

# Kripto Piyasalarında Genetik ve Makine Öğrenmesi Algoritmaları ile Performans Karşılaştırması\*

## Performance Comparison of Genetic and Machine Learning Algorithms in Crypto Markets

Berna Yaman Şahin<sup>1</sup> , Sema Ulutürk Akman<sup>2</sup> 

<sup>1</sup>(Dr.), İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, İstanbul, Türkiye

<sup>2</sup>(Prof. Dr.), İstanbul Üniversitesi, İktisat Fakültesi, İstatistik Anabilim Dalı, İstanbul, Türkiye

\*Bu çalışma, sorumlu yazarın İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Doktora Programı kapsamında yazmış olduğu “Genetik ve Makine Öğrenmesi Algoritmaları ile Kripto Varlıklar için AI-Sat Kararı Veren Model Çalışması” başlıklı doktora tezinden türetilmiştir.

### ÖZ

Araştırma alanında kullanılan analiz yöntemlerine yönelik istatistiksel metotların gelişmesi, analiz ve öngörü tekniklerinin çeşitlenmesine önemli bir katkıda bulunmuştur. Bu kapsamda, özellikle matematiksel ve istatistiksel metodolojiler kullanarak verilerden anlamlı çıkarımlar yapabilen ve bu çıkarımları kullanarak birtakım tahminlerde bulunan makine öğrenmesi, yapay zekâ alanında önemli bir gelişme kaydetmiştir. Makine öğrenmesi, bir veri setini modele dönüştüren çeşitli algoritmaları kapsar ve bu algoritmalar, analiz ve öngörü süreçlerinde temel bir disiplin olarak öne çıkmaktadır. Bu çalışma, kripto para piyasasında genetik algoritma ile optimize edilmiş MACD parametrelerini, makine öğrenmesi yöntemleri ve teknik analiz göstergeleri ile birleştirerek, 24 saat sürekli işlem gören kripto piyasasında yüksek doğrulukta alım ve satım sinyalleri üretmeyi amaçlamaktadır. Bu bağlamda farklı makine öğrenmesi algoritmalarının performansları karşılaştırılmış ve genetik algoritma ile optimize edilerek en uygun modele ulaşılmaya çalışılmıştır. Sonuç olarak, optimize edilmiş MACD parametreleri kullanılarak yapılan işlemlerin, optimize edilmemiş MACD parametreleriyle yapılanlardan daha iyi kârlılık sağladığı gözlemlenmiştir. Modelin, LTCUSDT çiftinde daha iyi performans sergilediği sonucuna varılmıştır. Özellikle derin öğrenme algoritmasının LTCUSDT paritesinde daha iyi kâr elde edebildiği ancak, modelin ADAUSDT çiftinde kâr elde edemediği görülmüştür. Bunun sebebi de kripto piyasasının volatilitesinin yüksek, istikrarsız ve güncel haberlere olumlu/olumsuz çok hızlı tepki vermesinden kaynaklanmaktadır. Buradan yola çıkarak geliştirilen modelin farklı kripto para çiftlerine farklı derecelerde uyduğu sonucuna varılmıştır.

### ABSTRACT

The evolution of statistical methodologies for research analysis has notably contributed to the diversification of analytical and predictive techniques. Notably, machine learning, which leverages mathematical and statistical approaches to draw meaningful inferences from data, has made remarkable strides in artificial intelligence, generating predictions based on these inferences. Encompassing a spectrum of algorithms that transform datasets into models, machine learning emerges as a cornerstone in analytical and predictive processes. Herein, we produce high-accuracy buying and selling signals in the cryptomarket—a market that continuously operates 24 h a day. This is achieved by integrating MACD (Moving Average Convergence Divergence) parameters optimized with a genetic algorithm specific to the cryptocurrency market, machine learning methods, and technical analysis indicators. Contextually, we compared the performances of different machine learning algorithms. Using genetic algorithm optimization, we identified the most suitable model. Results underscore the enhanced profitability of trades executed with optimized MACD parameters compared with those executed using nonoptimized MACD parameters. The model performed optimally on the LTCUSDT pair. Notably, the deep learning algorithm exhibited better profitability in the LTCUSDT pair. However, its effectiveness in generating profits in the ADAUSDT pair was somewhere limited; this can be attributed to the high volatility, instability, and rapid response of the cryptomarket to current news, whether positive or negative. Therefore, the developed model fits different cryptocurrency pairs to varying degrees.

**Anahtar Kelimeler:** Makine Öğrenmesi Algoritmaları, Genetik Algoritma, Kripto Para, Derin Öğrenme, Karar Ağacı

**Corresponding Author:** Berna Yaman Şahin **E-mail:** berna.yamansahin@gmail.com

**Submitted:** 28.12.2023 • **Revision Requested:** 29.01.2024 • **Last Revision Received:** 12.02.2024 • **Accepted:** 29.02.2024 • **Published Online:** 15.05.2024



This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

**Keywords:** machine learning algorithms, genetic algorithm, cryptocurrency, deep learning, decision tree

### EXTENDED SUMMARY

Machine learning algorithms are increasingly being embraced for their easy implementation and effective outcomes, particularly in financial predictions. In financial applications, these algorithms have emerged as potent tools for information processing and analysis, particularly in trading strategies, price predictions, and portfolio management. Deep learning algorithms excel in creating high-performance classification models, especially in complex datasets. Decision tree algorithms are suitable for solving classification and regression problems, whereas genetic algorithms have emerged as optimal methods for addressing complex problems, optimization, and modeling systems related to randomness.

We aim to produce high-accuracy buying and selling signals in the cryptomarket, operating continuously 24 hours a day. The approach combines MACD parameters, optimized with a genetic algorithm in the cryptocurrency market, machine learning methods, and technical analysis indicators. Machine learning algorithms are essential tools that transform datasets into models. We compared the performances of different machine learning algorithms.

Furthermore, we examine the results obtained by optimizing the performance of these algorithms using genetic algorithms. The data collection process commenced by obtaining candlestick data for ADAUSDT and LTCUSDT assets through the API of Binance Crypto Exchange. A 1-h candlestick chart was used for the analysis, spanning November 9, 2021, to November 22, 2022. Each candlestick data item includes information such as transaction time, opening, closing, high values, low values, and trading volume. The candlestick data were separated into optimization and test data. The optimization data were created by adding CMF, RSI, Z-SCORE, ATR, BOP, CMO, and CC INDICATOR signals during the strategy generation phase. Next, this dataset was divided into machine learning training and test data. Long and short trading signals were established based on MACD and Signal line crossovers, and a decision column was added.

During the optimization phase, the parameters of the MACD indicator were optimized using a genetic algorithm. The MACD indicator uses the default parameters of 12, 26, and 9. Employing the NSGA-II genetic algorithm, the optimal parameter values for the MACD indicator were calculated over 25 cycles. Subsequently, optimized MACD parameters were identified for ADAUSDT and LTCUSDT based on the test results. Backtesting was performed using the optimized MACD parameters to obtain gain and profitability ratios. Upon examining the accuracy rates of various machine learning algorithms, deep learning exhibited the highest accuracy rate.

The optimized MACD parameters, training data of the most suitable machine learning algorithm, and the test data were consolidated. The test data were evaluated by backtesting, employing optimized MACD parameters and trained machine learning algorithms; this process revealed the profit rate and profitability. The results indicate a high gain ratio and profitability in the LTCUSDT asset when optimized MACD parameters and a deep learning algorithm were employed. However, for the ADAUSDT asset, the combination failed to generate a profit. This highlights that the success of certain combinations of assets and strategies may vary depending on market conditions. Therefore, for effective implementation of the proposed model, each asset's strategy needs careful evaluation.

In backtests focusing on ADAUSDT and LTCUSDT cryptocurrency pairs, long–short trades using optimized MACD parameters yielded higher profits than trades executed with nonoptimized settings. The default MACD parameters typically involve three parameters: a fast period of 12, a slow period of 26, and a correction period of 9. However, the averages obtained from the optimization process deviated noticeably from these standard values, suggesting that investors engaged in cryptoasset trading may benefit from an indicator responding rapidly to market dynamics.

Additionally, owing to the volatile nature of cryptoassets, the application of machine learning algorithms poses challenges in accurately determining profits and losses before ensuring a clear data separation. This underscores the risk of exposure to sudden price fluctuations in cryptoassets. In conclusion, this study found that long–short trades using optimized MACD parameters do not always yield optimal results. However, profitability can be enhanced by leveraging machine learning algorithms to filter out data leading to losses. Notably, the developed model demonstrated better compatibility with the LTCUSDT pair than the ADAUSDT, showcasing a profit of 93.55% in the LTCUSDT pair. These results underscore the potential advantages of integrating machine learning and technical analysis in the cryptocurrency market.

## Giriş

Makine öğrenimi, yapay zekanın bir alt dalı olarak dikkat çeken bir teknolojidir. Özellikle matematiksel ve istatistiksel yöntemleri kullanarak verilerden çıkarımlar yapar ve öngörülerde bulunur. Bu çalışma, yaygın olarak kullanılan makine öğrenimi algoritmalarını inceleyerek, performanslarını genetik algoritma ile optimize ederek karşılaştırmaktadır. Farklı yaklaşımlarla başarıları değişen bu algoritmalar, sınıflandırma, tahmin ve kümeleme gibi problemlerde farklı sonuçlar ortaya koymaktadır.

Finansal piyasa tahminleri günümüzde büyük bir ilgi odağı olmuştur. Kripto para piyasası, son yıllarda hızlı bir evrim geçirmiş ve geleneksel finans dünyasında yeni bir varlık sınıfı olarak yerini almıştır. Ancak, bu dinamik piyasa volatilitesi ve karmaşıklığıyla tanınmaktadır. Kripto para piyasalarının tahmin edilmesi, kısa vadeli büyük kârların yanı sıra büyük riskleri de beraberinde getirmektedir. Bu bağlamda, kripto varlıkları üzerinde etkili ticaret stratejileri geliştirmek, karar alma süreçlerini iyileştirmek ve piyasa hareketlerini öngörmek, yatırımcılar için kritik öneme sahiptir. Bu çalışma, geleneksel teknik analiz göstergelerini makine öğrenmesi yöntemleriyle birleştirerek ve genetik algoritma ile optimize ederek, 24 saat boyunca işlem gören kripto para piyasasında doğruluk oranı yüksek alım-satım sinyalleri üretmeyi amaçlamaktadır. Kripto varlıkların hassas ve ani fiyat değişimleri, teknik analiz ve makine öğrenmesi modellerinin entegrasyonunu zorunlu kılmaktadır. Bu kapsamda, çalışmada çeşitli makine öğrenmesi algoritmaları incelenmiş, performansları karşılaştırılmış ve genetik algoritma kullanılarak bu algoritmaların optimize edilmesi üzerinde durulmuştur. Finansal piyasalardaki karmaşık ilişkileri anlamak için geliştirilen bu model, yatırımcılara daha bilinçli kararlar alma imkânı sunmayı hedeflemektedir.

Çalışma, Ada ve Litecoin çiftleri üzerinden yapılan geriye dönük testlerle bir modelin önerildiği bir çerçeveye sunmaktadır. Bu model, optimize edilmiş Hareketli Ortalama Yakınsama Sapması (Moving Average Convergence Divergence- MACD) parametreleri kullanılarak elde edilen işlemlerin, optimize edilmemiş parametrelerle yapılan işlemlerden daha iyi performans gösterdiğini göstermektedir. Ancak, kripto varlıklarına özgü volatiliteyi ve dış etkenlere bağlı olarak modellerin etkinliği üzerinde belirleyici olan faktörleri anlamak oldukça önemlidir. Bu nedenle, çeşitli makine öğrenmesi algoritmalarının yanı sıra genetik algoritma ile optimize edilmiş stratejilerin performans karşılaştırmaları, yatırımcılara daha güvenilir ticaret kararları alma konusunda rehberlik etmektedir.

## Literatür Taraması

Makine öğrenmesi algoritmalarının çok yönlü kullanımı, pek çok sektörde önemli bir rol oynamaktadır. Her geçen gün daha fazla kabul gören bu yöntem, kolay uygulanabilirliği ve etkili sonuçlarıyla öne çıkmaktadır. Finansal piyasalarda makine öğrenmesi uygulamalarına dair literatürde yer alan çalışmalar, bu alandaki önemli gelişmeleri yansıtmaktadır.

Pai & Wei (2007), gerçekleştirmiş oldukları çalışmada Tayvan hisse senedi endeksi vadeli işlem fiyatlarının hareket yönlerini öngörmek amacıyla teknik göstergeler içeren alım satım verilerini değerlendirmişlerdir. Destek Vektör Makinesi yöntemini kullanmışlardır. Analiz sonuçları, SVM modelinin, veri ölçekleme ve farklılaştırma işlemleri uygulandığında en etkili performansı sergilediğini göstermiştir.

Choudhry & Garg (2008), çalışmalarında hisse senedi piyasası tahminleri için Genetik Algoritma (GA) ve Destek Vektör Makineleri (SVM) temelli bir hibrit makine öğrenme sistemi önermişlerdir. Yapılan analizler sonucunda, hibrit GA-SVM sisteminin bağımsız SVM sistemine kıyasla daha üstün bir performans sergilediği sonucuna ulaşmışlardır.

Kara vd. (2011), yaptıkları çalışmada iki etkin model geliştirmeye yönelik bir çalışma sürdürmüşler ve İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi'ndeki hareketin yönünü tahmin etme performanslarını karşılaştırmışlardır. Yapılan analizde yapay sinir ağları ve destek vektör makinesi yöntemlerine odaklanılmıştır. Sonuçlar, Yapay Sinir Ağı (YSA) modelinin ortalama performansının (%75,74) Destek Vektör Makinesi (SVM) modelinden (%71,52) önemli ölçüde daha iyi olduğunu göstermiştir.

Qiu & Song (2016), çalışmalarında günlük borsa endeksinin yönünü tahmin etmek amacıyla iki temel girdi değişkeni türünü karşılaştırmışlardır. Japon borsa endeksinin ertesi günkü fiyatının yönünü tahmin etmek için optimize edilmiş bir yapay sinir ağı (YSA) modeli kullanmışlardır. Araştırmanın sonuçları, Tip 2 girdi değişkenlerinin daha yüksek tahmin doğruluğu sağlayabildiğini ve girdi değişkenlerini uygun şekilde seçerek optimize edilmiş YSA modelinin performansını artırmanın mümkün olduğunu göstermişlerdir.

Aguirre, Medina, & Méndez (2020), gerçekleştirdikleri çalışmada hisse senedi piyasasında varlık fiyatlarının tahmininde Genetik Algoritmaları kullanarak, geleneksel teknik analize karşı avantajları araştırmayı amaçlamışlardır. Sonuçlar, Genetik Algoritmalar aracılığıyla daha yüksek bir yatırım getirisi elde eden teknik gösterge parametrelerinin optimal değerlerinin bulunabileceğini ve geleneksel teknik analizi ile AI ve Tut stratejisini yaklaşık %4 oranında geride bırakabildiğini önermektedir.

Demirel & Hazar (2021), çalışmalarında 2016-2020 yılları arasında yüksek piyasa değerine ve işlem hacmine sahip kripto varlıkların günlük piyasa değerleri kullanılarak, BIST 100 endeksinin hareket yönünü tahmin etmeyi hedeflemişlerdir. Analizde, Bitcoin, Ethereum ve Ripple gibi geçmiş piyasa değerleri, destek vektör makinelerinin eğitiminde kullanılan girdi değişkenlerdir. Üç farklı model oluşturularak, optimizasyon sağlanmaya çalışılmıştır. Model B'nin performans skoru %52 olarak belirlenmiştir.

Latha & Sreekanth vd. (2022), K-En Yakın Komşu (KNN) algoritmasını kullanan bir makine öğrenimi modeline dayalı olarak borsa tahmini önerdikleri çalışmada elde ettikleri sonuçlar, %70 daha yüksek bir doğruluk göstermiştir.

Pabuçcu vd. (2023), Bitcoin fiyatlarının hareketlerini yüksek doğrulukla tahmin etmeyi amaçladıkları çalışmada, lojistik regresyonun yanı sıra Destek Vektör Makineleri (SVM), Yapay Sinir Ağı (ANN), Naive Bayes (NB) ve Rastgele Orman (RF) gibi dört farklı Makine Öğrenimi (ML) algoritması uygulanmıştır. Analiz sonuçları, RF'nin en yüksek tahmin performansına sahip olduğunu, NB'nin ise en düşük tahmin performansına sahip olduğunu göstermiştir.

Şenol & Denizhan (2023), yapmış oldukları çalışmada yüksek işlem hacmine sahip olan Bitcoin, Ethereum ve Cardano gibi üç kripto para üzerinde fiyat tahmini gerçekleştirmişlerdir. Çalışmanın amacı, çoklu regresyon analizi ve yapay sinir ağlarının performansını değerlendirmektir. Analiz sonuçları, Yapay Sinir Ağları ile yapılan tahminlerin Regresyon Analizi ile yapılanlara kıyasla daha başarılı bir performans sergilediğini göstermiştir.

## Metodoloji

### Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt kümesi olarak karşımıza çıkmaktadır. Derin öğrenme sınıflandırması, yapay sinir ağlarının çalışma mantığı ile aynıdır. İnsanların büyük miktardaki verileri anlamaları ve işlemeleri yıllar sürebilirken, derin öğrenme bu işlemi birkaç saniye içerisinde başarabilmektedir. Özellikle karmaşık ve büyük veri setlerinde yüksek performanslı sınıflandırma modelleri oluşturmak için derin sinir ağları kullanılmaktadır. Bu yöntem, makine öğrenimi alanında etkili sonuçlar vermektedir.

Derin öğrenme, aşağıdaki bağlamlarda kullanılabilir (Olorunnimbe ve Viktor, 2023:2086):

- Ticaret Stratejisi: Borsada alım ve satım kararları almak için algoritmik olarak oluşturulan yöntemler veya prosedürler.
- Fiyat Tahmini: Finansal varlıkların, özellikle hisse senetlerinin gelecekteki değerlerinin tahmin edilmesi. Bu genellikle bir ticaret stratejisi olarak kullanılır.
- Portföy Yönetimi: Uzun vadeli kar elde etmek için bir grup finansal varlığın seçilmesi ve yönetilmesi.
- Piyasa Simülasyonu: Çeşitli piyasa senaryoları altında piyasa verilerinin simülasyonu.
- Hisse Senedi Seçimi: Gelecekteki getirilere dayalı olarak borsadaki hisse senetlerinin seçilmesi. Bu genellikle bir ticaret veya portföy yönetimi stratejisi olarak kullanılır.
- Risk Yönetimi: Alım satımla ilgili risklerin değerlendirilerek getirileri en üst düzeye çıkarmak.
- Riskten Korunma Stratejisi: Bir varlığa yatırım yapma riskini azaltmak için başka bir varlıkta ters bir yatırım pozisyonu almayı içeren strateji.

### Yapay Sinir Ağları (Artificial Neural Networks- ANN)

Yapay sinir ağları, derin öğrenme alanında temel bir yapı taşı olarak kullanılmaktadır. Biyolojik sinir ağlarını taklit eden yapay bir modeldir. Bu yapay zekâ yapıları, birbirine bağlı işlem yapılarını kullanarak yeni bilgiler üretme ve hiç görmediği durumlarla karşılaştığında kararlar verebilme yeteneğine sahiptir (Karadağ, 2022:40). Bir yapay sinir ağında üç temel katman bulunmaktadır (Yavuz ve Deveci, 2012:172):

**Girdi Katmanı (Input Layer):** İlk katmandır. Dışarıdan gelen verileri kabul eder. Her bir giriş, bir yapay sinir hücresine bağlanır.

**Gizli Katmanlar (Hidden Layers):** Gizli katmandaki nöronlar, dış ortamla doğrudan bir bağlantıya sahip değildirler. Girdi katmanı ile çıktı katmanı arasında bulunur ve birbirine bağlı olan yapay sinir hücrelerinden oluşur. Sadece girdi katmanından gelen sinyalleri alıp, bunları işleyerek çıktı katmanına iletir.

**Çıktı Katmanı (Output Layer):** Son katmandır. Ağın nihai çıktılarını üreten katmandır. Problem tipine göre tek bir çıktı hücresi veya birden fazla çıktı hücresi olabilir.

Girdileri alır, gizli katmanlardaki ağırlıklı toplamlarla birbirine bağlanmış düğümlerden geçirir ve ardından bir çıktı üretir (Odabaşı ve Toklu, 2023:98).

### Karar Ağaçları

Bir denetimli öğrenme tekniği olan karar ağacı algoritması hem sınıflandırma hem de regresyon problemlerinde sıklıkla başvurulan yöntemlerden biridir. Bu algoritma data setlerindeki karmaşıklıkları ele almak için kullanılan uygun bir algoritmadır ve ağaç tabanlı bir yapıya sahiptir. Karar ağaçları bilgiyi bir ağaç yapısında modelleme yaklaşımına dayanmaktadır. Bir karar ağacında karar ve yaprak düğümü olmak üzere iki düğüm bulunmaktadır. Dallar karar düğümlerini temsil ederken yapraklar sonuç düğümlerini temsil etmektedir. Her bir dalı, programlama dilinde bulunan "eğer" yapısına uygun olarak ayrılmış olan karar ağacı,

analiz edilen veriyi tüm modele entegre etmektedir. Bu kapsamda çeşitli sınıflandırma problemlerini etkili bir şekilde çözmek için karar ağaçları kullanılabilir. Karar ağacı modellerinin diğer yöntemlere göre daha hızlı sonuç vermesi ve veriler arasındaki ilişkileri yapısallıkla göstermesi, tercih edilmesinde önemli bir etken olarak öne çıkmaktadır (Sel, 2020:90).

Karar ağacı yöntemi, veri sınıflandırmasını iki aşamalı bir süreç olarak gerçekleştirir: öğrenme ve sınıflandırma. Öğrenme aşamasında, sınıflandırma algoritması eğitim verilerini inceleyerek bir model oluşturur. Bu model, sınıflandırma kuralı veya karar ağacı şeklinde ifade edilir. Sınıflandırma aşamasında ise, bu kurallar veya karar ağacı, test verileri kullanılarak doğruluğunu değerlendirmek için uygulanır. Eğitim verilerinde kullanılacak alanlar ve ağacın oluşturulma sırası, belirlenmesi gereken önemli faktörlerdir. Bu bağlamda, en yaygın kullanılan ölçü, entropi ölçüsüdür. Yüksek entropi, sonuçların belirsiz ve kararsız olduğunu gösterir. Bu nedenle, karar ağacının kökündeki en düşük entropiye sahip alanlar öncelikli olarak kullanılır (Çalış ve ark., 2014: 6).

Karar ağaçlarında yaygın olarak kullanılan algoritma nitel değişkenler için entropidir (Gupta vd., 2017).

### ID3 (Iterative Dichotomiser 3) Algoritması

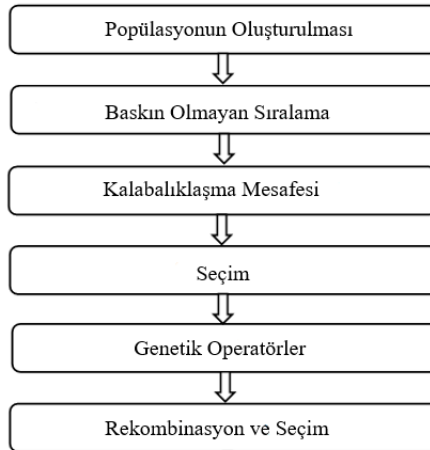
ID3, J. R. Quinlan tarafından geliştirilen ve karar ağaçlarını oluşturmak için kullanılan ilk algoritmadır. Sınıflandırma problemleri için kullanılabilir etkili bir algoritmadır.

ID3 algoritması, özellik değerlerini test ederek nesnelere sınıflandırmak için kullanılmaktadır. Verilen bir veri setinden başlayarak, üstten aşağıya bir karar ağacı oluşturur. Her düğümde, bilgi kazancı (information gain) maksimize etmek ve entropiyi minimize etmek için bir özellik test edilir ve sonuçlar nesnelere gruplamak için kullanılır. Bilgi kazancı, bir özneliğin bir veri kümesini ne kadar iyi böleceğini ölçmektedir. Bu işlem, grup homojen olana kadar tekrarlanır ve bu, karar ağacının bir yaprak düğümüne ulaştığı noktada sona erer (Singh & Gupta, 2014:50-51).

### Genetik Algoritma

Genetik algoritmalar, yapay zekâ alanının önemli bir bileşenidir ve büyük bir potansiyele sahiptir. Genetik algoritmalar 1960'larda John Holland tarafından tasarlanmıştır. Holland'ın 1975 tarihli "Doğal ve Yapay Sistemlerin Uyumu" adlı kitabı, genetik algoritmayı biyolojik bir evrim soyutlaması olarak tanıtmıştır ve Genetik algoritma kapsamında uyarılma için teorik bir temel sağlamıştır (Holland, 1992). Bu algoritmalar, doğal seleksiyon ve doğal genetik kavramlarına dayanan arama algoritmalarıdır. Aynı zamanda bir optimizasyon algoritmasıdır. Genetik algoritmalar, karmaşık sorunların çözümünde oldukça etkilidir. Özellikle optimizasyon problemleri ve rastgelelikle ilgili modelleme sistemlerinde kullanılmaktadır (Kumar ve Husian vd., 2010:451).

Genetik algoritmaların temel adımları aşağıdaki gibidir (Kim & Shin, 2007:573):



Şekil 1. Genetik Algoritmanın Temel Adımları

Genetik algoritma, en iyi çözümü bulma amacıyla doğal seçim ve kalıtım süreçlerini taklit eden bir algoritmadır.

### NSGA-II (Non-dominated Sorting Genetic Algorithm II - Baskın Olmayan Sıralamalı Genetik Algoritma II)

NSGA-II, genetik algoritma tabanlı bir optimizasyon algoritmasıdır. NSGA-II, genetik algoritma adımlarını kullanarak çok amaçlı optimizasyon problemlerinde çözüm kümesinin kalitesini artırmayı amaçlamıştır. Karar verme problemlerinde ve karmaşık sistem optimizasyonu dahil olmak üzere çeşitli uygulamalar için yararlı bir yaklaşımdır. (Chatterjee vd., 2018).





### Mum Verilerin Elde Edilmesi

ADAUSDT ve LTCUSDT varlıklarına ait mum grafiği verileri, Binance Kripto Borsası'nın API (Application Programming Interface) aracılığıyla toplanmıştır. Bu uygulamada, analiz için 1 saatlik mum grafiği kullanılmıştır. Mum verileri, ADAUSDT ve LTCUSDT'nin düşüş yaşamaya başladığı 9 Kasım 2021- 22 Kasım 2022 tarih aralığını kapsamaktadır. Her bir mum grafiği verisi satırında işlem zamanı, açılış, kapanış, yüksek, düşük ve işlem hacmi bilgileri bulunmaktadır. Bu veriler, belirtilen tarih aralığında ADAUSDT ve LTCUSDT varlıklarının fiyat hareketlerini detaylı bir şekilde içermektedir.

### Optimizasyon ve Test Verilerinin Elde Edilmesi

Mum verileri elde edildikten sonra, 2/3 oranında optimizasyon ve 1/3 oranında da test verisi olarak ikiye ayrılmıştır.

**Tablo 1.** Analizde Kullanılan Göstergeler

CMF (Chaikin Money Flow)	:	Chaikin Para Akışı Göstergesi
RSI (Relative Strength Index)	:	Görelî Güç Endeksi Göstergesi
Z-SCORE	:	Z-Skor Göstergesi
ATR (Average True Range)	:	Ortalama Gerçek Aralık Göstergesi
BOP (Balance of Power)	:	Güç Dengesi Göstergesi
CMO (Chande Momentum Oscillator)	:	Chande Momentum Osilatörü Göstergesi
CC (Coppock Curve)	:	Coppock Eğrisi Göstergesi

Optimizasyon verisine, strateji oluşturma aşamasında CMF, RSI, Z-SCORE, ATR, BOP, CMO, CC GÖSTERGE sinyalleri eklenmiştir.

Optimizasyon verisi de kendi içerisinde 2/3 oranında "Makine Öğrenmesi Eğitim Verisi" ve 1/3 oranında "Makine Öğrenmesi Test Verisi" olarak ikiye ayrılmıştır. Bu işlemler tamamlandıktan sonra, Id, Açılış, Kapanış, Yüksek, Düşük, Hacim, CMF, RSI, Z Score, ATR, BOP, CMO, CC, MACD, Sinyal, Histogram değerleri olan veri seti elde edilmiştir.



**Şekil 4.** Uzun ve Kısa İşlemlerin Mum Grafik Üzerinde Gösterilmesi

"MACD" ve "Sinyal" işaretlerinin birbirini kesmesine göre uzun ve kısa işlem sinyalleri veri çerçevesine eklenmiştir. "MACD" işareti, "Sinyal" işaretini yukarı yönlü kestiği an "uzun", "MACD" işareti, "Sinyal" işaretini aşağı yönlü kestiği an "kısa" işlem ve diğer durumlarda işlem olamayacak şekilde bir "karar" (decision) sütunu oluşturulmuştur.

Ada ve Litecoin için özet istatistikî bilgiler şu şekildedir:

- 9 Kasım 2021 tarihinde ADA kripto varlığının değeri 2.3146 USDT dir. 22 Kasım 2022 tarihinde ise 0.2976 USDT dir. İlgili tarihler arasında %87,14 'lük bir düşüş sergilemiştir.
- 9 Kasım 2021 tarihinde LTC kripto varlığının değeri 291,09 USDT dir. 22 Kasım 2022 tarihinde ise 60.25 USDT dir. İlgili tarihler arasında %79,3 'lük bir düşüş sergilemiştir.

Analizde kullanılan gözlem sayılarına aşağıdaki tabloda yer verilmiştir:

**Tablo 2.** Analizde Kullanılan Gözlem Sayıları

<b>Toplam Gözlem Sayısı</b>	:	9074
<b>Optimizasyon Verisi</b>	:	6048
Makine Öğrenmesi Eğitim Verisi	:	4032
Makine Öğrenmesi Test Verisi	:	2016
<b>Test Verisi</b>	:	3026

### MACD Optimizasyonu ile Geriye Yönelik Test

İçerisinde göstergelerin ve karar sütununun bulunduğu mum grafiği verileri, optimizasyon aşamasına gönderilmiştir. Optimizasyon aşamasında, MACD göstergesine ait parametrelerin (hızlı, yavaş, düzeltme) optimizasyonu sağlanmıştır. MACD göstergesi varsayılan 12, 26, 9 parametrelerini kullanmaktadır. NSGA-II genetik algoritması ile, toplam 25 döngüde MACD indikatörünün optimum parametre değerleri hesaplanmıştır. Bu uygulamada, varsayılan MACD parametreleri ile işlem yapmak yerine, ilgili kripto varlığa ait, karlılığı maksimize eden MACD parametreleri ile işlem yapılması hedeflenmiştir.

Geriye yönelik testte, elde belirli bir miktar nakit olduğu kabul edilir. Stratejinin oluşturulması sırasında, elde edilen karar sütunu ilk satırdan itibaren incelenir. "Uzun" veya "Kısa" işlem kararı alındığında, mevcut nakit oranında o anki mum kapanış verisine göre varlık satın alınır. Karar sütunu taranmaya devam eder, sonraki "uzun" veya "kısa" işlemde varlık satılır ve bu satışın ardından belirlenen işarete göre (uzun veya kısa) yeni bir işleme girilir. Bu işlem, tüm mum grafiği satırları tamamlanana kadar tekrarlanır. Tüm satırlar incelendikten sonra geriye yönelik test, iki ana çıktı üretir:

- **Kazanç oranı:** Gerçekleştirilen n adet işlemin yüzde kaçının kazançlı sonuçlandığını gösteren bir çıktıdır. Bu sonuç, 0 ile 100 arasında bir değer alır.
- **Kârlılık:** Geriye yönelik testte yatırım için kullanılan paranın yüzde kaçının kar sağladığını ifade eder. Bu sonuç, 0 ile sonsuz arasında bir değer beklenir.

Algoritma, her iterasyonda, bir öncekinden daha optimum değerleri hesaplayarak pareto çizgisini oluşturur. Bu çizgide birden fazla değer bulunabilir bu nedenle çizgideki bir değer, optimum değer olarak kullanılabilir. Yatırımda, kârın maksimizasyonu her zaman önceliklidir. Bu nedenle, optimizasyon sonucunda elde edilen çözüm kümesi içinde öncelikle en yüksek kârlılığa sahip olan, ardından en yüksek kazanç oranına sahip olan MACD parametreleri seçilmiştir. Uygulamada test edilen kripto varlıklar için optimize edilmiş MACD parametreleri Tablo 3'te ayrıntılı olarak sunulmuştur.

**Tablo 3.** Kripto Varlıklara Ait Optimize Edilmiş MACD Parametre Değerleri

	<b>Hızlı</b>	<b>Yavaş</b>	<b>Düzeltilme</b>
<b>ADAUSDT</b>	8.1740	22.4026	5.2920
<b>LTCUSDT</b>	8.1740	23.2559	5.9233

Optimizasyon sonuçlarına göre, ADAUSDT ve LTCUSDT kripto varlıkları için hızlı, yavaş ve düzeltme periyotları belirlenmiştir.

### Geriye Yönelik Test ve Makine Öğrenmesi

Optimize edilmiş MACD parametreleri, "uzun" ve "kısa" işlemlerin zamanlarını doğal olarak değiştirmiştir. Optimizasyon verileri kullanılarak elde edilen optimum MACD parametreleri ile geriye yönelik test gerçekleştirilmiş ve 'kâr' ve 'zarar' verileri elde edilmiştir. Bu göstergeler, işlem tipi (uzun, kısa) ve sonuç (kazanç, kayıp) verilerini içeren bir tabloya kaydedilerek makine öğrenmesi veri seti oluşturulmuş ve bu veriler 2/3 eğitim ve 1/3 test verisi olarak ayrılmıştır.



Optimizasyon veri seti üzerinde makine öğrenmesi sınıflandırma algoritması kullanılarak zarar ettiren alım ve satış sinyallerinin ayıklanması hedeflenmiştir. Bu amaçla, öncelikle optimizasyon verisinin geriye yönelik testi gerçekleştirilmiştir. Geriye yönelik test sırasında, alım anındaki pozisyon, MACD, CMF, RSI, ZSCORE, ATR, BOP, CMO, CC ve sonuç verileri satırlar halinde bir tabloya kaydedilerek makine öğrenmesi veri seti oluşturulmuştur. Bu set, 2/3 oranında eğitim veri seti ve 1/3 oranında test veri seti olarak ikiye ayrılmıştır. Burada, alım esnasındaki CMF, RSI, ZSCORE, ATR, BOP, CMO, CC göstergeleri ile yanlış alım kararların elenebileceği değerlendirilmektedir.

Makine öğrenmesi veri setinde, kategorik veriler aşağıdaki gibi yeniden ifade edilmiştir:

- Uzun (long) :0
- Kısa (short) :1
- Kazanç (profit) :0
- Kayıp (loss) :1

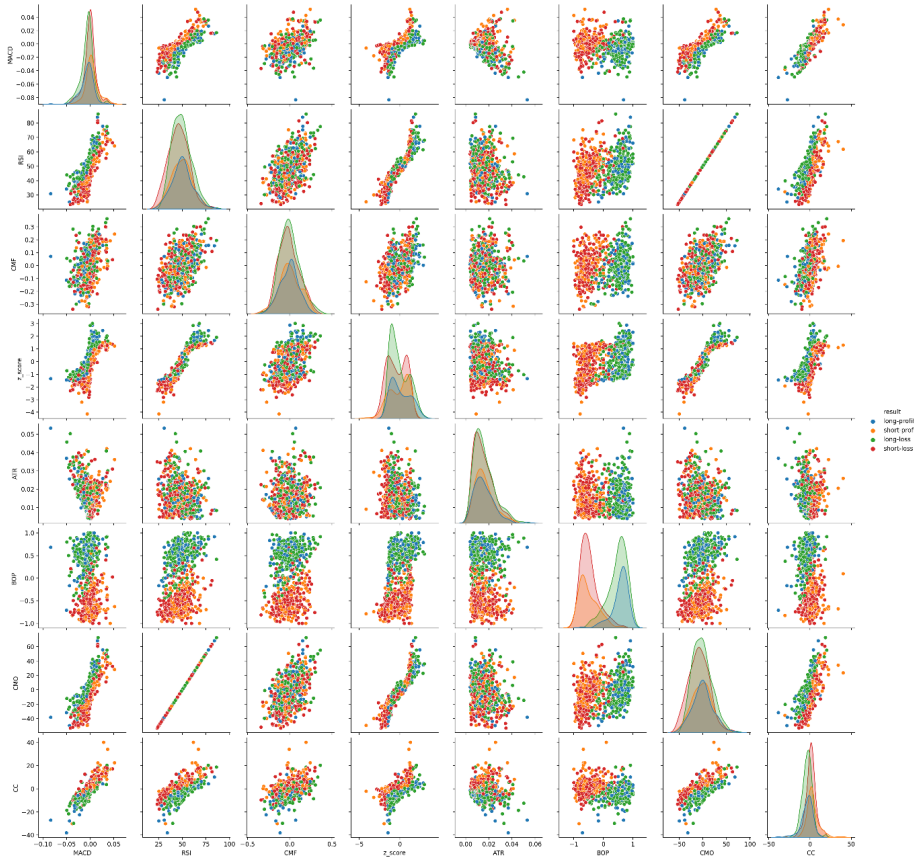
Eğitim verileri ile Karar Ağaçları ve Derin Öğrenme sınıflandırma algoritmaları eğitim ve test sürecine tabi tutulmuştur. Test süreci, ayrılan 1/3 test verisi ile gerçekleştirilmiş, bu süreçte hata matrisi oluşturulmuş ve doğruluk oranı hesaplanmıştır.

Doğruluk oranı (DO), aşağıda gösterilen denklemdeki gibidir:

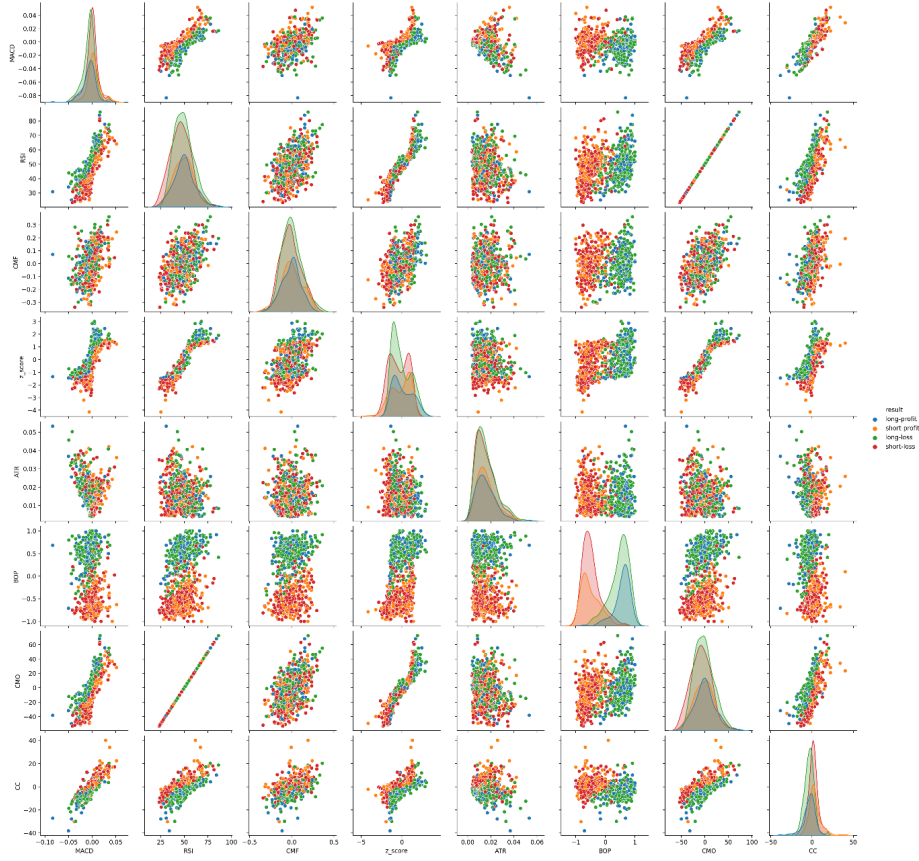
$$DO = \frac{Gerçek\ Pozitif\ (GP) + Gerçek\ Negatif\ (GN)}{Gerçek\ Pozitif\ (GP) + Gerçek\ Negatif\ (GN) + Yanlış\ Pozitif\ (YP) + Yanlış\ Negatif\ (YN)}$$

Uygulanılan modelde, en yüksek doğruluk oranına sahip makine öğrenmesi algoritmasına ait eğitilmiş veri kaydedilmiş ve bir sonraki aşamada bu veriler kullanılmıştır.

Bu çalışmada, ADAUSDT ve LTCUSDT'nin uzun-kısa işlemleri sırasında elde edilen tüm gösterge değerleri çift grafikler üzerinde aşağıda gösterilmiştir. Grafikler incelendiğinde, göstergelere ait “zarar” veya “kâr” değerlerinin herhangi bir alanda sistematik olarak toplanmadığı gözlemlenmiştir. Verilerin sistemli bir şekilde bir araya getirilememesi, doğru makine öğrenmesi algoritmasının belirlenmesini zorlaştırmaktadır.



Şekil 5. ADAUSDT



Şekil 6. LTCUSDT

Eğitim sonrasında test edilen makine öğrenmesi algoritmalarının doğruluk oranları Tablo4'te sunulmuştur.

Çalışmada, derin öğrenme yöntemi tercih edilmiş ve bunun için yapay sinir ağı algoritması kullanılmıştır. Toplamda dokuz adet input olduğu için derin öğrenmede kullanılan katmanlar, 9-18-27-18-9-1 şeklindedir. Çıktı katmanı, ikili bir sınıflandırma problemi için belirlenmiş olup, 1 (Al), 0 (Alma) durumlarını temsil etmektedir. Derleme esnasında şu parametreler kullanılmıştır: optimizer="Nadam", loss="binary\_crossentropy", metrics=['binary\_accuracy']) 400 defa eğitim gerçekleştirilmiştir. Tahmin eşiği 0.5'in üzerindedir.

Karar ağaçları için kullanılan parametre ise "Entropy" dir. Bu kapsamda ID3 algoritması kullanılmıştır.

Tablo 4. Eğitim Sonrasında Test Edilen Makine Öğrenmesi Algoritmalarının Doğruluk Oranları

	Derin Öğrenme	Karar Ağaçları
ADAUSDT	0.5956	0.5478
LTCUSDT	0.5854	0.5769

Tabloya göre, kripto varlıkların sınıflandırılmasında en yüksek doğruluk oranını sağlayan algoritmanın Derin Öğrenme olduğu görülmektedir; bu algoritma yaklaşık %60 doğruluk oranı sunmaktadır.

### Modelin Nihai Testi

Yukarıda elde edilen aşamaların sonucunda elimize 3 veri bulunmaktadır. Bunlar:

- Optimize edilmiş MACD parametreleri,
- En uygun makine öğrenmesi algoritmasına ait eğitim verileri
- Mum verileri elde edildikten sonra "Optimizasyon" ve "Test" verisi olarak ikiye ayrılan mum verilerinden "Test" verisi.

Test verisi, optimize edilmiş MACD parametreleri ve eğitilmiş makine öğrenmesi algoritmalarının geriye yönelik testiyle değerlendirilmiş ve iki önemli sonuç elde edilmiştir: kazanç oranı ve kârlılık. Aslında, geriye yönelik test aşamasındaki mum verilerine şimdiye kadarki süreçte müdahale edilmediği için gelecekteki tahminler yapılmış gibi değerlendirilebilir.

Yine bu aşamada, varsayılan MACD parametreleri, optimize edilmiş MACD parametreleri ve hem optimize edilmiş MACD parametreleri hem de makine öğrenmesi algoritmaları ile “uzun” kısa işlemler gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır.

Bu çalışmada önerilen model, herhangi bir kripto varlık için, varsayılan MACD parametrelerinden daha iyi sonuç üreten MACD parametrelerinin bulunması, zarar ettiren uzun-kısa işlemlerin makine öğrenmesi sınıflandırma algoritmaları ile ayıklanması üzerinedir. Burada, en çok doğruluk oranına sahip olan makine öğrenmesi algoritması ile işlem yapmak en rasyonel seçim olacaktır. Ancak, diğer makine öğrenmesi algoritmalarının nasıl bir sonuç ürettiği de test edilmiş ve böylelikle makine öğrenmesi algoritmaları karşılaştırılmıştır.

Sunulan modelin, varsayılan MACD parametreleri ile oluşturulan stratejiden daha kârlı olacağını varsayabiliriz. Ayrıca, zarar ettiren kararları da ayırtmamızın da kârlılığımızı artıracığını varsayabiliriz. Bu maksatla, varsayılan MACD parametreleri ile oluşan sonuçlar, sadece optimize edilmiş MACD parametreleri ile oluşan sonuçlar (makine öğrenmesi algoritmalarının zarar ettiren sinyalleri ayıklamadığı senaryo) ve hem optimize edilmiş MACD parametreleri hem de makine öğrenmesi algoritmaları ile zarar ettiren işlemlerin ayıklandığı modelin geriye yönelik test sonuçları tablo-5’te yer almaktadır.

**Tablo 5.** Modelin Geriye Yönelik Test Sonuçları

	Optimize Edilmemiş MACD Parametreleri ile Yapılan Geriye Yönelik Test Sonuçları		Optimize Edilmiş MACD Parametreleri ile Yapılan Geriye Yönelik Test Sonuçları		Optimize Edilmiş MACD Parametreleri ve Eğitilmiş Makine Öğrenmesi Sınıflandırma Algoritmaları ile Yapılan Geriye Yönelik Test Sonuçları			
					Derin Öğrenme		Karar Ağaçları	
	Kazanç Oranı	Karlılık (%)	Kazanç Oranı	Karlılık (%)	Kazanç Oranı	Karlılık (%)	Kazanç Oranı	Karlılık (%)
<b>ADAUSDT</b>	0.3464	0.8467	0.3200	0.6972	0.3189	0.7096	0.3113	0.7953
<b>LTCUSDT</b>	0.3290	0.4518	0.3389	0.5578	0.3882	0.9355	0.000	0.000

Tablodaki veriler, optimize edilmemiş ve optimize edilmiş MACD parametreleri kullanılarak yapılan geriye yönelik test sonuçlarını içermektedir. Ayrıca, optimize edilmiş MACD parametreleri ve eğitilmiş makine öğrenimi sınıflandırma algoritmalarıyla yapılan test sonuçları da bulunmaktadır. Bu testlerin her biri için kazanç oranı ve karlılık oranları verilmiştir.

İlk sütun, optimize edilmemiş MACD parametreleri ile yapılan test sonuçlarını temsil ederken, ikinci sütun optimize edilmiş MACD parametreleri ile yapılan test sonuçlarını göstermektedir. Üçüncü sütunda, optimize edilmiş MACD parametreleri ile derin öğrenme ve karar ağacı algoritması kullanılarak yapılan test sonuçları yer almaktadır.

Her bir varlık (ADAUSDT ve LTCUSDT) için kazanç oranı ve karlılık oranları verilmiştir. Bu kapsamda, ADAUSDT için optimize edilmemiş MACD parametreleri ile kazanç oranı %34.64 ve karlılık oranı %84.67 olarak belirtilmiştir. Benzer şekilde, optimize edilmiş MACD parametreleri ve derin öğrenme algoritmasıyla yapılan testte kazanç oranı %31.89 ve karlılık oranı %70.96 olarak görülmektedir. Yani bu modelde ADAUSDT için karlılık elde edilmemiştir. Buna karşın LTCUSDT için optimize edilmemiş MACD parametreleri ile kazanç oranı %32.90 ve karlılık oranı %45.18 olarak belirtilmiştir. Optimize edilmiş MACD parametreleri ve derin öğrenme algoritmasıyla yapılan testte kazanç oranı %38.82 ve karlılık oranı %93.55 olarak görülmektedir.

Bu veriler, farklı parametreler ve algoritmalar kullanılarak yapılan ticaret stratejilerinin performansını karşılaştırmak için kullanılabilir. Karlılık oranları ve kazanç oranları, stratejinin ne kadar etkili olduğunu değerlendirmek için önemli ölçütlerdir.

Sonuç olarak Optimize Edilmiş MACD Parametreleri ile LTCUSDT varlığı için derin öğrenme algoritması kullanıldığında hem kazanç oranı hem de karlılık önemli ölçüde artmaktadır. Bu durum, derin öğrenme algoritmasının LTCUSDT üzerinde daha etkili olduğunu ve optimize edilmiş MACD parametreleri ile birleştirildiğinde daha başarılı sonuçlar elde edildiğini göstermektedir. Öte yandan, ADAUSDT varlığında elde edilen sonuçlar, kar elde edilememesi şeklinde görülmektedir. Bu durum, belirli varlık ve strateji kombinasyonlarının her zaman aynı başarıyı elde etmediğini ve piyasa koşullarına bağlı olarak değişebileceğini vurgulamaktadır. Her varlık, farklı karakteristiklere sahiptir ve bu nedenle bir stratejinin bir varlık üzerinde başarılı olup olmayacağını belirlemek için dikkatlice değerlendirilmesi gerekmektedir.

## Sonuç

Bu çalışmada makine öğrenmesi yöntemlerine teknik analiz göstergeleri entegre edilip genetik algoritma ile optimize edilerek 24 saat işleme açık olan kripto para piyasasında, geçmiş verilere istatistik ve makine öğrenmesi metodlarını uygulayarak doğruluk oranı yüksek al ve sat sinyallerinin üretilmesi hedeflenmiştir.

Makine öğrenmesi algoritmaları bir veri setini modele dönüştüren algoritmalarıdır. Bu çalışmada da makine öğrenmesi algoritmaları sunulmuş ve performansları karşılaştırılmıştır. Çalışmada ayrıca makine öğrenmesi algoritmalarının performansını artırmak amacıyla, genetik algoritma ile optimize ederek performans karşılaştırması yapılmıştır. Farklı makine öğrenmesi algoritmalarını karşılaştırıp en başarılı ve en uygun modelin hangisi olacağı kripto varlıklar üzerinde uygulanması ile belirlenmiştir.

ADAUSDT ve LTCUSDT'ye ait geriye yönelik testin icrasından sonra, bu makalede ileri sürülen modelde, Optimize edilmiş MACD parametreleri ile yapılan uzun-kısa işlemlerden elde edilen kârlılığın, optimize edilmemiş MACD parametreleri ile yapılan uzun kısa işlemlerden elde edilen kârlılıktan daha iyi sonuç ürettiği gözlemlenmiştir.

Varsayılan MACD değerleri,

- Hızlı: 12
- Yavaş: 26,
- Düzeltme: 9 'dur.

Bu parametreler, MACD indikatörünün ilk olarak Gerald Appel tarafından geliştirildiği 1970'lerde yaygın olarak kullanılan parametrelerdir. Bu parametreler, MACD indikatörünün temel özelliklerini yansıtır ve çoğu yatırımcı için iyi bir başlangıç noktasıdır.

Tablo 3'te elde edilen değerlerin, varsayılan değerlere pek de yakın olmadığı gözlemlenmiştir. Bu değerlerin ortalamaları alındığında,

- Hızlı: 11,1
- Yavaş: 20,89,
- Düzeltme: 5,28 'dir.

MACD indikatörü parametrelerini değiştirmek, MACD indikatörünün çalışmasını etkilemek anlamına gelmektedir. Örneğin, 9 periyotluk EMA'yı 5 periyotluk EMA ile değiştirmek, göstergenin daha hızlı tepki vermesini sağlar. Ancak, bu aynı zamanda göstergenin daha az hassas olmasına da neden olur. Optimize edilmiş MACD parametreleri ortalamalarının, varsayılan MACD parametrelerinden daha düşük olması, kripto varlıklarda kâr elde etmek amacı ile yapılan işlemlerde, yatırım yapan kişilerin daha hızlı tepki veren bir indikatöre ihtiyaç duymasından kaynaklanabilir.

Uygulamadaki grafikler incelendiğinde, veriler makine öğrenmesine daha girmeden kâr ve zarar verilerinin net ayrıştığı bir sonuç gözlenmemiştir. Bunun nedeni, kripto varlıkların herhangi bir kurum/kuruluş tarafından denetimi olmamasıdır. Bu yüzden kripto varlıkları "volatil" veya istikrarsız olarak değerlendirmek yerinde olacaktır. Çünkü, bir haber akışıyla, spekülasyonla veya sosyal medya fenomeninin yüklü işlemi ile ani yükselişler ve düşüşler sergileyebilir. Bu ani yükselişler veya düşüşler, satın alma işleminden hemen sonra oluşursa, mum verilerinden elde edilen istatistiksel hesaplamalara göre alım ve satım işlem kararının sağlıklı verildiğinden bahsedilemeyecektir.

Optimize edilmiş MACD parametreleri ile karar verilen uzun-kısa işlemler, eğitilmiş makine öğrenmesi algoritmaları ile tahmin ettirildiğinde, "en iyi sonuç veren" algoritma gözlemlenmemiştir. Ancak, makine öğrenmesi algoritmaları ile, zarar ettiren verilerin ayıklanması ile daha iyi kârlılığın elde edilebileceği gözlemlenmiştir. Bu modelde, ADAUSDT kripto para çiftinde bir kar elde edilememiştir. Ancak LTCUSDT çiftinde, derin öğrenme algoritmasının kullanılması ile LTCUSDT paritesinde %93.55 kar elde edilebileceği gözlemlenmiştir. Dolayısıyla geliştirilen bu modelin LTCUSDT çiftine ADAUSDT çiftinden daha fazla uyduğu söylenebilir.

**Hakem Değerlendirmesi:** Dış bağımsız.

**Yazar Katkısı:** Çalışma Konsepti/Tasarımı: S.U.A.; Veri Toplama: B.Y.Ş.; Veri Analizi /Yorumlama: B.Y.Ş.; Yazı Taslağı: B.Y.Ş.; İçeriğin Eleştirel İncelemesi: S.U.A.; Son Onay ve Sorumluluk: S.U.A., B.Y.Ş.

**Çıkar Çatışması:** Yazarlar çıkar çatışması bildirmemiştir.

**Finansal Destek:** Yazarlar bu çalışma için finansal destek almadığını beyan etmiştir.

**Peer Review:** Externally peer-reviewed

**Author Contributions:** Conception/Design of study: E.Ç.A., D.T.; Data Acquisition: E.Ç.A., D.T.; Data Analysis/Interpretation: E.Ç.A., D.T.; Drafting Manuscript: E.Ç.A., D.T.; Critical Revision of Manuscript: E.Ç.A., D.T.; Final Approval and Accountability: E.Ç.A., D.T.

**Conflict of Interest:** The authors have no conflict of interest to declare.

**Grant Support:** The authors declared that this study has received no financial support.

#### ORCID:

Berna Yaman Şahin 0000-0002-9796-8864

Sema Ulutürk Akman 0000-0002-4075-8313

#### KAYNAKLAR / REFERENCES

- Aguirre, A. A. A., Medina, R. A. R., & Méndez, N. D. D. (2020). Machine learning applied in the stock market through the Moving Average Convergence Divergence (MACD) indicator. *Investment Management & Financial Innovations*, 17(4), 44.
- Chatterjee, S., Sarkar, S., Dey, N., Ashour, A. S., & Sen, S. (2018). Hybrid non-dominated sorting genetic algorithm: II-neural network approach. In *Advancements in Applied Metaheuristic Computing* (pp. 264-286). IGI Global.
- Choudhry, R., & Garg, K. (2008). A hybrid machine learning system for stock market forecasting. *International Journal of Computer and Information Engineering*, 2(3), 689-692.
- Çalış, A., Kayapınar, S., & Çetinyokuş, T. (2014). Veri Madenciliğinde Karar Ağacı Algoritmaları ile Bilgisayar ve İnternet Güvenliği Üzerine Bir Uygulama. *Endüstri Mühendisliği*, 25(3), 2-19.
- Demirel, A. C., & Hazar, A. (2021). Kripto para değerlerine dayanılarak BİST 100 endeks hareketi tahmininde destek vektör makineleri uygulaması. *Başkent Üniversitesi Ticari Bilimler Fakültesi Dergisi*, 5(1), 27-35.
- Gupta, B., Rawat, A., Jain, A., Arora, A. ve Dhami, N. (2017). Veri madenciliğinde sınıflandırmaya yönelik çeşitli karar ağacı algoritmalarının analizi. *Uluslararası Bilgisayar Uygulamaları Dergisi*, 163 (8), 15-19.
- Holland, J. H. (1992). Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence.
- Kara, Y., Boyacıoğlu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with Applications*, 38(5), 5311-5319.
- Karadağ, K. (2022). *Hibrit derin öğrenme modelleri ile hisse senedi fiyat tahmini* (Master's thesis, Trakya Üniversitesi Sosyal Bilimler Enstitüsü).
- Kim, H., & Shin, K. (2007). A hybrid approach based on neural networks and genetic algorithms for detecting temporal patterns in stock markets. *Applied Soft Computing*, 7(2), 569-576. doi:10.1016/j.asoc.2006.03.004
- Kumar, M., Husain, M., Upreti, N., & Gupta, D. Genetic algorithm: review and application. Available at SSRN 3529843 (2010).
- Latha, R. S., Sreekanth, G. R., Suganthe, R. C., Geetha, M., Selvaraj, R. E., Balaji, S., ... & Ponnusamy, P. P. (2022, January). Stock Movement Prediction using KNN Machine Learning Algorithm. In *2022 International Conference on Computer Communication and Informatics (ICCCI)* (pp. 1-5). IEEE.
- Odabaşı, M. B., & Toklu, M. C. Yapay Sinir Ağları ve Derin Öğrenme Algoritmalarının Kripto Para Fiyat Tahmininde Karşılaştırmalı Analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(2), 96-107.
- Olorunnimbe, K., & Viktor, H. (2023) Deep Learning in The Stock Market—A Systematic Survey of Practice, Backtesting, and Applications. *Artif Intell Rev*, 56, 2057-2109. <https://doi.org/10.1007/s10462-022-10226-0>
- Pabuççu, H., Ongan, S., & Ongan, A. (2023). Forecasting the movements of Bitcoin prices: an application of machine learning algorithms. *arXiv preprint arXiv:2303.04642*.
- Pai, P. F., & Wei, W. R. (2007, December). Predicting movement directions of stock index futures by support vector models with data preprocessing. In *2007 IEEE International Conference on Industrial Engineering and Engineering Management* (pp. 169-173). IEEE.
- Sel, A. (2020). Pandemi sürecinde altın fiyatları ile kripto para ilişkisinin makine öğrenme metotları ile incelenmesi. *İstatistik ve Uygulamalı Bilimler Dergisi*, 1(2), 85-98.
- Singh, S., & Gupta, P. (2014). Comparative study ID3, cart and C4. 5 decision tree algorithm: a survey. *International Journal of Advanced*



*Information Science and Technology (IIAIST)*, 27(27), 97-103.

Şenol, D., & Denizhan, B. (2023). Kripto Para Değerinin Yapay Sinir Ağları ile Tahmini. *Endüstri Mühendisliği*, 34(1), 42-69.

Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.

Yusoff, Y., Ngadiman, M. S., & Zain, A. M. (2011). Overview of NSGA-II for optimizing machining process parameters. *Procedia Engineering*, 15, 3978-3983.

#### **Atıf Biçimi / How cite this article**

Yaman Şahin, B., Ulutürk Akman, S. Performance comparison of genetic and machine learning algorithms in crypto markets. *EKOIST Journal of Econometrics and Statistics*, 40, 151–164. <https://doi.org/10.26650/ekoist.2024.40.1411482>