştirilen bu indikatör, fiyatın belirli bir periyot içinde ulaştığı en yüksek ve en düşük seviyeler arasındaki kapanış fiyatının konumunu yüzdelik olarak ifade eder.

İndikatör yorumlamasında, WR değeri -20'nin üzerindeyse 'aşırı alım' sinyali, -80'nin altındaysa 'aşırı satım' sinyali ve -80 ile -20 arasındaki değerlerin ise 'nötr' sinyali olarak değerlendirilmiştir.

Emtia Kanalı Endeksi (CCI)

CCI, Donald Lambert tarafından 1980 yılında geliştirilen bir teknik indikatördür. CCI, yeni bir trendi belirlemek veya piyasadaki aşırı alım, aşırı satım durumlarını tespit etmek için kullanılabilecek bir teknik indikatördür.

İndikatör yorumlamasında, CCI değeri 100'ün üzerindeyse 'aşırı alım' sinyali, -100'ün altındaysa 'aşırı satım' sinyali ve -100 ile 100 arasındaki değerlerin ise 'nötr' sinyali olarak değerlendirilmiştir.

Nihai Osilatör (UO)

UO, Larry Williams tarafından geliştirilen ve kısa, orta ve uzun dönemli fiyat hareketlerini birleştiren bir momentum indikatörüdür. UO, piyasadaki aşırı alım veya aşırı satım durumlarını tespit etmeye yardımcı olur.

İndikatör yorumlamasında, UO değeri 70'in üzerindeyse 'aşırı alım' sinyali, 30'un altındaysa 'aşırı satım' sinyali ve 30 ile 70 arasındaki değerlerin ise 'nötr' sinyali olarak değerlendirilmiştir.

Boğa-Ayı Gücü (BBP)

Boğa-Ayı Gücü indikatörü, piyasanın gücünü ölçmek için kullanılan bir teknik analiz aracıdır. Bu indikatör, Dr. Alexander Elder tarafından geliştirilmiştir ve özellikle hisse senedi, endeks ve diğer finansal varlıkların mevcut fiyatlarının ortalama fiyatlarına göre güç veya zayıflık seviyelerini değerlendirmek için kullanılır. Boğa gücü, mevcut günün en yüksek fiyatının, belirli bir süre için hesaplanan üssel hareketli ortalamasının (EMA) üstündeki farkı ölçer. Ayı gücü ise mevcut günün en düşük fiyatının aynı hareketli ortalamaadan ne kadar aşağıda olduğunu ölçer.

Eğer hesaplanan güç değeri sıfırdan büyük ve artış gösteriyorsa, bu 'boğa momentumu' sinyali olarak yorumlanmıştır; değer sıfırdan küçük ve azalış

gösteriyorsa, bu 'ayı momentumu' sinyali olarak kabul edilmiştir. Bu durumların dışında kalan değerler ise 'nötr' sinyali olarak değerlendirilmiştir.

Hareketli Ortalamalar

Hareketli ortalama, teknik analizde yaygın olarak kullanılan ve trend takip etmekte kullanılan önemli bir indikatördür. Bu indikatör, fiyatların gelecekteki yönünü tahmin etmek yerine, mevcut eğilimini gecikmeli bir şekilde gösterir. Hesaplama yapılırken geçmiş fiyat verilerini kullanıldığı için, hareketli ortalamalardan elde edilen sonuçlar gecikmelidir. Kullanılan hareketli ortalamalar üssel hareketli ortalama (EMA) ve basit hareketli ortalama'dır (SMA). SMA belirli bir süre içindeki fiyatların aritmetik ortalamasını alarak hesaplanır. EMA ise son fiyatlara daha fazla ağırlık veren bir ortalama hesaplama yöntemidir.

Hem SMA hem de EMA hesaplaması yapılmıştır. Kısa, orta, uzun olarak üç farklı periyot seçilmiştir. Bunların birbiriyle keşisimleriyle dört farklı özellik oluşturulmuştur.

Pivot Noktaları

Pivot noktaları, işlem yapılan enstrümanda direnç ve destek bölgelerini hesaplamak için kullanılır. Direnç bölgesi, enstrümanın fiyatının o an için çıkabileceği maksimum nokta yani satış noktasıdır. Destek bölgesi ise enstrümanın fiyatının o an için düşebileceği minimum nokta yani alım noktasıdır. Kullanılan pivotlar, klasik ve fibonacci pivottur.

Hesaplama sonucunda üç adet direnç, üç adet destek ve bir adet pivot noktası bulunmuştur. Enstrümanın fiyatı hangi iki bölge arasındaysa, ona göre 'güçlü al', 'al', 'nötr al', 'nötr sat', 'sat', 'güçlü sat' sinyalleri olarak yorumlanmıştır.

KDJ

KDJ indikatörü, Stokastik osilatörün bir türevi olan ve özellikle hisse senedi ve diğer finansal piyasalarda trend dönüşlerini ve potansiyel alım-satım noktalarını belirlemek için kullanılan bir teknik analiz aracıdır. KDJ, üç ana bileşenden oluşur: K, D ve J. Bu göstergeler, bir varlığın fiyat momentumunu ve potansiyel piyasa dönüş noktalarını izlemek için kullanılır.

Hesaplanan J değeri 20'nin altında ise ve K değeri, D değerini aşağıdan yukarıya doğru kesiyorsa 'al' sinyali olarak yorumlanmıştır. Hesaplanan J değeri 80'in üzerindeyse ve K değeri, D değerini yukarıdan aşağıya doğru kesiyorsa 'sat' sinyali olarak değerlendirilmiştir. Ayrıca, bu durumlar dışında, eğer K değeri D değerinden büyükse 'boğa momentumu' sinyali; K değeri D değerinden küçükse 'ayı momentumu' sinyali olarak indikatör yorumlaması yapılmıştır.

Parabolik Durdurma ve Geri Alma (PSAR)

PSAR indikatörü, J Welles Wilder Jr. tarafından 1976'da geliştirilmiştir. PSAR'ın üç ana işlevi vardır: mevcut piyasa eğilimini belirlemek, trend dönüşlerinde potansiyel alım veya satım sinyalleri sunmak.

Hesaplanan değer eğer kapanış fiyatının altındaysa 'al' sinyali, kapanış fiyatının üstündeyse 'sat' sinyali olarak yorumlanmıştır.

Denge Hacmi (OBV)

OBV indikatörü, işlem hacmine dayalı olarak alım satım baskısını ölçerek piyasa trendi gücünü ve fiyat değişimlerini değerlendirmeyi amaçlar. Tarihi 1960'lara kadar dayanan OBV, Joseph Granville tarafından geliştirilmiştir.

Hesaplanan değer sürekli artıyor ve fiyat da aynı şekilde artış gösteriyorsa, bu 'al' sinyali olarak yorumlanmıştır. Öte yandan, değer giderek azalıyor ve fiyat da düşüş gösteriyorsa, bu 'sat' sinyali olarak değerlendirilmiştir. Bu durumların dışında kalanlar ise 'nötr' sinyali olarak yorumlanmıştır.

Chaikin Para Akışı (CMF)

CMF, Marc Chaikin tarafından 1966 yılında geliştirilmiş bir piyasa gücü indikatörüdür. Bu indikatör, belirli bir zaman dilimi boyunca bir finansal enstrümana olan para akışının, girişini veya çıkışını tespit etmek amacıyla kullanılır.

Hesaplanan değer sıfırdan büyük ve artış gösteriyorsa, bu 'boğa momentumu' sinyali olarak yorumlanmıştır; değer sıfırdan küçük ve azalış gösteriyorsa, bu 'ayı momentumu' sinyali olarak kabul edilmiştir. Bu durumların dışında kalan değerler ise 'nötr' sinyali olarak değerlendirilmiştir.

Müthiş Osilatör (AO)

AO, teknik analizde kullanılan bir indikatör olup, bir varlığın momentumunu ölçmek için kullanılır. Momentum, bir varlığın fiyatının değişim hızını gösterir ve bir varlık için yüksek momentum, fiyatının hızlı yükselişini veya düşüşünü gösterir.

Hesaplanan değer sıfırdan büyük ve artış gösteriyorsa, bu 'boğa momentumu' sinyali olarak yorumlanmıştır; değer sıfırdan küçük ve azalış gösteriyorsa, bu 'ayı momentumu' sinyali olarak kabul edilmiştir. Bu durumların dışında kalan değerler ise 'nötr' sinyali olarak değerlendirilmiştir.

Keltner Kanalı (KC)

KC, Chester W. Keltner tarafından 1960'larda geliştirilen ve daha sonra Linda Bradford Raschke tarafından modifiye edilen bir teknik analiz aracıdır. Bu indikatör, bir varlığın fiyat trendinin yönünü, volatilitelerini ve potansiyel destek ve

direnç seviyelerini belirlemek için kullanılır. Üç kısımdan oluşmaktadır; Orta çizgi, üst bant ve alt bant. EMA ile orta çizgi hesaplanır. Üst ve alt bant ise Ortalama Gerçek Aralık (ATR) ile hesaplanır.

Hesaplanan değer, üst bandın yukarısına çıkıyorsa 'boğa trendi' sinyali, alt bandın aşağısına iniyorsa 'ayı trendi' sinyali olarak yorumlanmıştır. Hesaplanan değer, alt bandı yukarı yönlü kestiye 'al' sinyali, üst bandı aşağı doğru kestiye 'sat' sinyali olarak yorumlanmıştır. Hesaplanan değer eğer orta noktayı kestiye de 'stabil' sinyali ve bunların dışındaki durumlar ise 'nötr' sinyali olarak yorumlanmıştır.

SuperTrend

SuperTrend, finansal piyasalarda trendin yönünü belirlemek için kullanılan ve son yıllarda oldukça popüler olan bir teknik indikatördür. Olivier Seban tarafından geliştirilen bu indikatör, fiyat trendlerini takip etmek ve trend dönüş noktalarını belirlemek amacıyla tasarlanmıştır. İndikatör, hareketli ortalama benzeri bir trend çizgisi ve fiyatın oynaklığını göz önünde bulunduran bir volatilité bantları sistemini birleştirir. İndikatör yorumlamasında, hesaplanan değer eğer sıfırdan fazlaysa 'al' sinyali, sıfırdan düşükse 'sat' sinyali olarak yorumlanmıştır.

Ortalama Gerçek Aralık (ATR)

ATR, J. Welles Wilder, Jr. tarafından geliştirilen, finansal enstrümanın fiyatındaki volatilitéyi ölçmeye yarayan bir teknik indikatördür. Ayrıca ATR, fiyat hareketlerinin genişliğini belirlemede yardımcı olur. Hesaplanan değer nümerik özellik olarak eklenmiştir.

2.2.3 Teknik Analiz Modelleri

Bu bölümde, teknik indikatörler kullanılarak hazırlanan veri seti için çeşitli modeller ele alınmıştır. İlk olarak LazyPredict [22] kütüphanesi sayesinde geleneksel makine öğrenmesi modelleri temel düzeyde karşılaştırılmıştır. Ek olarak, tablo veriler üzerinde performansları kanıtlanmış Gradyan artırma algoritmalarından olan, Aşırı Gradyan Artırma (XGBoost) ve Hafif Gradyan Artırma Makinesi (LGBM) 'de ayrıca model değerlendirme sürecine dahil edilmiştir. XGBoost modelinin tanımı 2.1.1 bölümde yer almaktadır. Bu nedenle bu kısımda sadece LazyPredict kütüphanesinin ve LGBM modelinin tanımları sunulmuştur.

LazyPredict [22]

LazyPredict kütüphanesi, bir dizi makine öğrenmesi algoritmasını otomatik olarak uygulayarak, her bir modelin eğitim ve test süreçlerini yönetir. Sonuç olarak, kullanıcıya her bir modelin doğruluk, hata oranı gibi performans metrikleri

üzerinden bir karşılaştırma sunar. Bu, modelin problem setine uygunluğunu ve veri üzerindeki genel performansını objektif bir şekilde değerlendirme fırsatı sağlar.

Bunun yanı sıra, LazyPredict kütüphanesinin kullanımı, model seçim süreçlerini sadeleştirerek, zaman ve kaynak optimizasyonu sağlar. Bu kütüphane sayesinde, önceden uzun süreler alabilecek model deneme ve değerlendirme işlemleri, önemli ölçüde daha kısa sürelerde gerçekleştirilebilmektedir. Dolayısıyla, LazyPredict, makine öğrenmesi projelerinde erken aşama model değerlendirmeleri için önemli bir araçtır. Bu sayede, modellerin performansları hakkında erken aşamada bilgiye sahip olunması sağlanır.

Hafif Gradyan Artırma Makinesi (LGBM) [23]

LGBM, büyük veri setlerinde yüksek performans sağlayan ölçeklenebilir ve esnek bir gradyan artırma algoritmasıdır. LGBM, genel gradyan artırma modelleri prensibine dayanır ve ardışık olarak zayıf öğrencileri (genellikle karar ağaçları) optimize ederek güçlü bir tahmin modeli oluşturur. XGBoost yönteminden farklı olarak, daha hızlı eğitim süreleri, daha düşük bellek kullanımı sunar. Geleneksel gradyan artırma yöntemlerinden farklı olarak, LGBM daha iyi bir hata oranı azaltımı sağlayacak şekilde yaprakları odaklı büyütme stratejisi benimser. Bu, modelin daha az sayıda yaprakla daha etkili bölünmeler yapabilmesini sağlar. LGBM, bu özellik sayesinde, daha düşük kaynak tüketimiyle daha iyi performans göstereceği tezini sunar.

2.3 Topluluk Modelleme Yaklaşımı

Her iki modelleme yaklaşımından en iyi performans gösterenler belirlenerek topluluk öğrenme yaklaşımı uygulanacaktır. Bu yaklaşımın temel amacı, iki farklı yaklaşımdaki modelin birbirleriyle ne kadar ilişki içinde olduğunu görmek ve sonuçların birleştirilmesi durumunda performanslarında ne derece bir iyileşme olduğu gözlemlemektir. Bu süreçte, ilk olarak zaman serisi analizinde en iyi performans gösteren modelin, hedef değişkeni için yüzdesel olarak fiyat değişimi hesaplanacaktır. Bu yaklaşım ile modellemenin, Bitcoin'in ham olarak kapanış değerlerine kıyasla yüzdesel değişim verisiyle daha iyi performans gösterdiğini göstermesi beklenmektedir.

Bu aşamada her iki yaklaşımda da en iyi performans gösteren modelin optimizasyonu için hiperparametre uzayı genişletilip, hiperparametre deneme sayıları artırılmıştır. Bunun amacı ise modellerin en iyi performans göstereceği hiperparametre değerlerine daha çok yaklaşabilmektir.

2.3.1 Ortalama Alma Yöntemi

Her iki yöntemde de bulunan en iyi iki modelin tahmin sonuçlarının basit ortalaması alınarak yeni bir tahmin elde edilir. Bu yöntem, her iki modelin sonuçlarını eşit derecede önemseyerek birleştirir. İlgili denklem 2.7’de verilmiştir.

$$\text{Tahmin} = \frac{\text{ZMST} + \text{TİMT}}{2} \quad (2.7)$$

burada "ZSMT" (Zaman Serisi Model Tahmini) ve "TİMT" (Teknik İndikatör Model Tahmini), sırasıyla modellerden elde edilen tahminleri temsil etmektedir.

2.3.2 Ağırlıklı Ortalama Alma Yöntemi

Her iki yöntemde de bulunan en iyi iki modelin tahmin sonuçlarının ağırlıklı ortalaması alınarak yeni bir tahmin elde edilir. Ağırlıklı ortalamaadaki katsayılar, modellerin performanslarına göre belirlenmiştir. Daha düşük hata oranına sahip modele daha yüksek ağırlık verilerek hesaplama yapılır. İlgili denklem 2.8’de verilmiştir.

$$\text{Tahmin} = \frac{\text{ZSMT} \times K_1 + \text{TİMT} \times K_2}{2} \quad (2.8)$$

burada "ZSMT" (Zaman Serisi Model Tahmini) ve "TİMT" (Teknik İndikatör Model Tahmini), sırasıyla modellerden elde edilen tahminleri temsil etmektedir. K_1 ve K_2 ’de aynı sırayla modeller için belirtilen katsayıları temsil etmektedir.


2.3.3 Meta Öğrenme Yöntemi

Her iki yöntemde de bulunan en iyi iki modelin tahmin sonuçları ile bir lineer regresyon modeli eğitilir. Burada da doğru değerlendirme yapabilmek için veri eğitim ve test olarak ayrılmıştır. Eğitim verisi ile model geliştirilip, test verisiyle de değerlendirme yapılacaktır.

2.4 Zaman Serisi Modellerinin Veri Seti

Bitcoin’in geçmiş verileri Binance Uygulama Programlama Arabirimi (API) [24] aracılığıyla toplandı. Bu veriler, 2020 yılı başından 2024 yılı başına kadar olan dört yıllık dönemi kapsıyor. Finansal piyasalarda yaygın olarak kullanılan dört saatlik zaman dilimleri baz alınarak veriler dört saatlik olarak elde edildi. Bu seçim, finansal piyasalarda teknik analizlerin genellikle dört saatlik veriler üzerinden

yapılmasından kaynaklanmaktadır. Grafiği elde edilen veri seti Şekil 2.2’de verilmiştir.



Şekil 2.2 Bitcoin kapanış fiyatlarının görselleştirilmesi.

Toplanan veriler, özellikle Bitcoin’in kapanış değerlerine odaklanılarak analize edildi. Veri setine dijital sinyal işleme olarak, makine öğrenmesi modelleri için normalizasyon yöntemi, ARIMA modelleri için ise fark alma yöntemi uygulanmıştır.

2.5 Teknik İndikatör Modellerinin Veri Seti

Toplanan dört saatlik veri setleri, açılış, kapanış, en yüksek, en düşük fiyatları ve işlem hacmi değerleri dikkate alınarak analiz edilmiştir. Belirtilmiş olan teknik indikatörler bu veriler kullanılarak hesaplanmıştır. Hesaplanan her bir teknik indikatör değeri daha sonra kategorik veya nümerik biçimde olarak işlenerek özellik setine eklenmiştir. Bu veriler üzerinde gerçekleştirilen veri mühendisliği işlemleri, aşağıda ‘Özellik Mühendisliği’ başlığı altında sırasıyla açıklanmıştır.

2.5.1 Teknik İndikatörlerin Yorumlanması

Kullanılan çoğu teknik indikatör kategorik ‘al’, ‘sat’ vb. şeklinde yorumlanmıştır. Bunun nedeni, karmaşık ve sürekli değişen piyasa verilerini anlamlandırma ve yatırım kararlarına doğrudan uygulanabilir hale getirme amacıdır. Ayrıca bazı indikatörler birden fazla nümerik sonuç ortaya çıkmaktadır. Bunlar yalnız başlarına genelde anlamsız olmaktadır. Bu değerlerin bazen birbirini kesme durumlarına bazen de belirli bir noktayı kesme durumlarına bakılır. Bu sebeplerden indikatör sonuçları kategoriklendirilmiştir.

2.5.2 Hedef Değişken Tanımlanması

Bitcoin fiyatının kapanış değerlerinin bir önceki kapanış değerine yüzdesel oranlaması yapıp hesaplanmıştır. Bu hesaplanan değer makine öğrenmesi modellerinde bizim hedef değişkenimiz olacaktır. Direkt olarak kapanış değerinin hedef değişken seçilmeme nedeni piyasanın farklı zamanlarda çok farklı fiyatlamalar yaptığından karışıklığa neden olmamaktadır. Bitcoin fiyatının kapanış değerlerinin bir önceki kapanış değerine göre yüzdesel oranlaması denklem 2.9'da verilmiştir.

$$\text{Yüzdesel Değişim} = \left(\frac{\text{Mevcut Kapanış Fiyatı} - \text{Önceki Kapanış Fiyatı}}{\text{Önceki Kapanış Fiyatı}} \right) \quad (2.9)$$

2.5.3 Özellik Mühendisliği

Özellik mühendisliği, veri setlerinden maksimum fayda sağlamak ve makine öğrenmesi modellerinin performansını artırmak için önemli süreçtir. Bu süreç, veri setinde ham şekilde bulunan veriyi, anlamlı özelliklere dönüştürmeyi içerir. Bitcoin kapanış fiyatı tahmin modelimizde, çeşitli özellik mühendisliği yöntemleri uygulanmıştır. Bu tekniklerin temel amacı, veriyi makine öğrenmesinin anlayabileceği uygun nümerik formata çevirebilmek, modelin karmaşıklığını azaltmak ve modelin başarısını artırmaktır. Aşağıda, uygulanan özellik mühendisliği adımları detaylandırılmıştır. Bu işlemlerden önce veri setinde bulunan metin tabanlı 'al', 'sat' vb. sinyaller uygun bir biçimde nümerik olarak işlenmiştir.

Korelasyona Göre Veri Seti İndirgenmesi

Veri setindeki özellikler arasındaki korelasyon incelenmiş ve yüksek korelasyona sahip özellikler çıkarılmıştır. Bu, modelin aşırı uyumunu önlemek ve hesaplama yükünü azaltmak için yapılmıştır. Çalışmada elde edilen teknik indikatör sonuçlarına göre, kategorik veriler için Cramer'in V metodu [25] ile veri seti indirgenmesi yapılmıştır. Nümerik sonuçlar için ise Pearson korelasyon [26] kullanılarak veri seti indirgenmesi yapılmıştır.

Cramer'in V yöntemi, nominal ölçekli iki kategorik değişken arasındaki ilişkinin gücünü ölçmek için kullanılan bir istatistiksel yöntemdir. Bu yöntem, iki kategorik değişkenin oluşturduğu çapraz tablo üzerindeki chi-kare istatistiğini temel alır ve değişkenlerin özgürce varyasyon gösterdiği durumda beklenen chi-kare değerlerine göre bir normalizasyon gerçekleştirir. Cramer'in V değeri, bir çapraz tablonun her hücresindeki gözlem sayıları ile bu hücrelerde beklenen sayılar arasındaki farkların karelerinin toplamı olan chi-kare istatistiği kullanılarak hesaplanır. Bu hesaplama,

gözlemlenen değerler ile eğer herhangi bir bağımlılık olmasaydı beklenen değerler arasındaki farkların büyüklüğünü değerlendirir. Cramer'in V yöntemi denklemi 2.10'da verilmiştir.

$$Cramer's V = \sqrt{\frac{\chi^2}{n \cdot \min(k-1, r-1)}} \quad (2.10)$$

Bu denklemde χ^2 , chi-kare istatistiği; n , gözlem sayısını; k ve r tablonun sütun ve satır sayısını verir.

Pearson korelasyon katsayısı, iki sürekli rassal değişken arasındaki doğrusal ilişkinin gücünü ve yönünü ölçen bir istatistiksel yöntemdir. Karl Pearson tarafından geliştirilen bu yöntem, iki değişken arasındaki doğrusal bağlantının derecesini sayısal olarak ifade eder. Pearson korelasyon katsayısı, iki değişkenin birlikte nasıl değiştiğinin bir ölçüsü olarak kabul edilir ve -1 ile +1 arasında değerler alır. Pearson korelasyon katsayısının denklemi 2.11 verilmiştir.

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (2.11)$$

Veri Normalizasyonu

Veri normalizasyonu, farklı ölçeklere sahip değişkenlerin arasındaki büyük farkları azaltarak verileri belirli bir standart veya ortak bir ölçeğe dönüştürme sürecidir. Bu işlem, makine öğrenimi ve veri madenciliği gibi alanlarda, algoritmaların daha etkili ve doğru çalışmasını sağlamak için yaygın olarak kullanılır. Çalışmada verilerimize minimum maksimum ölçekleme uygulanmıştır. Bu yöntemde tüm veriler sıfır ile bir değerleri arasına ölçeklendirilir. Minimum maksimum ölçekleme yönteminin denklemi 2.12'de verilmiştir.

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2.12)$$

Tek Sıcak Kodlama (OHE)

Makine öğrenimi modelleri genel olarak kategorik değişkenleri işleyemez. Kategorik değişkenleri kullanarak model geliştirebilmek için, bu değişkenlerin sayısal bir formata çevrilmesi gerekir. OHE yöntemi, kategorik değişkenlerin ikili olarak temsil edilmesine olanak sağlar. Yöntemde bir özelliğe ait her kategoriye bir adet sütun oluşturulur. Sütun altında ise ikili formatta kodlama yapılır. Çalışmada BBAND ve KC indikatörlerinin sonuçlarının yorumlanması sonucu oluşan verilerin

kodlanması için uygulanmıştır.

Özellik Önemliliği ile Özellik Seçimi

Makine öğrenmesi modellerinde başarılı sonuçlar elde edebilmek için özelliklerin doğru bir şekilde seçilebilmesi kritik bir öneme sahiptir. Özellik önemliliği, bir modelin tahminlerinde farklı özelliklerin ne kadar etkisi olduğunu belirlemek için kullanılır. Bu sayede, hangi özelliklerin modelin performansına daha fazla katkıda bulunduğu tespit edilebilir. Rasgele orman algoritması [27] özellik önemliliği belirlemede güçlü bir araçtır. Rasgele orman, bir çok karar ağacını bir araya gelmesiyle oluşan bir topluluk öğrenme yöntemidir. Çalışmada, daha önce belirtilen özellik mühendisliği adımlarından sonra elde edilen tüm özelliklerimiz kullanılarak bir rasgele orman modeli eğitilmiştir. Rasgele orman'da özellik önemliliği, her bir özelliğin modelin tahmin performansına katkısını ölçer. Bu değerlendirme, genellikle özelliğin her bir karar ağacında yapılan dallanmalarda ne kadar bilgi kazandırdığına dayanır. Bu yöntem sayesinde belirlenmiş olan %2 eşik değerinden daha fazla öneme sahip olan özellikler, özellik setini oluşturmuştur.

Gecikme Verisi Eklenmesi

Zamansal verilerde gecikme verisinin eklenmesi, zaman serisi analizlerinde yaygın bir yöntemdir. Bu yöntem, geçmiş dönemlerdeki verilerin şimdiki zamandaki etkisini belirlemeye yardımcı olur. Çalışmada, özellik setimize gecikme verileri eklenmiştir ve bu sayede önceki zamana ait verilerin özellikleri de üç gecikme adımı boyunca dikkate alınmıştır.

2.6 Optimizasyon

Optimizasyon süreci, modelin hiperparametrelerini ayarlayarak en iyi tahmin performansını elde etmeyi amaçlar. Ancak, uygun hiperparametre kombinasyonlarını bulmak genellikle zor ve zaman alıcıdır. Geleneksel hiperparametre optimizasyon yöntemleri arasında ızgara arama ve rastgele arama bulunur. Izgara arama, önceden belirlenmiş hiperparametre değerlerinin tüm mümkün kombinasyonlarını deneyerek en iyisini seçerken, rastgele arama, parametre uzayında rastgele seçilen kombinasyonları değerlendirir. Her iki yöntem de yüksek boyutlu parametre uzaylarında verimsiz olabilir. Bu zorlukların üstesinden gelmek için Genetik Algoritmalar (GA) [28] ve Yapay Arı Kolonisi (ABC) [29] gibi farklı optimizasyon algoritmaları kullanılabilir. Doğadan ilham alan bu algoritmalar, hiperparametre seçim sürecini otomatikleştirir ve daha verimli bir arama sağlar. Ancak, daha iyi sonuçlar için literatürde Optuna gibi araçlar kullanılmaktadır.

2.6.1 Optuna

Optuna [30], özellikle makine öğrenimi için tasarlanmış otomatik bir hiperparametre optimizasyon yazılım çerçevesidir. Optuna, geniş bir parametre yelpazesi içinde en iyi model konfigürasyonlarını belirleme konusunda etkili bir araçtır. Optuna, farklı hiperparametre konfigürasyonlarını örneklemek için Bayesçi tabanlı Ağaç Yapılı Parzen Tahminleyici (TPE) kullanır.

Ağaç Yapılı Parzen Tahminleyici (TPE) [31]

TPE, Bayesçi optimizasyonun bir çeşidi olarak, performansı daha önceki denemelere dayanarak gelecekteki hiperparametre değerlerini tahmin etmek ve önermek için kullanılır. TPE, veri setinin önceki denemelerden elde edilen performansına dayanarak hiperparametrelerin olası değerlerinin dağılımlarını modellemek için biri iyi, diğeri kötü sonuçlar için iki yoğunluk fonksiyonu kullanır. İyi sonuçlar genellikle bir eşik değerin üstündeki performansı, kötü sonuçlar ise bu değerin altındaki performansı ifade eder. TPE, yeni hiperparametre değerlerini seçmek için aşağıdaki oranı maksimize eder.

$$EI(x) = \frac{l(x)}{g(x)} \quad (2.13)$$

$l(x)$ iyi sonuçlar için yoğunluk fonksiyonunu, $g(x)$ ise kötü sonuçlar için yoğunluk fonksiyonunu temsil eder. Ayrıca $EI(x)$, beklenen iyileştirmeyi ifade eder. Bu oran, yeni bir hiperparametre setinin iyi sonuçlar elde etme olasılığının, kötü sonuçlar elde etme olasılığına oranını gösterir. Süreç ise ilk olarak örnekleme aşamasıyla başlar, burada $g(x)$ daha önce kötü performans göstermiş parametrelerin dağılımı belirlenir. Sonraki aşama olarak seçim aşaması gelir. Seçim aşamasında $l(x)/g(x)$ oranını maksimize etmek için hiperparametreler seçilir.

Optuna, hiperparametre ayarlama ve model seçim süreçlerinde kullanılmıştır. Bu çalışmada ARIMA modelleri hariç her modelin performansını maksimize etmek için kullanılmıştır.

2.7 Değerlendirme Metrikleri

Model performanslarını değerlendirmek için Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE) metrikleri kullanılmıştır[32]. Bu metrikler, model tahminleri ile gerçek değerler arasındaki farkları ölçmek ve modeller arasında karşılaştırmalar yapmak için yaygın olarak kullanılmaktadır. İki değerlendirme metriğinin hesaplamalarında kullanılan denklemler 2.14 ve 2.15’de verilmiştir.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{tahmin edilen}_i - \text{ölçülen}_i)^2} \quad (2.14)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\text{tahmin edilen}_i - \text{ölçülen}_i| \quad (2.15)$$



3.1 Veri Seti

Zaman serisi yaklaşımı kapsamında, Bitcoin'in dört saatlik kapanış fiyatları üzerinden oluşturulan veri seti, toplamda 8764 adet kapanış fiyat verisini içermektedir. Teknik analiz yaklaşımında ise, teknik indikatörlerin kullanımı ile 27 özellik hesaplanmıştır. Bu süreçte kullanılan veri sayısı 8711 olarak belirlenmiştir. Özellik mühendisliği sürecinin tamamlanmasıyla birlikte özellik sayısı 45'e yükseltilmiştir. Topluluk modelleme yaklaşımında ise, her iki yaklaşımın ortak olarak kullanmış olduğu tarih aralığındaki veriler kullanılmıştır. Kullanılan özellikler ise her biri için kendine özgüdür.

3.2 Zaman Serisi Yaklaşımı

Bu bölümdeki çalışmada, Transformer modelinin Bitcoin'in kapanış değerlerini tahmin etmedeki performansı, literatürdeki çeşitli modellerin performansı ile karşılaştırıldı. Eğitim ve test veri setlerini bölmek için üç farklı oran seçildi (0.5-0.5, 0.7-0.3, 0.8-0.2). XGBoost, Yapay Sinir Ağları'nda ve Transformer'da zaman adımı olarak 6 ve 12 değerleri kullanıldı. Bu seçim, dört saatlik veri aralıkları kullanılarak bir günlük ve iki günlük periyotları temsil etmek içindir.

3.2.1 ARIMA ve ARIMAX

ARIMA modelinde, veri durağan olmadığı için önce fark alma yöntemi uygulandı. Daha sonra, modelin parametreleri auto-ARIMA [33] aracı kullanılarak optimize edildi. ARIMAX modelinde benzer bir fark alma yöntemi uygulandı, ek olarak, yüksek, düşük ve hacim değerleri için pencere boyutları 3, 7 ve 30 gün olarak belirlendi ve bu pencere boyutlarına göre standart sapma ve ortalama değerler hesaplandı. Ayrıca, mevsimsellik etkilerini hesaba katmak için gün, ay ve haftanın günleri değişkenleri eklendi. Bu ek değişkenler, ARIMAX modelinde dışsal değişkenler olarak kullanıldı.

3.2.2 XGBoost

XGBoost modeli, Optuna hiperparametre optimizasyon çerçevesi kullanılarak optimize edilmiş parametrelerle eğitildi. Optuna, 'estimatör sayısı', 'maksimum derinlik', 'öğrenme oranı', 'subsample' ve 'colsample bytree' gibi kritik hiperparametrelerin optimal değerlerini belirlemek için kullanıldı. Bu parametrelerin seçimi, modelin genel performansını maksimize etme amacıyla yapıldı ve bu süreç, Bitcoin fiyat tahmini konusunda modelin doğruluğunu artırmayı amaçlıyor.

3.2.3 RNN, LSTM ve ANN

Bu çalışmada kullanılan modeller, Optuna hiperparametre optimizasyon çerçevesi aracılığıyla elde edilen optimal hiperparametre değerleri bazında eğitildi. Optimizasyonu yapılan hiperparametreler; 'batch size', 'nöron sayısı', 'aktivasyon fonksiyonu', 'optimizer' ve 'öğrenme oranı'. Ayrıca, yığın LSTM modeli için, 'ikinci katman nöron sayısı' ve 'dropout oranı' değerleri, aşırı uyumu önlemek ve model mimarisinin derinliğini ayarlamak için ek olarak optimize edildi.

3.2.4 TCN

TCN modeli, Optuna hiperparametre optimizasyon çerçevesi tarafından sağlanan sonuçlara dayanarak seçilen hiperparametrelerle eğitildi. Optimizasyonu yapılan hiperparametreler; 'batch size', 'filtre sayısı', 'kernel boyutu', 'dilations', 'optimizer' ve 'öğrenme oranı'. Bu hiperparametrelerin ayarlanması, TCN modelinin veri setinin zamansal özelliklerini etkili bir şekilde öğrenmesi ve tahmin performansını maksimize etmesi amacıyla gerçekleştirildi.

3.2.5 Transformer

Literatürdeki temel Transformer modeli, çalışmamızın başlangıç noktası olarak kullanıldı. Bu temel Transformer mimarisi Şekil 2.1'de verilmiştir. Ancak, çalışmamız mevcut modelin bir uygulaması değildir. Özellikle hiperparametre optimizasyonu açısından önemli yenilikler sunar. Temel model mimarisinden farklı olarak, hiperparametrelerin seçimi ve ayarlanması için gelişmiş bir yöntem olan Optuna tabanlı bir optimizasyon süreci uygulanmıştır. Bu süreç, modelin performansını maksimize etmek için özel olarak tasarlanmıştır ve modelimizi literatürdeki diğer çalışmalardan ayıran temel bir yeniliktir. Transformer modelimiz, Optuna hiperparametre optimizasyon çerçevesi tarafından sağlanan sonuçlara dayanarak seçilen hiperparametrelerle eğitildi. Optimizasyonu yapılan hiperparametreler; 'kafa boyutu', 'kafa sayısı', 'feed-forward size', 'Transformer

blok sayısı', 'MLP nöron sayısı', 'dropout oranı', 'MLP için dropout oranı', 'öğrenme oranı' ve 'batch size'. Bu hiperparametrelerin seçimi, hem model karmaşıklığını yönetmek hem de Transformer'ın eğitim sürecinde genelleştirmeyi optimize etmek amacıyla dikkatlice yapıldı.

3.2.6 Zaman Serisi Yaklaşımı Sonuçları

Her Sinir Ağı (NN) tabanlı model için eğitim 20 devir boyunca gerçekleştirildi. Optuna optimizasyonlarının her biri için 25 hiperparametre denemesi yapıldı. NN tabanlı modellerde, 5 sabır değeri olan bir erken durdurma mekanizması kullanıldı. Optuna'nın erken durdurma özelliğini kullanarak yapılan optimizasyon sürecinde, 'başlangıç deneme sayısı' 5 olarak ve 'ısınma adımı sayısı' 10 olarak ayarlandı. Bu parametrelerin belirlenmesi, hiperparametre arama sürecinin erken aşamalarında yeterli keşif sağlamak ve modelin performansını hızlı bir şekilde değerlendirmek için yapıldı. Bu yaklaşım, özellikle büyük parametre uzaylarında, erken durdurma özelliği sayesinde performansı düşük deneylerin daha fazla kaynak tüketmeden durdurulmasına izin verdiği için etkili bir optimizasyon için önemlidir. Eğitim tamamlandıktan sonra, tüm modeller test veri setinde değerlendirildi ve performansları MAE ve RMSE metrikleri kullanılarak ölçüldü. Elde edilen sonuçlar Tablo 3.1 ve Tablo 3.2'de sunulmuştur.

Tablo 3.1 Zaman serisi yaklaşımı modellerinin performans karşılaştırması.


Model	6 Zaman Adımı						12 Zaman Adımı					
	0.5-0.5		0.7-0.3		0.8-0.2		0.5-0.5		0.7-0.3		0.8-0.2	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
XGBoost	397.29	606.58	250.29	385.22	253.93	393.71	440.96	645.22	272.07	405.05	257.86	397.48
ANN	886.67	1077.33	730.78	962.94	529.36	729.76	1026.38	1237.71	791.25	1035.36	576.84	796.13
RNN	556.47	710.31	413.25	516.71	331.15	485.94	868.51	1100.52	842.56	1119.70	605.94	837.32
LSTM	904.44	1083.61	692.56	924.04	383.38	570.37	498.60	752.14	397.83	578.89	373.91	523.41
Yığın LSTM	435.72	659.90	362.31	552.59	326.29	491.70	476.98	689.07	350.98	506.40	267.01	418.02
BiLSTM	421.16	620.64	292.02	461.62	277.90	426.82	327.69	517.70	265.39	396.12	261.25	390.23
TCN	357.60	535.66	227.15	354.97	301.88	449.04	428.06	593.51	237.02	382.52	252.14	391.75
Transformer	327.37	517.73	228.49	363.11	231.84	371.17	366.14	548.50	286.81	410.81	239.78	378.91

Tablo 3.2 Zaman serisi yaklaşımı modellerinin genel performans karşılaştırması.

Model	6 Zaman Adımı		12 Zaman Adımı		Genel	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
ARIMA	-	-	-	-	38961.62	39311.11
ARIMAX	-	-	-	-	37556.31	39933.63
XGBoost	300.50	461.84	323.63	482.58	312.07	472.21
ANN	715.60	923.34	798.16	1023.07	756.88	973.20
RNN	433.62	570.99	772.34	1019.18	602.98	795.08
LSTM	660.13	859.34	423.45	618.15	541.79	738.74
Yığın LSTM	374.77	568.06	364.99	537.83	369.88	552.95
BiLSTM	330.36	503.03	284.78	434.68	307.57	468.85
TCN	295.54	446.56	305.74	455.93	300.64	451.24
Transformer	262.52	417.34	297.57	446.07	280.07	431.71

6 zaman adımıyla yapılan çalışmanın sonuçları, 12 zaman adımıyla yapılan çalışmadan çok daha başarılı bulundu. Veri setinin bölünmesi sırasında, eğitim-test setinin 0.7 ile 0.3 olarak bölünmesinin en başarılı sonuçları verdiği gözlemlendi. Bitcoin'in kapanış değeri verilerinin zaman serisi için karmaşık yapısı göz önüne alındığında, en çok eğitim verisini içeren 0.8-0.2 eğitim-test oranında en iyi sonucun elde edilmediği görülmüştür.

Transformer yaklaşımı için en iyi sonuçlar, 6 zaman adımı ve 0.7-0.3 eğitim-test bölünmesinde 228.49 MAE değeri ve 363.11 RMSE değeri ile elde edildi. Bu sonuçların grafiği Şekil 3.1'de verilmiştir. Modeller 0.5-0.5 eğitim-test bölünme oranlarına göre karşılaştırıldığında, Transformer 6 zaman adımı için 327.37 MAE değeri ve 517.73 RMSE değeri ile en iyi performansı gösterdi. Bu bölünme oranının önemi, Transformer'ın en az sayıda eğitim verisi ile en iyi performansı gösterdiğini göstermektedir. Transformer'ın 6 zaman adımında 262.57 MAE değeri ve 417.34 RMSE değeri ile en iyi sonuçları verdiği gözlemlendi. Ek olarak, BiLSTM'in 12 zaman adımında 284.78 MAE değeri ve 434.68 RMSE değeri ile en iyi sonuçları verdiği gözlemlendi. Ancak, Transformer'ın 297.57 MAE değeri ve 446.07 RMSE değeri ile çok benzer bir performans gösterdiği de gözlemlenmiştir. Sonuçların genel ortalaması incelendiğinde, Transformer yaklaşımının diğer modellere göre daha üstün performans sergilediği gözlemlenmiştir.



Şekil 3.1 6 zaman adımı ve (0.7-0.3) eğitim-test bölünme oranı için Transformer'ın tahminleri.

3.3 Teknik Analiz Yaklaşımı

Veri seti, belirlenen tarih aralıklarına göre Bitcoin'in dört saatlik zaman dilimleri için oluşturulmuştur. İlk olarak veri seti, açılış, kapanış, en yüksek, en düşük fiyatlar ve işlem hacmi gibi temel verileri içermektedir. Kapanış fiyatları kullanılarak daha önce 2.5.2 Bölümde açıklanan yöntemle hedef değişken oluşturulmuştur. Elde edilen veri seti ile teknik indikatörler, belirlenen tüm zaman aralıkları

iin hesaplanmıřtır. İndikatörler iin kullanılan parametreler, Tablo 3.3’de belirtilmiřtir. Hesaplamalar sonucunda, 2.2.2 Bölümünde açıklanan indikatör yorumlarına göre çoėu indikatör iin ‘al’ ve ‘sat’ vb. sinyaller kategorik olarak özellik setine eklenmiřtir. BBAND iin bant geniřliėi ve ATR iin hesaplanan deėer nümerik olarak muhafaza edilmiřtir. Elde edilen yeni özellik seti üzerinde çeřitli özellik mühendisliėi yöntemleri uygulanmıřtır. Bunlar arasında kategorik verilerin nümerik formata dönüřtürölmesi, yüksek korelasyona sahip özelliklerden birinin veri setinden ıkarılması, verilerin normalizasyonu, gerektiėinde OHE uygulanması, özellik önemine göre az önemli özelliklerin ıkarılması ve gemiř verilerin etkisini dahil etmek iin gecikme verilerinin eklenmesi yer almaktadır. Model eėitimi iin, alıřmadaki zaman serisi modellerinde en bařarılı olan 0.7’lik eėitim-test bölünme oranı belirlenmiřtir. Teknik indikatörlerin nasıl yorumlandıėı ve hangi kategorik isimlerle adlandırıldıėı Tablo 3.4’de sunulmuřtur.

Tablo 3.3 Teknik indikatör parametreleri.

İndikatör İsmi	Parametre İsmi	Parametre Değeri
RSI	Periyot	14
STOCH	K	14
STOCH	D	3
STOCH	Düz K	3
STOCHRSI	Periyot	14
STOCHRSI	RSI Periyot	14
STOCHRSI	K	3
STOCHRSI	D	3
MACD	Hızlı Periyot	12
MACD	Yavaş Periyot	26
MACD	Sinyal Periyodu	9
BBAND	Periyot	20
BBAND	Standart Sapma	2
BBAND	Eşik Değeri	0.5
ADX	Periyot	14
WR	Periyot	21
CCI	Periyot	20
CCI	C	0.015
ATR	Periyot	14
UO	Kısa Periyot	7
UO	Orta Periyot	14
UO	Uzun Periyot	28
BBP	Periyot	13
Pivot Noktaları	Periyot	6
MA	Kısa Periyot	9
MA	Orta Periyot	26
MA	Uzun Periyot	52
KDJ	Periyot	9
KDJ	Sinyal Periyodu	3
PSAR	Hızlanma Faktörü (AF)	0.02
PSAR	Maks. AF	0.2
CMF	Periyot	20
AO	Hızlı Periyot	5
AO	Yavaş Periyot	34
KC	Periyot	20
KC	Skaler	2
KC	Eşik Değeri	0.5
SuperTrend	Periyot	7
SuperTrend	Çarpan	3

3.3.1 Model Seçimi

Model seçimi sürecinde, LazyPredict kütüphanesinden yararlanılmıştır. Bu kütüphane, çok fazla kod yazmaya gerek kalmadan birçok temel modelin oluşturulmasını sağlar ve hiperparametre ayarlaması yapmadan hangi modellerin

Tablo 3.4 Teknik indikatör yorumlaması.

İndikatör İsmi	İndikatör Yorumlaması
RSI	Aşırı Alım, Aşırı Satım, Nötr
WR	Aşırı Alım, Aşırı Satım, Nötr
CCI	Aşırı Alım, Aşırı Satım, Nötr
UO	Aşırı Alım, Aşırı Satım, Nötr
STOCH	Al, Sat, Boğa Momentumu, Ayı Momentumu
STOCHRSI	Al, Sat, Boğa Momentumu, Ayı Momentumu
MACD	Al, Sat, Boğa Momentumu, Ayı Momentumu
KDJ	Al, Sat, Boğa Momentumu, Ayı Momentumu
BBP	Boğa Momentumu, Ayı Momentumu, Nötr
CMF	Boğa Momentumu, Ayı Momentumu, Nötr
AO	Boğa Momentumu, Ayı Momentumu, Nötr
BBAND	Boğa Trendi, Ayı Trendi, Al, Sat, Stabil, Nötr
KC	Boğa Trendi, Ayı Trendi, Al, Sat, Stabil, Nötr
MA x4	Al, Sat
PSAR	Al, Sat
OBV	Al, Sat
SuperTrend	Al, Sat
ADX	Al, Sat, Nötr Al, Nötr Sat
PİVOT x4	Güçlü Al, Al, Nötr Al, Nötr Sat, Sat, Güçlü Sat
BBAND_P	Nümerik
ATR	Nümerik

daha iyi performans gösterdiğini belirlemeye yardımcı olur. Bu modeller arasından en başarılı üç model ve sonuçları, Tablo 3.5’de sunulmuştur.

Tablo 3.5 Teknik analiz yaklaşımında LazyPredict modellerinin performans karşılaştırması.

Model	MAE	RMSE
ElasticNet	148.84	247.22
LassoLars	148.84	247.22
BayesianRidge	149.00	247.20

LazyPredict aracılığıyla elde edilen en başarılı üç modelin dışında, tablo veriler üzerinde performansı farklı problemler üzerinde kanıtlanmış olan LGBM modeli ve XGBoost modeli de ayrıca optimizasyon sürecine dahil edilmiştir.

3.3.2 Başarılı Modellerin Optimizasyonu


Optuna çerçevesi kullanılarak, en başarılı bulunan beş modelin performansını artırmak amacıyla hiperparametre optimizasyonları yapılmıştır. Bu optimizasyon ile edilen edilen hiperparametreler ile geliştirilen modellerin performansları, Tablo 3.6’de sunulmuştur.

Tablo 3.6 Teknik analiz yaklaşımı modellerinin performans karşılaştırması.

Model	MAE	RMSE
XGBoost	148.80	246.79
BayesianRidge	148.98	247.20
LassoLars	149.00	247.16
ElasticNet	149.12	247.14
LGBM	149.07	246.73

3.3.3 Teknik Analiz Yaklaşımı Sonuçları

Optimizasyon sonuçlarını içeren 3.6 tablosuna göre ilk olarak daha önce çıkartılan optimizasyonsuz sonuçlara göre , modellerin hiperparametre optimizasyonu sonrası hata oranlarının çok değişmediği hatta hata oranlarının arttığı gözlemlenmiştir. Tablodaki hata oranlarına göre değerlendirme yapıldığında beş modelin de birbirine yakın performanslar gösterdiği görülmüştür. Fakat sonraki süreç için bir model seçileceği ile devam edileceğinden MAE skoruna ve RMSE skoruna göre değerlendirme yapılmıştır. Topluluk yöntemine, XGBoost modeli diğer modellere göre biraz daha iyi performans göstermiştir. Bu sebeple topluluk modelleme yaklaşımına XGBoost modeli seçilmiştir. XGBoost modelinin tahminleri Şekil 3.2’de verilmiştir.



Şekil 3.2 Teknik analiz yaklaşımıyla XGBoost modelinin tahminleri.

3.4 Topluluk Modelleme Yaklaşımı

Bu kısımda zaman serisi yaklaşımında en iyi performans gösteren Transformer modelinin ve teknik analiz yaklaşımında en iyi performans gösteren XGBoost modelinin topluluk modelleme yaklaşımındaki performansları incelenmiştir. Kullanılan veri seti zaman serisi yaklaşımındaki zaman adımlarına göre ve teknik analiz yaklaşımındaki teknik indikatörlerin parametre değerlerine göre ortak bir

şekilde ele alınmıştır. Bu şekilde önceki kısımlardan biraz daha farklı boyutta bir veri seti elde edilmiştir. Bu elde edilen yeni veri setine göre performans karşılaştırmaları yapılmıştır. Bu şekilde her iki modelde tekrardan eğitime sokulmuş olup, test setiyle birlikte değerlendirme metrikleri hesaplanmıştır. Ayrıca Transformer modeli için hedef değişken doğrudan fiyatlar üzerinden belirlenmemiş olup, teknik analiz yöntemindeki 2.5.2 bölüme göre yüzdesel olarak hedef değişkenler oluşturulmuştur. Bu yeni yaklaşımın performans üzerindeki etkisi ilerleyen bölümlerde tartışılmıştır.

Bu bölümde üzerinde çalışılan model sayısı azaltıldığından dolayı, Optuna ile hiperparametre optimizasyon sürecinde modellerin hiperparametre uzayları genişletilip, deneme ve devir sayısı artırılarak modellerin en iyi performanslarını göstermesi hedeflenmiştir.

Optimize edilmiş hiperparametrelerle birlikte her iki model için de eğitim gerçekleştirilip test verisi üzerinde performansları karşılaştırılmıştır. Elde edilen tahmin sonuçları da 2.3 bölümde bahsedilen üç farklı yöntem ile birleştirilip performansları hesaplanmıştır. Bu üç farklı yöntemden aşağıda tekrardan kısaca bahsedilmiştir.

3.4.1 Ortalama Alma Yöntemi

Transformer ve XGBoost modelinin test verisi üzerinde yaptıkları tahminler hesaplanmıştır. Bu hesaplanan tahminler üzerinde yapılan tahminlerin ortalaması alınarak yeni bir tahmin sonucu elde edilmiştir.

3.4.2 Ağırlıklı Ortalama Alma Yöntemi

Transformer ve XGBoost modelinin test verisi üzerinde yaptıkları tahminler hesaplanmıştır. Her iki modelinde MAE değerlerine göre bir katsayısı belirlenmiştir. Bu katsayı, modellerin MAE değerlerine ters orantılı olacak şekilde belirlenmiştir. Daha sonra bu katsayılar ile ağırlıklı ortalama alma yöntemine göre yeni bir tahmin sonucu elde edilmiştir.

3.4.3 Meta Öğrenme Yöntemi

Transformer ve XGBoost modelinin test verisi üzerinde yaptıkları tahminler hesaplanmıştır. Her iki modelin tahmin sonuçlarıyla birlikte basit bir lineer regresyon modeli eğitilmiştir. Bu modelde de verinin eğitim-test bölünme oranı olarak 0.7 belirlenmiştir. Eğitilen model ile test verimiz tahmin edilerek yeni bir

tahmin sonucu elde edilmiştir.

Zaman serisi yöntemi tarafında en iyi performans sahip Transformer modeli tahminlerinin, Teknik analiz yöntemi tarafında en iyi performansa sahip XGBoost modeli tahminlerinin ve topluluk öğrenme yöntemlerinden elde edilen yeni tahminlerin hata oranları Tablo 3.7’de verilmiştir.

Tablo 3.7 Topluluk modelleme yaklaşımlarının performans karşılaştırması.


Model	MAE	RMSE
XGBoost (TAY)	149.5478	247.5915
Transformer (ZSY)	149.2821	247.5293
Ortalama Alma Yöntemi	149.1491	247.3687
Meta Öğrenme Yöntemi	177.4003	281.7483
Ağırlıklı Ortalama Alma Yöntemi	149.1490	247.3687

Bu tabloda, 'TAY' (Teknik Analiz Yaklaşımı) ve 'ZSY' (Zaman Serisi Yaklaşımı) kısaltmaları kullanılmıştır.

3.4.4 Topluluk Modelleme Yaklaşımı Sonuçları

Elde edilen Tablo 3.7’ye göre Meta Öğrenme Yöntemi hariç yöntemlerin performanslarının birbirine çok yakın olduğu görülmüştür. ZSY yönteminin, TAY yöntemine göre biraz daha iyi performans gösterdiği görülmüştür. Ayrıca Transformer modeli için yüzdesel olarak hedef değişken belirlenmesinin, doğrudan fiyat değerinin hedef değişken belirlenmesine göre daha iyi sonuçlar verdiği görülmüştür.

MAE metriklerine göre en iyi performans gösterenler sonuçlar Ortalama Alma Yöntemi ve Ağırlıklı Ortalama Alma Yöntemi’dir. RMSE metriğine göre ise en iyi performans gösteren Ağırlıklı Ortalama Alma Yöntemi’dir. MAE ve RMSE metriklerine göre en iyi yöntemi seçmek istersek de en iyi performansın Ağırlıklı Ortalama Alma Yöntemi ile alındığı görülmüştür. En iyi performans gösteren topluluk öğrenme yönteminin grafiği Şekil 3.3’de verilmiştir.



Şekil 3.3 6 zaman adımı ve (0.7-0.3) eğitim-test bölünme oranı için Ağırlıklı Ortalama Alma Yöntemi'nin tahminleri.

4 SONUÇ

Çalışmada farklı yapay zeka yaklaşımlarıyla Bitcoin'in ABD dolarına karşı dört saatlik kapanış fiyatı tahmin edilmeye çalışılmıştır. Zaman serisi yaklaşımı altında önerilen modeller; ARIMA, ARIMAX, XGBoost, ANN, RNN, LSTM, TCN ve Transformer'dır. Bu modellerin hiperparametreleri Optuna ile optimize edilip fiyat tahmini için eğitilmiştir. Değerlendirme yaparken RMSE ve MAE metrikleri göz önüne alınmıştır. Modeller arasındaki karşılaştırma, üç farklı eğitim-test bölünme oranına ve iki farklı zaman adımına göre yapılmıştır. Sonuçlar, bu modellerin Bitcoin fiyatını tahmin etmedeki etkinliğini göstermiştir ve her birinin güçlü ve zayıf yönlerini ortaya çıkarmıştır. En başarılı değerlendirme performansını Transformer modelinin gösterdiği görülmüştür. Derin öğrenme tabanlı BiLSTM ve TCN modelleri, bazı eğitim-test bölünmeleri ve bazı zaman adımları için en başarılı sonuçları verdiği görülmüştür. Ancak genel performans dikkate alındığında Transformer modelinin özellikle dikkat mekanizması nedeniyle daha başarılı performans gösterdiği ifade edilebilir. Transformer'ın 6 zaman adımı ve 0.7-0.3 eğitim-test bölünmesiyle en başarılı performansını gösterdiği görülmüştür. Geleneksel olarak zaman serisi analizinde kullanılmayan Transformer modelinin bu alanda geleneksel modellere göre övgüye değer bir performans gösterdiği gözlemlenmiştir. Bu, zaman serisi analizi için Transformer tabanlı modellerin benimsenmesinin umut verici olduğunu ve gelecekte önemli ilerlemeler sağlamanın beklenebileceğini göstermektedir. Ayrıca, Transformer modelinde doğrudan kapanış fiyatını hedef değişken olarak kullanmak yerine, yüzdesel değişimleri hedef değişken olarak belirlemenin daha başarılı sonuçlar verdiği görülmüştür. Teknik analiz yaklaşımı altında finansal piyasalarda çokça kullanılan teknik indikatörler incelenmiştir. Teknik indikatörler yardımıyla oluşturulan ve özellik mühendisliğinden geçirilen yeni bir özellik seti oluşturulmuştur. Performans karşılaştırması için LazyPredict kütüphanesinin sağladığı geleneksel modeller ve literatürde çok çeşitli alanlarda başarılı performans gösteren gradyan artırma metodlarından olan XGBoost ve LGBM modelleri de eklenmiştir. Zaman serisi yaklaşımıyla benzer ilerleyebilmek için Transformer modelinin en başarılı olduğu

eđitim-test bölünme oranına göre özellik seti ayrılmıştır. Bu modellerde, zaman serisi analizinde kullanılan modellerle benzer şekilde Optuna ile hiperparametreleri optimize edilmiştir. Burada elde edilen sonuçlar kıyaslandığında, sonuçların birbirine çok yakın olduđu görölmüştür. Bunun anlamı olarak oluşturulan özellik setinin belirli bir noktada başarılı olduđunu düşündürmüştür. Son olarak da topluluk modelleme yaklaşımına göre daha önce belirtilen zaman serisi yaklaşımı ve teknik analiz yaklaşımının tahminleri birleştirilmiştir. Burada da topluluk şeklinde bir modelleme yapısıyla başarının ne derece deđiştii gözlemlenmiştir. Çok az bir farkla da olsa Ağırlıklı Ortalama Alma Yöntemi'nin sonuçlarının, bireysel yaklaşım sonuçlarına göre daha başarılı olduđu görölmüştür.

Finansal tahmin modellerinde model seçimi ve parametre optimizasyonunun önemi vurgulanmaktadır. Çalışmamız, farklı modellerin farklı senaryolarda nasıl performans gösterdiğini ortaya koyarak bu alandaki uygulamalara yol gösterici olabilir. Modellerin karmaşıklığı ve hesaplama maliyeti dikkate alınarak, gerçek zamanlı uygulamalar için optimize edilmiş çözümlerin geliştirilmesi önerilmektedir. Teknik indikatörlerin yapay zeka modeline önceden yorumlanıp eklenmesi literatürde sık görülen bir durum değıldir. Genelde teknik indikatörlerin sonuçları nümerik olarak veri setine eklenip bu şekilde model geliştirilmektedir. Fakat çođu teknik indikatörün tek başlarına nümerik olarak bir anlamı bulunmamaktadır. Genelde nümerik sonuçlar 'al', 'sat' vb. sinyaller şeklinde yatırımcılar tarafından yorumlanarak anlamlandırılmaktadır. Bu sebepten dolayı teknik indikatör özellik seti oluştururken kategoriklendirme işlemi yapılmıştır.

Donanım kaynaklarının kısıtlı olması sebebiyle modelleme yaklaşımlarında, büyük boyutlu hiperparametre uzayında optimizasyon gerçekleştirilemedi. Gelecek çalışmalarda donanım kaynakları artırılabilir. Ayrıca gelecek çalışmalarda daha büyük veri setleri ve farklı kripto para birimleri üzerinde de benzer analizler yapılabilir. Bu, modelleme yaklaşımlarının geçerliliğini ve uyarlanabilirliğini test etmeye yardımcı olacaktır. Çok daha uzun bir eğitim süresi için daha fazla deneme adımı eklenerek hiperparametrelerin çok daha iyi sonuçlar verecek şekilde oluşturulabileceđi düşünölmektedir. Ayrıca çalışmada, dört saatlik kapanış fiyatları üzerine odaklanılmıştır. Bu zaman aralığı gelecek çalışmalarda, saatlik, günlük veya haftalık olarak değıştirilerek modelleme çalışması yapılabilir. Son olarak da makroekonomik göstergeler ve piyasanın duygu durumunu ölçüp ekleyebileceğimiz bir dođal dil işleme çalışması da yapılabilir. Bu çalışma, Bitcoin fiyat tahmininde kullanılan mevcut modellerin anlaşılmasına ve geliştirilmesine katkıda bulunmayı amaçlamaktadır. Bulgular, finansal zaman serisi tahmini konusundaki anlayışımızı derinleştirme ve hem akademik hem de pratik alanlarda gelecekteki araştırmalara rehberlik etme potansiyeline sahiptir.

- [1] S. Bai, J. Z. Kolter, V. Koltun, *An empirical evaluation of generic convolutional and recurrent networks for sequence modeling*, 2018. arXiv: 1803.01271.
- [2] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio, *Learning phrase representations using rnn encoder–decoder for statistical machine translation*, 2014. arXiv: 1406.1078.
- [3] M. Schuster, K. K. Paliwal, “Bidirectional recurrent neural networks,” *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997.
- [4] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, I. Polosukhin, “Attention is all you need,” in *Advances in Neural Information Processing Systems*, 2017.
- [5] S. Hochreiter, J. Schmidhuber, “Long short-term memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997. doi: 10.1162/neco.1997.9.8.1735.
- [6] D. E. Rumelhart, G. E. Hinton, R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986.
- [7] M. Poongodi, V. Vijayakumar, N. Chilamkurti, “Bitcoin price prediction using arima model,” *International Journal of Internet Technology and Secured Transactions*, pp. 396–406, 2020.
- [8] M. Iqbal, M. S. Iqbal, F. H. Jaskani, K. Iqbal, A. Hassan, “Time-series prediction of cryptocurrency market using machine learning techniques,” *EAI Endorsed Transactions on Creative Technologies*, 2021.
- [9] B. A. Pai, L. Devareddy, S. Hegde, B. S. Ramya, “A time series cryptocurrency price prediction using lstm,” in *Emerging Research in Computing, Information, Communication and Applications* (Lecture Notes in Electrical Engineering), Lecture Notes in Electrical Engineering. Singapore: Springer, date not specified, vol. 790.
- [10] R. V. Saraswathi, S. B. Bollina, R. Bongu, A. Cherukuru, N. Chintala, “A novel lstm based approach for crypto currency price prediction,” in *2023 International Conference on Sustainable Communication Networks and Application (ICSCNA)*, Theni, India, 2023, pp. 1–6. doi: 10.1109/ICSCNA58489.2023.10370544.
- [11] P. L. Seabe, C. R. B. Moutsinga, E. Pindza, “Forecasting cryptocurrency prices using lstm, gru, and bi-directional lstm: A deep learning approach,” *Fractal and Fractional*, vol. 7, p. 203, 2023.

- [12] J. Fajou, A. McCarren, “Forecasting gold prices using temporal convolutional networks,” in *29th Irish Conference on Artificial Intelligence and Cognitive Science*, Dublin, Ireland, 2021, pp. 9–1.
- [13] S. Sridhar, S. Sanagavarapu, “Multi-head self-attention transformer for dogecoin price prediction,” in *2021 14th International Conference on Human System Interaction (HSI)*, Gdańsk, Poland, 2021, pp. 1–6. doi: 10.1109/HSI52170.2021.9538640.
- [14] H. S. Jung, S. H. Lee, H. Lee, J. H. Kim, “Predicting bitcoin trends through machine learning using sentiment analysis with technical indicators,” *Computer Systems Science & Engineering*, vol. 46, no. 2, 2023.
- [15] M. A. L. Khaniki, M. Manthouri, “Enhancing price prediction in cryptocurrency using transformer neural network and technical indicators,” *arXiv preprint arXiv:2403.03606*, 2024.
- [16] S. Alonso-Monsalve, A. L. Suárez-Cetrulo, A. Cervantes, D. Quintana, “Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators,” *Expert Systems with Applications*, vol. 149, p. 113 250, 2020.
- [17] J. Wang, F. Ma, E. Bouri, Y. Guo, “Which factors drive bitcoin volatility: Macroeconomic, technical, or both?” *Journal of Forecasting*, vol. 42, no. 4, pp. 970–988, 2023.
- [18] S. A. Gyamerah, “Two-stage hybrid machine learning model for high-frequency intraday bitcoin price prediction based on technical indicators, variational mode decomposition, and support vector regression,” *Complexity*, vol. 2021, pp. 1–15, 2021.
- [19] S. Nakamoto, “Bitcoin: A peer-to-peer electronic cash system,” 2008.
- [20] G. E. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung, *Time Series Analysis: Forecasting and Control*. John Wiley & Sons, 2015.
- [21] T. Chen, C. Guestrin, “Xgboost: A scalable tree boosting system,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794.
- [22] S. R. Pandala, *Lazy predict*, <https://github.com/shankarpandala/lazypredict>, Erişim tarihi: 2024-04-02, 2022.
- [23] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, T.-Y. Liu, “Lightgbm: A highly efficient gradient boosting decision tree,” *Advances in neural information processing systems*, vol. 30, pp. 3146–3154, 2017.
- [24] Binance, *Binance api documentation*, <https://binance-docs.github.io/apidocs/spot/en>, Erişim tarihi: 2024-01-02, 2024.
- [25] J. F. Hair Jnr, W. C. Black, B. J. Babin, R. E. Anderson, “Multivariate data analysis,” 2010.
- [26] J. H. Zar, *Biostatistical analysis*. Pearson Education India, 1999.
- [27] L. Breiman, “Random forests,” *Machine learning*, vol. 45, pp. 5–32, 2001.
- [28] J. H. Holland, *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press, 1992.

- [29] D. Karaboga, “An idea based on honey bee swarm for numerical optimization,” Technical report-tr06, Erciyes university, engineering faculty, Tech. Rep., 2005.
- [30] T. Akiba, S. Sano, T. Yanase, T. Ohta, M. Koyama, “Optuna: A next-generation hyperparameter optimization framework,” in *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, 2019, pp. 2623–2631.
- [31] J. Bergstra, R. Bardenet, Y. Bengio, B. Kégl, “Algorithms for hyper-parameter optimization,” *Advances in neural information processing systems*, vol. 24, 2011.
- [32] G. James, D. Witten, T. Hastie, R. Tibshirani, *et al.*, *An introduction to statistical learning*. Springer, 2013, vol. 112.
- [33] R. J. Hyndman, Y. Khandakar, “Automatic time series forecasting: The forecast package for r,” *Journal of statistical software*, vol. 27, pp. 1–22, 2008.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. B. Yildirim, M. Taskiran, “Optuna based optimized transformer model approach in bitcoin time series analysis,” in 2024 26th International Conference on Digital Signal Processing and its Applications (DSPA), 2024, pp. 1-6.

