



Makine Öğrenmesi Yöntemleri ile Kripto Varlık Fiyat Tahmini ve En İyi Yöntemin ÇKKV Teknikleri ile Belirlenmesi*

Yunus Emre Korkmaz¹, Serpil Altınırmak², Çağlar Karamaşa³

Öz: Bu çalışma, kripto varlık fiyatlarının makine öğrenmesi algoritmaları ile tahmin edilmesini ve en başarılı yöntemin çok kriterli karar verme (ÇKKV) teknikleriyle belirlenmesini amaçlamaktadır. Bitcoin, Ethereum, BNB, Ripple ve Dogecoin için 01.01.2018 ve 31.12.2023 yılları arasındaki günlük veriler kullanılarak, fiyat hareketleri, teknik göstergeler, yatırımcı duyarlılığı ve makroekonomik faktörleri içeren çok boyutlu bir veri seti oluşturulmuştur. Tahmin modelleri olarak SVR, RF, XGBoost ve LSTM algoritmaları uygulanmış olup, performansları R^2 , MAE, MSE ve RMSE gibi hata metrikleriyle değerlendirilmiştir. Ayrıca değişkenlerin önem düzeyleri, SVR ve LSTM için permütasyon önem analizi ile, RF ve XGBoost'un ise gömülü önem hesaplama yöntemleri ile analiz edilmiştir. Model performanslarına göre oluşturulan karar matrisi üzerinden CRITIC yöntemiyle kriter ağırlıkları hesaplanarak TOPSIS, ARAS ve CODAS yöntemleriyle sıralamalar yapılmış ve en başarılı algoritma Copeland yöntemiyle belirlenmiştir. Sonuçlara göre, en yüksek genel başarıyı XGBoost algoritmasının sağladığı görülmektedir. LSTM algoritması ikinci sırada yer alırken, RF üçüncü ve SVR dördüncü sırada yer almıştır. Ayrıca bulgular, teknik analiz değişkenlerinin model başarısında belirleyici olduğunu ancak, makroekonomik ve duyarlılık göstergelerinin sınırlı katkı sağladığını göstermektedir.

Anahtar Sözcükler: Kripto Varlık, Fiyat Tahmini, Makine Öğrenmesi, Aşırı Gradyan Artırma, Destek Vektör Makinesi, Rastgele Orman, Uzun Kısa Küreli Bellek, ÇKKV

JEL: C45, C53, G17

Geliş : 04 Ağustos 2025
Düzeltilme : 11 Eylül 2025
Kabul : 07 Ekim 2025

Tür : Araştırma

Cryptocurrency Price Prediction Using Machine Learning Methods and Determining the Best Method Using MCDM Techniques

Abstract: This study aims to predict cryptocurrency prices using machine learning algorithms and to determine the most successful method through multi-criteria decision-making (MCDM) techniques. A multidimensional dataset was constructed for Bitcoin, Ethereum, BNB, Ripple, and Dogecoin using daily data from January 1, 2018, to December 31, 2023, incorporating price movements, technical indicators, investor sentiment, and macroeconomic factors. Prediction models such as SVR, RF, XGBoost, and LSTM were applied, and their performances were evaluated using error metrics like R^2 , MAE, MSE, and RMSE. The importance levels of variables were analyzed through permutation importance for SVR and LSTM, and embedded importance calculation methods for RF and XGBoost. Based on model performances, a decision matrix was created, criterion weights were calculated using the CRITIC method, and rankings were conducted using TOPSIS, ARAS, and CODAS methods. The most successful algorithm was determined using the Copeland method. According to the results, the XGBoost algorithm demonstrated the highest overall performance. The LSTM algorithm ranked second, followed by RF in third and SVR in fourth place. Additionally, the findings indicate that technical analysis variables play a decisive role in model performance, whereas macroeconomic and sentiment indicators provide limited contribution.

Keywords: Cryptocurrency, Price Prediction, Machine Learning, Extreme Gradient Boosting, Support Vector Machine, Random Forest, Long Short-Term Memory, MCDM

JEL: C45, C53, G17

Received : 04 August 2025
Revised : 11 September 2025
Accepted : 07 October 2025

Type : Research

Cite this article as: Korkmaz, Y. E., Altınırmak, S., & Karamaşa, Ç. (2025). Makine öğrenmesi yöntemleri ile kripto varlık fiyat tahmini ve en iyi yöntemin ÇKKV teknikleri ile belirlenmesi. *Business and Economics Research Journal*, 16(4), 463-492. <http://dx.doi.org/10.20409/berj.2025.477>

Copyright: © 2025 by the author(s). This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 (CC BY-NC) International License.

¹ PhD. Student, Anadolu University, Graduate School of Education, Department of Business Administration, Finance Program, Eskişehir, Türkiye, yunusemkorkmaz@gmail.com (Corresponding Author)

² Prof., PhD., Anadolu University, Eskişehir Vocational School, Department of Wholesale and Retail Sales, Eskişehir, Türkiye, saltinirmak@anadolu.edu.tr

³ Assoc. Prof., PhD., Anadolu University, Faculty of Economics and Administrative Sciences, Department of Business Administration, Eskişehir, Türkiye, ckaramasa@anadolu.edu.tr

1. Giriş

Kripto varlık kavramı, Satoshi Nakamoto'nun 2008 yılında yayımladığı teknik dokümanla gündeme gelmiş ve 2009 yılında Bitcoin'in ilk kez işlem görmesiyle birlikte finansal sistemde önemli bir dönüşümün başlangıcını oluşturmuştur (Nakamoto, 2008). Bitcoin'in artan popülaritesi, Ethereum ve Litecoin gibi diğer dijital varlıkların da piyasaya sürülmesine öncülük etmiş ve kripto varlık ekosisteminin hızla genişlemesini sağlamıştır (Lee ve Wang, 2024). 2025 yılı itibarıyla kripto varlıkların toplam piyasa değeri yaklaşık 3,9 trilyon ABD Dolarını aşarak küresel finans sistemi içindeki etkisini pekiştirmiştir. Bu gelişmeler, kripto varlıkları yalnızca alternatif bir yatırım aracı olmaktan çıkarıp, akademik araştırmaların odak noktalarından biri haline getirmiştir. Bu araştırma alanlarının başında, piyasa dinamiklerinin anlaşılması ve yatırım kararlarının desteklenmesi açısından önem arz eden fiyat tahmini gelmektedir. Fiyatların doğru tahmini özellikle, portföy yönetimi, riskten korunma ve algoritmik işlemler açısından stratejik önem taşımaktadır (Bouteska vd., 2024). Bununla birlikte, kripto varlıkların yüksek volatilitesi fiyat hareketlerinin öngörülmesini güçleştirmektedir. Örneğin, Bitcoin fiyatı 1 Ocak 2025'te yaklaşık 94 bin ABD Doları seviyesindeyken, Ocak ayında 104 bin ABD Dolarını aşmış, ancak Şubat 2025'te 84 bin ABD Doları seviyelerine kadar gerilemiştir. Bu tür sert dalgalanmalar, yatırım kararlarında belirsizliği artırmakta ve tahmin modellerine olan ihtiyacı daha da artırmaktadır.

Makine öğrenmesi (ML) yaklaşımları, bu belirsizlikleri aşmak için önemli fırsatlar sunmaktadır. Zaman serisi analizinde sıkça kullanılan geleneksel istatistiksel modeller (örneğin ARIMA), kripto piyasalarının doğrusal olmayan ve yüksek oynaklığa sahip yapısı karşısında sınırlı başarı gösterirken, ML tabanlı algoritmalar, karmaşık örüntüleri öğrenebilme ve doğrusal olmayan ilişkileri modelleyebilme kapasiteleriyle öne çıkmaktadır. Özellikle derin öğrenme temelli yöntemler, büyük veri kümeleri içinde gizli ilişkileri keşfedebilmekte ve uzun vadeli bağımlılıkları etkili biçimde yakalayabilmektedir. Bu modeller, piyasa koşullarındaki ani değişimlere uyum sağlayarak fiyat tahminlerinde daha yüksek doğruluk sunmaktadır. Bu bağlamda literatürdeki bulgular, ML ve derin öğrenme modellerinin kripto varlık fiyat tahmininde geleneksel yöntemlere kıyasla daha başarılı sonuçlar verdiğini göstermektedir (Bouteska vd., 2024; Hua, 2021; Latif vd., 2023; Omole ve Enke, 2024).

Kripto varlık piyasalarındaki fiyat hareketlerinin yalnızca rasyonel beklentilerle açıklanması mümkün değildir. Davranışsal finans bakış açısı; aşırı iyimserlik, belirsizlikten kaçınma, hataları yanlış değerlendirme, sürü davranışı, kumarbaz yanılışı, aşırı güven, kayıptan kaçınma, gibi irrasyonel davranışlarının yatırımcı kararını etkilediğini vurgulamaktadır (Doğan ve Evlimoğlu, 2022). Bununla birlikte piyasa mikro yapısı perspektifi; yüksek işlem yoğunluğu, likidite koşulları ve emir akımlarının fiyat aralıkları üzerindeki etkileri aracılığıyla anlık fiyat oluşumuna yön verdiğini ortaya koymaktadır (Kayalı ve Ünal, 2015). Kripto piyasalarının 7/24 açık ve merkeziyetsiz yapısı, bu davranışsal ve mikro yapısal unsurların etkisini daha da artırmaktadır. Dolayısıyla kripto varlık fiyatlarının doğru tahmini için yatırımcı psikolojisini ve piyasa işleyişine özgü mikro mekanizmaları dikkate alan modeller kurulmalı ve bu yaklaşımlar ampirik analizlere entegre edilmelidir.

Bu çalışmanın temel amacı, yatırımcı duyarlılığı, teknik analiz göstergeleri ve makroekonomik faktörleri entegre eden çok boyutlu bir veri seti kullanarak, makine öğrenmesi algoritmalarından destek vektör regresyonu (SVR), rastgele orman (RF), aşırı gradyan artırma (XGBoost) ve uzun kısa süreli bellek (LSTM) modelleri aracılığıyla kripto varlık fiyat tahmini yapılması ve bu modellerin tahmin performanslarının karşılaştırmalı olarak analiz edilmesidir. Kripto varlık piyasalarının yüksek volatiliteye, dinamik yapıya ve doğrusal olmayan ilişkilere sahip olması, bu piyasada doğru ve zamanında tahmin yapılmasını zorlaştırmakta, bu nedenle gelişmiş analiz yöntemlerinin kullanımını gerekli kılmaktadır.

Kripto varlık piyasalarının yüksek oynaklığı ve karmaşık yapısı, tek bir modelin tüm koşullarda en iyi performansı sunmasını güçleştirmektedir. Bu nedenle, farklı varsayımlara ve öğrenme mekanizmalarına dayanan birden fazla makine öğrenmesi algoritmasının birlikte değerlendirilmesi önem taşımaktadır. SVR, çekirdek fonksiyonları sayesinde yüksek boyutlu ve doğrusal olmayan veri setlerinde güçlü genelleme kabiliyeti sunmaktadır (Salb vd., 2021). RF, bootstrap (toplama) örnekleme ve rastgele öz nitelik seçimi sayesinde model çeşitliliği oluşturmakta ve aşırı öğrenme riskini azaltarak yüksek genelleme performansı sağlamaktadır (Lyu, 2022). XGBoost, gradyan artırma tekniği ile her adımda hatalı tahminleri düzelten zayıf

öğrenicilerden oluşan bir topluluk modeli kurarak yüksek doğruluk ve genelleme kapasitesi sunmaktadır (Ranjan vd., 2022). LSTM ise tekrarlayan sinir ağı mimarisi sayesinde zaman serilerindeki uzun vadeli bağımlılıkları etkili biçimde modelleyebilmekte ve başarılı tahmin performansları ile öne çıkmaktadır (Aggarwal vd., 2019). Bu çeşitlilik, farklı model varsayımlarının avantajlarını karşılaştırmalı olarak test etmeye ve daha sağlam sonuçlara ulaşmaya olanak tanımaktadır.

Bu kapsamda, 2018–2023 dönemine ait günlük frekansta verilerden oluşan çok boyutlu bir veri seti oluşturulmuş ve ilgili algoritmalarla tahmin modelleri geliştirilmiştir. Modellerin başarı düzeyleri, istatistiksel performans metrikleri olan belirleme katsayısı (R^2), ortalama mutlak hata (MAE), ortalama karesel hata (MSE) ve hata kareleri ortalamasının karekökü (RMSE) ile değerlendirilmiştir. Ayrıca, modellerin açıklayıcı değişkenleri ne ölçüde dikkate aldığı, SVR ve LSTM için permütasyon temelli değişken önem düzeyleri; RF ve XGBoost için ise gömülü değişken önem derecelendirme yöntemleri ile analiz edilmiştir. Ayrıca, farklı metriklerin bir arada değerlendirilmesi ile oluşturulan karar matrisi, çok kriterli karar verme (ÇKKV) yöntemleri kullanılarak analiz edilmiş ve böylece en iyi modelin seçimi sistematik, nesnel ve çok boyutlu bir bakış açısıyla gerçekleştirilmiştir.

Bu çalışmanın özgün katkısı, kripto varlık fiyatlarının tahminine yönelik olarak teknik analiz göstergeleri, yatırımcı duyarlılığı ve makroekonomik faktörleri birlikte içeren çok boyutlu bir veri yapısı kullanması ve bu veri setini farklı ML algoritmalarıyla test etmesidir. Literatürde çoğu çalışma bu veri gruplarından yalnızca birine odaklanmakta veya sınırlı kapsamda değerlendirme yapmaktadır. Ayrıca, kullanılan değişkenlerin fiyat tahminine etkisi model bazında detaylı olarak incelenmemekte, genel olarak model başarıları ile yetinilmektedir. Bu kapsamda, değişken önem analizleriyle hangi göstergelerin hangi modellerde daha belirleyici olduğu ortaya konmuş ve model performanslarının nesnel biçimde sıralanabilmesi için ÇKKV yöntemlerinden yararlanılması yönleriyle bu çalışma hem veri çeşitliliği hem yöntemsel bütünlüğü hem de karar destek işlevi ile literatüre anlamlı bir katkı sunmaktadır.

Bu çalışmanın ikinci bölümünde, kripto varlık fiyat tahmininde kullanılan ML modellerine ilişkin literatüre yer verilmiştir. Üçüncü bölümde, veri seti ve değişkenler açıklanmış, çalışmada kullanılan makine öğrenmesi yöntemleri ve performans metrikleri hakkında bilgi verilmiştir. Dördüncü bölümde, uygulama sonuçları model bazında raporlanmış, elde edilen bulgular karşılaştırmalı olarak tartışılmış ve istatistiksel performans metriklerine dayalı olarak oluşturulan karar matrisi üzerinden ÇKKV yöntemleri uygulanarak en başarılı makine öğrenmesi algoritması belirlenmiştir. Beşinci ve son bölümde ise, araştırma bulgularının genel değerlendirmesi yapılmış, literatürle olan tutarlılığı vurgulanmış ve gelecekteki araştırmalara yönelik öneriler sunulmuştur.

2. Literatür Taraması

Finansal piyasalarda hisse senetleri, emtialar, döviz kurları ve kripto varlıklar gibi çeşitli enstrümanların fiyat tahmini, yatırımcılar ve araştırmacılar için önemli bir çalışma alanı olmuştur. Geleneksel yöntemler (ARIMA, GARCH vb.) bu alanda uzun süre kullanılsa da finansal verilerin karmaşık ve doğrusal olmayan yapısı, ML gibi veri odaklı yaklaşımların öne çıkmasına neden olmuştur. ML yöntemleri, yalnızca kripto varlıklar için değil, hisse senedi, altın ve petrol gibi varlıkların tahmininde de yaygın biçimde kullanılmakta ve yüksek doğruluk oranlarıyla dikkat çekmektedir. Bu çalışmada, yalnızca kripto varlık fiyat tahmininde kullanılan ML yöntemlerine odaklanılmış ve ilgili literatür bu çerçevede ele alınmıştır.

Atlan vd. (2018), Bitcoin'in Türkiye borsalarındaki fiyatını tahmin etmeyi amaçlamışlardır. Çalışmada 2017-2018 yılları arasındaki günlük fiyat verileri kullanılmıştır. Ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve polinomsal eğri uydurma yöntemleri uygulanmıştır. ANFIS yöntemi daha başarılı sonuç vermiştir. Karasu vd. (2018), Bitcoin fiyatlarını tahmin etmek amacıyla çalışmışlarında kapanış, en yüksek ve en düşük fiyatlardan oluşan bir veri seti kullanmışlardır. Destek vektör makinesi (SVM) ve doğrusal regresyon (LR) yöntemleri karşılaştırılmış ve SVM modeli daha başarılı sonuçlar üretmiştir. Hitam ve İsmail (2018), kripto para fiyatlarını tahmin etmek üzere ML algoritmalarını karşılaştırmışlardır. Bitcoin, Ethereum, Litecoin, Stellar, Ripple ve Nem için 2013-2017 arası fiyat verileri kullanılmıştır. Yapay sinir ağları (YSA) ve SVM yöntemleri uygulanmıştır. SVM modeli genel olarak en iyi performansı göstermiştir. Phaladisailoed ve Numnonda (2018), Bitcoin fiyatlarını

tahmin etmeyi amaçlayan çalışmalarında, açılış, kapanış, en yüksek, en düşük fiyatlar ile işlem hacmi ve zaman damgası verilerini kullanmışlardır. Theil-Sen regresyonu, huber regresyonu, uzun kısa süreli bellek (LSTM) ve geçitli tekrarlayan birim (GRU) yöntemleri karşılaştırılmıştır. LSTM ve GRU yöntemleri daha başarılı bulunmuştur.

Atsalakis vd. (2019), Bitcoin'in fiyat yönünü tahmin etmeyi amaçlamışlardır. Günlük kapanış fiyatlarından oluşan veri seti kullanılmıştır. YSA, ANFIS ve nöro bulanık denetleyici tahmin sistemi (PATSON) yöntemleri uygulanmıştır. En iyi sonuç PATSON yöntemiyle elde edilmiştir. Mallqui ve Fernandes (2019), Bitcoin'in yön ve seviye tahminini gerçekleştirmeyi amaçlamışlardır. Fiyat, işlem hacmi, ücretler ve hash oranı gibi iç veriler ile petrol, altın ve endeks fiyatları gibi dış veriler kullanılmıştır. YSA, SVM, tekrarlayan sinir ağları (RNN) ve k-means yöntemleri uygulanmıştır. En iyi sonuç SVM ile elde edilmiştir. Rathan vd. (2019), Bitcoin fiyatlarını tahmin etmeyi amaçlayan çalışmalarında, açılış, kapanış, en yüksek, en düşük fiyatlar ile hacim ve ağırlıklı fiyat verilerini kullanmışlardır. Karar ağaçları (DT) ve LR yöntemleri uygulanmıştır. Her iki yöntem de başarılı bulunmuş, LR daha iyi sonuç vermiştir. Hitam vd. (2019), altı farklı kripto paranın fiyatlarını tahmin etmeyi hedeflemişlerdir. Günlük açılış, kapanış, en yüksek ve en düşük fiyatlar kullanılmıştır. YSA, SVM, parçacık sürü optimizasyonu ile optimize edilmiş SVM (SVM-PSO) yöntemleri karşılaştırılmıştır. En iyi sonuç SVM-PSO yöntemiyle elde edilmiştir. Zhao vd. (2019), Bitcoin, Ethereum ve Litecoin fiyatlarını tahmin etmeyi amaçlamışlardır. Fiyat ve hacim verileriyle birlikte Bollinger Bands (BB), MACD ve RSI gibi teknik göstergeler kullanılmıştır. Rastgele orman (RF), aşırı gradyan artırma (XGBoost) ve SVM yöntemleri uygulanmıştır. En başarılı sonuç SVM yöntemiyle elde edilmiştir. Aggarwal vd. (2019), Bitcoin fiyatlarını altın fiyatı ve sosyal medya duyarlılığına dayalı olarak tahmin etmeyi amaçlamışlardır. Altın fiyatı ve Twitter duyarlılık puanları kullanılmıştır. Evrişimli sinir ağı (CNN), LSTM ve GRU yöntemleri uygulanmıştır. LSTM modeli uzun vadeli bağımlılıkları en iyi tahmin eden yöntem olarak belirlenmiştir.

Yavuz vd. (2020), Bitcoin fiyatlarını tahmin etmeyi amaçladıkları çalışmalarında, açılış, kapanış, en yüksek, en düşük fiyatlar, hacim, maliyet, işlem hacmi ve toplam işlem sayısı verilerini kullanmışlardır. YSA yönteminin uygulandığı çalışmada, yüksek doğrulukla başarılı tahmin sonuçları elde edilmiştir. Atlan vd. (2020), kripto varlıkları çevrim içi ortamda tahmin etmeyi hedeflemişlerdir. Fiyat verileri kullanılarak farklı dönem uzunluklarıyla tahminler yapılmıştır. ANFIS, YSA, polinomsal eğri uydurma ve LSTM yöntemleri uygulanmıştır. En başarılı sonuçlar ANFIS yöntemiyle ve günlük veriyle elde edilmiştir. Chen vd. (2020), Bitcoin fiyatlarını ML algoritmalarıyla tahmin etmeyi amaçlamışlardır. Blok boyutu, hash oranı, işlem sayısı, mempool büyüklüğü, piyasa değeri, Google ve Baidu arama hacmi gibi zincir, medya ve piyasa verileri kullanılmıştır. LR, doğrusal diskriminant analizi, RF, XGBoost, karesel diskriminant analizi, SVM ve LSTM yöntemleri uygulanmıştır. SVM yöntemi en iyi makine öğrenmesi modeli olarak belirlenmiştir. Chowdhury vd. (2020), kripto varlıkların fiyat tahminini yapmayı amaçlamışlardır. Açılış, kapanış, en yüksek ve en düşük fiyatlar, işlem hacmi, piyasa değeri ve işlem tarihleri kullanılmıştır. Gradyan artırılmış ağaçlar, YSA, topluluk öğrenimi ve en yakın komşu (K-NN) yöntemleri uygulanmıştır. En başarılı sonuç topluluk öğrenimi yöntemiyle elde edilirken, K-NN en düşük performansı göstermiştir. Aggarwal vd. (2020), Bitcoin fiyatlarının çeşitli vadelerde öngörülüp öngörülemediğini araştırmışlardır. Günlük fiyat verileri kullanılmıştır. SVM algoritması uygulanmış ve Bitcoin fiyatlarının kısa, orta ve uzun vadeli olarak tahmin edilebildiği görülmüştür.

Çağlar ve Yavuz (2021), olumlu ve olumsuz haberler ile cüzdan sayısı, işlem sayısı ve zorluk derecesi gibi blok zincir verileri kullanarak Bitcoin fiyatını tahmin etmişlerdir. YSA yönteminin kullanıldığı çalışmada, haberlerin etkisi bulunmamış, zincir verileriyle yüksek ilişki tespit edilmiştir. Guo vd. (2021), Bitcoin fiyatı için yeni bir model (WT-CATCN) önermişlerdir. Günlük fiyat, Google arama eğilimleri ve borsa değişkenleri kullanılmıştır. WT-CATCN yöntemi, ARIMA, CNN, çok katmanlı algılayıcı (MLP), LSTM ve diğer yöntemlerle karşılaştırılmıştır. Önerilen model en iyi performansı göstermiştir. Liu vd. (2021), Bitcoin fiyatını etkileyen değişkenleri dikkate alarak tahmin modeli geliştirmişlerdir. Piyasa, blok zincir, teknik ve makroekonomik 40 değişken kullanılmıştır. Yığılmış gürültü giderici otomatik kodlayıcı (SDAE) yöntemi, geri yayılım sinir ağı (BPNN) ve SVM ile karşılaştırılmıştır. En başarılı sonuç SDAE ile elde edilmiştir.

Karğın vd. (2022), Bitcoin fiyat tahmini amacıyla LSTM yöntemini kullanmışlardır. 2018-2022 arası fiyat verileri ile model eğitilmiş ve test edilmiştir. LSTM ile yapılan tahminlerin, gerçek fiyatlarla uyumlu olduğu görülmüştür. Budak ve Aytekin (2022), çeşitli kripto varlıkların kısa vadeli fiyatlarını tahmin etmeyi

amaçlamışlardır. LR yöntemi ve fiyat verileri kullanılmıştır. En başarılı tahminler yedi günlük dönemlerde elde edilmiştir. Ranjan vd. (2022), Bitcoin fiyatlarını günlük tahmin etmeyi hedeflemişlerdir. Lojistik regresyon, doğrusal ve karesel diskriminant analizi, RF, XGBoost, en yakın komşu (K-NN), DT ve SVM yöntemleri uygulanmıştır. Beş dakikalık fiyat tahmini için XGBoost en başarılı model olmuştur. Erfanian vd. (2022), Bitcoin fiyatını etkileyen makroekonomik, teknik ve blok zincir göstergeler ile analiz gerçekleştirmişlerdir. Piyasa değeri, işlem sayısı, zorluk derecesi gibi veriler kullanılmıştır. Sıradan en küçük kareler (OLS), topluluk öğrenme, SVM ve MLP yöntemleri uygulanmıştır. SVM yöntemi diğer modellerden daha başarılı bulunmuştur. Basher ve Sadorsky (2022), makroekonomik ve teknik değişkenlerin Bitcoin ve altın fiyatlarını tahmin etmedeki önemini incelemişlerdir. Günlük fiyat, RSI, MACD, ADX, VIX, OVX gibi teknik göstergeler ile faiz ve enflasyon verileri kullanılmıştır. RF ve torbalama yöntemleri uygulanmıştır. Sonuç olarak teknik göstergelerin Bitcoin fiyat yönü için önemli tahmin ediciler olduğuna ulaşılmıştır.

Gradojevic vd. (2023), Bitcoin fiyatlarını tahmin etmek için çeşitli duyarlılık ve teknik göstergeleri analiz etmiştir. Saatlik ve günlük fiyatlar ile Google trendi, hacim ve korku ve açgözlülük endeksi kullanılmıştır. YSA, RF ve SVM yöntemleri uygulanmıştır. RF modeli en doğru sonuçları vermiştir. Penmetsa ve Vemula (2023) Bitcoin, Ethereum ve Litecoin fiyatlarını tahmin etmek için tarihsel fiyat verileriyle birlikte teknik göstergeleri kullanarak LSTM ve transformer tabanlı derin öğrenme modelleri geliştirmişlerdir. 2019–2023 dönemine ait günlük açılış, kapanış, en yüksek ve en düşük fiyat verilerine ek olarak işlem hacmi, RSI, MACD, sinyal hattı, histogram ve BB göstergeleri kullanılmıştır. Karşılaştırma sonuçları, teknik göstergelerin tüm modellerin doğruluğunu artırdığını ve özellikle transformer modelinin en düşük MAE, RMSE ve MAPE değerleriyle en başarılı tahminleri sağladığını göstermiştir.

Labba Khaniki ve Manthouri (2024) Bitcoin, Ethereum ve Litecoin fiyatlarını tahmin etmek için teknik göstergelerle (RSI, basit ve üssel hareketli ortalamalar, BB ve emtia kanal endeksi (CCI)) zenginleştirilmiş verileri kullanan Performer (FAVOR+) tabanlı transformer ile çift yönlü uzun kısa süreli bellek (BiLSTM) katmanını birleştiren bir derin öğrenme modeli geliştirmişlerdir. 2018–2024 dönemine ait günlük ve saatlik verilerle yapılan analizde, teknik göstergelerin trend, momentum ve volatilité bilgisi sağlayarak modelin karmaşık ilişkileri yakalamasına ve tahmin doğruluğunun artmasına önemli katkı sunduğu; Performer + BiLSTM modelinin ise LSTM, GRU, BiLSTM ve klasik transformer yöntemlerine göre en düşük MSE, RMSE ve MSLE ile en yüksek R^2 değerlerini elde ettiği belirlenmiştir. Hafid vd. (2024), Bitcoin fiyatlarını tahmin etmek için XGBoost yöntemini kullanmışlardır. Çalışmada 1 Şubat 2021–1 Şubat 2022 dönemine ait 15 dakikalık kapanış fiyatları, açılış, en yüksek, en düşük fiyatlar ve hacim gibi piyasa verileri ile çok sayıda teknik gösterge kullanılmıştır. Bu göstergeler arasında üssel hareketli ortalamalar, RSI, momentum, MACD, stokastik osilatör ve ROC yer almaktadır. Sonuçlar, XGBoost modelinin en düşük MAE ve RMSE ve en yüksek R^2 değerlerini sağlayarak Bitcoin fiyat tahmininde yüksek doğruluk sunduğunu göstermiştir. Lee ve Xu (2024), Bitcoin fiyat hareketlerini kısa vadede tahmin etmek için teknik göstergelerle (stokastik osilatör, RSI ve MACD) zenginleştirilmiş verileri kullanan dikkat mekanizmalı GRU modeli geliştirmişlerdir. 2018–2024 dönemine ait günlük açılış, kapanış, en yüksek, en düşük fiyat ve hacim verileriyle yürütülen çalışmada, teknik göstergelerin trend, momentum ve volatilitéyi temsil ederek modelin karmaşık ilişkileri yakalamasına katkı sağladığı belirtilmiştir. Karşılaştırma sonuçları, göstergesiz modele kıyasla MACD eklenmesiyle doğruluğun %72’den %75’e yükseldiğini; RSI’nin olumlu, stokastik osilatörün ise sınırlı etki yaptığını ortaya koymuştur. Böylece dikkat mekanizmalı GRU modeli, özellikle MACD desteğiyle en yüksek doğruluk ve güçlü genelleme başarısı göstermiştir.

Islam vd. (2025), kripto varlık fiyat hareketlerini tahmin etmek amacıyla ML tabanlı modeller geliştirmişlerdir. Çalışmada açılış, kapanış, en yüksek ve en düşük fiyatlar ile işlem hacmi ve teknik göstergeler (basit ve üssel hareketli ortalamalar, RSI, BB) kullanılmıştır. Lojistik regresyon, RF ve XGBoost modelleri karşılaştırılmış; en yüksek doğruluk oranı %56,03 ile lojistik regresyon modeli tarafından elde edilmiştir. Sonuçlar, teknik göstergelerin ML modellerinin tahmin gücünü artırdığını ve kripto para fiyat yönünün tahmininde özellikle lojistik regresyonun öne çıktığını göstermiştir. Ben Hamadou vd. (2025), yatırımcı duyarlılığının Bitcoin getirilerinin tahminine etkisini incelemişlerdir. Çalışmada 2014–2022 dönemine ait günlük veriler kullanılmış ve dönem, Covid-19 öncesi ve Covid-19 dönemi olarak ikiye ayrılmıştır. Bitcoin’in kapanış fiyatı, işlem hacmi, piyasa değeri, Parkinson volatilitesi, zincir verileri, finansal stres endeksi (FSI),

EPU, S&P500, petrol ve altın fiyatları ile Google trend verilerine dayalı özgün bir yatırımcı duyarlılığı endeksi modele dâhil edilmiştir. Çalışmada tek boyutlu evrişimli sinir ağı (1D-CNN), çift yönlü uzun kısa süreli bellek (BLSTM) ve SVR kullanılmıştır. Bulgular, yatırımcı duyarlılığının her iki dönemde de en etkili değişken olduğunu; EPU ve FSI'nin öneminin Covid-19 sırasında azaldığını; S&P500 ve altının ise güçlü öngörü gücünü koruduğunu göstermiştir.

Sonuç olarak, literatürde kripto varlık fiyatlarının tahmini için pek çok ML yöntemi (SVR, LSTM, GRU, YSA, RF, XGBoost, LR, ANFIS vb.) kullanılmıştır. Bazı çalışmalarda yalnızca fiyat ve hacim gibi teknik veriler yer alırken; Aggarwal vd. (2019), Chen vd. (2020), Liu vd. (2021), Erfanian vd. (2022), Basher ve Sadorsky (2022), Nagula ve Alexakis (2022), Gradojevic vd. (2023), Penmetsa ve Vemula (2023), Labbaf Khaniki ve Manthouri (2024), Hafid vd. (2024), Lee ve Xu (2024), İslam vd. (2025), Ben Hamadou vd. (2025) gibi araştırmacılar tarafından yapılan çalışmalarda modeller, yatırımcı duyarlılığı, makroekonomik faktörler ve teknik göstergeleri içerecek şekilde daha kapsamlı olarak tasarlanmıştır.

Kripto varlık fiyatlarının tahminine yönelik literatürde, veri türleri genellikle birbirinden bağımsız biçimde ele alınmakta; teknik göstergeler, makroekonomik veriler veya yatırımcı duyarlılığı göstergeleri çoğu zaman tek başına kullanılmaktadır. Bu durum, piyasanın çok boyutlu yapısını yeterince yansıtamamakta ve tahmin modellerinin bütüncül doğruluk düzeyini sınırlayabilmektedir. Ayrıca, birçok çalışmada yalnızca model performansları karşılaştırılmakta, kullanılan değişkenlerin tahmin sürecine katkı düzeyleri model bazında detaylı şekilde incelenmemektedir. Bu bağlamda, mevcut çalışma teknik analiz, yatırımcı duyarlılığı ve makroekonomik verileri birlikte içeren çok boyutlu bir veri seti ile gerçekleştirilmiştir. Ayrıca değişken önem analizleriyle her bir göstergenin model performansına katkısını ayrı ayrı ortaya koymaktadır. Elde edilen sonuçların nesnel biçimde değerlendirilmesi için ÇKKV tekniklerinden yararlanılması da çalışmayı benzerlerinden ayıran önemli bir yaklaşımdır. Bu yönüyle araştırma hem teorik literatüre katkı sağlamakta hem de yatırım süreçlerinde yatırımcılara rehberlik edebilecek bütüncül bir çerçeveye sunmaktadır.

3. Materyal ve Yöntem

3.1. Materyal

Bu araştırmanın evrenini kripto varlık piyasası oluşturmaktadır. Çalışmada, 1 Ocak 2018- 31 Aralık 2023 tarihleri arasındaki günlük veriler kullanılmış olup, piyasa değeri en yüksek beş kripto varlık olan Bitcoin (BTC), Ethereum (ETH), Binance Coin (BNB), Ripple (XRP) ve Dogecoin (DOGE) analize dahil edilmiştir.

Veri seti tarih aralığı hem boğa hem de ayı piyasası döngülerini içermesi, Covid-19 pandemisi, 2022 faiz artış döngüsü ve kripto sektöründeki önemli regülasyon ve siber saldırılar gibi makroekonomik ve sektörel şokları barındırması nedeniyle farklı piyasa koşullarını temsil edebilecek zengin ve çeşitli bir örneklem sunmaktadır. Ayrıca, günlük veri frekansı, kısa dönemli volatilitiyi ve ani fiyat hareketlerini yakalayarak modellerin farklı piyasa koşullarında genelleme kabiliyetinin test edilmesine olanak tanımaktadır.

Ayrıca veri seti, 01.01.2018 – 31.12.2022 tarihleri arasını eğitim, 01.01.2023 – 31.12.2023 tarihleri arasını ise test verisi olarak ayıracak şekilde düzenlenmiştir. Bu sayede model yalnızca geçmiş dönem verileriyle eğitilmiş ve geleceğe dair hiç görmediği bir veri setinde test edilerek veri sızıntısı riski önlenmiştir. Aşırı öğrenme (overfitting) riskini azaltmak amacıyla, eğitim ve test verileri zaman bazlı olarak ayrılmış, zaman serisine uygun çapraz doğrulama yöntemi ile hiperparametreler optimize edilmiş ve makine öğrenmesi modellerinde düzenleme (regularizasyon) parametreleri dikkatle seçilmiştir. Son olarak, model performansı eğitim verisinde değil, ayrılmış test verisinde değerlendirilmiş ve böylece genelleme başarısı güvence altına alınmıştır.

Bu araştırma belirli varsayımlar ve sınırlılıklar dahilinde yürütülmüştür. Öncelikle, tahmin değişkeni olarak yalnızca günlük kapanış fiyatı kullanılmış, fiyatın diğer anlık özellikleri (örneğin yüksek/düşük fiyat) modelleme dışında bırakılmıştır. Açıklayıcı değişkenler; fiyat hareketleri, teknik analiz göstergeleri, makroekonomik göstergeler ve yatırımcı duyarlılığı göstergeleri ile sınırlandırılmış ve Tablo 1'de yer verilen toplam 27 değişken analize dahil edilmiştir. Piyasa üzerinde etkili olabilecek zincir verileri (işlem hacmi, aktif cüzdan sayısı, hash oranı vb.), düzenleyici kararlar, haber metinleri, sosyal medya içerikleri (X, Reddit, Ekşi

Sözlük vb.), forum analizleri, blog yorumları ve YouTube kullanıcı tepkileri gibi alternatif veri türleri kapsam dışında tutulmuştur. Ayrıca, ABD Dolarına sabitlenmiş stable coinler ve 2018 sonrasında piyasaya giren kripto varlıklar çalışmaya dahil edilmemiştir.

Tablo 1. Araştırmada Kullanılan Değişkenler ve Literatürdeki Kaynaklar

Değişkenler	Sembol	Grup	Referanslar
Açılış Fiyatı	Open	Kripto Varlık Değişkenleri	Hitam ve İsmail (2018), Phaladisailoed ve Numnonda (2018), Hitam vd. (2019), Zhao vd. (2019), Rathan vd. (2019), Mallqui ve Fernandes (2019)
Kapanış Fiyatı	Close		Hitam ve İsmail (2018), Phaladisailoed ve Numnonda (2018), Karasu vd. (2018), Hitam vd. (2019), Zhao vd. (2019), Rathan vd. (2019), Atsalakis vd. (2019), Mallqui ve Fernandes (2019), Aggarwal vd. (2019)
En Yüksek Fiyat	High		Hitam ve İsmail (2018), Phaladisailoed ve Numnonda (2018), Karasu vd. (2018), Hitam vd. (2019); Zhao vd. (2019), Rathan vd. (2019), Mallqui ve Fernandes (2019)
En Düşük Fiyat	Low		Hitam ve İsmail (2018), Phaladisailoed ve Numnonda (2018), Karasu vd. (2018), Hitam vd. (2019), Zhao vd. (2019), Rathan vd. (2019), Mallqui ve Fernandes (2019)
Hacim (USD)	Volume		Phaladisailoed ve Numnonda (2018), Zhao vd. (2019), Rathan vd. (2019), Gradojevic vd. (2023)
Göreceli Güç Göstergesi	RSI	Teknik Analiz Göstergeleri	Zhao vd. (2019), Basher ve Sadorsky (2022), Gradojevic vd. (2023), Penmetsa ve Vemula (2023), Labbaf Khaniki ve Manthouri (2024), Hafid vd. (2024), Lee ve Xu (2024), Islam vd. (2025),
Hareketli Ortalama Çapraz Sapma	MACD, MACD_Signal		Zhao vd. (2019), Basher ve Sadorsky (2022), Gradojevic vd. (2023), Penmetsa ve Vemula (2023), Hafid vd. (2024), Lee ve Xu (2024),
Stokastik Osilatör (Yavaş, Hızlı)	Yavaş_%D, Hızlı_%D, Hızlı_%K		Basher ve Sadorsky (2022), Hafid vd. (2024), Lee ve Xu (2024),
İlerleme-Düşüş Çizgisi	ADX		Basher ve Sadorsky (2022)
Fiyat Değişim Oranı	ROC10, ROC50		Basher ve Sadorsky (2022), Gradojevic vd. (2023), Hafid vd. (2024),
Denge Hacmi	OBV		Basher ve Sadorsky (2022), Gradojevic vd. (2023)
50 Günlük Hareketli Ortalama	MA50		Basher ve Sadorsky (2022), Gradojevic vd. (2023), Labbaf Khaniki ve Manthouri (2024), Islam vd. (2025)
200 Günlük Hareketli Ortalama	MA200		Basher ve Sadorsky (2022), Gradojevic vd. (2023), Labbaf Khaniki ve Manthouri (2024), Islam vd. (2025)
Williams Birikim ve Dağılımı	WAD		Basher ve Sadorsky (2022), Gradojevic vd. (2023)
Spot Altın Fiyatı	XAU	Makroekonomik Göstergeler	Aggarwal vd. (2019), Chen vd. (2020), Ranjan vd. (2022), Ben Hamadou vd. (2025)
Ham Petrol Vadeli İşlem Fiyatı	WTI		Liu vd. (2021), Erfanian vd. (2022), Ben Hamadou vd. (2025)
Faiz Oranları (ABD FED)	FED		Basher ve Sadorsky (2022)
Enflasyon	CPI		Basher ve Sadorsky (2022)
ABD Dolar Endeksi	DXY		Liu vd. (2021)
Ekonomi Politikası Belirsizliği	EPU		Basher ve Sadorsky (2022), Ben Hamadou vd. (2025)
CBOE Hisse Senedi Belirsizliği	VIX	Yatırımcı Duyarlılığı Göstergeleri	Basher ve Sadorsky (2022)
CBOE Petrol Piyasası Belirsizliği	OVX		Basher ve Sadorsky (2022)
Korku ve Açgözlülük Endeksi	FGI		Gradojevic vd. (2023)
Google Arama Eğilimleri	GTRENDS		Chen vd. (2020), Guo vd. (2021), Liu vd. (2021), Ranjan vd. (2022), Gradojevic vd. (2023), Ben Hamadou vd. (2025)

Bu çalışmada kullanılan değişkenler farklı kaynaklardan elde edilmiştir. Kripto varlık değişkenleri investing.com, Yahoo Finance ve Binance.com üzerinden edilmiş olup, teknik göstergeler değişkenleri kripto varlık verileri kullanılarak hesaplanmıştır. EPU endeksine ait veriler <https://www.policyuncertainty.com/> web sitesinden, ABD faiz oranı ve CPI Fred Economic Data (<https://fred.stlouisfed.org/>) sitesinden, VIX ve petrol OVX değişkenleri <https://www.cboe.com/> sitesinden, XAU, WTI ve DXY investing.com sitesinden, Google arama eğilimleri <https://trends.google.com/> adresinden, Bitcoin korku ve açgözlülük endeksi ise <https://alternative.me/crypto/fear-and-greed-index/> adresinden temin edilmiştir.

3.2. Yöntem

Bu çalışma, çok aşamalı bir analiz süreciyle yapılandırılmıştır. İlk aşamada, kripto varlık fiyatları, teknik analiz göstergeleri, makroekonomik değişkenler ve yatırımcı duyarlılığına ilişkin veriler çeşitli açık kaynaklardan temin edilmiştir. İkinci aşamada, farklı kaynaklardan elde edilen veriler birleştirilerek zaman serisi formatına uygun hale getirilmiş ve eksik gözlemler düzeltilerek model eğitimi ve testi için veri seti, 01.01.2018 ile 31.12.2022 tarihleri arası eğitim; 01.01.2023 ile 31.12.2023 tarihleri arası ise test verisi olarak ayrılmıştır. Üçüncü aşamada, değişkenlerin farklı ölçeklerde olmasının modeller üzerindeki etkisini azaltmak amacıyla min-max normalizasyon ve standart scaler yöntemi kullanılarak tüm değişkenler aynı ölçeğe getirilmiştir.

Dördüncü aşamada, tahmin modellerinin oluşturulması sürecinde SVM, RF, XGBoost ve LSTM algoritmaları kullanılarak her bir model için eğitim ve tahmin işlemleri gerçekleştirilmiştir. Beşinci aşamada, model başarımı istatistiksel hata metrikleri olan R^2 , MAE, MSE ve RMSE ile değerlendirilmiştir.

Altıncı aşamada, değişkenlerin modele katkı düzeylerini belirlemek üzere değişken önem analizleri yapılmıştır. Bu kapsamda; SVR ve LSTM modelleri için permütasyon yöntemi kullanılmış, RF ve XGBoost algoritmalarında ise gömülü önem derecelendirme yaklaşımları tercih edilmiştir.

Son aşamada, ÇKKV yöntemleri aracılığıyla modeller performanslarına göre sıralanmıştır. Bu bağlamda, kriter ağırlıkları kriterler arası korelasyon yoluyla kriterlerin önem tespiti (CRITIC) yöntemi ile belirlenmiş, alternatiflerin sıralanmasında ise ideal çözüme benzerliğe göre sıralama tekniği (TOPSIS), eklemeli nispi değerlendirme (ARAS) ve birleştirilebilir uzaklık tabanlı değerlendirme (CODAS) yöntemleri kullanılmış ve nihai sıralama ise Copeland yöntemiyle oluşturulmuştur.

Kullanılan makine öğrenmesi algoritmaları ve ilgili literatüre Tablo 2’de yer verilmiştir.

Tablo 2. Kullanılan Yöntemler ve Literatürdeki Referanslar

Yöntemler	Referanslar
Aşırı Gradyan Artırma (XGBoost)	Zhao vd. (2019), Chen vd. (2020), Ranjan vd. (2022), Chowdhury vd. (2020)
Destek Vektör Makineleri (SVM)	Hitam ve İsmail (2018), Karasu vd. (2018), Hitam vd. (2019), Mallqui ve Fernandes (2019), Aggarwal vd. (2020), Chen vd. (2020), Salb vd. (2021), Ranjan vd. (2022), Gradojevic vd. (2023)
Uzun Kısa Süreli Bellek (LSTM)	Aggarwal vd. (2019), Altan vd. (2020), Guo vd. (2021), Karğın vd. (2022), Phaladisailoed ve Numnonda (2018)
Rastgele Ormanlar (RF)	Zhao vd. (2019), Chen vd. (2020), Basher ve Sadorsky (2022), Ranjan vd. (2022), Gradojevic vd. (2023)

3.2.1. SVM

Destek vektör makineleri (SVM), Vapnik ve Cortes tarafından 1995 yılında geliştirilen bir makine öğrenmesi teknolojisidir. SVM, hem regresyon hem de sınıflandırma analizleri için kullanılan popüler bir denetimli öğrenme modelidir. Algoritma, kategorileri ayırt eden iki sınıf arasında düz bir çizgi oluşturarak analizi gerçekleştirmektedir (Lyu, 2022).

SVM; maksimum marj hiper düzlemleri, destek vektörleri, konveks (çıkıntılı) yapılar, gevşeklik değişkenleri ve Mercer çekirdeği (kernel) gibi kavramları içermektedir. Bu teknik teori, özellikle küçük, basit,

yüksek boyutlu ve doğrusal olmayan problemler için oldukça idealdir ve makine öğrenimi ile genelleme açısından yüksek bir kapasiteye sahiptir (Salb vd., 2021).

Bu çalışmada, SVM'in regresyon uyarlaması olan "destek vektör regresyonu" (SVR) yöntemi kullanılmıştır. SVR modeli, modelin yakın çevresindeki belirli bir eşik (ϵ) içinde kalan örnekleri göz ardı ettiğinden, eğitim verilerinin yalnızca seçili bir kısmını dikkate almaktadır. Veriler doğrusal olmayan ancak ayrılabilir özellikler gösterdiğinde, çekirdek (kernel) yöntemi faydalı olmaktadır. Bağımsız değişkenler uzayında doğrusal olarak çözilemeyen birçok regresyon problemi, uygun bir dönüştürme ile daha yüksek boyutlu bir öznitelik uzayına ($x \mapsto \phi(x)$) aktarılabilen, bu da etkili bir regresyonu mümkün kılmaktadır. SVR çerçevesinde amaç, gözlenen bir değer t için gerçek bir çıktı y 'yi tahmin etmektir (Menendez-García vd., 2024).

Bu çalışmada, hiperparametre optimizasyonu amacıyla GridSearchCV yöntemi tercih edilmiştir. "C", "gamma" ve "kernel" parametreleri için farklı kombinasyonlar oluşturularak 5 katlı çapraz doğrulama ile test edilmiş, böylece en uygun parametre seti belirlenmiştir. Tablo 3'te sunulan hiperparametre sonuçları, farklı kripto varlık birimlerinde elde edilen en iyi parametrelerin birbirinden farklı olduğunu göstermektedir. Bu durum, farklı kripto varlık birimlerinin fiyat yapılarının modele duyarlılığının değiştiğini ve optimal hiperparametrelerin varlık bazında farklılık gösterebildiğini ortaya koymaktadır.

Tablo 3. SVR Modeli için Yapılan Hiperparametre Optimizasyonu Sonuçları

Kripto varlık	C	Gamma	Kernel
Bitcoin	100	0.01	linear
Ethereum	100	0.01	linear
Ripple	0.1	0.1	linear
BNB	100	0.01	linear
Dogecoin	0.1	0.1	linear

SVR ile yapılan tahminlerin genel performans değerlendirmesi yapıldıktan sonra modelin karar mekanizmasında hangi değişkenlerin ne düzeyde etkili olduğunu belirlemek amacıyla permütasyon önem analizi uygulanmıştır.

3.2.2. RF

RF algoritması, Leo Breiman tarafından 2001 yılında geliştirilmiş ve sınıflandırma ile regresyon problemlerine yönelik güçlü bir topluluk öğrenme yöntemidir. Bu yöntem, birçok karar ağacının bir araya getirilmesiyle oluşturulmakta ve her bir ağaç, bootstrap (toplama) yöntemiyle oluşturulan rastgele örneklem kümeleri üzerinden inşa edilmektedir. Her ağacın büyüme sürecinde, düğümlerde tüm öznitelikler arasından en iyi ayrımı aramak yerine, rastgele seçilen özniteliklerin alt kümesinden en iyi bölünme tercih edilmektedir. Bu sayede modelde çeşitlilik sağlanmakta ve aşırı öğrenme riski azaltılmaktadır (Lyu, 2022).

Karar ağaçları, öznitelik uzayını yinelemeli olarak bölmek için ağaç yapısını benimsemekte ve her bir düğüm, saflığı maksimize etmek amacıyla bölünmeye devam etmektedir. Bu süreç, düğümlerin yalnızca tek sınıfa ait örnekler içerdiği noktaya kadar sürmektedir. Bu tamamen saf düğümler yaprak düğümler olarak adlandırılmaktadır. Bir test örneği karar ağacına verildiğinde, bu örnek ağacın dallarından yaprak düğüme kadar izlenmekte ve böylece bir sınıf etiketi atanabilmektedir. Bootstrap işlemi uygulanarak, her ağacın büyümesinde kullanılacak öznitelik uzayının rastgele bir alt kümesi belirlenmektedir (Chen vd., 2020).

Hedef bilgi her bir ağaç modeline girdi olarak verildiğinde, ağaç modelleri doğaları gereği birbirinden bağımsız şekilde kendi sonuçlarını üretmektedir. Ormanın çıktısı, bu sonuçların çoğunluk kararı ile belirlenmektedir ya da bu çıktıların aritmetik ortalaması alınmaktadır. Bu tahminde, sınıflandırma ağaçlarından oluşan bir RF modeli, oy birliğiyle verilmiş bir karar üretirken, regresyon ağaçlarından oluşan bir RF modeli ise aritmetik ortalama ile tahmin yapmaktadır (Mbedzi, 2022).

Bu çalışmada RF algoritması, 100 karar ağacından oluşan bir topluluk modeli olarak eğitilmiş ve test verisi üzerinde tahmin gerçekleştirilmiştir. Model performansı R^2 , MAE, MSE ve RMSE metrikleri ile

değerlendirilmiştir. Ayrıca modelin karar mekanizmasında hangi değişkenlerin daha etkili olduğunu belirlemek amacıyla, RF algoritmasının sunduğu özellik önem düzeyleri hesaplanmıştır.

3.3.3. XGBoost

XGBoost, karar ağacının geliştirilmiş bir versiyonudur. Bu algoritmanın amacı ağaçların büyütülmesi için gereken süreyi en aza indirmek ve optimizasyon sürecini hızlandırmaktır (Chen vd. 2020).

XGBoost, karar ağaçlarını yinelemeli olarak oluşturmaktadır. Yüksek hataya sahip her ağaç, zayıf öğrenici olarak adlandırılmaktadır. Gradyan artırma tekniği, başlı başına tatmin edici performansa sahip olmayan basit bir ilk ağaç oluşturarak başlamaktadır. Daha sonra, bu ilk ağacın başaramadığı tahminleri yapacak şekilde eğitilen başka bir ağaç oluşturulmakta ve bu ağaç da zayıf bir öğrenicidir. Bu süreç, her biri bir öncekini düzelten daha fazla zayıf öğrenici inşa edilerek sırayla devam etmekte ve oluşturulacak ağaç sayısı gibi bir durdurma koşuluna ulaşılan kadar devam etmektedir (Ranjan vd., 2022).

Kripto varlıkların fiyat tahmininde XGBoost modeli kullanılırken, tüm değişkenler StandardScaler ile ölçeklendirilmiştir. Modelin eğitimi için XGBRegressor sınıfı kullanılarak 100 tahmin ağacı ve 0,1 öğrenme oranı ile yapılandırılmış bir XGBoost modeli geliştirilmiştir. Eğitim sonrası model, test verisi üzerinde tahminler üretmiş ve performansı R^2 , MAE, MSE ve RMSE gibi hata metrikleriyle değerlendirilmiştir. Ayrıca modelin karar sürecinde hangi değişkenlerin daha belirleyici olduğunu analiz edebilmek amacıyla özellik önem analizi gerçekleştirilmiştir. Bu analizde, XGBoost modelinin içsel `get_score()` fonksiyonu ile değişkenlerin F score değerleri hesaplanmış ve en önemli özellikler sıralanarak görselleştirilmiştir.

3.3.4. LSTM

LSTM, uzun kısa süreli bellek bloklarından oluşan RNN yapısının bir varyasyonudur. Standart RNN'lerin sahip olduğu gradyan kaybolması sorununa LSTM ile çözüm bulunmuştur. LSTM ağı, hücre durumu ve gizli durum olmak üzere iki duruma ve giriş, çıkış ve unutma kapısı olmak üzere üç kapiya sahiptir. Bu sayede, ne zaman hatırlanacağına ve unutulacağına karar vererek uzun vadeli bağımlılıkları öğrenme yeteneğine sahip olmaktadır (Aggarwal vd., 2019).

LSTM yapısına göre işlemler şu şekildedir: Unutma kapısı (F_t), bellek hücresi durumuna bilgiyi seçici olarak eklemekte ya da çıkarmaktadır. Ağ, öncelikle ne kadar bilginin atılması gerektiğine karar vererek başlamaktadır. Bu işlem için bilgi önce unutma kapısından geçirilmekte ve buna ek olarak, önceki LSTM hücresinden gelen çıktı ($H_t - 1$), yani gizli durum da kullanılmaktadır. Daha sonra, önceki hücre durumuna ($C_t - 1$) eklenip saklanması gereken yeni bilgiler iki adımda gerçekleşmektedir. İlk olarak, giriş kapısı hangi değerlerin güncellenmesi gerektiğine karar vermektedir. Tanh fonksiyonunun çıktısı, önceki hücre durumunu güncelleyerek, aday değerler kümesi (C_t) oluşturmaktadır. Bu da yeni bellek hücresi durumunu (C_t) oluşturmaktadır. Son olarak, yeni bellek hücresi durumu ve (O_t)' den gelen bilgi kullanılarak, çıktı kapısından sonuç elde edilmektedir (Daniels, 2022).

Kripto varlıkların fiyat tahmininde LSTM modeli kullanılırken, tüm değişkenler MinMaxScaler ile ölçeklendirilmiştir. LSTM mimarisi, 60 zaman adımı içeren üç boyutlu girdi yapısında oluşturulmuş ve iki LSTM katmanı, Dropout katmanları ve tam bağlantılı çıkış katmanlarından oluşacak şekilde yapılandırılmıştır. Model, adam optimizasyon algoritması ve MSE kayıp fonksiyonu ile derlenmiş; erken durdurma mekanizmasıyla aşırı öğrenme riski azaltılmıştır. Ayrıca, fiyat tahmininde hangi değişkenlerin ne düzeyde etkili olduğunu belirlemek amacıyla permütasyon önem analizi uygulanmıştır.

3.4. Performans Metrikleri

Model performanslarının değerlendirilmesinde kullanılan istatistiksel metrikler arasında kök ortalama kare hatası (RMSE), ortalama kare hatası (MSE), belirleme katsayısı (R^2) ve mutlak ortalama hata (MAE) yer almaktadır. Bu metrikleri kullanan çalışmalara Tablo 4'te yer verilmiştir. Ayrıca hata metriklerinin açıklamaları aşağıda yer almaktadır.

Tablo 4. Performans Metrikleri ve Literatürdeki Kaynaklar

Performans Metrikleri	Referanslar
R^2	Phaladisailoed ve Numnonda (2018), Koç Ustalı vd. (2021), Erfanian vd. (2022), Bardak vd. (2024)
MAE	Karasu vd. (2018), Atsalakis vd. (2019), Mallqui ve Fernandes (2019), Guo vd. (2021)
MSE	Phaladisailoed ve Numnonda (2018), Karasu vd. (2018), Atsalakis vd. (2019), Guo vd. (2021)
RMSE	Hitam ve İsmail (2018), Karasu vd. (2018), Atsalakis vd. (2019), Mallqui ve Fernandes (2019), Aggarwal vd. (2019), Guo vd. (2021), Mittal ve Geettha (2022)

Kök ortalama kare hatası (RMSE), gerçek ve tahmin edilen değerler arasındaki farkın karelerinin ortalamasının kareköküdür. Artıkların standart sapmasını ölçer ve model tahminlerinin gözlemlenen değerlerden ne kadar sapma gösterdiğini belirtmektedir. Düşük bir RMSE değeri, modelin verilere daha iyi uyduğunu gösterirken, yüksek olması modelin veriye uyum sağlamakta zorlandığını göstermektedir. RMSE değerinin sıfır olması ise, tahmin edilen ve gözlemlenen veriler arasında tam bir uyum olduğunu ifade etmektedir. RMSE, eşitlik 1'deki gibi hesaplanmaktadır (Menendez-García vd., 2024):

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \bar{y}_t)^2} \quad (1)$$

Burada, y_t tahmin edilen değişkenin t zamanındaki gerçek değerini, $\bar{y}_t$ ise tahmin edilen değerini ifade etmektedir. Ayrıca t zaman indeksini gösterirken, n ise toplam gözlem sayısını temsil etmektedir.

Ortalama kare hatası (MSE), gerçek ve tahmin edilen değerler arasındaki farkın başka bir ifadeyle hataların karelerinin ortalamasıdır. MSE, eşitlik 2'de verildiği şekilde tanımlanmaktadır (Agrawal vd., 2021):

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \bar{y}_t)^2 \quad (2)$$

Belirleme katsayısı (R^2), bir tahmin modelinin ne kadar iyi uyum sağladığını gösteren bir ölçüttür. R^2 değeri, gerçek değerlerin ne kadarını tahmin modelinin açıkladığını göstermektedir. R^2 , 1'e yaklaştıkça, modelin daha iyi bir uyum sağlamaktadır (Özgür vd., 2023). R^2 , eşitlik 3'teki gibi ifade edilmektedir (He vd., 2024):

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \bar{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y}_t)^2} \quad (3)$$

Mutlak ortalama hata (MAE), tahmin edilen ve gerçek gözlemler arasındaki mutlak farkların ortalamasıdır. MAE, doğrusal bir skordur. Bu, tüm bireysel farkların ortalama eşit şekilde dikkate alındığı anlamına gelmektedir. Dolayısıyla, daha büyük hatalar toplam hataya doğrusal olarak katkıda bulunmaktadır. MAE değerinin hesaplanma şekli eşitlik 4'te yer almaktadır (Ayala vd., 2021):

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \bar{y}_t| \quad (4)$$

4. Araştırmanın Bulguları

4.1. SVR Yöntemi ile Yapılan Tahmin Bulguları


SVR modelinin tahmin performansı, eğitim ve test veri setleri üzerinde elde edilen sonuçlar doğrultusunda değerlendirilmiştir. Modelin başarımına ilişkin R^2 , MAE, MSE ve RMSE değerleri Tablo 5'te sunulmaktadır. Ayrıca, SVR ile yapılan tahminlerin gerçek değerlerle ne ölçüde örtüştüğünü gösteren grafiksel

karşılaştırmalara Şekil 1’de yer verilmiştir. Bu görselleştirme, modelin tahmin kabiliyetini zamana bağlı olarak değerlendirme açısından önemli bir çerçeve sunmaktadır.

Tablo 5. SVR Yöntemi ile Kripto Varlık Fiyat Tahmini Performans Değerlendirmesi

Kripto Varlık	Yöntem	Hata Metrikleri			
		R^2	MAE	MSE	RMSE
Bitcoin	SVR	0,995509	256,557350	155985,295498	394,949737
Ethereum	SVR	0,995733	10,627267	204,569135	14,302766
Ripple	SVR	0,799939	0,039878	0,045268	0,002049
BNB	SVR	0,995685	1,783359	2,751695	2,751695
Dogecoin	SVR	-15,671967	0,041862	0,001800	0,042433

Şekil 1. SVR Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması



Tablo 5’te yer alan SVR modeliyle yapılan tahmin sonuçları incelendiğinde, Bitcoin için oldukça yüksek bir performans elde edilmiştir. R^2 değeri 0,995509 olup fiyat serisindeki varyansın neredeyse tamamı açıklanabilmektedir. MAE (256,55) ve RMSE (394,95) değerleri Bitcoin’in binlerce dolarlık fiyat seviyesine göre düşük kalırken, MSE (155.985,29) değeri diğer varlıklara kıyasla oldukça yüksektir; bu durum modelin yetersizliğinden değil, Bitcoin’in yüksek fiyat ölçeği nedeniyle hata karelerinin büyümesinden kaynaklanmaktadır. Ethereum için model benzer şekilde başarılı sonuçlar vermiş, R^2 değeri 0,995733 olarak hesaplanmış, MAE (10,62), RMSE (14,30) ve MSE (204,57) değerleri düşük kalarak tahmin performansının güçlü olduğunu göstermiştir. Ripple’da ise R^2 değeri 0,799939 ile açıklama gücü görece zayıflamış, MAE (0,0399) ve RMSE (0,0020) değerleri küçük olsa da fiyat seviyesinin düşük olması nedeniyle bu hatalar anlamlı bir doğruluk sergilememiş, MSE (0,0453) değeri de tahmin kapasitesinin sınırlı kaldığını teyit etmiştir. BNB için sonuçlar oldukça başarılı çıkmış, R^2 değeri 0,995685 ile fiyat serisinin büyük kısmı açıklanabilmış, MAE (1,78), RMSE (2,75) ve MSE (2,75) değerleri düşük seviyelerde kalarak modelin güçlü bir tahmin gücü sunduğu görülmüştür. Dogecoin’de ise model başarısız olmuş, R^2 değeri -15,671967 ile negatif çıkmıştır. Her ne kadar MAE (0,0419), RMSE (0,0424) ve MSE (0,0018) değerleri küçük görünse de Dogecoin’in düşük fiyat seviyesi dikkate alındığında bu hatalar tahmin doğruluğu açısından anlamlı değildir. Sonuç olarak, SVR modeli, bazı varlıklarda başarılı sonuçlar verirken, özellikle oynaklık düzeyi yüksek ve yapısal özellikleri farklılaşan kripto varlıklarda performans kaybı yaşayabilmektedir. Bu durum, modelin veri setindeki farklılıklara karşı duyarlı olduğunu göstermektedir.

Tablo 6. SVR Yöntemi İçin Değişkenlerin Önem Düzeyi

Sıra	Bitcoin		Ethereum		Ripple		BNB	
	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi
1	High	7.689.580	High	39.502	Low	0,003561	High	2.509,763303
2	Low	6.255.837	Low	29.847	High	0,003403	Low	1.695,768649
3	Open	2.027.157	Open	9.706	MA50	0,002813	Open	1.376,768691
4	MA50	1.948.024	MA50	1.148	Hızlı_%D	0,001222	MA50	20,231441
5	MACD	443.323	MACD	931	Hızlı_%K	0,000810	MACD	7,561504
6	RSI	18.414	Hızlı_%K	355	RSI	0,000605	Hızlı_%K	0,777817
7	MA200	8.566	Hızlı_%D	338	Yavaş_%D	0,000401	Hızlı_%D	0,558783
8	WAD	7.838	MACD_Signal	107	WAD	0,000254	MACD_Signal	0,241114
9	ROC50	6.921	FGI	4	MACD	0,000237	MA200	0,044086
10	FGI	4.294	RSI	2	MA200	0,000229	FGI	0,006737
11	ROC10	2.334	ROC50	1	ROC50	0,000082	ROC50	0,005063
12	FED	2.287	VIX	1	OBV	0,000070	OVX	0,003673
13	CPI	1.601	WAD	0	FED	0,000068	VIX	0,002825
14	Hızlı_%D	1.226	XAU	0	MACD_Signal	0,000037	CPI	0,002512
15	WTI	1.223	OVX	0	OVX	0,000029	EPU	0,001600
16	Yavaş_%D	1.108	ROC10	0	EPU	0,000018	RSI	0,001338
17	MACD_Signal	792	OBV	0	ROC10	0,000016	GTRENDS	0,000301
18	GTRENDS	519	EPU	0	Volume	0,000005	OBV	0,000204
19	VIX	148	GTRENDS	0	GTRENDS	0,000003	WAD	0,000000
20	DXY	115	Volume	0	ADX	-0,000009	XAU	-0,000217
21	Volume	-66	ADX	0	FGI	-0,000079	DXY	-0,000536
22	Hızlı_%K	-75	CPI	0	VIX	-0,000083	Volume	-0,002165
23	OVX	-112	DXY	0	XAU	-0,000094	ROC10	-0,002570
24	EPU	-118	FED	-1	WTI	-0,000133	WTI	-0,004922
25	ADX	-316	Yavaş_%D	-1	DXY	-0,000160	ADX	-0,009202
26	OBV	-1.116	MA200	-1	Open	-0,000390	Yavaş_%D	-0,015115
27	XAU	-1.833	WTI	-1	CPI	-0,000604	FED	-0,020583

SVM modeli Dogecoin için fiyat tahmini yapamadığı için önem analizi de yapılamamıştır.


Tablo 6’da SVR modeli ile yapılan tahminlerde kullanılan değişkenlerin önem düzeylerine yer verilmiştir. Bitcoin, Ethereum, Ripple ve BNB için yapılan analizlerde genel olarak fiyat düzeyleri (High, Low, Open) ve MA50 gibi teknik göstergeler ön sıralarda yer almıştır. RSI, MACD ve Hızlı %K gibi momentum göstergeleri de çoğu kripto varlıkta etkili olmuştur. Buna karşın, makroekonomik ve yatırımcı duyarlılığına ilişkin değişkenlerin büyük bölümünün düşük önem düzeyi aldığı görülmektedir. Modelin Dogecoin için tahmin üretmediği için bu varlığa ait analiz yapılamamıştır.

4.2. RF Yöntemi ile Yapılan Tahmin Bulguları

RF modelinin tahmin performansı, eğitim ve test veri setleri üzerinden elde edilen sonuçlar dikkate alınarak değerlendirilmiştir. Modelin doğruluk düzeyini yansıtan R^2 , MAE, MSE ve RMSE değerleri Tablo 7’de sunulmuştur. Ayrıca, RF ile yapılan tahminlerin gerçek fiyatlarla olan uyumunu görselleştiren karşılaştırmalara Şekil 2’de yer verilmiştir.

Tablo 7. RF Yöntemi ile Kripto Varlık Fiyat Tahmini Performans Değerlendirmesi

Kripto Varlık	Yöntem	Hata Metrikleri			
		R^2	MAE	MSE	RMSE
Bitcoin	RF	0,992618	405,247122	256.375,685813	506,335546
Ethereum	RF	0,984681	21,295081	734,551103	27,102603
Ripple	RF	0,992014	0,007083	8,179584	0,009044
BNB	RF	0,985560	3,981,093	25,343070	5,034190
Dogecoin	RF	0,974158	0,001175	2,790934	0,001670

Şekil 2. RF Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması

Tablo 7’de kripto varlıkların fiyat tahmininde kullanılan RF modelinin sonuçları sunulmaktadır. Bitcoin için R^2 değeri 0,992618 olup fiyat serisindeki varyansın büyük kısmı açıklanabilmektedir. MAE (405,25) ve RMSE (506,34) değerleri Bitcoin’in yüksek fiyat ölçeğine göre makul düzeyde kalırken, MSE (256.375,69) değeri fiyat seviyelerinin büyüklüğü nedeniyle yüksek çıkmıştır. Ethereum’da R^2 değeri 0,984681 olarak hesaplanmış, MAE (21,30), RMSE (27,10) ve MSE (734,55) değerleri düşük seviyelerde kalarak modelin başarılı bir tahmin performansı sergilediğini göstermiştir. Ripple için sonuçlar oldukça güçlüdür; R^2 değeri 0,992014 olup varyansın büyük kısmı açıklanmış, MAE (0,0071), RMSE (0,0090) ve MSE (8,18) değerleri modelin son derece düşük hata ile tahmin üretebildiğini ortaya koymuştur. BNB’de R^2 değeri 0,985560 olarak elde edilmiş, MAE (3,98), RMSE (5,03) ve MSE (25,34) değerleri düşük kalarak RF modelinin bu varlıkta da güçlü bir performans sergilediğini göstermiştir. Dogecoin’de ise R^2 değeri 0,974158 olup yüksek bir açıklama gücü elde edilmiş, ayrıca MAE (0,0012), RMSE (0,0017) ve MSE (2,79) değerlerinin oldukça düşük seviyelerde kalması modelin bu varlık üzerinde de başarılı sonuçlar verdiğini ortaya koymuştur. Genel olarak RF modeli, tüm kripto varlıklarda yüksek açıklama gücü ve düşük hata metrikleriyle güçlü bir tahmin performansı sunmuştur.

RF modeli ile yapılan tahminlerde kullanılan değişkenlerin önem düzeylerine Tablo 8’de yer verilmiştir. Genel olarak değerlendirildiğinde, RF modeliyle yapılan analizlerde kripto varlık fiyat tahminlerinde en etkili değişkenlerin geçmiş fiyat hareketlerine ilişkin veriler olduğu görülmektedir. Model, özellikle günlük fiyat seviyelerine yüksek duyarlılık göstermekte ve tahmin başarısını büyük ölçüde bu veriler üzerinden sağlamaktadır. Teknik göstergeler model üzerinde kripto varlıklara göre farklılık göstermekle birlikte, genel olarak ikincil düzeyde etkili olmuş, hacim, momentum ve trend temelli bazı göstergeler kısmen önemli katkılar sunmuştur. Öte yandan, yatırımcı duyarlılığı ve makroekonomik faktörlerin model performansına etkisi sınırlı kalmış, bu tür göstergeler çoğu durumda düşük önem düzeylerinde yer almıştır.

Tablo 8. Rastgele Orman Yöntemi İçin Değişkenlerin Önem Düzeyi

Bitcoin			Ethereum		Ripple	
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi
1	Low	0,486122	High	0,541757	High	0,663215
2	High	0,260549	Low	0,456601	Low	0,202252
3	Open	0,252491	Open	0,000679	Open	0,086892
4	WAD	0,000130	Hızlı_%K	0,000115	ROC50	0,020640
5	Hızlı_%K	0,000118	RSI	0,000092	MACD	0,007022

Tablo 8. Rastgele Orman Yöntemi İçin Değişkenlerin Önem Düzeyi (Devam)

Bitcoin			Ethereum		Ripple	
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi
6	RSI	0,000057	OBV	0,000091	ADX	0,007001
7	ROC10	0,000053	VIX	0,000067	VIX	0,004547
8	ROC50	0,000051	ROC50	0,000063	RSI	0,001958
9	VIX	0,000046	ADX	0,000059	EPU	0,001950
10	OBV	0,000037	WAD	0,000057	ROC10	0,000797
11	Volume	0,000037	Volume	0,000049	XAU	0,000556
12	ADX	0,000034	MACD_Signal	0,000040	WTI	0,000528
13	Hızlı_%D	0,000030	DXY	0,000039	Hızlı_%D	0,000374
14	FGI	0,000027	OVX	0,000038	Hızlı_%K	0,000351
15	Yavaş_%D	0,000026	ROC10	0,000037	MA50	0,000309
16	MACD	0,000025	XAU	0,000035	Yavaş_%D	0,000262
17	OVX	0,000023	Yavaş_%D	0,000028	OBV	0,000249
18	MACD_Signal	0,000023	WTI	0,000026	MACD_Signal	0,000199
19	DXY	0,000022	Hızlı_%D	0,000024	Volume	0,000164
20	MA50	0,000021	MACD	0,000023	WAD	0,000164
21	WTI	0,000020	FGI	0,000022	DXY	0,000146
22	XAU	0,000020	MA50	0,000020	OVX	0,000124
23	MA200	0,000018	MA200	0,000015	MA200	0,000123
24	FED	0,000008	FED	0,000008	FGI	0,000089
25	CPI	0,000006	CPI	0,000008	GTRENDS	0,000034
26	GTRENDS	0,000006	GTRENDS	0,000007	FED	0,000028
27	EPU	0,000002	EPU	0,000002	CPI	0,000026
BNB			Dogecoin			
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi		
1	Low	0,338469	High	0,541685		
2	High	0,228263	Low	0,365496		
3	Open	0,189609	OBV	0,028943		
4	MA200	0,146793	ROC50	0,025104		
5	MA50	0,094763	Open	0,023313		
6	OBV	0,000756	MA200	0,009176		
7	MACD	0,000532	MA50	0,001974		
8	Hızlı_%K	0,000137	MACD_Signal	0,001340		
9	ROC10	0,000082	Hızlı_%K	0,000544		
10	MACD_Signal	0,000079	ROC10	0,000374		
11	RSI	0,000079	RSI	0,000362		
12	ROC50	0,000057	WAD	0,000271		
13	OVX	0,000048	Yavaş_%D	0,000229		
14	VIX	0,000044	VIX	0,000202		
15	DXY	0,000038	DXY	0,000130		
16	Yavaş_%D	0,000035	OVX	0,000119		
17	Hızlı_%D	0,000035	XAU	0,000117		
18	FGI	0,000033	Hızlı_%D	0,000116		
19	XAU	0,000031	MACD	0,000107		
20	ADX	0,000031	Volume	0,000100		
21	WTI	0,000030	ADX	0,000089		
22	Volume	0,000029	FGI	0,000084		
23	GTRENDS	0,000011	WTI	0,000083		
24	CPI	0,000008	FED	0,000020		
25	FED	0,000005	GTRENDS	0,000011		
26	EPU	0,000001	CPI	0,000009		
27	WAD	0,000000	EPU	0,000003		


4.3. XGBoost Yöntemi ile Yapılan Tahmin Bulguları

XGBoost modelinin tahmin performansı, eğitim ve test veri setleri üzerinde elde edilen sonuçlar doğrultusunda değerlendirilmiştir. Modelin başarımına ilişkin R^2 , MAE, MSE ve RMSE değerleri Tablo 9’de sunulmaktadır. Ayrıca, XGBoost ile yapılan tahminleri ile gerçek değerlerin grafiksel karşılaştırmalarına Şekil 3’te yer verilmiştir.

Tablo 9. XGBoost Yöntemi ile Kripto Varlık Fiyat Tahmini Performans Değerlendirmesi

Kripto Varlık	Yöntem	Hata Metrikleri			
		R^2	MAE	MSE	RMSE
Bitcoin	XGBoost	0,984059	537,128611	553.671,875160	744,091308
Ethereum	XGBoost	0,953708	39,673307	2219,689030	47,113575
Ripple	XGBoost	0,990885	0,006806	9,335673	0,009662
BNB	XGBoost	0,986399	4,008921	23,871751	4,885872
Dogecoin	XGBoost	0,974717	0,001179	2,730505	0,001652

Şekil 3. XGBoost Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması



Tablo 9’da kripto varlıkların fiyat tahmininde kullanılan XGBoost modeline ilişkin sonuçlar yer almaktadır. Bitcoin için R^2 değeri 0,984059 olup varyansın büyük kısmı açıklanmıştır. MAE (537,13) ve RMSE (744,09) değerleri Bitcoin’in yüksek fiyat seviyesine kıyasla kabul edilebilir düzeyde kalırken, MSE (553.671,88) fiyat ölçeğinin büyüklüğünden dolayı oldukça yüksek çıkmıştır. Ethereum’da modelin performansı görece daha zayıftır; R^2 değeri 0,953708 olarak bulunmuş, MAE (39,67), RMSE (47,11) ve MSE (2.219,69) değerleri diğer varlıklara kıyasla daha yüksek gerçekleşmiştir. Ripple için elde edilen R^2 değeri 0,990885 olup modelin fiyat serisinde güçlü bir açıklama gücüne sahip olduğunu göstermektedir. Ayrıca MAE (0,0068), RMSE (0,0097) ve MSE (9,34) değerlerinin düşük seviyelerde kalması, XGBoost’un Ripple fiyatlarını oldukça başarılı şekilde tahmin ettiğini ortaya koymaktadır. BNB için sonuçlar da tatmin edici düzeydedir; R^2 değeri 0,986399 olup varyansın büyük kısmı açıklanmış, MAE (4,01), RMSE (4,89) ve MSE (23,87) değerleri düşük kalarak modelin güçlü tahmin performansını teyit etmiştir. Dogecoin’de ise R^2 değeri 0,974717 olup yüksek açıklama gücü elde edilmiş, ayrıca MAE (0,0012), RMSE (0,0017) ve MSE (2,73) değerleri çok düşük seviyelerde kalarak modelin bu varlık üzerinde de başarılı sonuçlar verdiğini göstermiştir. Genel olarak XGBoost yöntemi, fiyat düzeyi daha istikrarlı olan kripto varlıklarda başarılı sonuçlar verirken, fiyatı yüksek ve dalgalı varlıklarda hata metrikleri açısından dikkatli analiz gerektiren çıktılar üretmiştir.

Tablo 10’da XGBoost yöntemiyle yapılan tahminlerde kullanılan değişkenlerin önem düzeyleri sunulmuştur. Bitcoin için en etkili değişkenlerin büyük çoğunluğu teknik analiz göstergeleri sınıfında yer almakta olup, makroekonomik göstergeler ve yatırımcı duyarlılığına ilişkin değişkenler daha alt sıralarda

kalmıştır. Ethereum’da da benzer biçimde fiyat ve hacim gibi temel teknik değişkenler tahmin başarısında belirleyici rol oynamıştır. Ripple için teknik göstergeler ön planda olmakla birlikte, yatırımcı duyarlılığı göstergelerinin model üzerindeki katkısı orta düzeyde kalmıştır. BNB tarafında teknik analiz değişkenleri belirgin şekilde öne çıkarken, bazı yatırımcı duyarlılığı ve makroekonomik değişkenler sınırlı düzeyde katkı sağlamıştır. Dogecoin özelinde ise fiyat ve hacme dayalı teknik göstergeler etkili olmuştur.

Tablo 10. XGBoost İçin Değişkenlerin Önem Düzeyi

Bitcoin			Ethereum		Ripple	
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi
1	High	540,0	High	586,0	High	394,0
2	Low	296,0	Volume	296,0	Hızlı_%K	307,0
3	Volume	291,0	Hızlı_%K	292,0	Volume	262,0
4	Hızlı_%K	290,0	Low	285,0	Low	243,0
5	RSI	257,0	RSI	262,0	RSI	226,0
6	Hızlı_%D	190,0	Hızlı_%D	229,0	Yavaş_%D	178,0
7	ROC10	182,0	Yavaş_%D	167,0	Hızlı_%D	174,0
8	Yavaş_%D	166,0	ROC10	165,0	ROC10	173,0
9	MACD	147,0	MACD	158,0	OBV	122,0
10	FGI	134,0	ROC50	130,0	FGI	120,0
11	ROC50	127,0	MACD_Signal	127,0	Open	116,0
12	OBV	126,0	ADX	124,0	MACD	115,0
13	XAU	116,0	OBV	118,0	ROC50	114,0
14	ADX	113,0	FGI	109,0	ADX	114,0
15	MACD_Signal	107,0	Open	107,0	MACD_Signal	107,0
16	Open	103,0	XAU	101,0	VIX	100,0
17	VIX	101,0	DXY	101,0	WTI	90,0
18	WAD	98,0	WAD	98,0	WAD	87,0
19	WTI	97,0	VIX	93,0	MA50	81,0
20	OVX	89,0	OVX	81,0	OVX	78,0
21	DXY	82,0	WTI	74,0	DXY	77,0
22	MA50	71,0	MA50	67,0	XAU	75,0
23	MA200	53,0	MA200	48,0	MA200	48,0
24	GTRENDS	31,0	FED	32,0	GTRENDS	28,0
25	CPI	19,0	GTRENDS	23,0	CPI	25,0
26	FED	8,0	CPI	15,0	EPU	22,0
27	EPU	7,0	EPU	8,0	FED	17,0

BNB			Dogecoin	
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi
1	High	613,0	High	182,0
2	Low	297,0	Low	108,0
3	Volume	244,0	Hızlı_%K	89,0
4	Hızlı_%K	242,0	Volume	68,0
5	RSI	202,0	RSI	57,0
6	Hızlı_%D	175,0	OBV	56,0
7	ROC10	152,0	WAD	55,0
8	Open	147,0	Open	55,0
9	FGI	142,0	Yavaş_%D	51,0
10	MACD	141,0	Hızlı_%D	44,0
11	ROC50	140,0	MACD	40,0
12	Yavaş_%D	135,0	ROC50	36,0
13	OBV	118,0	MACD_Signal	34,0
14	MACD_Signal	112,0	ROC10	33,0
15	ADX	105,0	XAU	27,0
16	XAU	101,0	FGI	25,0
17	OVX	99,0	MA200	22,0

Tablo 10. XGBoost İçin Değişkenlerin Önem Düzeyi (Devam)

18	VIX	98,0	ADX	22,0
19	WTI	87,0	DXY	22,0
20	MA50	79,0	VIX	19,0
21	DXY	70,0	WTI	18,0
22	MA200	44,0	MA50	16,0
23	GTRENDS	20,0	OVX	11,0
24	FED	20,0	EPU	2,0
25	EPU	19,0	GTRENDS	2,0
26	CPI	14,0	FED	2,0
27	WAD	4,0	CPI	2,0


Genel olarak değerlendirildiğinde, XGBoost modelinde teknik analiz göstergeleri tüm kripto varlıklar için en yüksek önem düzeyine sahip değişken grubu olarak öne çıkmaktadır. Yatırımcı duyarlılığına ilişkin dışsal göstergeler ve makroekonomik değişkenler ise model içinde görece daha düşük düzeyde önem kazanmıştır. Bu bulgu, XGBoost algoritmasının kısa vadeli fiyat hareketlerini açıklamada teknik sinyalleri daha baskın şekilde değerlendirdiğini göstermektedir.

4.4. LSTM Yöntemi ile Yapılan Tahmin Bulguları

LSTM modelinin tahmin performansı, eğitim ve test veri setleri üzerinden elde edilen sonuçlar dikkate alınarak değerlendirilmiştir. Modelin doğruluk düzeyini yansıtan R^2 , MAE, MSE ve RMSE değerleri Tablo 11’de sunulmuştur. Ayrıca, LSTM ile yapılan tahminlerin gerçek fiyatlarla olan uyumunu görselleştiren karşılaştırmalara Şekil 4’te yer verilmiştir.

Tablo 11. LSTM Yöntemi ile Kripto Varlık Fiyat Tahmini Performans Değerlendirmesi

Kripto Varlık	Yöntem	Hata Metrikleri			
		R^2	MAE	MSE	RMSE
Bitcoin	LSTM	0,909544	1.239,143834	2.566.413,863513	80,205624
Ethereum	LSTM	0,833087	61,148925	6432,942162	81,432750
Ripple	LSTM	0,697342	0,039751	0,002536	0,050358
BNB	LSTM	0,862361	12,582522	240,518902	15,508671
Dogecoin	LSTM	0,796686	0,003508	2,092764	0,004574

Şekil 4. LSTM Yöntemi ile Tahmin Edilen ile Gerçek Değerlerin Karşılaştırılması

Tablo 11’de kripto varlıkların fiyat tahmininde kullanılan LSTM modeline ilişkin sonuçlar yer almaktadır. Bitcoin için R^2 değeri 0,909544 olup varyansın önemli bir kısmı açıklanmıştır. MAE (1.239,14), RMSE (80,21) ve MSE (2.566.413,86) değerleri, modelin Bitcoin fiyat serisinde belirgin doğruluk sağladığını göstermektedir.

Ethereum için R^2 değeri 0,833087 olarak hesaplanmış, MAE (61,15), RMSE (81,43) ve MSE (6.432,94) değerleri elde edilmiştir. Ripple’da R^2 değeri 0,697342 olup açıklama gücü görece daha düşük seviyededir. MAE (0,0398), RMSE (0,0504) ve MSE (0,0025) değerleri, modelin Ripple fiyatlarında belirli bir tahmin gücüne sahip olduğunu göstermektedir. BNB için R^2 değeri 0,862361 olarak bulunmuş, MAE (12,58), RMSE (15,51) ve MSE (240,52) değerleri ile modelin tatmin edici sonuçlar verdiği görülmektedir. Dogecoin’de ise R^2 değeri 0,796686 olup açıklama gücü kabul edilebilir düzeydedir. MAE (0,0035), RMSE (0,0046) ve MSE (2,09) değerleri modelin bu varlıkta da uyumlu sonuçlar ürettiğini ortaya koymaktadır. Genel olarak LSTM modeli, farklı kripto varlıkların fiyat serilerinde anlamlı düzeyde açıklama gücü sağlamış ve tüm hata metriklerinde istikrarlı tahminler ortaya koymuştur.

Tablo 12’de LSTM yöntemiyle yapılan tahminlerde kullanılan değişkenlerin önem düzeyleri sunulmuştur. Genel olarak değerlendirildiğinde, LSTM modelinin en çok önem verdiği değişkenlerin başında fiyat seviyeleri (Open, High, Low) ve bazı teknik göstergeler (RSI, MA50, Hızlı %K, Yavaş %D) gelmektedir. Fiyatların geçmiş hareketlerine dayanan bu göstergeler, modelin zaman serisi temelli öğrenme sürecinde belirleyici rol oynamaktadır. Buna karşın, CPI, FED ve GTRENDS gibi bazı makroekonomik ve duyarlılık göstergelerinin çoğu kripto varlık için düşük veya negatif önem skorları aldığı görülmektedir. Bu durum, LSTM modelinin özellikle kısa vadeli piyasa dinamiklerine duyarlı olduğunu, ancak daha karmaşık, ekonomik içerikli göstergelerin model tarafından yeterince öğrenilemediğini göstermektedir.

Tablo 12. LSTM Yöntemi İçin Değişkenlerin Önem Düzeyi

Bitcoin			Ethereum		Ripple	
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi
1	Open	4.873.575,86020	Yavaş_%D	9.320,72940	MA50	0,00181
2	High	3.754.888,11797	High	6.330,60190	RSI	0,00168
3	Low	3.584.021,11355	Low	4.770,00606	Hızlı_%K	0,00160
4	RSI	2.268.700,29459	Hızlı_%K	4.458,96847	Yavaş_%D	0,00124
5	FGI	1.062.611,66705	FGI	1.835,19708	Open	0,00105
6	MA50	841.460,67920	Hızlı_%D	1.690,38214	Low	0,00047
7	ROC10	524.471,28264	Open	1.283,33887	MA200	0,00047
8	ROC50	503.227,51354	MACD_Signal	1.271,36048	High	0,00027
9	WAD	168.451,48700	ROC50	1.138,29915	ROC10	0,00017
10	OBV	103.435,63326	OBV	892,34052	Hızlı_%D	0,00013
11	OVX	84.185,02029	ROC10	660,86994	Volume	0,00013
12	Hızlı_%D	63.243,35951	WTI	602,41656	ADX	0,00009
13	VIX	3.567,42348	MA200	551,57151	VIX	0,00007
14	Yavaş_%D	979,78895	MA50	449,59718	MACD	0,00006
15	EPU	0,22694	WAD	168,26374	OBV	0,00006
16	Hızlı_%K	-2.698,57437	CPI	77,99932	DXI	0,00006
17	WTI	-7.340,54156	VIX	27,08417	OVX	0,00003
18	MACD_Signal	-32.698,37094	EPU	-0,02106	MACD_Signal	0,00002
19	XAU	-64.085,71776	DXI	-21,18818	GTRENDS	0,00001
20	MA200	-65.131,35335	GTRENDS	-42,00916	ROC50	0,00001
21	DXI	-83.022,91051	Volume	-105,64256	EPU	0,00000
22	FED	-94.754,29642	OVX	-132,15046	FGI	-0,00000
23	Volume	-113.190,33457	FED	-132,82190	XAU	-0,00002
24	CPI	-135.519,41437	MACD	-225,95207	WTI	-0,00005
25	MACD	-138.787,81544	XAU	-474,55578	WAD	-0,00007
26	GTRENDS	-194.661,66668	ADX	-656,91918	FED	-0,00016
27	ADX	-248.771,11098	RSI	-854,82000	CPI	-0,00036
Bnb			Dogecoin			
Sıra	Değişken	Önem Düzeyi	Değişken	Önem Düzeyi		
1	High	272,43826	Hızlı_%K	0,00010		
2	Low	247,42273	Yavaş_%D	0,00005		
3	Open	204,27413	RSI	0,00003		
4	MA50	146,11107	Low	0,00001		
5	Yavaş_%D	139,74877	High	0,00001		

Tablo 12. LSTM Yöntemi İçin Değişkenlerin Önem Düzeyi (Devam)

6	Hızlı_%K	83,85170	MA50	0,00001
7	Hızlı_%D	29,83660	MACD_Signal	0,00000
8	FGI	22,14861	WTI	0,00000
9	MACD	15,97976	GTRENDS	0,00000
10	ROC50	12,14226	Open	0,00000
11	MACD_Signal	10,63658	Hızlı_%D	0,00000
12	ROC10	9,53006	MACD	0,00000
13	FED	7,37363	OBV	0,00000
14	RSI	7,13802	Volume	0,00000
15	XAU	2,76493	VIX	0,00000
16	DXY	2,22540	ADX	0,00000
17	WTI	2,13107	FED	0,00000
18	MA200	0,65765	ROC10	0,00000
19	OBV	0,03980	EPU	-0,00000
20	Volume	0,00067	XAU	-0,00000
21	WAD	0,00000	ROC50	-0,00000
22	EPU	-0,00006	MA200	-0,00000
23	OVX	-1,74463	FGI	-0,00000
24	CPI	-3,11922	CPI	-0,00000
25	ADX	-3,16182	DXY	-0,00000
26	VIX	-7,11611	OVX	-0,00000
27	GTRENDS	-15,98472	WAD	-0,00000

4.5. Makine Öğrenmesi Yöntemlerinin Hata Metriklerine Göre Karşılaştırılması

ML yöntemlerinin için kripto varlıklara ilişkin tahmin sonuçları dikkate alınarak, hata metrikleri bazında genel bir sıralama yapılmıştır. Tablo 13'te yer verildiği üzere, her bir hata metriği için kripto varlık özelinde yöntemlerin sıralamaları belirlenmiş ve bu sıralamalar üzerinden her yöntemin genel başarı düzeyi ortaya konmuştur. Böylece model seçimine yönelik daha objektif ve karşılaştırmalı bir değerlendirme yapılması mümkün hale gelmiştir.

Tablo 13. ML Yöntemlerinin Hata Metriklerine Göre Sıralaması

Kripto Varlık	Yöntem	Hata Metrikleri							
		R^2	Sıra	MAE	Sıra	MSE	Sıra	RMSE	Sıra
Bitcoin	SVR	0,995509	1	256,55735	1	155.985,30	1	394,949737	2
	RF	0,992618	2	405,247122	2	256.375,685813	2	506,335546	3
	XGBoost	0,984059	3	537,128611	3	553.671,875160	3	744,091308	4
	LSTM	0,909544	4	1.239,14	4	2.566.413,86	4	80,205624	1
Ethereum	SVR	0,995733	1	10,627267	1	204,569135	1	14,302766	1
	RF	0,984681	2	21,295081	2	734,551103	2	27,102603	2
	XGBoost	0,953708	3	39,673307	3	2219,68903	3	47,113575	3
	LSTM	0,833087	4	61,148925	4	6432,942162	4	81,432750	4
Ripple	SVR	0,799939	3	0,039878	4	0,045268	2	0,002049	1
	RF	0,992014	1	0,007083	2	8,179584	3	0,009044	2
	XGBoost	0,990885	2	0,006806	1	9,335673	4	0,009662	3
	LSTM	0,697342	4	0,039751	3	0,002536	1	0,050358	4
BNB	SVR	0,995685	1	1,783359	1	2,751695	1	2,751695	1
	RF	0,985560	3	3,981,093	2	25,343070	3	5,034190	3
	XGBoost	0,986399	2	4,008921	3	23,871751	2	4,885872	2
	LSTM	0,862361	4	12,582522	4	240,518902	4	15,508671	4
Dogecoin	SVR	-15,67197	4	0,041862	4	0,0018	1	0,042433	4
	RF	0,974158	2	0,001175	1	2,790934	4	0,001670	2
	XGBoost	0,974717	1	0,001179	2	2,730505	3	0,001652	1
	LSTM	0,796686	3	0,003508	3	2,092764	2	0,004574	3

Bitcoin tahmininde en yüksek R^2 değeri ve en düşük MAE ile SVR yöntemi öne çıkmıştır. RMSE açısından ise en düşük değeri LSTM sağlamış olsa da diğer metriklerdeki yüksek hata değerleri nedeniyle genel başarı düzeyi düşüktür. RF, SVR'ye yakın sonuçlar verirken, XGBoost bu üçüncü düzeyde bir başarı elde etmiştir. Bu bağlamda, Bitcoin için SVR yöntemi genel olarak en başarılı yöntem olarak değerlendirilmektedir.

Ethereum tahmininde de SVR yöntemi tüm hata metriklerinde en düşük değerlere sahip olarak en başarılı sonuçları vermiştir. RF ikinci sırada yer alırken, XGBoost ve LSTM daha yüksek hata değerleriyle sıralamanın sonlarında kalmıştır. Bu sonuçlar, Ethereum fiyat tahmini için SVR'nin tutarlı ve güçlü performansını göstermektedir.

Ripple özelinde RF yöntemi, en yüksek R^2 ile en başarılı yöntem olarak değerlendirirken, MAE'ye göre XGBoost, MSE'ye göre LSTM, RMSE'ye göre ise SVR en başarılı yöntem olarak değerlendirilmektedir.

BNB fiyat tahmininde SVR yöntemi, tüm hata metrikleri açısından en başarılı yöntem olarak öne çıkmıştır. XGBoost ve RF benzer hata seviyelerinde sıralanırken, LSTM yine yüksek hata değerlerine sahip yöntem olmuştur.

Dogecoin tahmininde ise en yüksek R^2 ve en düşük RMSE değeri ile en başarılı yöntem XGBoost olarak öne çıkmıştır. En düşük MSE değeri ile SVR yöntemine ait olsa da eksi R^2 değeri ile fiyat tahmininde tamamen başarısız olmuştur.

Bu sonuçlar dikkate alındığında, her bir hata metriği farklı bir ML yöntemini en başarılı olarak göstermektedir. Bu durumda, en başarılı yöntemi belirlemek ve sıralama yapmak zorlaşmaktadır. Her metriğin farklı yönleri ölçmesi nedeniyle, yöntemler arasında objektif ve bütüncül bir sıralama yapabilmek ancak bu kriterlerin birlikte değerlendirilmesiyle mümkündür. İşte bu noktada, ÇKKV teknikleri devreye girerek, tüm hata metriklerini eş zamanlı olarak dikkate alan dengeli ve tutarlı bir karşılaştırma imkânı sunmakta ve en başarılı yöntemin çok boyutlu olarak belirlenmesine katkı sağlamaktadır.

4.6. Makine Öğrenmesi Yöntemlerinin ÇKKV Tekniklerine Göre Değerlendirilmesi

Kripto varlıkların fiyat tahmininde kullanılan makine öğrenmesi yöntemlerinin istatistiki performans metriklerini kullanarak çok kriterli karar verme teknikleriyle en iyi yöntemin seçildiği bu bölümde, kriterlerin ağırlıkları CRITIC yöntemiyle hesaplanarak TOPSIS, ARAS ve CODAS yöntemleriyle yöntemlerin sıralaması elde edilmiştir. Yöntemler arasında farklı sıralamalar olduğundan, genel sıralama için Copeland birleştirme yöntemi kullanılmıştır.

4.6.1. İstatistiki Performans Metriklerinin Ağırlıklarının Hesaplanması

Bu çalışmada kullanılan performans metriklerinin karar verme sürecine katkı düzeylerini objektif olarak belirlemek amacıyla literatürde yaygın kullanıma sahip olan, hesaplaması zor olmayan ve alternatif sıralama yöntemlerine kolaylıkla entegre edilebilen CRITIC yöntemi uygulanmıştır. CRITIC yöntemi, her bir kriterin varyansı ile diğer kriterlerle olan korelasyonlarını dikkate alarak kriter ağırlıklarını hesaplamaktadır. Bu yöntem sayesinde, sadece kriterlerin kendi içindeki bilgi miktarı değil, aynı zamanda diğer kriterlerle olan ilişkileri de dikkate alınmaktadır. Tablo 14'te R^2 , MAE, MSE ve RMSE performans metriklerinin CRITIC yöntemiyle elde edilen ağırlıkları sunulmaktadır.

Tablo 14. Performans Metriklerinin CRITIC Yöntemi ile Ağırlıklarının Hesaplanması

Kriterler	R^2	MAE	MSE	RMSE
Kriterlerin Ağırlıkları	0,28	0,18	0,19	0,35

Buna göre en yüksek ağırlık değeri %35 ile RMSE metriğine aittir. Bu durum, RMSE'nin hem varyansının yüksek olduğunu hem de diğer metriklerle olan korelasyonlarının görece düşük olduğunu göstermektedir. Dolayısıyla RMSE, model değerlendirmesinde en fazla bilgi katkısı sağlayan kriter olarak öne çıkmaktadır. İkinci en yüksek ağırlık ise %28 ile R^2 metriğine aittir. Bu metrik, modelin bağımlı değişken üzerindeki açıklayıcı gücünü ifade ettiği için, karar sürecinde önemli bir rol oynamaktadır. MSE ve MAE metriklerinin ağırlıkları ise

sırasıyla %19 ve %18 olarak hesaplanmıştır. Bu değerler, bu metriklerin bilgi katkısının görece daha az olduğunu, ancak yine de çok değişkenli performans analizlerinde dikkate alınması gerektiğini göstermektedir.

Bu sonuçlar doğrultusunda, çok kriterli karar verme aşamalarında, performans metriklerine eşit ağırlık verilmesi yerine CRITIC gibi objektif ağırlıklandırma yöntemlerinin kullanılması, daha sağlıklı ve veri odaklı sonuçların elde edilmesini sağlamaktadır.

4.6.2. İstatistiki Performans Metriklerinin ÇKKV ile Sıralanması

Makine öğrenmesi yöntemlerinin tahmin performanslarının çok boyutlu olarak değerlendirilmesi, tek bir metrikle karar verilmesinin ötesine geçerek daha objektif ve kapsamlı bir karşılaştırma imkânı sunar. Bu kapsamda, çalışmada kullanılan yöntemlerin performansları, TOPSIS, ARAS ve CODAS olmak üzere üç farklı ÇKKV tekniğiyle değerlendirilmiştir. Bu yöntemler, her modelin istatistiki metriklerine dayalı olarak puanlamalar yapmakta ve bu puanlara göre sıralamalar oluşturmaktadır. Bu yöntemlerin seçilme nedenleri literatürde yaygın kullanım alanı bulması, anlaşılmasının kolay olması, hesaplama karmaşıklığı olmaması ve paket program gerektirmemesi nedeniyle karar problemlerinde kolaylıkla uygulanabilir olmasıdır. TOPSIS yöntemi, alternatifleri pozitif ideal ve negatif ideal çözüme olan göreceli uzaklıkları Öklid mesafesi yaklaşımını dikkate alarak sıralarken; ARAS yöntemi ise oransal derecelendirme amacı kapsamında her alternatifin ideal alternatife göre oransal benzerliğini ortaya koymaktadır. CODAS yöntemi ise alternatiflerin sıralanmasında ele alınan negatif ideal çözüme uzaklık kapsamında TOPSIS yönteminde kullanılan Ökliden uzaklığa ek olarak Taxicab uzaklığını da dikkate almaktadır.

Tablo 15'te yöntemlerin her bir ÇKKV tekniği açısından aldıkları puanlar ve bu puanlara göre elde ettikleri sıralamalar yer almaktadır. TOPSIS yöntemi, en yüksek puanı 0,660059 ile LSTM yöntemine atayarak onu birinci sıraya yerleştirmiştir. 0,607004 puan ile XGBoost ikinci sırada, RF ise üçüncü sıradadır. SVR ise en düşük TOPSIS puanını alarak son sırada yer almıştır. Benzer şekilde ARAS yöntemi, RF yöntemine en yüksek puanı (0,401288) verirken, XGBoost ikinci sırada ve LSTM üçüncü sıradadır. CODAS yöntemi ise 0,3797 puan ile XGBoost'u en üst sıraya koymuş, ardından LSTM, RF ve SVR gelmiştir.

Tablo 15. ÇKKV Teknikleri ile Makine Öğrenmesi Yöntemlerinin İstatistiki Performans Göstergelerine Göre Sıralanması

Yöntem	TOPSIS		ARAS		CODAS	
	Sıra	Puan	Sıra	Puan	Sıra	Puan
LSTM	1	0,660059	3	0,298264	2	0,3700
XGBoost	2	0,607004	2	0,399135	1	0,3797
RF	3	0,518230	1	0,401288	3	0,3468
SVR	4	0,466939	4	-0,567570	4	0,2722

TOPSIS, ARAS ve CODAS yöntemlerinden elde edilen sıralamalar temel alınarak yöntemler arasında ikili karşılaştırmalar yapılmış ve bu doğrultuda Tablo 16'da verilen Copeland ikili karşılaştırma matrisi oluşturulmuştur.

Tablo 16. Copeland İkili Karşılaştırma Matrisi

Yöntem	LSTM			XGBoost			RF			SVM		
ÇKKV Yöntem	TOPSIS	ARAS	CODAS	TOPSIS	ARAS	CODAS	TOPSIS	ARAS	CODAS	TOPSIS	ARAS	CODAS
LSTM	-			1	-1	-1	1	-1	1	1	1	1
XGBoost	-1	1	1	-			1	-1	1	1	1	1
RF	-1	1	-1	-1	1	-1	-			1	1	1
SVR	-1	-1	-1	-1	-1	-1	-1	-1	-1	-		

Matrisin satırlarında yer alan yöntemler, sütunlardaki yöntemlerle karşılaştırıldığında, kazanılan karşılaştırmalar için +1, kaybedilenler için -1 puan verilmiştir. Elde edilen bu değerler doğrultusunda her yöntemin toplam galibiyet ve yenilgi puanları hesaplanarak Tablo 17'de yer verilen Copeland puanları belirlenmiştir.


Tablo 17. Galibiyet, Yenilgi ve Copeland Puanları ile Genel Sıra

Yöntemler	Galibiyet Puanı	Yenilgi Puanı	Copeland Puanı	Genel Sıra
XGBoost	7	-2	5	1
LSTM	6	-3	3	2
RF	5	4	1	3
SVR	0	-9	-9	4

Tablo 16'ya göre, en yüksek galibiyet puanı olan XGBoost yöntemi, 7 galibiyet ve 2 yenilgi ile en yüksek 5 puan ile Copeland puanına ulaşmış ve birinci sırada yer almıştır. LSTM yöntemi 6 galibiyet ve 3 yenilgi ile ikinci sırada, RF yöntemi ise 5 galibiyet ve 4 yenilgi ile üçüncü sırada yer almıştır. En düşük performansı gösteren yöntem ise karşılaşmaların tamamında yenilgi yaşayan SVM olmuştur. Bu durum, SVR'nin değerlendirme kriterleri açısından diğer yöntemlere kıyasla daha zayıf kaldığını göstermektedir.

4.6.3. Duyarlılık Analizi


Duyarlılık analizi bağlamında CRITIC-TOPSIS, CRITIC-ARAS ve CRITIC-CODAS modelleri açısından alternatif olan makine öğrenmesi yöntemlerinin sıralama sonuçları üzerinde kriter ağırlıklarının etkisi ele alınmıştır. Bu amaçla 20 farklı ağırlık senaryosu oluşturulmuş olup bunların grafiksel gösterimi Şekil 5'te verilmiştir.

Şekil 5. Oluşturulan Senaryolara Göre Kriter Ağırlıklarında Gözlenen Değişimler


Şekil 5'te kriter olarak ele alınan hata metriklerinden R^2 , K1 ile gösterilirken MAE K2, MSE K3 ve RMSE ise K4 ile ifade edilmiştir. İlk senaryo olan S0'da önerilen model kullanılarak bulunan mevcut sıralama sonuçları ortaya konulmaktadır. Diğer senaryolar olan (S1-S20) ise ilgili kriter ağırlıklarının %10, %30, %50, %70 ve %90 oranında azaltılmasıyla oluşturulmuştur. Yeni kriter ağırlıklarının elde edildiği senaryoların oluşturulmasında Ecer (2022) tarafından ortaya konulan eşitlik 5'ten yararlanılmıştır.

$$w_{yad} = (1 - w_{ad}) \left(\frac{w_{od}}{1 - w_{aod}} \right) \quad (5)$$


Eşitlik (5)'te w_{yad} kriter için yeni hesaplanan ağırlık değerlerini gösterirken, w_{ad} ise kriterin azaltılmış (indirgenmiş) değerini ifade etmektedir. Buna ek olarak kriterin orjinal değeri w_{od} ile gösterilirken, azaltılmış (indirgenmiş) değere sahip kriterin orjinal değeri ise w_{aod} ile belirtilmektedir. Duyarlılık analizi sonuçları CRITIC-TOPSIS için Şekil 6'da, CRITIC-ARAS için Şekil 7'de ve CRITIC-CODAS için ise Şekil 8'de sırasıyla verilmiştir.

Şekil 6. Oluşturulan Senaryolara Göre Makine Öğrenmesi Yöntemlerinin Sıralanması (CRITIC-TOPSIS)

Şekil 6'ya göre CRITIC-TOPSIS modeli bağlamında kriter ağırlıklarındaki değişimlere karşılık oluşturulan tüm senaryolarda makine öğrenmesi yöntemlerinin sıralamasında değişiklik gözlenmemektedir. Başka bir deyişle oluşturulan tüm senaryolarda LSTM birinci, XGBoost ikinci, RF üçüncü ve SVM ise dördüncü sırada yer almaktadır. Bu açıdan bakıldığında CRITIC-TOPSIS modeli kriter ağırlıklarındaki değişimlere karşı geçerli, dayanıklı ve sağlamdır.

Şekil 7. Oluşturulan Senaryolara Göre Makine Öğrenmesi Yöntemlerinin Sıralanması (CRITIC-ARAS)

Şekil 7'ye göre CRITIC-ARAS modeli bağlamında kriter ağırlıklarındaki değişimlere karşılık oluşturulan tüm senaryolarda alternatif olan makine öğrenmesi yöntemlerinin sıralamasında değişiklik görülmemektedir. Yani oluşturulan tüm senaryolarda RF birinci, XGBoost ikinci, LSTM üçüncü ve SVM ise dördüncü sırada yer almaktadır. Bu açıdan bakıldığında CRITIC-ARAS modeli kriter ağırlıklarındaki değişimlere karşı geçerli, dayanıklı ve sağlamdır.

Şekil 8. Oluşturulan Senaryolara Göre Makine Öğrenmesi Yöntemlerinin Sıralanması (CRITIC-CODAS)

Şekil 8'e göre CRITIC-CODAS modeli bağlamında kriter ağırlıklarındaki değişimlere karşılık oluşturulan tüm senaryolarda alternatif olan makine öğrenmesi yöntemlerinin sıralamasında küçük değişiklikler görülmektedir. Elde edilen tüm senaryolarda SVM dördüncü sırada yer alırken, senaryo 17-20 haricinde XGBoost birinci, 10,14,15,17-20 senaryoları dışında LSTM ikinci ve 10,14 ile 15. senaryoların haricinde ise RF üçüncü sıradaki yerini korumaktadır. Bu açıdan bakıldığında ise CRITIC-CODAS modeli kriter ağırlıklarındaki değişimlere karşı daha az duyarlıdır.

Ecer vd. (2019) ve Ecer'in (2021) ifade ettiği gibi önerilen CRITIC-TOPSIS, CRITIC-ARAS ve CRITIC-CODAS modelleri açısından sıralama sonuçları ile oluşturulan tüm senaryoların sıralama sonuçları Spearman sıra korelasyon katsayısı (SSKK) ile incelenmiştir. Tüm korelasyon katsayıları en az 0,8'den büyük olup önerilen modellerin sıralama sonuçları ile elde edilen farklı senaryoların sıralama sonuçları arasında yüksek bir korelasyonu göstermektedir. SSKK'dan elde edilen sonuçlar ise farklı senaryolar açısından ağırlıklarda yaşanan değişimlerin önerilen modellerin final sıralamasını anlamlı şekilde etkilemediğini ortaya koymaktadır.

5. sonuç

Bu çalışma, kripto varlık piyasalarının yüksek oynaklığı ve doğrusal olmayan yapısı göz önünde bulundurularak, SVR, RF, XGBoost ve LSTM algoritmalarının fiyat tahmin performanslarını karşılaştırmalı olarak değerlendirmiştir. Bitcoin, Ethereum, BNB, Ripple ve Dogecoin'e ait 2018–2023 dönemine ilişkin verilerle oluşturulan veri setinde, teknik göstergelerin yanı sıra yatırımcı duyarlılığı ve makroekonomik değişkenler de modele entegre edilmiştir.

Çalışmada kullanılan modellerin performansları, hata metrikleri çerçevesinde incelendiğinde farklı kripto varlıklar için değişken düzeylerde başarı elde edildiği görülmüştür. R^2 değerlerine göre, SVR yöntemi eksi R^2 değeriyle Dogecoin için fiyat tahmininde başarısız olmuştur. Bunun dışında dört yöntem de tüm varlıkların fiyatlarını başarılı şekilde tahmin etmiştir. Ayrıca R^2 değerlerine göre, Bitcoin, Ethereum ve Ripple için en başarılı sonucu SVR yöntemi verirken, Ripple için RF yöntemi, Dogecoin için ise XGBoost yöntemi en başarılı tahmini yapmıştır. Ancak MAE, MSE ve RMSE metrikleriyle karşılaştırıldığında her bir hata metriği farklı bir ML yöntemini en başarılı olarak gösterebilmektedir. Örneğin, Bitcoin tahmini için LSTM yöntemi R^2 değerine göre dördüncü sırada yer alırken, RMSE metriğine bakıldığında en düşük hata oranını vermektedir. Bulgulara göre, farklı yöntemlerin farklı varlıklarda farklı sonuçlar verdiği görülmektedir. Hitam ve İsmail (2018), Hitam vd. (2019) ve Salb vd. (2021) gibi çalışmalarda da yöntemlerin başarı düzeylerinin varlık türüne göre değişebildiği vurgulanmakta ve bu durum literatür tarafından da desteklenmektedir. Bu durumda, en başarılı yöntemi belirlemek ve sıralama yapmak zorlaşmaktadır. Her metriğin farklı yönleri ölçmesi nedeniyle,

yöntemler arasında objektif ve bütüncül bir sıralama yapabilmek ve bu kriterleri birlikte değerlendirilmek amacıyla, ÇKKV teknikleriyle sıralama yapılmıştır.

Ayrıca, ÇKKV teknikleri ile sıralama yapmadan önce, araştırmada kullanılan değişkenlerin fiyat tahminine ne düzeyde katkı sağladığını belirlemek amacıyla değişken önem düzeyi analizleri gerçekleştirilmiştir. Yapılan analizlere göre, geçmiş fiyat hareketleri ile göreceli güç endeksi (RSI), hareketli ortalama yakınsama ıraksama (MACD), 50 günlük basit hareketli ortalama (MA50) ve 200 günlük basit hareketli ortalama (MA200) gibi teknik göstergeler tahmin performansına belirgin katkı sağlamaktadır. Bu bulgular; Liu vd. (2021), Basher ve Sadorsky (2022), Gradojevic vd. (2023), Labbaf Khaniki ve Manthouri (2024), Hafid vd. (2024), Lee ve Xu (2024) ve Islam vd. (2025) gibi çalışmalarda da desteklenmektedir.

Teknik göstergelerin önemli katkılarına rağmen, makroekonomik ve yatırımcı duyarlılığı göstergelerinin sınırlı katkısı tespit edilmiştir. Bulgular literatürle karşılaştırıldığında hem benzerlikler hem de farklılıklar göze çarpmaktadır. Örneğin Aggarwal vd. (2019), altın fiyatı ile Bitcoin fiyatı arasında pozitif bir ilişki bulamamışlar, bu çalışmada da benzer biçimde altın göstergesi anlamlı bir etki göstermemiştir. Basher ve Sadorsky (2022) enflasyon oranının Bitcoin fiyat yönünün güçlü bir göstergesi olmadığını belirtmişler, bu bulgu da bu çalışma tarafından teyit edilmiştir. Buna karşılık aynı çalışmada petrol piyasası belirsizliği (OVX) önemli bir tahmin edici olduğu ifade edilirken, bu çalışmada böyle bir ilişki saptanamamıştır. Ayrıca Gradojevic vd. (2023), Bitcoin piyasasının korku ve açgözlülük endeksi (FGI), hacim ve Google arama eğilimleri (GTRENDS) gibi yatırımcı duyarlılığı göstergeleri tarafından yönlendirildiğini ortaya koyarken, bu araştırmada söz konusu göstergelerle yalnızca sınırlı bir ilişki belirlenmiştir. Ben Hamadou vd.'nin (2025) çalışmalarında da GTRENDS ve altın göstergeleri güçlü öngörü gücünü korurken, bu çalışmada bu değişkenlerin anlamlı bir katkısı bulunmamıştır. Ayrıca aynı araştırmada ekonomi politikası belirsizliği (EPU) göstergesinin öneminin azalması bu çalışmayla benzerlik göstermektedir. Bu benzerlikler ve farklılıklar, piyasa koşullarına, döneme ve veri setinin kapsamına bağlı olarak değişkenlerin etkisinin farklılaşabileceğini göstermektedir.

ÇKKV teknikleriyle sıralama aşamasında, CRITIC yöntemiyle belirlenen kriter ağırlıklarıyla yapılan TOPSIS, ARAS ve CODAS sıralamalarının Copeland yöntemiyle birleştirilmesi sonucunda XGBoost algoritması en başarılı yöntem olarak öne çıkmıştır. Çalışmaya dahil edilen tüm yöntemler başarılı kabul edilebilecek düzeyde tahmin performansı sergilemiş olsa da en iyi sonuçlar XGBoost algoritmasıyla elde edilmiştir. Bu durum, yatırım kararları, portföy optimizasyonu ve algoritmik işlem stratejilerinin oluşturulmasında XGBoost gibi gradyan artırma tabanlı yöntemlerin öncelikli tercih edilebileceğini göstermektedir.

Yöntemsel açıdan, XGBoost algoritmasının öne çıkması Karğın vd. (2022), Ranjan vd. (2022) ve Hafid vd. (2024) gibi çalışmalarda elde edilen bulgularla da örtüşmektedir. Söz konusu araştırmalar, XGBoost'un gradyan artırma mantığı sayesinde hızlı öğrenme ve yüksek genelleme kabiliyeti sunduğunu ve diğer ML modellerine göre daha düşük hata metrikleri sağladığını göstermektedir. Ayrıca Karasu vd. (2018), Hitam ve İsmail (2018), Phaladisailoed ve Numnonda (2018), Atsalakis vd. (2019), Aggarwal vd. (2020), Zhao vd. (2019), Erfanian vd. (2022) ve Gradojevic vd. (2023), RF, LSTM ve SVR tabanlı modellerin de bazı durumlarda yüksek doğruluk sunduğunu ifade etmektedirler, bu da çalışmamızda RF, LSTM ve SVR'nin özellikle belirli varlıklarda güçlü sonuçlar vermesiyle paralellik göstermektedir.

Bu bağlamda, çalışmanın hem yöntemsel katkısı hem de çok değişkenli yapıyı bir araya getiren kapsamlı yaklaşımıyla literatüre özgün bir katkı sunduğu değerlendirilmektedir. Özellikle yatırımcı duyarlılığı ve makroekonomik göstergelerin modele entegrasyonu, klasik teknik analiz modellerine göre daha geniş perspektifli bir tahmin süreci geliştirilmesine imkân tanımıştır. Ancak bu tür değişkenlerin etkisinin sınırlı kalması, daha etkili duyarlılık ve temel veri kaynaklarının geliştirilmesi gerektiğini ortaya koymaktadır.

Araştırmanın sınırlılıkları arasında teknik analiz göstergeleri, makroekonomik faktörler ve yatırımcı duyarlılığına ilişkin seçilmiş göstergeler yer almaktadır. Bu yapı, ML algoritmalarının kripto varlık fiyatlarını çok boyutlu bir bakış açısıyla modellemesine olanak tanımaktadır. Ancak analiz kapsamında yer almayan, kripto varlık fiyatlarını etkileyebilecek potansiyel veri türlerinin de bulunduğu göz ardı edilmemelidir. Bu nedenle, gelecekte yapılacak çalışmalarda; zincir verileri (işlem hacmi, aktif cüzdan sayısı, hash oranı vb.), haber metinleri, sosyal medya içerikleri (X, Reddit, Ekşi Sözlük vb.), forum analizleri, blog yorumları ve YouTube kullanıcı tepkileri gibi alternatif veri türlerinin de modele entegre edilmesi, yatırımcı davranışlarının

daha doğru temsil edilmesini sağlayabilecektir. Ayrıca, işlem derinliği, emir defteri verileri, kripto varlık arz hareketleri gibi göstergelerin dahil edilerek veri setinin zenginleştirilmesi, algoritmaların özellikle yüksek volatilité içeren dönemlerde daha kararlı ve duyarlı tahminler üretmesine olanak tanıyabilecektir.

Sonuç olarak elde edilen bulgular, yalnızca akademik alana değil, aynı zamanda uygulayıcılar açısından da anlamlı ve kullanılabilir sonuçlar sunmaktadır. Özellikle güçlü tahmin performansı sergileyen algoritmaların öne çıkması hem kurumsal hem de bireysel yatırım kararlarının veri temelli ve sistematik şekilde desteklenmesine olanak tanımaktadır. Büyük ölçekli portföy yöneticileri, bu modelleri portföy optimizasyonu, risk yönetimi ve algoritmik işlem stratejilerinin geliştirilmesi süreçlerinde karar destek aracı olarak kullanabilirken, küçük yatırımcılar açısından ise daha sadeleştirilmiş ve yorumlanabilir modellerin sağladığı çıktıların, piyasa trendlerini anlamada ve alım ile satım zamanlamalarını belirlemede yol gösterici olabileceği değerlendirilmektedir. Ayrıca çalışmada kullanılan değişken önem düzeyi analizleri, yatırımcılara hangi tür göstergelerin yatırım süreçlerinde daha belirleyici olduğunu ortaya koyarak, yatırım stratejilerinin oluşturulmasında değişken seçimine ilişkin önemli ipuçları sunmaktadır. Bu kapsamda, bulgular sadece akademik bir katkı sağlamamakta, aynı zamanda pratikte veri odaklı yatırım anlayışını benimseyen tüm paydaşlar için somut bir referans noktası oluşturmaktadır.

Beyan ve Açıklamalar (Declarations and Disclosures)

Yazarların Etik Sorumlulukları (Ethical Responsibilities of Authors): Bu çalışmanın yazarları, araştırma ve yayın etiği ilkelerine uyduklarını kabul etmektedirler.

Çıkar Çatışması (Conflicts of Interest): Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Finansal Destek (Funding): Yazarlar, çalışmanın hazırlanması ve/veya yayınlanması sürecinde herhangi bir finansal destek almamışlardır.

Yazar Katkı Oranı (Author Contributions): Yazarlar, çalışmaya olan katkılarını şu şekilde beyan etmişlerdir: Kavramlaştırma ve çalışma dizaynı, Y. E. Korkmaz ve S. Altınırnak; verilerin toplanması, Y. E. Korkmaz; verilerin analizi ve sonuçların yorumlanması, Y. E. Korkmaz, S. Altınırnak ve Ç. Karamaşa; çalışmanın ilk/taslak halinin yazılması, Y. E. Korkmaz; çalışmanın gözden geçirilmesi ve düzenlenmesi/düzeltilmesi, Y. E. Korkmaz, S. Altınırnak ve Ç. Karamaşa. Çalışmanın ilk ve son hali tüm yazarlar tarafından okunmuş ve onaylanmış olup, yazarlar çalışmalarıyla ilgili sorumluluğu kabul etmektedirler.

İntihal Denetimi (Plagiarism Checking): Bu çalışma, intihal tarama programı kullanılarak intihal taramasından geçirilmiştir.

(*) İlave Açıklama (Additional Disclosure): Bu çalışma, Yunus Emre Korkmaz tarafından Anadolu Üniversitesi Lisansüstü Eğitim Enstitüsü İşletme Anabilim Dalı Finansman programında Prof. Dr. Serpil Altınırnak danışmanlığında yürütülen “Kripto Para Fiyatlarının Tahmininde Makine Öğrenmesi Modellerinin Karşılaştırmalı Analizi ve ÇKKV Teknikleri ile En İyi Yöntemin Belirlenmesi” başlıklı doktora tezinden üretilmiştir.

Kaynaklar

- Aggarwal, A., Gupta, I., Garg, N., & Goel, A. (2019). Deep learning approach to determine the impact of socio economic factors on Bitcoin price prediction. *2019 Twelfth International Conference on Contemporary Computing (IC3)*. <https://doi.org/10.1109/IC3.2019.8844928>
- Aggarwal, D., Chandrasekaran, S., & Annamalai, B. (2020). A complete empirical ensemble mode decomposition and support vector machine-based approach to predict Bitcoin prices. *Journal of Behavioral and Experimental Finance*, 27, 100335. <https://doi.org/10.1016/j.jbef.2020.100335>
- Agrawal, M., Shukla, P. K., Nair, R., Nayyar, A., & Masud, M. (2021). Stock prediction based on technical indicators using deep learning model. *Computers, Materials and Continua*, 70(1), 287-304. <https://doi.org/10.32604/cmc.2022.014637>
- Atlan, F., Pençe, I., & Çeşmeli, M. Ş. (2020). Online price forecasting model using artificial intelligence for cryptocurrencies as Bitcoin, Ethereum and Ripple. In *2020 28th Signal Processing and Communications Applications Conference (SIU)*, IEEE. <https://doi.org/10.1109/SIU49456.2020.9302082>

- Atlan, F., Pençe, I., Çeşmeli, M. S., & Kalkan, A. (2018). Bitcoin'in Türkiye piyasasındaki değerinin yapay zekâ teknikleri ile tahmini. *5th International Management Information Systems Conference*.
- Atsalakis, G. S., Atsalaki, I. G., Pasiouras, F., & Zopounidis, C. (2019). Bitcoin price forecasting with neuro-fuzzy techniques. *European Journal of Operational Research*, 276(2), 770-780. <https://doi.org/10.1016/j.ejor.2019.01.040>
- Ben Hamadou, F., Mezghani, T., Zouari, R., & Boujelbène-Abbes, M. (2025). Forecasting Bitcoin returns using machine learning algorithms: Impact of investor sentiment. *EuroMed Journal of Business*, 20(1), 179-200. <https://doi.org/10.1108/EMJB-03-2023-0086>
- Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F., & Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225, 107119. <https://doi.org/10.1016/j.knosys.2021.107119>
- Bardak, S., Ersen, N., Polat, K., & Akyüz, K. C. (2024). Makine öğrenmesi yöntemleri ile hisse senedi fiyat tahmini: Kâğıt firması örneği. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 25(2), 47-58. <https://doi.org/10.17474/artvinofd.1500569>
- Basher, S. A., & Sadorsky, P. (2022). Forecasting Bitcoin price direction with random forests: How important are interest rates, inflation, and market volatility? *Machine Learning with Applications*, 9, 100355. <https://doi.org/10.1016/j.mlwa.2022.100355>
- Bouteska, A., Abedin, M. Z., Hajek, P., & Yuan, K. (2024). Cryptocurrency price forecasting – a comparative analysis of ensemble learning and deep learning methods. *International Review of Financial Analysis*, 92, 103055. <https://doi.org/10.1016/j.irfa.2023.103055>
- Budak, M. Y., & Aytekin, S. (2022). Kripto varlık fiyatlarının makine öğrenmesi kullanılarak tahmin edilmesi. *Geçmişten Günümüze Para, Banka ve Finans Tartışmaları* (ss. 159-175). Ekin Yayınevi.
- Chen, H., Liu, L., & Li, X. (2018). The predictive content of CBOE crude oil volatility index. *Physica A: Statistical Mechanics and its Applications*, 492, 837-850. <https://doi.org/10.1016/j.physa.2017.11.014>
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365. <https://doi.org/10.1016/j.cam.2019.112395>
- Chowdhury, R., Rahman, M. A., Rahman, M. S., & Mahdy, M. R. C. (2020). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning. *Physica A: Statistical Mechanics and Its Applications*, 551, 124569. <https://doi.org/10.1016/j.physa.2020.124569>
- Çağlar, B., & Yavuz, U. (2021). Finansal haberlerin Bitcoin fiyatlarına etkisinin yapay sinir ağları ile analizi. *Bilişim Teknolojileri Dergisi*, 14(1), 65-78. <https://doi.org/10.17671/gazibtd.703688>
- Daniels, P. S. (2022). Machine learning techniques for pricing, hedging and statistical arbitrage in finance [Doktora tezi]. University of Technology Sydney (Australia). <http://hdl.handle.net/10453/172004>
- Doğan, Z., & Evlimoğlu, U. (2022). Bireysel yatırımcıların yatırım kararlarında davranışsal finansın rolü: Aydın ili örneği. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 11(4), 1983-2010. <https://doi.org/10.15869/itobiad.1079129>
- Ecer, F. (2021). Sustainability assessment of existing onshore wind plants in the context of triple bottom line: A best-worst method (BWM) based MCDM framework. *Environmental Science and Pollution Research*, 28(16), 19677-19693. <https://doi.org/10.1007/s11356-020-11940-4>
- Ecer, F. (2022). An extended MAIRCA method using intuitionistic fuzzy sets for coronavirus vaccine selection in the age of COVID-19. *Neural Computing and Applications*, 34, 5603-5623. <https://doi.org/10.1007/s00521-021-06728-7>
- Ecer, F., Pamucar, D., Zolfani, S. H., & Eshkalag, M. K. (2019). Sustainability assessment of OPEC countries: Application of a multiple attribute decision making tool. *Journal of Cleaner Production*, 241, 118324. <https://doi.org/10.1016/j.jclepro.2019.118324>
- Erfanian, S., Zhou, Y., Razzaq, A., Abbas, A., Safeer, A. A., & Li, T. (2022). Predicting Bitcoin (BTC) price in the context of economic theories: A machine learning approach. *Entropy*, 24(10), 1487. <https://doi.org/10.3390/e24101487>
- Gradojevic, N., Kukolj, D., Adcock, R., & Djakovic, V. (2023). Forecasting Bitcoin with technical analysis: A not-so-random forest? *International Journal of Forecasting*, 39(1), 1-17. <https://doi.org/10.1016/j.ijforecast.2021.08.001>
- Guo, H., Zhang, D., Liu, S., Wang, L., & Ding, Y. (2021). Bitcoin price forecasting: A perspective of underlying blockchain transactions. *Decision Support Systems*, 151, 113650. <https://doi.org/10.1016/j.dss.2021.113650>

- Hafid, A., Ebrahim, M., Rahouti, M., & Oliveira, D. (2024). Cryptocurrency price forecasting using XGBoost regressor and technical indicators. *2024 IEEE International Performance, Computing, and Communications Conference (IPCCC)*. <https://doi.org/10.1109/IPCCC59868.2024.10850357>
- He, X., Li, Y., & Li, H. (2024). Revolutionizing Bitcoin price forecasts: A comparative study of advanced hybrid deep learning architectures. *Finance Research Letters*, 69, 106136. <https://doi.org/10.1016/j.frl.2024.106136>
- Hitam, N. A., & Ismail, A. R. (2018). Comparative performance of machine learning algorithms for cryptocurrency forecasting. *Indonesian Journal of Electrical Engineering and Computer Science*, 11(3), 1121-1128. <http://doi.org/10.11591/ijeecs.v11.i3.pp1121-1128>
- Hitam, N. A., Ismail, A. R., & Saeed, F. (2019). An optimized support vector machine (SVM) based on particle swarm optimization (PSO) for cryptocurrency forecasting. *Procedia Computer Science*, 163, 427-433. <https://doi.org/10.1016/j.procs.2019.12.125>
- Hua, Y. (2020). Bitcoin price prediction using ARIMA and LSTM. In *E3s Web of Conferences*, 218, 01050. <https://doi.org/10.1051/e3sconf/202021801050>
- Islam, M. S., Bashir, M., Rahman, S., Al Montaser, M. A., Bortty, J. C., Nishan, A., & Haque, M. R. (2025). Machine learning-based cryptocurrency prediction: Enhancing market forecasting with advanced predictive models. *Journal of Ecohumanism*, 4(2), 2498-2519. <https://doi.org/10.62754/joe.v4i2.6663>
- Karasu, S., Altan, A., Saraç, Z., & Hacıoğlu, R. (2018). Prediction of Bitcoin prices with machine learning methods using time series data. *2018 26th Signal Processing and Communications Applications Conference (SIU)*. <https://doi.org/10.1109/SIU.2018.8404760>
- Karğın, M., Yıldız, S. B., & Gözkonan, Ü. H. (2022). Kripto para piyasasında fiyat tahminlemesi: Bitcoin üzerine bir uygulama. *Geçmişten Günümüze Para, Banka ve Finans Tartışmaları* (ss. 132–143). Ekin Yayınevi.
- Kayalı, M. M., & Ünal, S. (2015). Piyasa mikro yapısı, finansal varlıkların likitidesi ve fiyatların oluşumu. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (12).
- Koç Ustalı, N., Tosun, N., & Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 1-16. <https://doi.org/10.17153/Oguibf.636017>
- Latif, N., Selvam, J. D., Kapse, M., Sharma, V., & Mahajan, V. (2023). Comparative performance of LSTM and ARIMA for the short-term prediction of Bitcoin prices. *Australasian Accounting, Business and Finance Journal*, 17(1), 256-276. <https://doi.org/10.14453/aabfj.v17i1.1>
- Labba Khaniki, M. A., & Manthouri, M. (2024). Enhancing price prediction in cryptocurrency using transformer neural network and technical indicators. *arXiv*. <https://doi.org/10.48550/arXiv.2403.03606>
- Lee, M. C., & Xu, R. J. (2025). Cryptocurrency price forecasting using deep learning model with technical indicators. *2025 International Conference on Electronics, Information, and Communication (ICEIC)*, IEEE. <https://doi.org/10.1109/ICEIC64972.2025.10879755>
- Lee, S. S., & Wang, M. (2024). Variance decomposition and cryptocurrency return prediction. *Journal of Financial and Quantitative Analysis*, 60(4), 1859-1890. <http://doi.org/10.1017/S002210902400022X>
- Liu, M., Zhang, D., Yang, X., & Wang, Y. (2021). Forecasting the price of Bitcoin using deep learning. *Finance Research Letters*, 40, 101728. <https://doi.org/10.1016/j.frl.2020.101755>
- Lyu, H. (2022). Cryptocurrency price forecasting: A comparative study of machine learning model in short-term trading. *Proceedings-2022 Asia Conference on Algorithms, Computing and Machine Learning* (ss. 280-288). <https://doi.org/10.1109/CACML55074.2022.00054>
- Mallqui, D. C. A., & Fernandes, R. A. S. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques. *Applied Soft Computing Journal*, 75, 596-606. <https://doi.org/10.1016/j.asoc.2018.11.038>
- Mbedzi, T. A. (2022). Share price prediction for increasing market efficiency using random forest [Doktora tezi]. University of Venda.
- Menéndez-García, L. A., García-Nieto, P. J., García-Gonzalo, E., & Sánchez Lasheras, F. (2024). Time series analysis for COMEX platinum spot price forecasting using SVM, MARS, MLP, VARMA and ARIMA models: A case study. *Resources Policy*, 95, 105148. <https://doi.org/10.1016/j.resourpol.2024.105148>
- Mittal, M., & Geetha, G. (2022). Predicting Bitcoin price using machine learning. *2022 International Conference on Computer Communication and Informatics* (ss. 1-7). <https://doi.org/10.1109/ICCCI54379.2022.9740772>
- Nagula, P. K., & Alexakis, C. (2022). A new hybrid machine learning model for predicting the Bitcoin (BTC-USD) price. *Journal of Behavioral and Experimental Finance*, 36, 100741. <https://doi.org/10.1016/j.jbef.2022.100741>

- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. <https://bitcoin.org/bitcoin.pdf> (Erişim Tarihi: 7 Haziran 2025).
- Omole, O., & Enke, D. (2024). Deep learning for Bitcoin price direction prediction: Models and trading strategies empirically compared. *Financial Innovation*, 10, 117. <https://doi.org/10.1186/s40854-024-00643-1>
- Özgür, A. S., Tarhan, Ç., Komesli, M., & Tecim, V. (2023). Yapay zekâ teknikleri kullanılarak proje üretim sistemlerinin tasarımı ve geliştirilmesi. *Journal of Information Systems and Management Research*, 5(1), 1-12.
- Penmetsa, S., & Vemula, M. (2023). Cryptocurrency price prediction with LSTM and transformer models leveraging momentum and volatility technical indicators. *2023 IEEE 3rd International Conference on Data Science and Computer Application (ICDSCA)* (ss. 411–418). <https://doi.org/10.1109/ICDSCA59871.2023.10393319>
- Phaladisailoed, T., & Numnonda, T. (2018). Machine learning models comparison for Bitcoin price prediction. *2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE)*, (ss. 506-511), IEEE. <https://doi.org/10.1109/ICITEED.2018.8534911>
- Ranjan, S., Kayal, P., & Saraf, M. (2023). Bitcoin price prediction: A machine learning sample dimension approach. *Computational Economics*, 61(4), 1617-1636. <https://doi.org/10.1007/s10614-022-10262-6>
- Rathan, R., Reddy, M. V., & Reddy, S. K. (2019). Crypto-currency price prediction using decision tree and regression techniques. *2019 Third International Conference on Trends in Electronics and Informatics (ICOEI)* (ss. 938-942). <https://doi.org/10.1109/ICOEI.2019.8862585>
- Somayajulu, M. V. N. S. S. R. K., Ahmed, M., & Kotaiah, B. (2025). Bitcoin price prediction using LSTM and CNN. *SSRN Electronic Journal*, 5190840. <https://doi.org/10.2139/ssrn.5190840>
- Sakız, B., & Kutlugün, E. (2018). Bitcoin price forecast via blockchain technology and artificial intelligence algorithms. *2018 26th Signal Processing and Communications Applications Conference (SIU)*. <https://doi.org/10.1109/SIU.2018.8404719>
- Salb, M., Elsadai, A., Živković, M., & Bačanić Džakula, N. (2021). Cryptocurrency forecasting using optimized support vector machine with sine cosine metaheuristics algorithm. *In Singidunum University International Scientific Conference* (ss. 315-321). <https://doi.org/10.15308/Sinteza-2021-315-321>
- Yavuz, U., Özen, Ü., Taş, K., & Çağlar, B. (2020). Yapay sinir ağları ile blockchain verilerine dayalı bitcoin fiyat tahmini. *Journal of Information Systems and Management Research*, 2(1), 1-9.
- Zhao, D., Rinaldo, A., & Brookins, C. (2019). Cryptocurrency price prediction and trading strategies using support vector machines. *arXiv.org*, 1911.11819. <https://doi.org/10.48550/arXiv.1911.11819>