

Portfolio Formation Decisions and Optimal Allocation in Cryptocurrency Investments Considering Both Risk and Return

Iman Ebrahimi

Master of Business Administration, Faculty of Finance, Management and Entrepreneurship, Kashan University, Kashan, Iran

Hadi Mokhtari*

Associate Professor, Department of Industrial Engineering, Faculty of Engineering, University of Kashan, Kashan, Iran

Mohammad Taghi Rezvan

Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, University of Kashan, Kashan, Iran

Abstract

In today's world, investment in the cryptocurrency market is regarded as one of the most attractive yet high-risk opportunities. Given the rapid growth of this market and its impact on the global economy, examining the importance and challenges associated with cryptocurrency investments is essential. This paper, as a novel contribution, simultaneously explores the design of a cryptocurrency portfolio and the subsequent optimal allocation of investments in this market, considering both risk and return. In first stage, the focus is on constructing a portfolio in the cryptocurrency market using relevant indices. After forming this initial portfolio, capital allocation is optimized. This approach allows for creating a portfolio that aligns with the investor's risk preferences while also considering passive portfolio management. In the second stage, equally weighted portfolios are created relative to the market portfolio, as well as other portfolios selected based on criteria such as highest market capitalization and the best risk-return ratios, using Markowitz, Sharpe, and Sortino models. For optimal allocation of these portfolios, metaheuristic algorithms based on particle swarm optimization are employed. The results

* Corresponding Author: mokhtari_ie@kashanu.ac.ir

How to Cite: xxxxxxxx

show that portfolios including cryptocurrencies with the highest market capitalization exhibit lower risk, and the strategy based on the Sharpe model outperforms the other models.

Introduction

The rapid evolution of cryptocurrency markets has created both opportunities and challenges for investors. Unlike traditional assets, cryptocurrencies are highly volatile, decentralized, and driven by technological innovations such as blockchain. These unique features demand new approaches to portfolio design and optimization. Traditional models, such as Markowitz's mean-variance theory, provide valuable foundations but are insufficient in capturing the complexity of crypto markets. Recent advances in heuristic and metaheuristic optimization have introduced promising tools to address these challenges. This study contributes by integrating portfolio formation with optimal allocation strategies while considering both risk and return. By employing passive management approaches alongside advanced optimization models, it seeks to create robust portfolios that reflect investors' preferences. The research particularly emphasizes evaluating the performance of different models, including Markowitz, Sharpe, and Sortino, in combination with metaheuristic methods, offering practical insights for effective decision-making in cryptocurrency investments.

Research Background

Portfolio optimization has long been a central topic in financial management, evolving from classical mean-variance models to more advanced risk-adjusted approaches. With the emergence of cryptocurrencies, scholars have increasingly focused on adapting these models to highly volatile, fast-growing markets. Prior studies explored strategies such as equal-weight portfolios, maximum Sharpe ratio, and risk-parity allocations, often with mixed results. Additionally, machine learning and heuristic methods, including genetic algorithms and deep learning, have been applied to enhance prediction and asset allocation. However, most research addresses either portfolio formation or allocation optimization in isolation. A gap remains in simultaneously considering both aspects under realistic conditions. Furthermore, studies on passive portfolio management in cryptocurrency markets are limited. This research addresses these gaps by combining index-based portfolio construction with optimal allocation through particle swarm optimization (PSO), benchmarking results against classical genetic algorithms and well-established financial models.

Method

The study employs a two-stage methodology. First, cryptocurrency portfolios are constructed using different strategies: market index portfolios, equally weighted portfolios, and portfolios based on criteria such as highest market capitalization and superior return-to-risk ratios. These portfolios are then evaluated using three established financial models: Markowitz's mean-variance, Sharpe ratio, and Sortino ratio. In the second stage, the allocation of assets within each portfolio is optimized using the particle swarm optimization (PSO) algorithm, chosen for its ability to handle non-linear, NP-hard optimization problems. The PSO implementation is fine-tuned to balance exploration and exploitation, ensuring reliable convergence. To validate robustness, results are compared against those obtained from classical genetic algorithms. Data on the top 50 cryptocurrencies were collected from CRUX and Yahoo Finance over multiple horizons (30, 90, 180, and 365 days). Key performance metrics include return, variance, standard deviation, and risk-adjusted ratios, providing a comprehensive view of portfolio efficiency.

Discussion and Results

The findings indicate that portfolios composed of cryptocurrencies with the highest market capitalization consistently exhibit lower risk levels compared to alternatives. Among the evaluation models, the Sharpe-based strategy outperformed others, delivering superior risk-adjusted returns. The Sortino model also proved effective in emphasizing downside risk, aligning with investor concerns in volatile markets. Conversely, some Markowitz-based portfolios produced higher variance, highlighting the limitations of variance as a sole risk measure in cryptocurrency investments. Across different time horizons, return-to-standard deviation ratios provided robust selection criteria, particularly when optimized through PSO. Comparisons with the genetic algorithm demonstrated PSO's efficiency in convergence and accuracy, especially in capturing optimal weight distributions. The results suggest that integrating metaheuristic optimization with traditional financial models significantly improves portfolio performance. Overall, evidence supports the importance of market capitalization and model choice in shaping effective investment strategies, with PSO-based Sharpe optimization yielding the most promising outcomes.

Conclusion

This research demonstrates that simultaneous portfolio formation and optimal allocation, when supported by advanced optimization techniques, can effectively balance risk and return in cryptocurrency investments. Portfolios

weighted toward large-cap cryptocurrencies proved less risky, while the Sharpe model consistently delivered superior outcomes compared to Markowitz and Sortino. The application of particle swarm optimization enabled efficient identification of optimal weights, outperforming classical genetic algorithms in accuracy and stability. Importantly, the study highlights the relevance of passive portfolio management strategies in volatile digital markets, providing investors with practical tools to mitigate risks while maximizing returns. The findings emphasize the necessity of adopting scientific, data-driven methods rather than speculative approaches in crypto trading. Future research may extend this work by incorporating multi-objective optimization, hybrid algorithms, or alternative risk measures, offering deeper insights into dynamic portfolio strategies in evolving digital financial ecosystems.

Keywords: Cryptocurrency market, Investment portfolio, Risk-return ratio, Optimization models, Particle swarm optimization algorithm

تصمیمات شکل دهی و تخصیص بهینه‌ی پرتفوی سرمایه گذاری رمزارز با در نظر گرفتن همزمان ریسک و بازده

کارشناسی ارشد رشته مدیریت کسب و کار، دانشکده امور مالی، مدیریت و
کارآفرینی، دانشگاه کاشان، کاشان، ایران

ایمان ابراهیمی 

دانشیار گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه کاشان، کاشان، ایران

هادی مختاری *

استادیار گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه کاشان، کاشان، ایران

محمد تقی رضوان 

چکیده

سرمایه گذاری در بازار رمزارزها یکی از جذاب ترین اما پرریسک ترین فرصت های سرمایه گذاری در دنیای امروز به شمار می رود. رشد سریع این بازار و تأثیر آن بر اقتصاد جهانی، لزوم بررسی علمی و نظام مند این حوزه را برجسته می سازد. این پژوهش به عنوان یک نوآوری، به طور همزمان به طراحی پرتفوی رمزارزی و تخصیص بهینه سرمایه با در نظر گرفتن ریسک و بازده می پردازد. در گام نخست، پرتفوی مبتنی بر شاخص های بازار رمزارزها ایجاد شده و سپس بهینه سازی وزن اجزای آن با هدف سازگاری با ترجیحات ریسک سرمایه گذاران انجام شد. مدیریت غیرفعال نیز به عنوان رویکردی مکمل مدنظر قرار گرفت. در ادامه، پرتفوهایی با وزن مساوی و همچنین پرتفوهایی منتخب بر اساس بالاترین ارزش بازار و بهترین نسبت بازده به ریسک شکل گرفتند. برای بهینه سازی، از الگوریتم فراابتکاری بهینه سازی ازدحام ذرات (PSO) استفاده و نتایج مورد تجزیه و تحلیل قرار گرفت. یافته ها نشان دادند که پرتفوی های متشکل از رمزارزهای با بیشترین ارزش بازار، ریسک کمتری دارند و مدل شارپ در میان مدل های مورد استفاده، عملکرد بهتری ارائه می دهد. همچنین، انتخاب پرتفوی بر اساس نسبت بازده به ریسک انحراف معیار نتایج مطلوبی به همراه داشت. در نهایت، پژوهش تأکید می کند که بهره گیری از استراتژی های علمی می تواند مدیریت ریسک را تسهیل کرده و بازدهی سرمایه گذاری را بهبود بخشد.

کلیدواژه ها: بازار رمزارزها، سبد سرمایه گذاری، نسبت بازده به ریسک، مدل های بهینه سازی، الگوریتم بهینه سازی ازدحام ذرات

مقدمه

بهینه‌سازی پرتفوی همواره یکی از موضوعات اصلی در مدیریت مالی بوده است، اما در بازارهای نوظهور مانند رمزارزها، پیچیدگی‌های خاصی دارد. بازار رمزارزها طی سال‌های اخیر به دلیل رشد چشمگیر و بازدهی بالا، توجه بسیاری از سرمایه‌گذاران را به خود جلب کرده است. این بازار که با معرفی بیت‌کوین آغاز شد، اکنون شامل هزاران رمزارز با ویژگی‌ها و کاربردهای متفاوت است. غیرمتمرکز بودن و عدم وابستگی به نهادهای مالی سنتی، همراه با فناوری بلاکچین که امنیت و شفافیت تراکنش‌ها را تضمین می‌کند، جذابیت ویژه‌ای به این حوزه بخشیده است.

از زمان ارائه نظریه پرتفوی Markowitz (۱۹۵۹)، مدل‌های مختلفی برای مدیریت سبد سرمایه‌گذاری معرفی شده‌اند. با این حال، اضافه‌شدن محدودیت‌های واقعی باعث پیچیدگی این مسائل و تبدیل آن‌ها به چالش‌های NP-Hard شده است. به همین دلیل، پژوهشگران در دهه‌های اخیر به سمت استفاده از الگوریتم‌های فراابتکاری و روش‌های هوش مصنوعی گرایش پیدا کرده‌اند. این رویکردها به‌ویژه در بازار رمزارزها که با نوسانات شدید همراه است، کاربرد بالایی دارند.

بازار رمزارزها در حال حاضر شامل بیش از ۱۴,۵۰۰ رمزارز با ارزشی بالغ بر ۳ تریلیون دلار است. پس از ظهور بیت‌کوین در سال ۲۰۰۹، این بازار رشد شتابانی را تجربه کرده و سال‌های ۲۰۲۰ و ۲۰۲۱ به عنوان مقاطع کلیدی در پذیرش گسترده رمزارزها شناخته می‌شوند. تعداد دارندگان رمزارز در سطح جهانی از ۶۶ میلیون نفر در مه ۲۰۲۰ به بیش از ۲۹۵ میلیون نفر در دسامبر ۲۰۲۱ افزایش یافته است. (Bruhn & Ernst, 2022). همچنین، مطالعات نشان می‌دهد که این بازار از یک حوزه نابالغ به بازاری نسبتاً بالغ تبدیل شده است (Wątarek et al., 2021).

با وجود این، نوسانات بالای رمزارزها همچنان سرمایه‌گذاری در این حوزه را چالش‌برانگیز می‌سازد. نمونه بارز آن کاهش ۱۵ درصدی ارزش بیت‌کوین تنها طی چند ساعت، از ۱۳,۵۰۰ دلار به ۱۱,۵۰۰ دلار است. (Inci, & Lagasse, 2019). چنین رخدادهایی نشان می‌دهد که سرمایه‌گذاری در رمزارزها علاوه بر فرصت‌های سودآور، با ریسک‌های بالایی نیز همراه است.

از سوی دیگر، طی قرن اخیر گرایش جهانی به سمت تصمیم‌گیری‌های هوشمندانه و مبتنی بر الگوریتم افزایش یافته و این روند در بازار رمزارزها نیز قابل مشاهده است. به‌کارگیری روش‌های نوین مانند یادگیری ماشین و هوش مصنوعی می‌تواند تحلیل دقیق‌تر و مدیریت بهینه‌تری را فراهم آورد. با توجه به حضور گسترده سرمایه‌گذاران خرد و کلان و وجود ریسک‌های متنوع، طراحی مدل‌های نوین پرتفوی برای پوشش مناسب ریسک و افزایش اثربخشی سرمایه‌گذاری‌ها اهمیت بالایی دارد.

پیشینه پژوهش

انتخاب و تخصیص بهینه پرتفوی در بازار رمزارزها نیازمند استفاده از روش‌های بهینه‌سازی برای شناسایی بهترین ترکیب دارایی‌ها است. در طول سال‌ها، تکنیک‌های مختلفی برای بهینه‌سازی پرتفوی توسعه یافته‌اند، از جمله روش میانگین-واریانس (MV^1) که توسط مارکوویتز در سال ۱۹۵۹ معرفی شد، واریانس با چولگی (VwS^2) که Samuelson در سال ۱۹۷۰ ارائه کرد، ارزش در معرض خطر (Var^3) که Jorion در سال ۱۹۹۷ مطرح کرد، ارزش در معرض خطر شرطی ($CVaR^4$) که توسط Rockafellar & Uryasev در سال ۲۰۰۰ توسعه یافت، انحراف میانگین مطلق (MAD^5) که Konno & Yamazaki در سال ۱۹۹۱ معرفی کردند و حداقل حداکثر (MM^6) که یونگ در سال ۱۹۹۸ ارائه داد.

با شناسایی ویژگی‌های مثبت رمزارزها به‌عنوان یک نوع دارایی، برخی از تحقیقات به بررسی پرتفوی‌های خالص رمزارز با استفاده از روش‌های مختلف انتخاب و ارزیابی عملکرد آن‌ها پرداخته‌اند. رایج‌ترین استراتژی‌ها برای انتخاب پرتفوی شامل قانون وزن برابر ($N/1$) یا تنوع ساده، استراتژی بهینه‌سازی میانگین واریانس مارکوویتز، اصل برابری ریسک، حداکثر نسبت شارپ و همچنین ایجاد پرتفوی $CRIX^7$ هستند (Elender و همکاران، ۲۰۱۸؛ Platanakis و همکاران، ۲۰۱۸؛ Brauneis و Mestel، ۲۰۱۹؛ Liu، ۲۰۱۹).

¹ Mean-Variance

² Variance with Skewness

³ Value at Risk

⁴ Conditional Value at Risk

⁵ Mean Absolute Deviation

⁶ Minimum Maximum

⁷ CRyptocurrency IndeX

Saxena و همکاران (۲۰۱۸) عملکرد مدل‌های $ARIMA^1$ و $LSTM^2$ را در پیش‌بینی قیمت بیت‌کوین مقایسه کردند. Nakano و همکاران (۲۰۱۸) بازده بیت‌کوین را در یک بازه زمانی ۱۵ دقیقه‌ای با استفاده از ANN^3 و شاخص‌های تحلیل تکنیکال محاسبه کردند که منجر به بهبود عملکرد تراکنش‌های بیت‌کوین با هزینه تراکنش مناسب شد. Lahmiri & Bekiros (۲۰۱۹) نیز $LSTM$ و معماری شبکه عصبی رگرسیون تعمیم‌یافته ($GRNN^4$) را برای پیش‌بینی قیمت BTC^5 ، Digital Cash و XRP^6 پیاده‌سازی کردند که RMS^7 حاصل برای $LSTM$ نشان‌دهنده عملکرد بهتر آن نسبت به $GRNN^8$ بود. Chen و همکاران (۲۰۱۸)، اولین تحلیل اقتصادسنجی از خانواده $CRIX$ را ارائه دادند که تقریباً بر اساس ۳۰ رمزارز ساخته شده بود و پوشش بالایی از سرمایه بازار داشت.

Alonso-Monsalve و همکاران (۲۰۲۰)، عملکرد مدل‌های CNN^9 ، MLP^{10} ، $CNN-LSTM^{11}$ و شبکه‌های عصبی تابع مبنای شعاعی ($RFNN^{12}$) را برای پیش‌بینی روند قیمتی شش رمزارز شامل BTC ، $Dash$ ، ETH^{13} ، LTC^{14} ، XRP و XMR^{15} مقایسه کردند. Pintelas و همکاران (۲۰۲۰) با بهره‌گیری از مدل‌های یادگیری عمیق (DL^{16})، قیمت ساعتی رمزارزها را پیش‌بینی کردند و عملکرد مدل‌های $LSTM$ و $Bi-LSTM$ را مورد بررسی قرار دادند. Akyildirim و همکاران (۲۰۲۱)، بازده روزانه و دقیقه‌ای ۱۲ رمزارز شامل BCH^{17} ، BTC ، $Dash$ ، EOS ، ETC^{18} ، ETH ، IOT^{19} ، LTC ، OMG ،

¹ Autoregressive Integrated Moving Average

² Long-Short Term Memory

³ Artificial Neural Network

⁴ Generalized Regression Neural Network

⁵ Bitcoin

⁶ Ripple

⁷ Root Mean Squares

⁸ Generalized Regression Neural Network

⁹ Convolutional Neural Network

¹⁰ Multilayer Perceptron

¹¹ Convolutional Neural Network Long-Short Term Memory

¹² Radial basis Neural Network

¹³ Ethereum

¹⁴ Litecoin

¹⁵ Monero

¹⁶ Deep Learning

¹⁷ Bitcoin Cash

¹⁸ Ethereum Classic

¹⁹ Helium

XMR، XRP و ZEC^۱ را با استفاده از چهار مدل یادگیری ماشین (ML^۲) شامل SVM^۳، رگرسیون لجستیک، ANN و رگرسیون جنگل تصادفی (RFR^۴) پیش‌بینی کردند. Parvini و همکاران (۲۰۲۲)، یک مدل پیش‌بینی دو مرحله‌ای شامل تبدیل موجک گسسته و LSTM برای پیش‌بینی بازده بیت‌کوین ارائه دادند. آن‌ها از داده‌های طلا، نفت، USOI، VIX، S&P 500، ETH، XRP و قیمت تاریخی BTC به عنوان متغیرهای پیش‌بینی‌کننده استفاده کردند.

Elender و همکاران (۲۰۱۸)، به بررسی رمزارزها به عنوان دارایی‌های سرمایه‌گذاری جایگزین پرداختند و همبستگی قیمت آن‌ها با بیت‌کوین و بازدهی‌شان را تحلیل کردند. Platanakis و همکاران (۲۰۱۸) تنوع پرتفوی رمزارزها را از طریق دو مدل N/1 و MV بررسی قرار دادند. Brauneis و Mestel (۲۰۱۹)، تأثیر تنوع‌بخشی و کاهش ریسک در یک پرتفوی متشکل از رمزارزها را در مدل MV تحلیل کردند. لیو (۲۰۱۹)، تنوع پرتفوی رمزارزها را با استفاده از داده‌های ۱۰ رمزارز شامل BTC، ETH، XRP، LTC، XLM^۵، Dash، NEM، Verge، Tether و XMR بین سال‌های ۲۰۱۵ تا ۲۰۱۸ مورد آزمایش قرار داد و عملکرد شش مدل مختلف را مقایسه کرد. Han و همکاران (۲۰۲۴) به بررسی مزایای تنوع‌بخشی پرتفوی‌های مبتنی بر عوامل رمزارزی پرداخته و از روش‌های کمی برای ارزیابی عملکرد این پرتفوی‌ها در برابر پرتفوی‌های سنتی بهره برده است. Bulut و همکاران (۲۰۲۴) با استفاده از یک مدل تصمیم‌گیری چندمعیاره در محیط فازی، عوامل خطر رمزارزها را ارزیابی کرده و نقش آن‌ها در پرتفوی‌های سرمایه‌گذاری را تحلیل می‌کند. همچنین Boido, & Aliano (۲۰۲۵)، نقش رمزارزها در بهبود تنوع پرتفوی‌ها با استفاده از داده‌های بلندمدت و مدل‌سازی ریسک-بازده بررسی شده است. یافته‌ها نشان می‌دهد که اضافه کردن رمزارزها، خصوصاً در قالب توکن‌های بزرگ بازار، می‌تواند بازده پرتفوی را در برابر نوسانات بازارهای سنتی تقویت کند. با این حال، محققان هشدار می‌دهند که تأثیر تنوع‌بخشی به شدت وابسته به زمان ورود و وزن تخصیصی رمزارزها در پرتفوی است و توصیه به استفاده محتاطانه از آن‌ها در پرتفوی‌های محافظه‌کارانه دارند.

¹ Zcash

² Machine Learning

³ Support Vector Machine

⁴ Random Forest Regression

⁵ Stellar

توصیف مساله

این مطالعه به بررسی روش‌ها و رویکردهایی برای انتخاب و تخصیص مؤلفه‌های پرتفوی با توجه به بازده و ریسک می‌پردازد. تحلیل همزمان این دو موضوع برای سرمایه‌گذاران اهمیت ویژه‌ای دارد، اما برای دستیابی به بازده مطلوب و کاهش ریسک، باید ویژگی‌های خاص بازار رمزارزها نیز مد نظر قرار گیرد. پژوهش‌ها نشان می‌دهد که نوسانات شدید بازار رمزارزها تصمیم‌گیری در سرمایه‌گذاری را دشوار می‌کند. همچنین، پژوهش‌هایی که مدیریت غیرفعال پرتفوی را از منظر ریسک و بازده بررسی کنند، محدود هستند. این مقاله، به تحلیل شاخص بازار رمزارزها و تعدادی از رمزارزهای منتخب پرداخته و عملکرد پرتفوی‌های مختلف را با استفاده از معیارهای معتبر ارزیابی می‌کند. در ابتدا، یک پرتفوی نمونه طراحی شده که در آن تعداد، نوع و وزن رمزارزها تا حد ممکن ثابت باقی می‌ماند. سپس مقادیر مختلفی مانند بازده، واریانس و نسبت‌های مختلف محاسبه می‌شود. با استفاده از مدل‌ها و الگوریتم، وزن‌های بهینه برای هر رمزارز محاسبه شده و نتایج مقایسه می‌شوند. همچنین پرتفوی‌های دیگری بر اساس استراتژی‌های مختلف انتخاب خواهند شد تا عملکرد الگوریتم‌ها بهتر بررسی شود. تخصیص بهینه وزن‌های سرمایه‌گذاری عناصر پرتفوی، بر اساس مدل‌های مارکوفیتز، شارپ و سورتینو صورت می‌گیرد. قبل از بیان مدل‌ها، نمادهای به صورت زیر معرفی می‌شوند:

i	اندیس رمزارز
n	تعداد رمزارز پرتفوی
w	ماتریس وزن‌ها
w^T	ترانهاده ماتریس وزن‌ها
Σ	ماتریس واریانس-کوواریانس
μ	بردار بازده رمزارزها
μ_{Pe}	بازده مورد انتظار از پرتفوی
R_F	یک معیار مرجع مناسب بازده (مقدار نرخ بهره بدون ریسک)

مدل مارکوفیتز: هری مارکوفیتز اولین بار نظریه نوین انتخاب پرتفوی را مطرح کرد (مارکوفیتز، ۱۹۵۲). وی مدل ریاضی بهینه‌سازی پرتفوی را بر اساس پارامترهایی مانند

میانگین و واریانس ایجاد کرد که به همین دلیل به آن مدل میانگین - واریانس می‌گویند. این مدل بر به حداقل رساندن ریسک (واریانس) مشروط به بازده مورد انتظار دلالت دارد و در واقع رابطه بین ریسک و بازده مورد انتظار را تحلیل می‌کند.

$$\begin{aligned} & \text{Min } w^T \cdot \sum \cdot w \\ & \text{St: } \mu_{Pe} \leq w^T \cdot \mu \\ & \sum_{i=1}^n w_i = 1 \\ & w_i \geq 0 \quad i = 1 \dots n \end{aligned} \quad (1)$$

مدل شارپ: مدل شارپ یکی از ابزارهای مهم در ارزیابی استراتژی‌های سرمایه‌گذاری است. تعیین اینکه کدام یک از دو استراتژی با بازده‌های مشابه، ریسک بیشتری دارد، اهمیت زیادی دارد. در حوزه مالی، معمولاً نوسانات بازده و دوره‌های افت سرمایه مورد توجه قرار می‌گیرد. بنابراین، اگر یکی از این استراتژی‌ها نوسان بیشتری داشته باشد، احتمالاً جذابیت کمتری خواهد داشت؛ حتی اگر بازده‌های تاریخی آن ممکن است گمراه‌کننده باشند. این چالش‌ها در مقایسه و ارزیابی ریسک موجب استفاده از نسبت شارپ می‌شود. انجرف معیار به عنوان شاخص ریسک در نظر گرفته می‌شود. ویلیام شارپ، اقتصاددان برجسته‌ای که به خاطر ارائه مدل قیمت‌گذاری دارایی‌های سرمایه‌ای (CAPM) و توسعه نسبت شارپ در سال ۱۹۶۶ که در سال ۱۹۹۴ نیز به‌روزرسانی شد، برنده جایزه نوبل شد، این نسبت را معرفی کرد (شارپ، ۱۹۶۶؛ شارپ، ۱۹۹۴).

$$\begin{aligned} & \text{Max } (w^T \cdot \mu) - R_F \\ & \text{Min } \sqrt{w^T \cdot \sum \cdot w} \\ & \text{St: } \sum_{i=1}^n w_i = 1 \\ & w_i \geq 0 \quad i = 1 \dots n \end{aligned} \quad (2)$$

مدل سورتینو: نسبت سورتینو با این واقعیت به‌وجود آمده که نسبت شارپ، هر دو نوسان افزایش قیمت و کاهش قیمت را در مخرج کسر خود قرار داده در حالی که سرمایه‌گذاران و مدیران صندوق پوشش ریسک، عموماً زمانی که نوسان افزایش قیمت قابل توجهی وجود دارد، چندان نگران نیستند. آنچه از دیدگاه مدیریت ریسک مورد توجه است، نوسان کاهش قیمت و دوره‌های افت سرمایه است. در نتیجه، نسبت سورتینو به‌عنوان میانگین مازاد بازده

تقسیم بر میانگین انحراف کاهش قیمت تعریف شده است (سورتینو و پرایس^۱ ۱۹۹۴). معیار سورتینو، معیاری شبیه نسبت شارپ است؛ با این تفاوت که به جای انحراف معیار، از انحراف معیار منفی یا نامطلوب استفاده می‌کند. انحراف از معیار نامطلوب، معیاری از ریسک سرمایه‌گذاری است که به بررسی نوسانات منفی یا کمتر از میانگین نرخ بازده می‌پردازد.

$$\begin{aligned} & \frac{Max(w^T \cdot \mu) - R_F}{Min \sqrt{w^T \cdot \Sigma \cdot w}} \\ & St: \sum_{i=1}^n w_i = 1 \\ & w_i \geq 0 \quad i = 1 \dots n \end{aligned} \quad (3)$$

الگوریتم بهینه‌سازی ذرات

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) یک روش بهینه‌سازی الهام گرفته از طبیعت است که در سال ۱۹۹۵ برای حل مسائل بهینه‌سازی عددی با فضای جستجوی وسیع و بدون نیاز به اطلاعات گرادیان معرفی شد. الگوریتم بهینه‌سازی ازدحام ذرات، چیزی فراتر از یک مجموعه ذرات است. هیچ کدام از ذرات به تنهایی قدرت حل هیچ مسئله‌ای را ندارند؛ بلکه هنگامی می‌توان به حل مسئله امیدوار شد که آن‌ها با همدیگر ارتباط و تعامل سازنده داشته باشند. در واقع، برای ازدحام ذرات، توانایی حل مسئله یک مفهوم اجتماعی است که از رفتار تک تک ذرات و تعامل میان آن‌ها به وجود می‌آید. در مرحله ابتدایی الگوریتم، ذرات با موقعیت تصادفی و سرعت‌های صفر ایجاد می‌شوند. در طی اجرای الگوریتم، موقعیت و سرعت هر ذره در مرحله $t+1$ ام از الگوریتم، با توجه به اطلاعات مرحله قبلی ساخته می‌شوند. اگر منظور از Z_j مولفه j ام از بردار Z باشد، آنگاه روابط (۴) و (۵) سرعت و موقعیت ذرات را تغییر می‌دهند.

$$v_{ij}[t+1] = wv_{ij} + c_1 r_1 y_{ij}[t] - x_{ij}[t] + c_2 r_2 \hat{y}_i[t] - x_{ij}[t] \quad (4)$$

$$x_{ij}[t+1] = x_{ij}[t] + v_{ij}[t+1] \quad (5)$$

در این روابط، w ضریب اینرسی، r_1 و r_2 اعدادی تصادفی با توزیع یکنواخت و در بازه $[0, 1]$ هستند. همچنین c_1 و c_2 ضرایب یادگیری به حساب می‌آیند. r_1 و r_2 باعث تنوع در

¹ Sortino And Price

جواب‌ها می‌شوند و به این نحو، جست‌وجوی کامل‌تری روی فضا انجام می‌گیرد. c_1 ضریب یادگیری مربوط به تجارب شخصی هر ذره و در مقابل c_2 ضریب یادگیری مربوط به تجارب جمعی است.

اجراها و تجزیه و تحلیل نتایج

هدف این بخش، تحلیل داده‌های به‌دست‌آمده از اجرای پژوهش است. برای این منظور، ابتدا پرتفوی شاخص بازار رمزارزها در یک بازه زمانی مناسب که وزن رمزارزهای تشکیل‌دهنده در طولانی‌ترین مدت ثابت بماند، بازتولید می‌شود. سپس مقادیر مربوط به بازده، واریانس، انحراف معیار، ضریب تغییرات، نسبت شارپ و نسبت سورتینو برای این پرتفوی محاسبه خواهد شد. پس از آن، با توجه به مدل‌ها و الگوریتم مورد بررسی در این مطالعه، وزن اجزای تشکیل‌دهنده پرتفوی بازار بهینه‌سازی شده و نتایج حاصل با یکدیگر مقایسه می‌شوند.

داده‌ها و پرتفوی‌های منتخب

در این پژوهش به منظور بررسی و تحلیل پرتفوی بازار رمزارزها، داده‌های مربوط به شاخص CRIX از وب‌سایت Crix و اطلاعات خام رمزارزها از وب‌سایت Yahoo گردآوری شد. فرآیند پردازش و تحلیل داده‌ها با استفاده از نرم‌افزار پایتون انجام گرفت. بازه زمانی مورد بررسی، ۲۰۲۲ روز بین ۲۱ مه ۲۰۲۳ تا ۸ دسامبر ۲۰۲۳ انتخاب شد که در این مدت اجزای پرتفوی شاخص بازار از نظر تعداد، نوع و وزن ثابت نگه داشته شدند. علاوه بر پرتفوی شاخص، برای مقایسه و تحلیل دقیق‌تر عملکرد، مجموعه‌ای از پرتفوی‌های منتخب طراحی شد. این پرتفوی‌ها از میان ۵۰ رمزارز برتر از نظر ارزش بازار در تاریخ ۲۱ مه ۲۰۲۳ انتخاب گردیدند.

پرتفوی‌های منتخب شامل موارد زیر است:

- (۱) پرتفوی منتخب شامل اجزای شاخص بازار رمزارزها (CRIX)
- (۲) پرتفوی منتخب با بالاترین ارزش بازار
- (۳) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (واریانس) با استفاده از داده‌های تاریخی ۳۶۵ روز گذشته


- (۴) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (انحراف از معیار) با استفاده از داده‌های تاریخی ۳۶۵ روز گذشته
- (۵) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (واریانس) با استفاده از داده‌های تاریخی ۱۸۰ روز گذشته
- (۶) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (انحراف از معیار) با استفاده از داده‌های تاریخی ۱۸۰ روز گذشته
- (۷) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (واریانس) با استفاده از داده‌های تاریخی ۹۰ روز گذشته
- (۸) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (انحراف از معیار) با استفاده از داده‌های تاریخی ۹۰ روز گذشته
- (۹) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (واریانس) با استفاده از داده‌های تاریخی ۳۰ روز گذشته
- (۱۰) پرتفوی منتخب با بیشترین نسبت بازده به ریسک (انحراف از معیار) با استفاده از داده‌های تاریخی ۳۰ روز گذشته

پیاده‌سازی الگوریتم


در این پژوهش پارامترهای الگوریتم PSO با دقت و بر اساس رویکرد تجربی و آزمون حساسیت تنظیم شده‌اند. انتخاب مقادیر پارامترها به نحوی صورت گرفت که ضمن حفظ تعادل میان اکتشاف و بهره‌برداری در فضای جستجو، همگرایی پایدار و جلوگیری از گرفتار شدن در مینیمم‌های محلی رعایت شود.

نتایج مدل مارکوویتز

در این بخش، تمامی پرتفوی‌های منتخب، بر اساس مدل مارکوویتز و به روش حداقل بازده مورد انتظار و با استفاده از الگوریتم PSO، بهینه‌سازی خواهند شد. شکل (۱)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی شاخص بازار رمزارزها (پرتفوی ۱) را نمایش می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۵,۱۳٪، بازده ۰,۲۹٪ و ضریب تغییر برابر با ۱۷,۳۸ خواهد شد.




شکل ۱: همگرایی و تخصیص وزن بهینه به پرتفوی ۱
در شکل (۲)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین ارزش بازار در تاریخ ۲۰۲۳/۰۵/۲۱ (پرتفوی ۲) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۴,۷۴٪، بازده ۰,۷۵٪ و ضریب تغییر برابر با ۶,۲۹ خواهد شد.




شکل ۲: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۲


در شکل (۳)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۶۵ روز گذشته (پرتفوی ۳) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۵,۸۳٪، بازده ۰,۳٪ و ضریب تغییر برابر با ۱۹,۰۲ خواهد شد.



شکل ۳: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۳ در شکل (۴)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف از معیار) بر اساس داده‌های تاریخی ۳۶۵ روز گذشته (پرتفوی ۴) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۹,۱٪، بازده ۱٪ و ضریب تغییر برابر با ۹,۱ خواهد شد.




شکل ۴: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۴ در شکل (۵)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۱۸۰ روز گذشته (پرتفوی ۵) را نشان می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱,۷٪، بازده ۰,۲۲٪ و ضریب تغییر برابر با ۷,۴۸ خواهد شد.




شکل ۵: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۵

شکل (۶)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف از معیار) بر اساس داده‌های تاریخی ۱۸۰ روز گذشته (پرتفوی ۶) را نشان می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱۳,۲۲٪، بازده ۱٪ و ضریب تغییر برابر با ۱۳,۲۲ خواهد شد.




شکل ۶: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۶


شکل (۷)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۹۰ روز گذشته (پرتفوی ۷) نمایش می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۴,۹۲٪، بازده ۰,۲۸٪ و ضریب تغییر برابر با ۱۷,۱۲ خواهد شد.



شکل ۷: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۷
 شکل (۸)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف از معیار) بر اساس داده‌های تاریخی ۹۰ روز گذشته (پرتفوی ۸) است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱۲,۲۶٪، بازده ۱٪ و ضریب تغییر برابر با ۱۲,۲۶ خواهد شد.




شکل ۸: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۸
 شکل (۹)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۰ روز گذشته (پرتفوی ۹) را نمایش می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱۳,۴۳٪، بازده ۱٪ و ضریب تغییر برابر با ۱۳,۴۳ خواهد شد.



شکل ۹: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۹

مقایسه نتایج حاصل از بهینه‌سازی هر یک از پرتفوی‌های منتخب به وسیله مدل مارکوویتز (حداقل بازده مورد انتظار)، بر اساس شکل (۱۰) مشخص می‌کند که بهترین پرتفوی از نظر نسبت بازده به ریسک (انحراف از معیار) مربوط به پرتفوی منتخب با استفاده از داده‌های تاریخی ۳۶۵ روز بیشترین نسبت بازده به ریسک (واریانس) است.




شکل ۱۰: مقایسه پرتفوی بازار با پرتفوی‌های منتخب بر اساس مدل مارکوویتز

نتایج مدل شارپ


در این بخش تمامی پرتفوی‌های منتخب، بر اساس مدل شارپ و با استفاده از الگوریتم PSO، بهینه‌سازی خواهند شد. در شکل (۱۲)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی شاخص بازار رمزارزها (پرتفوی ۱) نمایش داده شده است. مقادیر حاصل، شامل ریسک

(انحراف از معیار) ۲,۰۵٪، بازده ۰,۲۶٪، ضریب تغییر ۷,۸ و نسبت شارپ برابر با ۰,۰۹ خواهد شد.



شکل ۱۱: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۱


نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین ارزش بازار در تاریخ ۲۰۲۳/۰۵/۲۱ (پرتفوی ۲) در شکل (۱۲) قابل مشاهده است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۳,۰۸٪، بازده ۰,۵٪، ضریب تغییر ۶,۰۶ و نسبت شارپ برابر با ۰,۱۴ خواهد شد.




شکل ۱۲: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۲

شکل (۱۳)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۶۵ روز گذشته (پرتفوی ۳) نمایش


می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۲٪، بازده ۰٫۲۱٪، ضریب تغییر ۹٫۲۶ و نسبت شارپ برابر با ۰٫۰۷ خواهد شد.



شکل ۱۳: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۳
 شکل (۱۴)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف از معیار) بر اساس داده‌های تاریخی ۳۶۵ روز گذشته (پرتفوی ۴) است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱۱٫۷۵٪، بازده ۱٫۴۶٪، ضریب تغییر ۸٫۰۱ و نسبت شارپ برابر با ۰٫۱۱ خواهد شد.




۱۴: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۴
 در شکل (۱۵)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۱۸۰ روز گذشته (پرتفوی ۵) است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱٫۷۶٪، بازده ۰٫۲۴٪، ضریب تغییر ۷٫۱۹ و نسبت شارپ برابر با ۰٫۱ خواهد شد.




شکل ۱۵: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۵

شکل (۱۶)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف از معیار) بر اساس داده‌های تاریخی ۱۸۰ روز گذشته (پرتفوی ۶) است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۴,۵۶٪، بازده ۰,۴۳٪، ضریب تغییر ۱۰,۵۵ و نسبت شارپ برابر با ۰,۰۸ خواهد شد.




شکل ۱۶: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۶

شکل (۱۷)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۹۰ روز گذشته (پرتفوی ۷) نشان می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۱,۷۱٪، بازده ۰,۲۳٪، ضریب تغییر ۷,۲۳ و نسبت شارپ برابر با ۰,۱ خواهد شد.




شکل ۱۷: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۷

شکل (۱۸)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف از معیار) بر اساس داده‌های تاریخی ۹۰ روز گذشته (پرتفوی ۸) نمایش می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۳,۸۱٪، بازده ۰,۳۹٪، ضریب تغییر ۹,۵۶ و نسبت شارپ برابر با ۰,۰۸ خواهد شد.




شکل ۱۸: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۸

در شکل (۱۹)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۰ روز گذشته (پرتفوی ۹) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار) ۴,۸۳٪، بازده ۰,۴۵٪، ضریب تغییر ۱۰,۵۸ و نسبت شارپ برابر با ۰,۰۸ خواهد شد.



شکل ۱۹: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۹

مطابق با شکل (۲۱)، با مقایسه نتایج حاصل از بهینه‌سازی هر یک از پرتفوی‌های منتخب با مدل شارپ، مشخص شد بهترین پرتفوی از نظر نسبت شارپ مربوط به پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۶۵ روزه است.




شکل ۲۰: مقایسه پرتفوی بازار با پرتفوی‌های منتخب بهینه شده بر اساس مدل شارپ

نتایج مدل سورتینو


در این بخش تمامی پرتفوی‌های منتخب، بر اساس مدل سورتینو و با الگوریتم PSO، بهینه‌سازی خواهند شد. شکل (۲۱)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی شاخص بازار رمزارزها (پرتفوی ۱) را نشان می‌دهد. مقادیر حاصل، شامل ریسک (انحراف

از معیار نامطلوب) ۱,۶۷٪، بازده ۰,۲۷٪، ضریب تغییر ۸,۶۵ و نسبت سورتینو برابر با ۰,۱۲ خواهد شد.




شکل ۲۱: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۱

در شکل (۲۲)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین ارزش بازار در تاریخ ۲۰۲۳/۰۵/۲۱ (پرتفوی ۲) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۲,۷٪، بازده ۰,۵۴٪، ضریب تغییر ۶,۲۸ و نسبت سورتینو برابر با ۰,۱۷ خواهد شد.




شکل ۲۲: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۲

نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۶۵ روز گذشته (پرتفوی ۳) در شکل (۲۳) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۱,۸۵٪، بازده ۰,۲۴٪، ضریب تغییر ۱۱,۹۹ و نسبت سورتینو برابر با ۰,۰۹ خواهد شد.




شکل ۲۳: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۳

شکل (۲۴)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف معیار) بر اساس داده‌های تاریخی ۳۶۵ روز گذشته (پرتفوی ۴) را نمایش می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۳۲٫۶۵٪، بازده ۳۳٫۱۱٪، ضریب تغییر ۱۳٫۴۶ و نسبت سورتینو برابر با ۱٫۰۱ خواهد شد.




شکل ۲۴: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۴

شکل (۲۵)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۱۸۰ روز گذشته (پرتفوی ۵) است. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۱٫۵۱٪، بازده ۰٫۲۲٪، ضریب تغییر ۷٫۶۶ و نسبت سورتینو برابر با ۰٫۱ خواهد شد.




شکل ۲۵: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۵

در شکل (۲۶) نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف معیار) بر اساس داده‌های تاریخی ۱۸۰ روز گذشته (پرتفوی ۶) قابل مشاهده است. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۱۵,۹۲٪، بازده ۱۶,۰۱٪، ضریب تغییر ۱۴,۰۴ و نسبت سورتینو برابر با ۱ خواهد شد.




شکل ۲۶: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۶

در شکل (۲۷) نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۹۰ روز گذشته (پرتفوی ۷) نمایش داده شده است. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۱,۷٪، بازده ۰,۲۶٪، ضریب تغییر ۱۰,۳۴ و نسبت سورتینو برابر با ۰,۱۱ خواهد شد.




شکل ۲۷: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۷

شکل (۲۸)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (انحراف معیار) بر اساس داده‌های تاریخی ۹۰ روز گذشته (پرتفوی ۸) را نمایش می‌دهد. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۱۵,۴۲٪، بازده ۱۵,۵۲٪، ضریب تغییر ۱۴,۰۲ و نسبت سورتینو برابر با ۱ خواهد شد.




شکل ۲۸: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۸

شکل (۲۹)، نتایج همگرایی و تخصیص وزن به اجزای پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۰ روز گذشته (پرتفوی ۹) است. مقادیر حاصل، شامل ریسک (انحراف از معیار نامطلوب) ۲۵,۰۹٪، بازده ۲۵,۱۳٪، ضریب تغییر ۱۴,۱۲ و نسبت سورتینو برابر با ۰,۹۹ خواهد شد.



شکل ۲۹: چگونگی همگرایی و تخصیص وزن بهینه به پرتفوی ۹

با مقایسه نتایج حاصل از بهینه‌سازی هر یک از پرتفوی‌های منتخب به وسیله مدل سورتینو، بر اساس شکل ۳۰ می‌توان گفت بهترین پرتفوی از نظر نسبت سورتینو مربوط به پرتفوی منتخب با بالاترین نسبت بازده به ریسک (واریانس) بر اساس داده‌های تاریخی ۳۶۵ روزه است.



شکل ۳۰: مقایسه پرتفوی بازار با پرتفوی‌های منتخب بهینه بر اساس مدل سورتینو

بررسی عملکرد پرتفوی‌های منتخب و مدل‌های بهینه‌سازی

در این قسمت پرتفوی‌های منتخب به وسیله پاسخ‌های بدست آمده و بر اساس نسبت ریسک به بازده، با یکدیگر مقایسه خواهند شد. همان‌طور که در جدول (۱) مشاهده می‌شود بر اساس میانگین پاسخ‌ها، واریانس پاسخ‌ها و بهترین پاسخ بدست آمده، پرتفوی منتخب با بیشترین ارزش بازار در بین تمامی پرتفوی‌های مورد مطالعه، بهترین عملکرد را از خود نشان می‌دهد. همچنین بر همین اساس مطابق با جدول (۲) مدل شارپ از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار است.

جدول ۱: مقایسه پرتفوی‌های منتخب بهینه، بر اساس میانگین نسبت ریسک به بازده، مربوط به مدل‌های مختلف

رتبه بر اساس تعداد بهترین پاسخ	رتبه بر اساس واریانس پاسخ‌ها	رتبه بر اساس میانگین پاسخ‌ها	بهترین پاسخ	واریانس پاسخ‌ها	میانگین پاسخ‌ها	پرتفوی منتخب
۲	۸	۳	۰	۱۶,۷۴۵۱۵۶۱۹	۱۰,۷۲۵۰۹۰۴	بر اساس اجزای پرتفوی بازار
۱	۱	۱	۱	۰,۰۵۶۹۷۳۶۶	۶,۳۳۰۹۹۲۴	بر اساس بیشترین ارزش بازار
۲	۷	۹	۰	۱۲,۷۰۶۲۱۸۹۶	۱۳,۲۷۴۹۳۷۶	بر اساس نسبت بازده به ریسک (واریانس)، طی ۳۶۵ روز گذشته
۲	۴	۴	۰	۷,۳۴۵۱۲۳۳۰۹	۱۱,۰۲۳۹۲۲۲	بر اساس نسبت بازده به ریسک (انحراف معیار)، طی ۳۶۵ روز گذشته
۲	۲	۲	۰	۰,۰۷۹۰۹۳۴۴۷	۷,۶۱۳۷۹۶۸	بر اساس نسبت بازده به ریسک (واریانس)، طی ۱۸۰ روز گذشته
۲	۶	۶	۰	۸,۸۴۳۰۵۵۸۲۹	۱۱,۸۵۴۱۷۳	بر اساس نسبت بازده به ریسک (انحراف معیار)، طی ۱۸۰ روز گذشته

رتبه بر اساس تعداد بهترین پاسخ	رتبه بر اساس واریانس پاسخ‌ها	رتبه بر اساس میانگین پاسخ‌ها	بهترین پاسخ	واریانس پاسخ‌ها	میانگین پاسخ‌ها	پرتفوی منتخب
۲	۹	۵	۰	۱۷,۹۵۷۱۴۱۸۲	۱۱,۰۵۱۰۳۲۶	بر اساس نسبت بازده به ریسک (واریانس)، طی ۹۰ روز گذشته
۲	۵	۷	۰	۴,۱۶۱۱۳۱۷۱۹	۱۲,۸۸۴۰۱۹۴	بر اساس نسبت بازده به ریسک (انحراف معیار)، طی ۹۰ روز گذشته
۲	۳	۸	۰	۲,۳۲۰۶۰۱۸۳۹	۱۳,۲۵۰۸۳۰۲	بر اساس نسبت بازده به ریسک، طی ۳۰ روز گذشته

جدول ۲: مقایسه مدل‌های بهینه‌سازی، بر اساس میانگین نسبت ریسک به بازده، مربوط به ۹ پرتفوی منتخب

نام مدل	میانگین پاسخ‌ها	واریانس پاسخ‌ها	بهترین پاسخ	رتبه بر اساس میانگین پاسخ‌ها	رتبه بر اساس واریانس پاسخ‌ها	رتبه بر اساس تعداد بهترین پاسخ
مدل مارکوویتز	۱۲,۸۱۶۳۴۳۲۲	۲۰,۴۳۷۹۰۶۶۴	۰	۵	۵	۲
مدل شارپ	۸,۴۷۶۵۴۵۸۸۹	۲,۵۲۶۱۶۴۹۹۹	۱	۱	۱	۱
مدل سورتینو	۱۱,۱۷۹۸۱۶	۹,۲۸۱۱۳۹۵۸۱	۰	۴	۳	۲

جمع‌بندی و نتیجه‌گیری

این پژوهش با تمرکز بر بازار رمزارزها، به بررسی تشکیل و تخصیص بهینه پرتفوی بر اساس مدل‌های کلاسیک (مارکوویتز، شارپ و سورتینو) و الگوریتم فراابتکاری بهینه‌سازی ازدحام ذرات (PSO) پرداخت. هدف اصلی، ایجاد رویکردی جامع برای تلفیق انتخاب پرتفوی و تخصیص وزنی بهینه با در نظر گرفتن همزمان ریسک و بازده بود. یافته‌ها نشان دادند که پرتفوی‌های مبتنی بر رمزارزهای با بیشترین ارزش بازار از ریسک کمتری برخوردارند و

مدل شارپ به دلیل توازن مناسب میان ریسک و بازده، عملکرد برتری نسبت به سایر مدل‌ها ارائه می‌دهد. این امر اهمیت استفاده از معیارهای ریسک-بازده در بازار پرنوسان رمزارزها را برجسته می‌سازد.

نوآوری اصلی مقاله، استفاده همزمان از سه مدل کلاسیک ارزیابی پرتفوی در کنار PSO و تمرکز بر پرتفوی شاخص رمزارزها به عنوان مبنای مدیریت غیرفعال است. این رویکرد نه تنها با داده‌های واقعی بازار آزمون شد، بلکه چارچوبی کاربردی و قابل پیاده‌سازی برای سرمایه‌گذاران ارائه کرد. مقایسه‌ها نشان دادند که ترکیب استراتژی‌های انتخاب پرتفوی (بر اساس ارزش بازار و نسبت‌های بازده به ریسک در بازه‌های زمانی مختلف) می‌تواند منجر به طراحی پرتفویی متعادل و کارآمد شود.

چالش‌های پژوهش، شامل ناپایداری داده‌های به‌روز، تغییرات سریع رمزارزها در شاخص‌ها و تأثیر عوامل کلان اقتصادی بر نوسانات بازار بود. در ادامه، تحقیقات آتی می‌تواند با به کارگیری معیارهای پیشرفته‌تر ریسک مانند ارزش در معرض خطر شرطی، لحاظ هزینه‌های معاملاتی، و ترکیب الگوریتم‌های مختلف (PSO، ژنتیک، مونت کارلو) چارچوبی دقیق‌تر برای مدیریت ریسک و افزایش بازده در بازار رمزارزها ارائه دهند.

تعارض منافع: نویسندگان هیچ گونه تعارض منافع ندارند.

ORCID

Iman Ebrahimi

 <http://orcid.org/0009-0000-4724-0210>

Hadi Mokhtari

 <http://orcid.org/0000-0002-5297-5841>

Mohammad Taghi
Rezvan

 <http://orcid.org/0000-0002-0164-2094>

References:

1. Abbas, S. F., & Usman, M. (2025). Optimizing Portfolios in Digital Finance: An Integration of Cryptocurrencies with Conventional Assets. *The Critical Review of Social Sciences Studies*, 3(1), 2894-2913. <https://www.doi.org/10.59075/wmw3j756>

2. Abdelmalek, W. (2024). Cryptocurrencies and portfolio diversification before and during COVID-19. *EuroMed Journal of Business*, 19(4), 1084-1120. <https://www.doi.org/10.1108/EMJB-10-2022-0182>
3. Akyildirim, E., Goncu, A., & Sensoy, A. (2021). Prediction of cryptocurrency returns using machine learning. *Annals of Operations Research*, 297, 3-36. <https://www.doi.org/10.1007/s10479-020-03575-y>
4. Alonso-Monsalve, S., Suárez-Cetrulo, A. L., Cervantes, A., & Quintana, D. (2020). Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators. *Expert Systems with Applications*, 149, 113250. <https://www.doi.org/10.1016/j.eswa.2020.113250>
5. Bulut, M., Uyar, M. E., & Özcan, E. (2024). An integrated model for evaluating the risk factors of crypto-currencies under fuzzy environment. *Engineering Applications of Artificial Intelligence*, 134, 108650. <https://www.doi.org/10.1016/j.engappai.2024.108650>
6. Boido, C., & Aliano, M. (2025). The contribution of cryptocurrencies to portfolio diversification. *INVESTMENT MANAGEMENT & FINANCIAL INNOVATIONS*, 22(2), 26-35. [https://www.doi.org/10.21511/imfi.22\(2\).2025.03](https://www.doi.org/10.21511/imfi.22(2).2025.03)
7. Brauneis, A., & Mestel, R. (2019). Cryptocurrency-portfolios in a mean-variance framework. *Finance Research Letters*, 28, 259-264. <https://www.doi.org/10.1016/j.frl.2018.05.008>
8. Bruhn, P., & Ernst, D. (2022). Assessing the Risk Characteristics of the Cryptocurrency Market: A GARCH-EVT-Copula Approach. *Journal of Risk and Financial Management*, 15(8), 346. <https://www.doi.org/10.1016/j.jrfm.2022.08.008>
9. Chen, S., Chen, C. Y.-H., Härdle, W. K., Lee, T. M., & Ong, B. (2018). Econometric analysis of a cryptocurrency index for portfolio investment. In *Handbook of Blockchain, Digital Finance, and Inclusion, Volume 1* (pp. 175-206). Elsevier. <https://www.doi.org/abs/pii/B9780128104415000087>
10. Elendner, H., Trimborn, S., Ong, B., & Lee, T. M. (2018). The cross-section of crypto-currencies as financial assets: Investing in cryptocurrencies beyond bitcoin. In *Handbook of Blockchain, Digital Finance, and Inclusion, Volume 1* (pp. 145-173). Elsevier. <https://www.doi.org/abs/pii/B9780128104415000075>
11. Han, W., Newton, D., Platanakis, E., Wu, H., & Xiao, L. (2024). The diversification benefits of cryptocurrency factor portfolios: Are they there?. *Review of Quantitative Finance and Accounting*, 63(2), 469-518. <https://www.doi.org/10.1007/s11156-024-01260-w>

12. Inci, A. C., & Lagasse, R. (2019). Cryptocurrencies: applications and investment opportunities. *Journal of Capital Markets Studies*. <https://www.doi.org/10.1108/JCMS-05-2019-0032>
13. Jorion, P. (1997). Value at risk: the new benchmark for controlling market risk. (No Title). <https://www.doi.org/1130282270956536960>
14. Konno, H., & Yamazaki, H. (1991). Mean-absolute deviation portfolio optimization model and its applications to Tokyo stock market. *Management science*, 37(5), 519-531.
15. Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118, 35-40. <https://www.doi.org/10.1016/j.chaos.2018.11.014>
16. Liu, W. (2019). Portfolio diversification across cryptocurrencies. *Finance Research Letters*, 29, 200-205. <https://www.doi.org/10.1016/j.frl.2018.07.010>
17. Markowitz, H. (1959). Portfolio Selection: Efficient Diversification of Investments, Wiley, New York, New York. <https://www.doi.org/>
18. Nakano, M., Takahashi, A., & Takahashi, S. (2018). Bitcoin technical trading with artificial neural network. *Physica A: Statistical Mechanics and its Applications*, 510, 587-609. <https://www.doi.org/10.1016/j.physa.2018.07.017>
19. Parvini, N., Abdollahi, M., Seifollahi, S., & Ahmadian, D. (2022). Forecasting Bitcoin returns with long short-term memory networks and wavelet decomposition: A comparison of several market determinants. *Applied Soft Computing*, 121, 108707. <https://www.doi.org/10.1016/j.asoc.2022.108707>
20. Pintelas, E., Livieris, I. E., Stavroyiannis, S., Kotsilieris, T., & Pintelas, P. (2020). Investigating the problem of cryptocurrency price prediction: a deep learning approach. Artificial Intelligence Applications and Innovations: 16th IFIP WG 12.5 International Conference, AIAI 2020, Neos Marmaras, Greece, June 5–7, 2020, Proceedings, Part II 16. https://www.doi.org/10.1007/978-3-030-49186-4_9
21. Platanakis, E., Sutcliffe, C., & Urquhart, A. (2018). Optimal vs naïve diversification in cryptocurrencies. *Economics Letters*, 171, 93-96. <https://www.doi.org/10.1016/j.econlet.2018.07.020>
22. Rockafellar, R. T., & Uryasev, S. (2000). Optimization of conditional value-at-risk. *Journal of risk*, 2, 21-42. <https://www.doi.org/10.21314/JOR.2000.038>
23. Samuelson, P. A. (1970). The fundamental approximation theorem of portfolio analysis in terms of means, variances and higher moments. *The Review of Economic Studies*, 37(4), 537-542. <https://www.doi.org/37/4/537/1514593>

24. Saxena, A., Sukumar, T., Nadu, T., & Nadu, T. (2018). Predicting bitcoin price using lstm And Compare its predictability with arima model. *International Journal of Pure and Applied Mathematics*, 119(17), 2591-2600. <https://www.doi.org/>
25. Wątarek, M., Drożdż, S., Kwapien, J., Minati, L., Oświęcimka, P., & Stanuszek, M. (2021). Multiscale characteristics of the emerging global cryptocurrency market. *Physics Reports*, 901, 1-82. <https://www.doi.org/10.1016/j.physrep.2020.10.005>
26. Young, M. R. (1998). A minimax portfolio selection rule with linear programming solution. *Management science*, 44(5), 673-683. <https://www.doi.org/10.1287/mnsc.44.5.673>