

Yayın Geliş Tarihi: 21.02.2025
Yayına Kabul Tarihi: 15.05.2025
Online Yayın Tarihi: 15.09.2025
<http://dx.doi.org/10.16953/deusosbil.1644348>

Dokuz Eylül Üniversitesi
Sosyal Bilimler Enstitüsü Dergisi
Cilt: 27, Sayı: 3, Yıl: 2025, Sayfa: 1026-1045
E-ISSN: 1308-0911

Araştırma Makalesi

BITCOIN FİYAT HAREKETLERİNİN TAHMİNİ: RSI VE SMA GÖSTERGELERİNE DAYALI ALGORİTMİK TİCARET MODELİ

*Diler TÜRKOĞLU**

Öz'

Bu çalışma, Bitcoin'in fiyat hareketlerini tahmin etmek ve yatırımcılar için alım-satım sinyalleri üretmek amacıyla Random Forest sınıflandırıcı modelini kullanarak bir algoritmik ticaret stratejisi geliştirmeyi hedeflemiştir. Model, RSI ve SMA gibi teknik analiz göstergeleriyle desteklenmiş ve geçmiş fiyat hareketlerine dayalı olarak yüksek doğruluk oranları elde etmiştir. Yapılan analizler ve görselleştirmeler, modelin ürettiği sinyallerin piyasa hareketleri ile tutarlı olduğunu ve yatırımcı kararlarını optimize edebilecek nitelikte olduğunu göstermektedir. Elde edilen bulgular, Random Forest modelinin geçmiş verilerdeki fiyat değişimlerini başarılı şekilde tahmin ettiğini ve yatırımcılara doğru zamanda işlem yapma konusunda güvenilir sinyaller sunduğunu kanıtlamaktadır. Modelin başarı oranı, gerçek fiyat hareketleriyle karşılaştırıldığında oldukça yüksek olup, ticaret sinyallerinin zaman içindeki etkileri grafikler ile açıkça ortaya konmuştur. Bu çalışma, Bitcoin ve benzeri volatil piyasalarda yatırım stratejilerinin geliştirilmesine katkı sağlamayı amaçlamakta ve algoritmik ticaret modellerinin etkinliğini ortaya koymaktadır. Aynı zamanda çalışma teknik analiz göstergeleri ve makine öğrenmesi yöntemlerinin birleştirilerek, finansal piyasalarda ticaret stratejilerinin geliştirilmesinde etkili bir araç olabileceğini ortaya koymaktadır.

Anahtar Kelimeler: Bitcoin, Rasgele Orman, Algoritmik Ticaret, RSI, SMA.

Bu makale için önerilen kaynak gösterimi (APA 7. Sürüm):

Türkoğlu, D. (2025). Bitcoin fiyat hareketlerinin tahmini: RSI ve SMA göstergelerine dayalı algoritmik ticaret modeli. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 27 (3), 1026-1045.

* Dr. Öğretim Üyesi, Ardahan Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, ORCID: <https://orcid.org/0000-0001-5247-1590>, dilerturkoglu@ardahan.edu.tr

FORECASTING BITCOIN PRICE MOVEMENTS: AN ALGORITHMIC TRADING MODEL BASED ON RSI AND SMA INDICATORS

Abstract

This study aimed to develop an algorithmic trading strategy using a Random Forest classifier model to predict Bitcoin price movements and generate buy-sell signals for investors. The model was supported by technical analysis indicators such as RSI and SMA, and achieved high accuracy rates based on historical price movements. The analyses and visualizations demonstrate that the signals generated by the model are consistent with market movements and have the potential to optimize investor decisions. The findings prove that the Random Forest model successfully predicts price changes in historical data and provides reliable signals to investors for executing trades at the right time. The model's success rate is notably high when compared to actual price movements, and the effects of trading signals over time have been clearly illustrated through graphs. This study aims to contribute to the development of investment strategies in volatile markets such as Bitcoin and similar assets, and demonstrates the effectiveness of algorithmic trading models. Additionally, the study reveals that combining technical analysis indicators with machine learning methods can be an effective tool in developing trading strategies for financial markets.

Keywords: Bitcoin, Random Forest, Algorithmic Trading, RSI, SMA.

GİRİŞ

Son yıllarda, dijital finans piyasalarında yaşanan dönüşümle birlikte kripto varlıklar, yatırımcılar ve finans sektörü için önemli bir alternatif varlık sınıfı haline gelmiştir. Geleneksel finansal sistemlerin merkezi yapılarından farklı olarak, kripto varlıklar merkeziyetsiz, şeffaf ve güvenli bir yapı sunan Blockchain teknolojisi üzerine inşa edilmiştir.

Bitcoin, 2008 yılında Satoshi Nakamoto tarafından ortaya konulan ilk kripto para birimi olup, sınırlı arzı, madencilik yoluyla üretimi ve merkeziyetsiz yapısıyla finansal piyasalarda dikkat çekici bir yatırım aracı olmuştur (Nakamoto, 2008). Ethereum, Binance Coin, Cardano, Solana gibi birçok alternatif kripto varlık da piyasaya sürülerek, dijital finans ekosisteminin genişlemesine katkı sağlamıştır. Ancak, kripto varlıklar yüksek volatiliteye sahip olup, fiyatları geleneksel finansal araçlara kıyasla çok daha hızlı değişebilmektedir. Bu oynak yapı, yatırımcılar açısından büyük kazanç fırsatları sunduğu gibi önemli riskler de barındırmaktadır. Kripto varlık piyasalarında başarılı ticaret stratejileri oluşturabilmek için algoritmik ticaret ve makine öğrenmesi temelli tahmin modelleri giderek daha fazla önem kazanmaktadır. Geleneksel teknik analiz yöntemleri, belirli göstergelere dayanarak fiyat hareketlerini inceleyip öngörmeye çalışırken, makine öğrenmesi algoritmaları daha fazla veriyi değerlendirerek fiyat değişimlerini daha yüksek doğrulukla tahmin edebilmektedir (S McNally vd., 2018; Park & Yang; Jain vd., 2025). Bu bağlamda, Rasgele Orman (Random Forest) modeli, karar ağacı tabanlı bir yöntem olarak, çok sayıda değişkeni aynı anda analiz ederek daha sağlam ve güvenilir tahminler üretme avantajı sağlamaktadır. Geleneksel ekonometrik modeller genellikle sınırlı sayıda

değişken üzerinden tahmin yaparken, Rasgele Orman modeli büyük veri setlerinde öğrenme kabiliyeti sayesinde oynak piyasalarda dahi başarılı sonuçlar verebilmektedir (Bozorgtabar vd., 2025; Islam vd., 2025; Arslan vd., 2025).

Kripto para piyasaları oldukça spekülattir. Borsalar öncelikle kar ticareti için kullanılır. Önemli volatiliteler ve likidite endişeleri nedeniyle, bu borsalar öncelikli olarak gerçek mal ve hizmetlerin işlemlerini kolaylaştırmak için kullanılmamaktadır. Bu nedenle, ağırlıklı olarak alım satım karı peşinde koşan katılımcılardan oluşan bir piyasada, güçlü bir davranışsal mercek ile inceleme yapmak gereklidir (Vo & Yost-Bremm, 2020). Bu motivasyonla Bitcoin'in dakikalık fiyat hareketlerini tahmin etmek amacıyla Rasgele Orman modeli kullanılarak bir algoritmik ticaret modeli geliştirilmesi amaçlanmaktadır. Modelin giriş değişkenleri olarak, kripto para piyasalarında yaygın olarak kullanılan RSI (Relative Strength Index) ve SMA (Simple Moving Average) gibi teknik analiz göstergeleri tercih edilmiştir. Bu göstergeler, Bitcoin fiyatlarının aşırı alım veya satım bölgelerinde olup olmadığını belirleyerek ticaret stratejilerinin oluşturulmasına yardımcı olmaktadır. Çalışmanın temel amacı, yatırımcıların ve trader'ların piyasada daha bilinçli ve sistematik kararlar almasına katkı sağlayacak bir algoritmik model geliştirmektir. Bunun yanı sıra elde edilen modelin performansı, işlem sinyallerinin doğruluğu ve getirisi açısından test edilmesidir.

Son yıllarda Bitcoin fiyat tahmini üzerine yapılan çalışmalar, geleneksel ekonometrik yöntemlerden derin öğrenme modellerine kadar geniş bir yöntem yelpazesi sunmaktadır. Büyükkör (2024), ARIMA ve LSTM modellerini karşılaştırarak, LSTM'nin büyük veri setlerinde Bitcoin'in oynak yapısını daha iyi yakaladığını göstermiştir. Benzer şekilde, Caliciotti vd. (2024) regresyon modelleri ile makine öğrenmesi yöntemlerini karşılaştırarak, destek vektör makinelerinin (SVM) uzun vadeli Bitcoin fiyat tahmininde başarılı sonuçlar verdiğini ortaya koymuştur. Bunun yanı sıra, Mansilha vd. (2024) Monte Carlo simülasyonu yöntemini kullanarak Bitcoin fiyat tahmini yapmış ve yüksek volatilitenin tahmin doğruluğu üzerindeki etkisini değerlendirmiştir.

Makine öğrenmesi ve derin öğrenme tekniklerine odaklanan çalışmalar, farklı modelleme yaklaşımlarını değerlendirmiştir. Farouk vd. (2024), Bitcoin fiyat tahmini için dokuz farklı makine öğrenmesi algoritmasını test ederek, farklı veri setlerinde değişen başarı oranlarını incelemiştir. Khaniki vd. (2024) ise Bitcoin, Ethereum ve Litecoin fiyatlarını tahmin etmek için Transformer tabanlı sinir ağlarını kullanarak geleneksel yöntemlere kıyasla daha yüksek doğruluk elde etmiştir. Ayrıca, Mehrdoust vd. (2024) hibrit bir model olan ARIMA-LS-SVM ile Bitcoin fiyat tahmini yaparak, geleneksel ekonometrik yöntemlerle desteklenen makine öğrenmesi tabanlı modellerin hata oranlarını düşürebileceğini göstermiştir.

Derin öğrenme yöntemleri üzerine yapılan çalışmalar da önemli bulgular sunmaktadır. Metin (2025), LSTM, GRU, RNN ve CNN modellerini karşılaştırarak, GRU'nun en yüksek doğruluk oranına sahip olduğunu bulmuştur. Benzer şekilde, Tayib & Abdulazeez (2024) çalışmaları, Bitcoin fiyat tahmininde RNN, CNN ve

LSTM gibi modellerin avantajlarını ve sınırlılıklarını karşılaştırarak, LSTM'nin uzun vadeli bağıntıları yakalamada en iyi performansı sunduğunu ortaya koymuştur. Tripathi & Sharma (2023), sinyal işleme yöntemleri ve Bayes optimizasyonunu kullanarak Bitcoin fiyat tahmininde hibrit bir derin öğrenme modeli geliştirmiş ve teknik göstergelerle eğitilen DANN modelinin en başarılı sonuçları verdiğini göstermiştir.

Farklı değişkenler ve veri setleri üzerine yapılan çalışmalar da literatürde önemli bir yer tutmaktadır. Nas & Ünal (2023), Bitcoin fiyatlarını etkileyen faktörleri belirleyerek, Fed faiz oranı ve altın fiyatlarının Bitcoin'in fiyat hareketlerine olan etkisini değerlendirmiştir. Öte yandan Sinha (2024), aşırı gradyan artırma (XGBoost) algoritmasının diğer makine öğrenmesi yöntemlerine kıyasla Bitcoin fiyat tahmininde en yüksek doğruluk oranını sağladığını göstermiştir. Bu çalışmalar, Bitcoin fiyat tahmininde farklı faktörlerin önemini vurgulayarak yatırımcı kararlarının daha bilinçli alınmasına katkı sağlamaktadır.

Hibrit model yaklaşımlarına odaklanan çalışmalar, farklı yöntemlerin entegrasyonunun tahmin performansını artırabileceğini göstermektedir. Özellikle Tripathi & Sharma (2023), sinyal işleme teknikleriyle desteklenen derin öğrenme modellerinin tahmin doğruluğunu artırmada kritik bir rol oynadığını ortaya koymuştur. Bunun yanı sıra, Farouk vd. (2024) çalışmaları, farklı makine öğrenmesi modellerinin Bitcoin fiyat tahmininde nasıl değişken performans sergileyebileceğini göstererek model seçiminde veri seti özelliklerinin önemine dikkat çekmiştir. Sonuç olarak, literatürde Bitcoin fiyat tahmini üzerine yapılan çalışmalar geniş bir yöntem çeşitliliği sunmakta olup, özellikle derin öğrenme ve hibrit modellerin geleneksel yöntemlere kıyasla daha yüksek doğruluk sağladığı görülmektedir. Çalışmalar, teknik göstergelerin tahmin performansını artırdığına ve model seçiminde veri setinin özelliklerinin belirleyici olduğuna dikkat çekmektedir. Gelecekte, farklı değişkenlerin entegrasyonu ve sinyal işleme teknikleriyle desteklenen modellerin daha başarılı tahminler sunabileceği öngörülmektedir. Ayrıca, derin öğrenme yöntemleri ve hibrit modellerin sürekli gelişmesiyle birlikte, Bitcoin piyasasında daha doğru ve güvenilir tahminlerin mümkün olacağı değerlendirilmektedir.

ALGORİTMİK TİCARET

Finansal piyasalarda algoritmik ticaret, son yıllarda önemli bir gelişim göstermiştir. Bu gelişim, bilgi teknolojilerinin ve veri analitiğinin finansal karar alma süreçlerine entegrasyonu ile mümkün olmuştur. Algoritmik ticaret, önceden belirlenmiş kurallar ve algoritmalar kullanarak otomatik olarak alım satım işlemlerinin gerçekleştirilmesini sağlamaktadır. Bu bağlamda, algoritmik ticaretin temel bileşenleri ve uygulama alanları üzerinde durmak, finansal piyasalardaki dinamik değişimleri anlamak açısından kritik öneme sahiptir. Algoritmik ticaretin temel özelliklerinden biri, yüksek frekanslı ticaret (HFT) uygulamalarıdır. Grindsted (2020) tarafından yapılan bir çalışmada, yüksek frekanslı ticaretin doğal afetler gibi

dışsal olaylara nasıl uyum sağladığı incelenmiştir. Yazar, stok piyasası işlemleri, mikro saniyeler içinde hızlanmış bir şekilde gerçekleştiğine değinerek, yüksek frekanslı ticaretin piyasa dinamiklerini nasıl yeniden yapılandırıldığını ve finansal sistem üzerindeki etkilerini vurgulamaktadır. Bu tür ticaret stratejileri, piyasa tepkilerini anlık olarak değerlendirme yeteneği sunarak, yatırımcılara önemli avantajlar sağlamaktadır. Ayrıca, algoritmik ticaretin bir diğer önemli yönü, bilgi teknolojisinin traderların risk alma davranışları ve portföy performansı üzerindeki etkisidir. El Fadl vd. (2015) tarafından gerçekleştirilen bir araştırmada, IT ticaret platformunun traderların risk alma davranışları üzerindeki etkisi incelenmiştir. Çalışma, algoritmik ticaretin, traderların risk alma davranışlarını ve hisse senedi portföy performansını önemli ölçüde etkilediğini ortaya koymaktadır (El Fadl vd., 2015). Bu bulgu, algoritmik ticaretin yalnızca işlem verimliliğini artırmakla kalmayıp, aynı zamanda traderların karar alma süreçlerini de dönüştürdüğünü göstermektedir.

Finansal piyasalarda algoritmik ticaretin bir diğer önemli uygulama alanı, teknik göstergelerin kullanımıdır. Salkar vd. (2021) tarafından yapılan bir çalışmada, finansal piyasalarda algoritmik ticaretin artan kullanımı ele alınmıştır. Çalışmada teknik göstergelerin, varlık fiyatlarının tahmin edilmesinde önemli bir rol oynadığını belirtilmektedir. Bu bağlamda, algoritmik ticaret stratejileri, teknik göstergeler kullanılarak geliştirilen zaman serisi analizleri ile desteklenmektedir. Bu tür stratejiler, yatırımcılara daha bilinçli kararlar alma imkânı sunmaktadır. Ayrıca, yüksek frekanslı ticaretin karmaşıklığı, kontrol stratejileri ile yönetilmektedir. Jia & Lau (2018) tarafından yapılan bir incelemede, yüksek frekanslı algoritmik ticaretin kontrol stratejileri üzerinde durulmuştur. Yazarlar piyasa yapıcılarının temel işlevleri ve kontrol stratejilerinin yüksek frekanslı ticaretteki rolünü analiz etmektedir. Bu kontrol stratejileri, algoritmik ticaretin güvenilirliğini artırmakta ve piyasa istikrarını sağlamaktadır. Görüldüğü üzere finansal piyasalardaki güçlü dalgalanmalar, hisse senedi piyasasını yatırımcılar için riskli bir alan haline getirmektedir. Borsadaki çeşitli yatırım stratejileri, daha fazla borsa hissesi satın almak için bir araç olarak karşımıza çıkmaktadır (Chihab vd., 2019). Benzer şekilde, kripto para piyasası da yüksek volatiliteye sahip olup yatırımcılar için büyük fırsatlar ve riskler barındırmaktadır. Kripto borsalarında yatırımcılar, teknik analiz, uzun vadeli tutma, arbitraj ve algoritmik ticaret gibi stratejiler kullanarak kazanç sağlamayı hedeflemektedir. Ancak, düzenleyici belirsizlikler, piyasa manipülasyonları ve likidite dalgalanmaları, kripto yatırımlarını geleneksel hisse senedi yatırımlarından farklı kılan önemli faktörler arasında yer almaktadır. Genellikle temel ve teknik analize dayanan geleneksel alım satım stratejileri, modern piyasaların hızlı dinamiklerine uyum sağlamakta zorlanabilmektedir. Bu durum, önceden tanımlanmış kriterlere göre işlem yapmak için bilgisayar algoritmalarını kullanan bir yöntem olan algoritmik ticarete olan ilginin artmasına yol açmıştır. Bu bağlamda, gelişmiş analitik araçların entegrasyonu, alım satım performansını ve karar alma sürecini iyileştirmek için elzem hale gelmektedir. Algoritmik alım satım, büyük miktarda veriyi işleme ve yüksek hızlarda alım satım gerçekleştirme ve böylece

piyasa erişimini demokratikleştirme kabiliyeti nedeniyle ilgi görmüştür (Sukma & Namahoot, 2024).

Özetle Algoritmik ticaret, finansal borsalarda alım satım kararlarını otomatik olarak uygulamak için bilgisayar algoritmalarının kullanılması şeklinde tanımlanabilmektedir. En yaygın olarak ABD hisse senetleri veya diğer gelişmiş piyasa para birimleri gibi iyi gelişmiş finansal piyasalarda kullanılmaktadır (Vo & Yost-Bremm, 2020). Mathur vd. (2021) algoritmik ticaretin avantajlarını hızlı ve düşük maliyetli ticaret, ticarete geliştirilmiş hassasiyet ve çeşitlilik, yatırımcıların bir ticaret fikrini değerlendirmesini ve ince ayar yapmasını sağlayan geriye dönük test şeklinde açıklamaktadır.

VERİ SETİ VE METODOLOJİ

Finansal varlık analizinin temel ve teknik analiz olmak üzere iki ana yöntemi vardır. Temel analiz, belirli bir varlığı etkileyen hem mikroekonomik hem de makroekonomik değişkenleri inceleyerek bir hedef fiyat oluşturmayı amaçlamaktadır. Mikroekonomik değişkenler yalnızca o varlığı etkilemekte; örneğin, belirli bir şirketin hisse senedi fiyatının değerlemesinde, bu değişkenler şirketin mali tablolarını, satışlarının gelişimini ve diğer parametreleri içermektedir. Makroekonomik değişkenler ise tüm bir sektörü, tüm bir ülkeyi ve hatta tüm dünyayı etkilemektedir. Teknik analiz ise temel olarak açılış ve kapanış fiyatlarının yanı sıra belirli bir dönemde farklı varlıkların ulaştığı en yüksek ve en düşük fiyatları girdi değişkenleri olarak kullanılmaktadır (Orte vd., 2023).

Çalışmada, Bitcoin'in 29.08.2024 ile 27.11.2024 tarihleri arasındaki geçmiş fiyat verilerinden elde edilen 51416 dakikalık veri kullanılarak, RSI (Göreceli Güç Endeksi) ve SMA (Basit Hareketli Ortalama) göstergeleri hesaplanmıştır. Bu göstergeler, modelin eğitiminde bağımsız değişken (öznitelik) olarak kullanılmıştır. Hesaplanan RSI ve SMA göstergeleri veri setine uyumluluk göstermesi açısından dakikalık verilere uygun şekilde ayarlanmıştır. RSI Hesaplanırken 14 periyotluk hareketli bir pencere kullanılmış, bu da dakikalık verilerde 14 dakikalık fiyat değişimlerini temel alınmıştır. SMA hesaplanırken ise 14 periyotluk hareketli ortalama, dakikalık kapanış fiyatlarıyla çalıştırılmıştır. Söz konusu teknik indikatörler ile makine öğrenme tekniklerinden biri olan Rastgele Orman modeli ile tahminlemeler yapılmıştır.

Rasgele Orman bir topluluk makine öğrenme tekniğidir. Hem regresyon hem de sınıflandırma görevlerini yerine getirebilmektedir. Asıl işlev modeldeki varyansı azaltmak amacıyla tek tek karar ağaçlarına güvenmek yerine nihai çıktıyı belirlemek için birden fazla karar ağacını birleştirmektir (Vijh vd., 2020). Rasgele Orman, $\{h(x, \theta_k), k = 1, \dots\}$ ağaç yapılı sınıflandırıcılar koleksiyonundan oluşan bir sınıflandırıcıdır; burada $\{\theta_k\}$ bağımsız özdeş dağılımlı rastgele vektörlerdir ve her ağaç x girişindeki en popüler sınıf için bir birim oy kullanmaktadır. Bu tanım, Rasgele Orman'ın birçok ağaç yapılı sınıflandırıcının bir kombinasyonu olduğunu

göstermektedir. Breiman (2001)'in Rastgele Orman modelinde, her ağaç bir eğitim örnek seti ve bir rastgele değişken temelinde dikilmektedir, k th ağaca karşılık gelen rastgele değişken θ_k olarak gösterilmekte, bu rastgele değişkenlerin herhangi ikisi arasında bağımsız ve aynı dağılır, sonuçta x 'in giriş vektörü olduğu bir sınıflandırıcı $h(x, \theta_k)$ elde edilmektedir. K kez çalıştırıldıktan sonra, $\{h_1(x), h_2, \dots, h_k(x)\}$ sınıflandırıcı dizisi elde edilmekte ve bunlar birden fazla sınıflandırma modeli sistemi oluşturmak için kullanılmaktadır. Bu sistemin karar fonksiyonu şu şekilde gösterilmektedir (Liv vd., 2012):

$$H(x) = \arg \max_y \sum_{i=1}^k I(h_i(x) = Y) \quad (1)$$

Eşitlik (1)'de $H(x)$ sınıflandırma modeli kombinasyonu, h_i tek bir karar ağacı modeli, Y çıktı değişkeni, $I(.)$ gösterge fonksiyonudur. Verilen bir girdi değişkeni için, her ağacın en iyi sınıflandırma sonucunu seçmek için oylama hakkı bulunmaktadır.

Çalışmada model olarak Rasgele Orman Sınıflandırma modeli kullanılmış ve modelin performansı RMSE doğruluk ölçütüyle değerlendirilmiştir. Eğitim ve test verileri %70-30 oranında ayrılarak, modelin genel başarısı test edilmiştir. Ayrıca, modelin tahminlerini görselleştirmek için karmaşıklık matrisi ve özellik önem skorları grafikleri oluşturulmuştur. Model seçim kriteri olarak kabul edilen RMSE (Mean square error (MSE), tahmin edilen (y) ile beklenen (y) arasındaki karesel farkın toplamı) ve MSE değerleri belirli bir birimde değildir. Bir model için MSE değerinin azalması, modelin anlamlılığı açısından olumlu olarak değerlendirilmektedir. MSE'nin karekökü olan RMSE değeri aşağıdaki şekilde hesaplanmaktadır (Göğen & Güney, 2024):

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Predicted_i - Actual_i)^2}{N}} \quad (2)$$

Teknik analizde en yaygın yöntemlerden biri teknik göstergelerin kullanılmasıdır. Bu matematiksel ve istatistiksel formülasyonları, bir finansal piyasanın koşullarıyla ilgili farklı yönleri ölçmek için kullanılmaktadır. (Orte vd., 202). Piyasa katılımcıları, temel veya teknik analiz kullanarak hangi hissede ne zaman işlem yapacağına karar vermektedirler. Temel analiz, ülkenin ve dünyanın ekonomik durumu, ilgili şirketin mali durumu ve yönetimi, güncel siyasi ve hava durumu bilgileri hakkındaki bilgileri kullanmaktadır. Teknik analiz, bir hisse senedinin gelecekteki fiyatını tahmin etmek için geçmiş fiyat bilgilerini kullanarak hisse senedi fiyat hareketini analiz etme yöntemidir. Hisse senedi hareketlerini analiz etmenin birçok yolu bulunmaktadır. Teknik analiz, SMA, EMA, RSI ve MACD gibi teknik göstergeleri kullanarak hisse senedi fiyatını tahmin etmeyi içermektedir (Anbalagan & Maheswari, 2015). Bu çalışmada RSI ve SMA teknik göstergeleri kullanılarak analiz yapılmıştır. Modelde destekleyici değişken olarak yalnızca RSI ve SMA kullanılması hem aşırı uyum riskini azaltmak hem de gereksiz korelasyonlu

değişkenlerden kaçınmak adına yapılan bir tercihtir. SMA, fiyat trendlerini belirlemede etkin bir gösterge olup, RSI ise piyasanın aşırı alım veya aşırı satım bölgelerinde olup olmadığını göstererek tamamlayıcı bir rol üstlenmektedir. Ayrıca, SMA ve EMA gibi teknik göstergeler benzer bilgileri içerdiğinden, fazla değişken kullanımı modelin hesaplama yükünü artırabilir ve gereksiz veri tekrarına neden olabilir. Modelin başarısını artırmaya yönelik olarak yapılan bu seçim, istatistiksel testler ve model performansı analizleriyle desteklenmiş olup, gereksiz özniteliklerden kaçınarak modelin genelleme kabiliyetini koruma amacı taşımaktadır.

Hisse senedi piyasaları için destekleyici ilke basit olmasına rağmen, düşük almak ve yüksek satmak ne zaman ve ne kadar alınıp satılacağına karar vermek o kadar basit değildir. Bu zorluğun üstesinden gelmek için bir dizi teknik ortaya çıkmıştır. Yükseliş ve düşüş eğilimlerini tahmin etmek amacıyla piyasa bilgilerinin incelenmesi olarak düşünülebilecek spekülasyon analizler etkinliği ve göreceli basitliği nedeniyle karar verme desteğinde en yaygın kullanılan mekanizmalardan biri olan teknik analizlerdendir (Escobar vd., 2013). Teknik göstergeler, geçmiş işlem verilerine sahip herhangi bir menkul kıymete uygulanabilmektedir. Bu menkul kıymetler, diğerlerinin yanı sıra hisse senetleri, para birimleri, vadeli işlemler, endeksler ve hammaddeler olabilmektedir. Aynı zamanda kripto varlık piyasalarında tam olarak kullanılabilmektedir (Orte vd., 2023). Çalışmada kullanılan teknik göstergelerden RSI (Göreceli Güç Endeksi), hisse senedinin aşırı alım mı yoksa aşırı satım mı olduğunu belirleyen popüler bir momentum gösterge olarak bilinmektedir. Bir hisse senedinin, talep fiyatı haksız bir şekilde yukarı çektiğinde aşırı alım yaptığı söylenebilmektedir. Bu durum genellikle hisse senedinin aşırı değerlendirildiğinin ve fiyatın düşebileceğinin bir işareti olarak yorumlanmaktadır. Fiyat keskin bir düşüşle gerçek değerinin altında bir seviyeye inmesi bir hisse senedinin aşırı satıldığına işaret etmektedir. Bu, panik satış nedeniyle ortaya çıkan bir sonuç olarak değerlendirilmektedir. RSI 0 ila 100 arasında değişmekte ve genellikle RSI 70'in üzerinde olduğunda hisse senedinin aşırı satın alındığını ve RSI 30'un altında olduğunda hisse senedinin aşırı satıldığını gösterebilmektedir (Khaidem vd., 2016). RSI teknik bir momentumdur. Belirli bir zaman aralığında (T) fiyat değişikliklerinin büyüklüğünü değerlendiren ve bunları bir osilatör olarak temsil ettiği bilinmektedir (Bâra & Oprea, 2024). Başka bir ifadeyle RSI trendin gücünü ölçer ve şu şekilde formülize edilmektedir (Alotaibi, 2021; Bara & Oprea, 2024):

$$RSI^t = \frac{\overline{Price_+}}{Price_+ + Price_-} \times 100 \quad (3)$$

$$burada \begin{cases} Price_+^{\Delta t} = 1 \times (Price^t - Price^{t-1}), \text{ eğer } Price^t - Price^{t-1} > 0 \\ Price_-^{\Delta t} = -1 \times (Price^t - Price^{t-1}), \text{ eğer } Price^t - Price^{t-1} < 0 \end{cases}$$

Eşitlikte $\overline{Price}$ kapanış fiyatını, t zamanı, $Price_+^{\Delta t}$ ve $Price_-^{\Delta t}$ fiyat değişikliklerini, $Price_+$ ve $Price_-$ ise fiyat değişikliklerinin ortalamasını, temsil etmektedir.


Benzer şekilde SMA (Basit Hareketli Ortalama) indikatörü de menkul kıymetlerin tahmin sürecinde hesaplanabilmekte ve göstergeler üzerinde çizilebilmektedir. Bir göstergenin hareketli ortalamasının yorumlanması, bir menkul kıymetin hareketli ortalamasının yorumlanmasına benzemektedir. Gösterge hareketli ortalamasının üzerine çıktığında, göstergenin yukarı doğru hareketinin devam ettiği anlamına gelmekte; gösterge hareketli ortalamasının altına düştüğünde, göstergenin aşağı doğru hareketinin devam ettiği anlamına gelmektedir (Achelis, 2001). Teknik göstergeler genel olarak verilerin kalitesini geliştirmek, verimliliği artırmak ve hisse senedi tahmin sürecini basitleştirmek için kullanılmaktadır. Bir SMA, menkul kıymetin en son “n” zaman periyodu için fiyatlarının toplanması ve ardından “n” ye bölünmesiyle hesaplanır ve bu hesaplama grafikteki her periyot için yapılmaktadır (Anbalagan & Maheswari, 2015).

$$SMA = \frac{\sum P_n}{N} \quad (4)$$


Burada $P_n = n$ 'inci periyottaki fiyatı, $N =$ Hareketli ortalamanın periyot sayısını, $\sum P_n$ ise N periyottaki fiyatların toplamını ifade etmektedir.

ANALİZ VE BULGULAR

Bu çalışmada 29.08.2024 ile 27.11.2024 tarihleri arasında Bitcoin'in dakikalık fiyat hareketlerini tahmin etmek için RSI (Relative Strength Index) ve SMA (Simple Moving Average) gibi teknik analiz göstergelerini kullanarak bir algoritmik ticaret modeli geliştirmek amaçlanmaktadır. Model, finansal piyasalarda ticaret stratejileri geliştirmeyi amaçlayan yatırımcılar ve trader'lar için bir araç sağlamayı hedeflemektedir. Bu amaç doğrultusunda çalışmada veri seti olarak Bitcoin fiyatlarının 51416 dakikalık fiyat verisi alınmıştır. Söz konusu veriler Yahoo Finance web sitesinden temin edilmiştir. Analizler Python Jupyter Notebook uygulaması aracılığıyla analiz edilmiştir. Bitcoin fiyat tahminlerinde Rasgele Orman Sınıflandırması kullanmak, modelin karmaşık ve değişken veri setleriyle etkili bir şekilde başa çıkabilmesini sağlamıştır. Yüksek doğruluk, gürültüye karşı direnç ve özelliklerin önem sıralaması gibi avantajlar, bu sınıflandırma yönteminin tercih edilmesinin sebepleridir. Bu model, finansal piyasalarda algoritmik ticaret stratejileri geliştirmek için etkili bir araç olmuştur. Grafik 1'de Bitcoin'in dakikalık fiyat hareketleri gösterilmektedir.




Grafik 1 modelin analiz ettiği dakikalık Bitcoin fiyat hareketlerini göstermektedir. Kripto para piyasaları, özellikle kısa vadeli işlemler söz konusu olduğunda yüksek volatilitelere sahiptir ve fiyatlar dakikalar içinde sert değişimler yaşayabilir. Bu grafik, modelin çalıştığı veri setinin dalgalanma seviyesinin anlaşılmasına yardımcı olmaktadır. Ancak, piyasanın genel yönünü belirlemek için tek başına yeterli değildir. Bu noktada, modelin sadece fiyat hareketlerini değil, aynı zamanda teknik göstergeleri de kullanarak alım ve satım kararları ürettiğini görmek gerekmektedir. Aşağıdaki al-sat sinyalleri grafiği, modelin belirlediği fırsat noktalarını göstermekte ve dakikalık fiyat hareketlerindeki iniş çıkışlara nasıl tepki verdiğini ortaya koymaktadır. Model, RSI ve SMA gibi göstergeleri analiz ederek piyasanın aşırı alım veya aşırı satım bölgelerine girip girmediğini tespit etmiş ve buna göre işlem sinyalleri oluşturmuştur. Böylece, dakikalık fiyat hareketlerindeki yüksek oynaklık içinde sistematik bir ticaret stratejisi geliştirilmiş ve yatırımcılara belirli zamanlarda işlem yapma imkânı sunulmuştur. Söz konusu sinyaller için şu kurallar uygulanmıştır: $RSI < 30$ ise aşırı satım bölgesinde ve fiyat SMA'nın altındaysa AL (Buy) Sinyali; $RSI > 70$: Aşırı alım bölgesinde ve fiyat, SMA'nın üstündeyse SAT (Sell) Sinyali; Yukarıdaki koşullara uymayan durumlarda ise TUT (Hold) Sinyalini ifade etmektedir. Grafik 2'de al sat sinyalleri gösterilmektedir.

Grafik 2: Bitcoin Dakikalık Fiyatları Al-Sat Sinyalleri


Grafik 2’te BUY sinyalleri yeşil üçgen, SELL sinyalleri kırmızı ters üçgen ile işaretlenmiştir. Grafik modelin tahminlerinin görsel olarak sunulmasını sağlamakta ve piyasa katılımcılarının al-sat kararları vermesine olanak tanımaktadır. Özellikle al, sat ve tut sinyallerinin ne zaman ve nasıl verildiğini göstermek, modelin başarısını değerlendirme, yatırımcıların doğru zamanlamalarla işlem yapmalarını sağlama ve stratejilerin etkinliğini görme adına son derece önemlidir. Ayrıca, grafiklerin kullanılması, modelin güvenilirliğini ve işlevselliğini daha iyi anlatmaya yardımcı olmaktadır. Bitcoin fiyat hareketlerindeki artış ve azalışlar görselleştirilmiştir. Yeşil oklar fiyatın yükseldiği, kırmızı oklar ise fiyatın düştüğü noktaları temsil etmektedir. Genel olarak fiyatların zaman içinde artış eğiliminde olduğu gözlemlenirken, belirli periyotlarda düzeltmeler yaşandığı dikkati çekmektedir. Özellikle yükseliş trendi içerisinde meydana gelen kırmızı ok kümelenmeleri, piyasanın volatilitesine ve ara düzeltmelere işaret etmektedir. Bu tür görselleştirmeler, yatırımcıların alım-satım stratejileri geliştirmesine ve piyasa momentumunu daha iyi analiz etmesine yardımcı olabilmektedir.

Çalışmanın amacı doğrultusunda hesaplanan RSI ve SMA göstergeleri dakikalık verilere uygun şekilde ayarlanmıştır. RSI Hesaplamasında 14 periyotluk hareketli bir pencere kullanılmaktadır, bu da dakikalık verilerde 14 dakikalık fiyat değişimlerini temel almaktadır. SMA Hesaplaması ise yine 14 periyotluk hareketli ortalama, dakikalık kapanış fiyatlarıyla çalışmaktadır. Grafik 3’te Bitcoin’in kapanış fiyatları ve 14 periyotluk Basit Hareketli Ortalaması (SMA) birlikte gösterilmektedir. Dakikalık fiyat hareketleri, piyasanın kısa vadeli oynaklığını gösterirken, aşağıdaki alım-satım sinyalleri grafiği, modelin bu fiyat hareketlerine nasıl tepki verdiğini göstermektedir. Daha uzun vadeli piyasa eğilimlerini anlamak için günlük kapanış fiyatları ve SMA göstergesi incelenmelidir.

Grafik 3. Bitcoin Kapanış Fiyatları ve 14 Periyotluk Basit Hareketli Ortalama (SMA)




Grafik 3'te Görselleştirmenin okunabilirliğini artırmak amacıyla zaman eksenini sadeleştirilmiş olup, kullanılan tüm veriler dakikalık fiyatlara dayanmaktadır. Bitcoin'in kapanış fiyatlarını (mavi) ve 14 periyotluk Basit Hareketli Ortalamasını (SMA- turuncu) göstermektedir. Hareketli ortalamalar, fiyat hareketlerini yumuşatarak piyasanın genel trendini belirlemeye yardımcı olmaktadır. Grafikte, özellikle Eylül ve Ekim aylarında fiyatların SMA çizgisine oldukça yakın seyrettiği görülmektedir. Bu durum, piyasanın kararsız olduğu ve belirgin bir yönelim göstermediği bir döneme işaret etmektedir. Ancak, Ekim ayının ortalarından itibaren fiyatların SMA'nın üzerine çıkmasıyla birlikte yukarı yönlü bir momentum oluşmuş ve Kasım ayında güçlü bir yükseliş trendi başlamıştır. Kasım ortasında SMA çizgisinin fiyat hareketlerini yukarı yönlü takip etmesi, piyasadaki güçlü alım baskısını ve boğa piyasasının ivme kazandığını göstermektedir. Bu eğilim, modelin ürettiği alım ve satım sinyallerinin genel piyasa hareketleriyle ne kadar uyumlu olduğunun anlaşılmasına yardımcı olmaktadır. Kısa vadeli dalgalanmalardan bağımsız olarak, SMA'nın genel yönelimi piyasanın uzun vadeli eğilimini belirlemek açısından kritik bir göstergedir. Dolayısıyla, modelin performansını değerlendirirken yalnızca dakikalık veriler üzerinden değil, aynı zamanda SMA gibi teknik göstergeler aracılığıyla piyasanın genel dinamikleri ile nasıl uyum sağladığı da göz önünde bulundurulmalıdır. Grafik 4'te ise Bitcoin'in 14 periyotluk RSI değerlerini gösterilmektedir.

Grafik 4. Bitcoin 14 Periyotluk RSI (Göreceli Güç Endeksi)


Grafik 4 Bitcoin'in 14 periyotluk Göreceli Güç Endeksi'ni (RSI) göstermektedir. RSI, fiyat hareketlerinin momentumunu ölçerek piyasanın aşırı alım ya da aşırı satım bölgelerinde olup olmadığını belirlemeye yardımcı olan önemli bir göstergedir. Grafikte yer alan kırmızı kesik çizgi (70 seviyesi) aşırı alım bölgesini, mavi kesik çizgi (30 seviyesi) ise aşırı satım bölgesini temsil etmektedir. RSI'nın 70 seviyesinin üzerine çıkması, varlığın aşırı alım bölgesine girdiğini ve fiyatın potansiyel olarak düşüş yaşayabileceğini gösterirken, 30 seviyesinin altına inmesi, aşırı satım bölgesine ulaşıldığını ve fiyatın toparlanma ihtimalinin yüksek olduğunu işaret etmektedir. Grafik incelendiğinde, Eylül ve Ekim aylarında RSI'nın sık sık 30'un altına düştüğü, yani satış baskısının ağır bastığı görülmektedir. Buna karşılık, Kasım ayının başlarından itibaren RSI'nın 70'in üzerine çıkarak alım iştahının arttığını ve güçlü bir boğa piyasası sinyali verdiğini gözlemlemek mümkündür. RSI değerinin bu denli sık dalgalanması, piyasanın oldukça volatil olduğunu ve yatırımcıların ani fiyat hareketlerine karşı dikkatli olması gerektiğini ortaya koymaktadır. Modelin ürettiği alım ve satım sinyallerinin güvenilirliğini değerlendirmek için RSI verileri kritik bir referans noktası olup, bu göstergenin piyasanın yönünü anlamak adına önemli bir rol oynadığı söylenebilmektedir.

Çalışmanın devamında RMSE, karmaşıklık matrisi ve sınıflandırma raporu ile performans değerlendirmesi yapılmıştır. Modelin özelliklere verdiği önem skorlarını incelenmiş ve gerçek ve tahmin edilen sinyalleri fiyat grafiği üzerinde gösterilmiştir. Karmaşıklık matrisi Grafik 5'te gösterilmiştir.

Grafik 5. Rasgele Orman Modeli İçin Karmaşıklık Matrisi



Çalışmada Al-Sat-Tut sinyalleri, RSI ve SMA göstergelerine dayalı belirli teknik kurallar çerçevesinde üretilmiştir. Bu kurallar yalnızca uygun piyasa koşulları oluştuğunda aktif hale geldiğinden, toplam veri setinin küçük bir kısmı sinyal olarak sınıflandırılabilmiştir. Bu durum metodolojik olarak filtrelenmiş veri seçimini yansıtmaktadır. Grafikte 5'te, bir makine öğrenmesi modelinin tahmin performansını değerlendirmek için kullanılan karmaşıklık matrisi gösterilmektedir. Gerçek ve tahmin edilen değerler üç sınıfa ayrılmıştır: "Hold" (Tut), "Buy" (Al) ve "Sell" (Sat). Model, 120 adet "Buy" sınıfını doğru tahmin ederek en yüksek başarıyı bu kategoride sağlamıştır. "Hold" sınıfında 13 doğru tahmin yapılırken, 1 yanlış tahmin "Buy" olarak sınıflandırılmıştır. Benzer şekilde, "Sell" sınıfında 25 doğru tahmin varken, 1 yanlış tahmin "Buy" olarak belirlenmiştir. Genel olarak, modelin "Buy" ve "Sell" sınıflarındaki doğruluk oranı yüksek olup, "Hold" sınıfında ise sınırlı düzeyde hata payı gözlemlenmiştir. Sonuçlara bakıldığında modelin genel doğruluk oranının oldukça yüksek olduğunu (%98.14) ve özellikle Buy sınıfında %99.17 doğruluk ile çok güçlü performans gösterdiğini ortaya koymaktadır. Bu sonuçlar, modelin alım ve satım sinyallerini başarılı bir şekilde yakaladığını ancak "Hold" tahminlerinde iyileştirmeye ihtiyaç duyduğunu göstermektedir. Zira Hold sınıfında yaklaşık %92.86 oranıyla daha düşük bir doğruluk oranı tespit edilmiştir. Sell sınıfı ise yaklaşık %96.15 oranında bir başarı sergilemiştir. Yanlış sınıflandırmaların oldukça düşük olması, modelin genel olarak başarılı ve geçerli bir tahmin performansına sahip olduğunu göstermektedir. Ancak, modelin daha büyük ve dengeli bir veri setiyle test edilmesi, genelleme yeteneğinin doğrulanması açısından faydalı olacaktır. Ardından modelin özelliklere verdiği önem derecesi Grafik 6'da gösterilmektedir.

Grafik 6. Modelin Özelliklere Verdiği Önem Skorları

Bu önem dereceleri, modelin eğitimi sırasında her bir özelliğin (Close, RSI, SMA) ne kadar etkili olduğunu gösteren katsayılarıdır. Burada kullanılan "önem dereceleri", Rasgele Orman gibi bir modelin özelliklerin her birine verdiği özellik etki derecesinin bir göstergesidir. Bu sayede hangi özelliklerin model için daha fazla bilgi taşıdığı ve tahmin yapmada daha etkili olduğunu anlaşılabilmektedir. Close 0.122 olarak elde edilmiştir. Bu, kapanış fiyatının model için önemli bir özellik olduğunu ve fiyat tahmini yaparken bu özelliğin etkili bir şekilde kullanıldığını gösterir. RSI göstergesi 0.736 şeklinde tahminlenmiştir. Bu, RSI göstergesinin modelin kararlarında çok daha güçlü bir rol oynadığını göstermektedir. RSI göstergesinin, aşırı alım veya aşırı satım durumlarını gösterdiği için, fiyat tahminlerini yönlendiren önemli bir teknik analiz aracı olduğu bilinmektedir. SMA ise 0.1403 skoruyla modelin kararları üzerinde kapanış fiyatından biraz daha fazla etkiye sahip bir başka göstergedir. SMA, fiyatların belirli bir süre zarfındaki ortalamalarını sunarak trend analizine yardımcı olmaktadır.

Son olarak tüm bu analizlerin hata oranını ölçen RMSE değeri ise 0.137 olarak belirlenmiş, bu da modelin tahminlerinin gerçek değerlere yakın olduğunu göstermektedir. Sonuç olarak çalışma, teknik analiz göstergeleri ve makine öğrenmesi yöntemlerinin birleştirilerek, finansal piyasalarda ticaret stratejilerinin geliştirilmesinde etkili bir araç olabileceğini ortaya koymaktadır.

SONUÇ VE DEĞERLENDİRME

Bu çalışmada, Bitcoin'in dakikalık fiyat hareketlerini tahmin etmek amacıyla Rasgele Orman Sınıflandırma modeli uygulanmış ve performansları

değerlendirilmiştir. Kripto para piyasasının doğası gereği oldukça volatil ve öngörülemez olduğu bilinmektedir. Ancak, makine öğrenimi ve büyük veri analitiği sayesinde, bu piyasada belirli kalıpları tespit etmek ve kısa vadeli tahminlerde bulunmak mümkün hale gelmektedir. Çalışma sonuçlarında, Rasgele Orman Sınıflandırması modelinin RMSE değerinin düşük olması sebebiyle iyi bir performans gösterdiği söylenebilmektedir. Elde edilen bulgular, literatürde yapılan önceki çalışmalarla kıyaslandığında hem benzerlikler hem de farklılıklar içermektedir. Önceki araştırmalarda genellikle uzun vadeli fiyat tahminleri üzerinde durulurken, bu çalışmada dakikalık fiyat hareketleri hedeflenmiştir. Bu bağlamda, yüksek frekanslı veri analizi ve kısa vadeli tahminlere odaklanılmış olması, çalışmayı önceki literatürden ayıran temel unsurlardan biridir. Ayrıca, çalışmada kullanılan veri ön işleme teknikleri ve model seçimi, daha önce yapılmış bazı araştırmalardan farklı olarak, piyasanın değişken doğasını daha iyi yansıtacak şekilde optimize edilmiştir. Ancak, önceki bazı çalışmaların doğruluk oranları ile kıyaslandığında, kripto piyasasının aşırı oynaklığı nedeniyle hata oranlarının tamamen ortadan kaldırılamadığı görülmektedir. Makine öğrenimi tekniklerinin kripto para piyasasında öngörülebilirliği artırma potansiyeli oldukça yüksektir. Bununla birlikte, bu tür modellerin etkinliği, kullanılan veri setinin büyüklüğü, model parametrelerinin doğru şekilde optimize edilmesi ve piyasanın beklenmedik olaylara karşı verdiği tepkiler gibi birçok faktöre bağlıdır. Özellikle ani piyasa haberleri, regülasyon değişiklikleri ve büyük yatırımcı hareketleri gibi dışsal faktörler, makine öğrenimi modellerinin tahmin gücünü sınırlandırabilmektedir. Dolayısıyla, bu çalışmanın ilerleyen aşamalarında, doğal dil işleme (NLP) yöntemleri kullanılarak haber analizleri ve duygu analizi gibi ek faktörlerin de modele dahil edilmesi, tahminlerin doğruluğunu artırabilir. Kripto piyasasının öngörülebilirliği, yatırımcılar, piyasa analistleri ve algoritmik ticaret stratejileri açısından büyük önem taşımaktadır. Dakikalık fiyat tahmini, özellikle yüksek frekanslı alım-satım yapan yatırımcılar için kritik bir bilgi kaynağıdır. Bu çalışma, kısa vadeli ticaret kararlarını optimize etmeye yönelik bir araç sunmakta ve makine öğrenimi yöntemlerinin finansal piyasalarda nasıl daha etkin kullanılabileceğine dair önemli ipuçları vermektedir. Gelecekte yapılacak çalışmalarda, daha büyük veri setleriyle farklı algoritmaların entegrasyonu, derin öğrenme yöntemlerinin kullanımı ve piyasa duyarlılığı gibi değişkenlerin modele eklenmesi, tahmin performansını artırabilir. Ayrıca, bu tür tahmin modellerinin uzun vadeli yatırım stratejilerine nasıl entegre edilebileceği de önemli bir araştırma alanı olarak değerlendirilebilir. Sonuç olarak, çalışma, Bitcoin fiyat hareketlerini kısa vadede tahmin etme konusunda makine öğrenimi modellerinin potansiyelini ortaya koymaktadır. Ancak, finansal piyasaların doğasından kaynaklanan belirsizlikler ve dışsal faktörlerin etkileri göz önünde bulundurulduğunda, daha gelişmiş modellerin ve daha kapsamlı veri analiz tekniklerinin geliştirilmesi gerekmektedir. Gelecekte yapılacak çalışmalarla birlikte, kripto para piyasalarının öngörülebilirliği daha da artırılabilir ve yatırımcılara daha sağlam veri odaklı stratejiler sunulabilir.

Yazar Katkı oranı ve Çıkar Çatışması Beyanı : Makale tek yazarlıdır. Çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- Achelis, S. (2001). *Technical analysis from A to Z*.
- Alotaibi, S. (2021). Ensemble technique with optimal feature selection for Saudi stock market prediction: A novel hybrid red deer-grey algorithm. *IEEE Access*, 9, 64929–64944. <https://doi.org/10.1109/ACCESS.2021.3073507>
- Anbalagan, T., & Maheswari, S. (2015). Classification and prediction of stock market index based on fuzzy metagraph. *Procedia Computer Science*, 47, 214–221. <https://doi.org/10.1016/j.procs.2015.03.200>
- Arslan, M., Shahzad, A., Shafique, A., & Ahmed, W. (2025). Forecasting Bitcoin: A comparative analysis of traditional versus machine learning approach. In *Transformations in Banking, Finance and Regulation*.
- Bâra, A., & Oprea, S.-V. (2024). An ensemble learning method for Bitcoin price prediction based on volatility indicators and trend. *Engineering Applications of Artificial Intelligence*, 133, 107991. <https://doi.org/10.1016/j.engappai.2024.107991>
- Bozorgtabar, B., Aghajannashtaei, Z., & Gholizadeh, M. (2025). Credit risk modeling of cryptocurrency market using machine learning: Application to money laundering detection in Bitcoin transactions. *Journal of Investment Knowledge*, 14 (55), 531–556. <https://doi.org/10.30495/jik.2025.23609>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32.
- Büyükkör, Y. (2024). Derin öğrenme ve ekonometrik model ile Bitcoin fiyat tahmini: LSTM ve ARIMA. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 26 (47), 978–993.
- Caliciotti, A., Corazza, M., & Fasano, G. (2024). From regression models to machine learning approaches for long-term Bitcoin price forecast. *Annals of Operations Research*, 336 (1), 359–381. <https://doi.org/10.1007/s10479-023-05444-w>
- Chihab, Y., Bousbaa, Z., Chihab, M., Bencharef, O., & Ziti, S. (2019). Algo-trading strategy for intraweek foreign exchange speculation based on random forest and probit regression. *Journal of Applied Mathematics*, 1–13. <https://doi.org/10.1155/2019/8342461>
- El Fadl, M., Abbey, B., & Choi, K. (2015). Effect of IT trading platform on financial risk-taking and portfolio performance. In *48th Hawaii International Conference on System Sciences* (pp. 3298–3306). IEEE.

- Escobar, A., Moreno, J., & Munera, S. (2013). A technical analysis indicator based on fuzzy logic. *Electronic Notes in Theoretical Computer Science*, 292, 27–37. <https://doi.org/10.1016/j.entcs.2013.02.003>
- Farouk, M., Ragaba, N., Salama, D., Elrashidy, O., Mandour, L., Ahmed, M., Attia R., Ahmed N., Elazab, R. (2024). Bitcoin_ML: An efficient framework for Bitcoin price prediction using machine learning. *Journal of Computing and Communication*, 3 (1), 70–87.
- Göğen, E., & Güney, S. (2024). Radyosonde rasatları ile makine öğrenmesi tabanlı hava durumu kestirimi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39 (4).
- Grindsted, T. (2020). Trading on earthquakes: Algorithmic financialization of tectonic events at global stock exchanges. *Geoforum*, 111, 80–87. <https://doi.org/10.1016/j.geoforum.2019.11.019>
- Islam, Z., Islam, S. I., Das, B. C., Reza, S. A., Bhowmik, P. K., Bishnu, K. K., Rahman M. S., Chowdhury, R., Pant, L. (2025). Machine learning-based detection and analysis of suspicious activities in Bitcoin wallet transactions in the USA. *Journal of Ecohumanism*, 4 (1), 3714–3734. <https://doi.org/10.62754/joe.v4i1.6214>
- Jain, R., Srivastava, S., & Shukla, P. (2025). Predicting Bitcoin prices: A machine learning approach for accurate forecasting. In A. Tiwari & M. Darbari (Eds.), *Emerging trends in computer science and its application* (pp. 377–381). CRC Press.
- Jia, X., & Lau, R. (2018). The control strategies for high frequency algorithmic trading. In *2018 IEEE 4th International Conference on Control Science and Systems Engineering (ICCSSE)* (pp. 49–52). IEEE. <https://doi.org/10.1109/CCSSE.2018.8724810>
- Khaidem, L., Saha, S., & Dey, S. (2016). Predicting the direction of stock market prices using random forest. *arXiv preprint arXiv:1605.00003*.
- Khaniki, M., & Manthouri, M. (2024). Enhancing price prediction in cryptocurrency using transformer neural network and technical indicators. *arXiv preprint arXiv:2403.03606*.
- Liu, Y., Wang, Y., & Zhang, J. (2012). New machine learning algorithm: Random forest. In *Information Computing and Applications: Third International Conference, ICICA 2012* (pp. 246–252). Springer.
- Mansilha, M., & Simoes, M. (2024). Bitcoin price prediction using Monte Carlo simulation.

- Mathur, M., Mhadalekar, S., Mhatre, S., & Mane, V. (2021). Algorithmic trading bot. In *ITM Web of Conferences*, 40, 03041. <https://doi.org/10.1051/itmconf/20214003041>
- McNally, S., Roche, J., & Caton, S. (2018). Predicting the price of Bitcoin using machine learning. In *2018 26th Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP)* (pp. 339–343). IEEE. <https://doi.org/10.1109/PDP2018.2018.00060>
- Mehrdoust, F. (2024). Forecasting Bitcoin price by a hybrid structure based on ARIMA, SVM and LSSVM models. *SSRN*. <https://doi.org/10.2139/ssrn.4374994>
- Metin, S. (2025). Derin öğrenme yöntemleri ile Bitcoin fiyat analizi. *Munzur Üniversitesi Sosyal Bilimler Dergisi*, 93–111.
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. <https://bitcoin.org/bitcoin.pdf>
- Nas, S., & Ünal, A. (2023). Bitcoin fiyat değişimlerinin makine öğrenmesi yöntemi ile tahmin edilmesi. *İşletme Araştırmaları Dergisi*, 15 (4), 2597–2608. <https://doi.org/10.20491/isarder.2023.1735>
- Orte, F., Mira, J., Sánchez, M., & Solana, P. (2023). A random forest-based model for crypto asset forecasts in futures markets with out-of-sample prediction. *Research in International Business and Finance*, 64, 101829. <https://doi.org/10.1016/j.ribaf.2022.101829>
- Park, S., & Yang, J.-S. (2024). Machine learning models based on bubble analysis for Bitcoin market crash prediction. *Engineering Applications of Artificial Intelligence*, 135, 107999. <https://doi.org/10.1016/j.engappai.2023.107999>
- Salkar, T., Shinde, A., Tamhankar, N., & Bhagat, N. (2021). Algorithmic trading using technical indicators. In *2021 International Conference on Communication Information and Computing Technology (ICCICT)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICCICT50803.2021.9510135>
- Sinha, H. (2024). Predicting Bitcoin prices using machine learning techniques with historical data. *International Journal of Creative Research Thoughts (IJCRT)*, 12 (8).
- Sukma, N., & Namahoot, C. (2024). An algorithmic trading approach merging machine learning with multi-indicator strategies for optimal performance. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2024.3516053>
- Tayib, H., & Abdulazeez, A. (2024). A review of Bitcoin price prediction based on deep learning algorithms. *Journal of Soft Computing and Data Mining*, 13 (2), 3582–3612.

- Tripathi, B., & Sharma, R. (2023). Modeling Bitcoin prices using signal processing methods, Bayesian optimization, and deep neural networks. *Computational Economics*, 62 (4), 1919–1945. <https://doi.org/10.1007/s10614-022-10325-8>
- Vijh, M., Chandola, D., Tikkiwal, V., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia Computer Science*, 167, 599–602. <https://doi.org/10.1016/j.procs.2020.03.326>
- Vo, A., & Yost-Bremm, C. (2020). A high-frequency algorithmic trading strategy for cryptocurrency. *Journal of Computer Information Systems*, 60 (6), 555–568. <https://doi.org/10.1080/08874417.2018.1552090>