



Feasibility and Performance Evaluation of the Hybrid Metaheuristic FHO–GPC versus the MO Algorithm for Optimizing MLP Networks to Predict Bitcoin Price Trends under Economic Crisis and Market Volatility

Javad Pourkarimi¹ | Fatemeh Gholami² | Fatemeh Nasrollahi nia³

1. Corresponding Author: Associate Professor, University of Tehran; Department of Educational Management and Planning, Faculty of Psychology and Educational Sciences; Tehran; Iran. Email: jpkarimi@ut.ac.ir
2. Master's student in Human Resources Education and Development, University of Tehran; Department of Educational Management and Planning, Faculty of Psychology and Educational Sciences; Tehran; Iran
3. Assistant Professor, University of Tehran; Department of Educational Management and Planning, Faculty of Psychology and Educational Sciences; Tehran; Iran.

Volume info

Vol. 6
Series: 24
Winter 2026
P.P: 61-87

Article Type

Research Paper

Article History

Received:
2025-01-31
Revised:
2025-09-07
Accepted:
2025-09-07
Published:
2025-12-18

ISSN – E-ISSN

ISSN: 2717-1809
E-ISSN: 2717-199x

Abstract

Cryptocurrencies, particularly Bitcoin, as digital assets based on blockchain technology, have increasingly attracted the attention of investors and financial researchers due to features such as decentralization, transaction transparency, and rapid transfer. However, this market is inherently subject to high volatility and is strongly influenced by economic, political, and technological factors. This challenge becomes even more critical in the context of Iran's economic crisis, caused by international sanctions, currency fluctuations, and high inflation, which highlights the necessity of developing more accurate prediction models. The aim of this study is to assess the feasibility and evaluate the performance of metaheuristic algorithms in optimizing artificial neural networks for forecasting Bitcoin price trends. To this end, the hybrid Fire Hawk Optimizer–Giza Pyramids Construction (FHO–GPC) algorithm was compared with the Moth Ox Optimizer (MO), and the dataset was divided into training (80%) and testing (20%) subsets. The parameters of a multilayer perceptron (MLP) neural network were optimized using these algorithms; specifically, FHO performed the global search, while GPC carried out local optimization. The findings revealed that the MO algorithm, by significantly reducing error metrics (RMSE and MAE) and increasing the coefficient of determination (R^2), delivered more accurate results compared to the hybrid model. This superiority was particularly evident under Iran's volatile and crisis-driven economic conditions. Overall, the results suggest that the MO algorithm can serve as an effective approach for enhancing prediction accuracy and reducing investment risk in emerging and high-risk financial markets.

Keywords: Multilayer Perceptron Neural Network, Metaheuristic Algorithms, Flaming Hawk Optimization (FHO), Giza Pyramids Construction (GPC), Bitcoin Price Prediction

Cite this article: pourkarimi, J., Gholami, F., & Nasrollahi nia, F. (2025). Generation Z Human Resources Leaders Competencies: A Meta-Synthesis Study. *Journal of Research in Human Resources Management*, 17(3), -.

DOR 20.1001.1.20084528.1404.17.3.1.7



Publisher: Imam Hossein University.

© The Author(s).



امکان‌سنجی و ارزیابی عملکرد الگوریتم فراابتکاری ترکیبی FHO-GPC در مقایسه با الگوریتم MO برای بهینه‌سازی شبکه پرسپترون چند لایه در پیش‌بینی روند قیمتی بیت‌کوین در شرایط بحران اقتصادی و نوسانات بازار

آیدین ابوطالبی^۱ | کامبیز بیکارجو^۲ | ابراهیم رضایی^۳ | رحیم خانیزاد^۴

۱. دانشجوی دکتری، گروه اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۲. نویسنده مسئول: استادیار، گروه علمی اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. k.peykarjou@srbiau.ac.ir

۳. دانشیار، پژوهشکده تحقیق و توسعه علوم انسانی، سازمان سمت، تهران، ایران.

۴. استادیار، دانشکده مدیریت، اقتصاد و مهندسی پیشرفت، دانشگاه علم و صنعت ایران، تهران، ایران.

چکیده

رمزارها، به‌ویژه بیت‌کوین، به‌عنوان دارایی‌های دیجیتال مبتنی بر فناوری بلاکچین، به دلیل ویژگی‌هایی همچون غیرمتمرکز بودن، شفافیت تراکنش‌ها و سرعت انتقال، توجه روزافزون سرمایه‌گذاران و پژوهشگران مالی را به خود جلب کرده‌اند. با این حال، این بازار ذاتاً با نوسانات شدید همراه است و تحت تأثیر عوامل اقتصادی، سیاسی و فناوری قرار دارد. این موضوع در شرایط بحران اقتصادی ایران، ناشی از تحریم‌های بین‌المللی، نوسانات نرخ ارز و تورم بالا، اهمیت توسعه مدل‌های پیش‌بینی دقیق‌تر را دوچندان می‌سازد. هدف این پژوهش امکان‌سنجی و ارزیابی عملکرد الگوریتم‌های فراابتکاری در بهینه‌سازی شبکه‌های عصبی مصنوعی جهت پیش‌بینی روند قیمتی بیت‌کوین است. در این راستا، الگوریتم ترکیبی شاهین آتشین-ساخت اهرام جیزه (FHO-GPC) با الگوریتم بهینه‌ساز گاو میش مشکی (MO) مورد استفاده قرار گرفت و داده‌ها به دو بخش آموزش (۸۰) و آزمون (۲۰) تقسیم شدند. پارامترهای شبکه عصبی پرسپترون چندلایه (MLP) توسط این الگوریتم‌ها بهینه‌سازی شدند؛ به‌گونه‌ای که FHO جستجوی سراسری را انجام داده و GPC بهینه‌سازی موضعی را بر عهده داشت. یافته‌ها نشان داد که الگوریتم MO با کاهش معنادار شاخص‌های خطا (RMSE) و (MAE) و افزایش ضریب تعیین (R^2)، عملکرد دقیق‌تری نسبت به مدل ترکیبی ارائه کرده است. این برتری به‌ویژه در شرایط پرنوسان و بحرانی اقتصاد ایران برجسته‌تر بود. نتایج این پژوهش بیانگر آن است که الگوریتم MO می‌تواند به‌عنوان رویکردی کارآمد برای بهبود دقت پیش‌بینی و کاهش ریسک سرمایه‌گذاری در بازارهای مالی نوظهور و پرنوسان مورد استفاده قرار گیرد.

کلیدواژه‌ها: شبکه عصبی پرسپترون چندلایه، الگوریتم‌های فراابتکاری، الگوریتم شاهین آتشین (FHO)، الگوریتم ساخت اهرام جیزه (GPC)، پیش‌بینی قیمت بیت‌کوین

استناد: پورکریمی، جواد، غلامی، فاطمه & نصراللهی نیا، فاطمه. (۱۴۰۴). شایستگی‌های رهبران منابع انسانی نسل زد: پژوهشی فراترکیب. *پژوهش‌های مدیریت منابع انسانی*. - (3) 17,

DOR 20.1001.1.20084528.1404.17.3.1.7

سال و شماره

سال ۶، پیاپی: ۲۴

زمستان ۱۴۰۴

صص: ۸۷-۶۱

نوع مقاله

مقاله پژوهشی

سابقه مقاله

تاریخ دریافت: ۱۴۰۳/۱۱/۱۲

تاریخ بازنگری: ۱۴۰۴/۰۶/۱۶

تاریخ پذیرش: ۱۴۰۴/۰۶/۱۶

تاریخ انتشار: ۱۴۰۴/۰۹/۲۷

شاپا چاپی و الکترونیکی

شاپا چاپی: ۱۸۰۹-۲۷۱۷

الکترونیکی: ۱۹۹۶-۲۷۱۷



نویسندگان.

ناشر: دانشگاه جامع امام

حسین (ع).



OPEN ACCESS

مقدمه و بیان مسئله

ظهور رمزارزها، به‌ویژه بیت‌کوین، در دهه اخیر چشم‌انداز نظام مالی جهانی را دگرگون ساخته و افق‌های تازه‌ای را در عرصه دارایی‌های دیجیتال گشوده است. ویژگی‌هایی همچون غیرمتمرکز بودن، شفافیت تراکنش‌ها و امکان مبادلات فرامرزی با سرعت بالا، بیت‌کوین را به یکی از محورهای اصلی پژوهش‌های مالی و سرمایه‌گذاری بدل کرده است. با این حال، نوسانات شدید قیمتی و حساسیت این بازار به متغیرهای کلان اقتصادی، تحولات سیاسی و رویدادهای اجتماعی، پیش‌بینی روند قیمتی آن را به چالشی اساسی و در عین حال جذاب برای پژوهشگران حوزه اقتصاد مالی تبدیل کرده است. اهمیت این مسأله در اقتصادهای در حال توسعه، نظیر ایران، دوچندان است؛ زیرا علاوه بر تأثیرپذیری از نوسانات جهانی، با بحران‌هایی همچون بی‌ثباتی نرخ ارز، تحریم‌های بین‌المللی و عدم قطعیت در سیاست‌های اقتصادی نیز مواجه‌اند. در چنین بستری، توسعه مدل‌های پیش‌بینی دقیق می‌تواند هم برای سرمایه‌گذاران و هم برای سیاست‌گذاران، نقشی راهبردی در کاهش ریسک و ارتقای کارایی تصمیم‌گیری‌های مالی ایفا کند. با وجود رشد مطالعات در زمینه پیش‌بینی دارایی‌های مالی، روش‌های سنتی مبتنی بر مدل‌های خطی اغلب توانایی لازم برای شناسایی و مدل‌سازی الگوهای پیچیده و غیرخطی داده‌های بازار را ندارند. در این میان، شبکه‌های عصبی مصنوعی، به‌ویژه پرسپترون چندلایه (MLP)، به دلیل قدرت بالا در تقریب توابع غیرخطی و استخراج الگوهای پیچیده، به‌عنوان ابزاری کارآمد در پیش‌بینی سری‌های زمانی مطرح شده‌اند. با این حال، انتخاب بهینه وزن‌ها و بایاس‌ها در این شبکه‌ها همچنان چالشی جدی است که بر دقت و پایداری پیش‌بینی تأثیر مستقیم دارد.

برای غلبه بر این چالش، بهره‌گیری از الگوریتم‌های فراابتکاری به‌عنوان رویکردی نوین در بهینه‌سازی شبکه‌های عصبی پیشنهاد می‌شود. این الگوریتم‌ها با الهام از پدیده‌های طبیعی و اجتماعی، توانایی بالایی در جستجوی سراسری و اجتناب از گرفتار شدن در بهینه‌های محلی دارند. این پژوهش به بررسی و مقایسه کارایی الگوریتم ترکیبی شاهین آتشین-ساخت اهرام جیزه (FHO-GPC) و الگوریتم بهینه‌ساز گاو میش مشکی (MO) در بهینه‌سازی شبکه عصبی پرسپترون چندلایه برای پیش‌بینی کوتاه‌مدت (۵ روزه) روند قیمتی بیت‌کوین پرداخته است.

یافته‌های این تحقیق علاوه بر غنی‌سازی ادبیات موجود، می‌تواند مبنای توسعه مدل‌های پیشرفته‌تر برای مدیریت ریسک و بهبود تصمیم‌گیری سرمایه‌گذاری در شرایط پرنوسان بازارهای نوظهور نظیر ایران قرار گیرد.

پیشینه پژوهش

عزیز نژاد و همکاران (۱۴۰۱) در مقاله خود به دنبال ایجاد یک الگوریتم دقیق و کارآمد برای پیش‌بینی قیمت بیت‌کوین پرداختند. آن‌ها برای دستیابی به این هدف، از الگوریتم‌های یادگیری ماشین مبتنی بر همکاری بهره‌برده‌اند. نتایج به‌دست‌آمده نشان می‌دهد که مدل پیشنهادی آن‌ها در تخمین قیمت بیت‌کوین عملکرد بهتری نسبت به الگوریتم‌های مقایسه‌شده داشته و دقت آن نزدیک به ۸۰ درصد است. با توجه به پیشرفت‌های اخیر در زمینه داده‌کاوی، استفاده از مدل‌های مشارکتی در تخمین قیمت بیت‌کوین بسیار مؤثر واقع شده است.

صیادی نژاد و همکاران (۱۴۰۲) در مقاله خود، مدل هیبریدی (LSTM)(CEEMD-DL) با ترکیب تکنیک‌های یادگیری عمیق و روش تجزیه مد تجزیه‌ی یکپارچه کامل (CEEMD) برای پیش‌بینی بازده قیمت بیت‌کوین، که به عنوان یکی از پرطرفدارترین ارزهای دیجیتال شناخته می‌شود، به کار گرفته‌اند. داده‌های روزانه قیمت بیت‌کوین در بازه زمانی ۲۰۱۳/۰۱/۰۱ تا ۲۰۲۲/۰۵/۲۸ جمع‌آوری و نتایج به‌دست‌آمده با سایر مدل‌های رقابتی بر اساس معیارهای عملکرد مقایسه شد. یافته‌ها نشان‌دهنده این است که استفاده از مدل (LSTM)(CEEMD-DL) باعث بهبود کارایی و دقت پیش‌بینی بازدهی بیت‌کوین شده است.

محمدی نژاد و همکاران (۱۴۰۲) در پژوهشی به بررسی و سنجش اثر سرریز شوک در دوره‌های متفاوت تحریم‌های اقتصادی پرداختند و از داده‌های روزانه مربوط به بازارهای سهام، ارز و سکه طلا طی دوره زمانی ۱۳۸۷/۰۹/۱۴ الی ۱۴۰۱/۱۰/۱۱ با استفاده از مدل VARMA-AGARCH استفاده کردند و نتیجه گرفتند ماندگاری شوک‌های وارده در دوره‌های تحریمی شدید در مقایسه با دوره‌های تحریمی غیر شدید بیشتر می‌باشد.

جواهری و همکاران (۱۴۰۳) در پژوهشی به بررسی رفتار تعاملی و اثر سرریزی بین بازارهای سه‌گانه ارز، بورس اوراق بهادار و رمزارز مبتنی بر تجزیه واریانس مرتبط با یک مدل خود

رگرسیون برداری با پارامترهای متغیر طی زمان (TVP-VAR) به صورت روزانه از ۱۳۹۰ تا ۱۴۰۱ پرداختند و نتایج حاصل نشان داد که بازار ارز و رمز ارز دارای سرریزی خالص مثبت و بازار بورس دارای سرریزی خالص منفی بوده است. همچنین بررسی پیوستگی بین سه بازار نشان می‌دهد هرچند ارتباط بین سه بازار در دوره مورد مطالعه افت و خیزهای متعددی را تجربه کرده ولی در محدوده ۰,۳۵ تا ۱۱,۹۸ درصدی در نوسان بوده است که کمترین ارتباط در سال ۱۳۹۸ و بیشترین ارتباط بین شبکه در بازه ۱۴۰۰ تا ۱۴۰۱ بوده است.

شهبانزی و همکاران (۲۰۲۲) در مطالعه خود به دنبال پیش‌بینی نرخ‌های تبادل روزانه ارز دیجیتال با استفاده از یک تکنیک نوین و اطلاعات متنوع بودند. این تحقیق از یادگیری ماشین برای پیش‌بینی نرخ‌های تبادل بیت‌کوین استفاده می‌کند که به درک بهتر بازار و کمک به معامله‌گران در تدوین استراتژی‌های سرمایه‌گذاری و تدابیر مدیریت ریسک کمک می‌کند. مسائل موجود در پیش‌بینی نرخ تبادل بیت‌کوین شامل کیفیت داده، پیچیدگی مدل و قابلیت تفسیر است که نیازمند اعتبارسنجی و بهبود برای کشف دانش قابل اعتماد و عملی می‌باشد. نتایج آن‌ها نشان می‌دهد که مدل یادگیری ماشین مورد استفاده در مطالعه آن‌ها توانسته به $MAE=0.608$ ، $RMSE=0.765$ و $MAPE=0.005$ دست پیدا کند.

صالح و همکاران (۲۰۲۴) دریافته‌اند که مدل ترکیبی LSTM-GRU به طور مؤثر دینامیک‌های پیچیده بازارهای ارزهای دیجیتال را شناسایی می‌کند و بر محدودیت‌های روش‌های تحلیل سری زمانی سنتی غلبه می‌نماید. این مطالعه از مدل‌های LSTM و GRU برای پیش‌بینی قیمت بیت‌کوین استفاده می‌کند که دقت این پیش‌بینی‌ها را افزایش داده و بینش‌های ارزشمندی برای سرمایه‌گذاران و معامله‌گران فراهم می‌آورد. نتایج آن‌ها نشان می‌دهد که $RMSE=496.077$ برای مدل پیشنهادی بدست آمده است.

فوک و همکاران (۲۰۲۴) در پژوهش خود به پیش‌بینی روند قیمت سهام در ویتنام با استفاده از الگوریتم حافظه طولانی کوتاه مدت (LSTM) و شاخص‌های تحلیل تکنیکال شامل میانگین متحرک ساده (SMA)، میانگین متحرک همگرایی-واگرایی (MACD)، و شاخص قدرت نسبی (RSI) بر اساس داده‌های VN-30 و VN-Index پرداختند. نتایج نشان داد مدل پیش‌بینی برای

بیشتر داده‌های سهام با دقت بالای ۹۳٪ عمل می‌کند. این یافته‌ها مناسب بودن مدل LSTM را در تحلیل و پیش‌بینی حرکات قیمت سهام نشان می‌دهد.

آجیگا و همکاران (۲۰۲۴) به مرور تکنیک‌های یادگیری ماشین (ML) برای پیش‌بینی بازار سهام پرداختند. در ابتدا مدل‌های سنتی سری زمانی مانند ARIMA و MACD و محدودیت‌های آن‌ها در شناسایی الگوهای پیچیده مالی بررسی می‌شوند. سپس، مدل‌های پیشرفته‌تری چون ماشین بردار پشتیبان (SVM)، شبکه‌های عصبی مصنوعی (ANN)، و روش‌های ترکیبی مثل جنگل تصادفی و تقویت گرادیانی مورد بحث قرار می‌گیرند. این مقاله مروری، چالش‌ها و فرصت‌های پیش‌رو برای بهبود دقت در پیش‌بینی‌های بازار را به‌طور جامع بررسی کرده و بینش‌های ارزشمندی برای محققان، فعالان و سرمایه‌گذاران ارائه می‌دهد.

مرور ادبیات نشان می‌دهد بیشتر پژوهش‌های پیشین یا بر مدل‌های سنتی و شبکه‌های عصبی پایه متمرکز بوده‌اند یا از یک الگوریتم فراابتکاری منفرد برای بهینه‌سازی استفاده کرده‌اند. نوآوری این پژوهش در ترکیب دو الگوریتم نوظهور FHO-GPC و مقایسه آن با الگوریتم MO برای بهینه‌سازی شبکه عصبی پرسپترون چندلایه در پیش‌بینی کوتاه مدت (۵ روزه) قیمت بیت‌کوین است.

روش‌شناسی پژوهش

این پژوهش با هدف پیش‌بینی کوتاه‌مدت (۵ روزه) قیمت بیت‌کوین با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) طراحی شده است. داده‌های روزانه بیت‌کوین طی دوره ۱۳ ساله (۶ فوریه ۲۰۱۲ تا ۱ ژوئیه ۲۰۲۵) گردآوری گردیده است. به منظور بهینه‌سازی پارامترهای شبکه در رویکرد پیشنهادی، ترکیب الگوریتم شاهین آتشین (FHO) و ساخت اهرام جیزه (GPC) به کار گرفته شده است، به گونه‌ای که FHO وظیفه جستجوی سراسری در فضای پارامترها و GPC بهینه‌سازی موضعی و پالایش راه‌حل‌ها را بر عهده داشت. داده‌ها به دو بخش آموزش (۸۰) و آزمون (۲۰) تقسیم شدند. برای ارزیابی دقت پیش‌بینی، شاخص‌های آماری استاندارد شامل MSE، RMSE، MAE، R2، RSE و EVS به کار رفته است.

مجموعه داده‌ی مورد استفاده و آماده‌سازی داده‌ها

مجموعه داده‌های قیمت بیت کوین مورد استفاده در این تحقیق مربوط به یک دوره‌ی ۱۳ ساله جمع‌آوری و مورد استفاده قرار گرفته است. این مجموعه داده شامل ۴۸۹۵ نمونه و ۶ متغیر می‌باشند. متغیرهای قیمت رمز ارز بیت کوین در هنگام باز شدن^۱، قیمت بالایی رمز ارز^۲، قیمت پایینی رمز ارز^۳، حجم معاملات^۴ و ارزش بازار ارز^۵ به عنوان متغیرهای ورودی و متغیر قیمت نهایی رمز ارز بیت کوین^۶ به عنوان متغیر خروجی در نظر گرفته شده است.

الگوریتم بهینه‌ساز گاومیش مشکین

الگوریتم بهینه‌سازی گاومیش مشکین (MO) مبتنی بر رفتار طبیعی گاومیش‌ها طراحی شده است که به دلیل قدرت بدنی، استقامت بالا و توانایی کار گروهی، الهام‌بخش حل مسائل بهینه‌سازی پیچیده است. برخلاف الگوریتم‌هایی با جهش‌های ناگهانی، MO پیشرفت تدریجی و پایدار را دنبال می‌کند که از گرفتار شدن در بهینه‌های محلی جلوگیری می‌کند و جستجوی جامع‌تر در فضای مسئله را ممکن می‌سازد. ویژگی همکاری و تبادل اطلاعات بین عامل‌ها در MO مشابه رفتار گروهی گاومیش‌ها است که باعث افزایش سرعت همگرایی و کیفیت راه‌حل‌ها می‌شود. همچنین، انعطاف‌پذیری و توان انطباق الگوریتم با مسائل گسسته و پیوسته، ساده و پیچیده، آن را به ابزاری چندمنظوره تبدیل کرده است. استقامت الگوریتم در اجرای طولانی‌مدت موجب پایداری عملکرد در جستجوی گسترده و پیچیده می‌شود. ساختار سلسله‌مراتبی و هدایت توسط عامل پیشرو در MO به هدفمند کردن فرآیند بهینه‌سازی کمک می‌کند و مقاومت الگوریتم در برابر چالش‌های محیطی مختلف، کارایی آن را در مسائل متنوع تضمین می‌کند. الگوریتم (OX) یک الگوریتم فراابتکاری مبتنی بر جمعیت است که رفتار اجتماعی، استقامت، و همکاری گاومیش‌های مشکین را مدل می‌کند. در این الگوریتم، هر عامل (Ox agent) نشان‌دهنده یک راه‌حل بالقوه در فضای جستجو است و کل جمعیت به صورت تصادفی مقداردهی اولیه می‌شود.

1. open
2. High
3. Low
4. Volume
5. Market Cap
6. Close

موقعیت اعضای جمعیت که با نمادهای $OX1$ و OX نمایش داده می‌شوند، به صورت تصادفی و در بازه‌های مجاز مقداردهی اولیه می‌شوند. این فرایند مطابق با روابط زیر صورت می‌گیرد:

$$OX^1_i = initialization(N, dim, ub, lb) \quad for \quad i = 1, \dots, N \quad (1)$$

$$OX_i = initialization(N, dim, ub, lb) \quad for \quad i = 1, \dots, N \quad (2)$$

که در آن N اندازه جمعیت، dim تعداد ابعاد فضای جستجو و lb, ub کران بالا و پایینی فضای جستجو هستند. شایستگی هر عضو جمعیت اولیه $OX1_i$ با استفاده از تابع هدف $fobj$ محاسبه می‌شود. سپس جمعیت بر اساس مقدار شایستگی مرتب می‌شود و بهترین موقعیت تعیین می‌شود:

$$OX\backslash sorted, idxsorted = sort(\{fOX\backslash i\}^i = 1 \dots N) \quad (3)$$

$$OX\backslash, best = OX\backslash, sorted, 1 \quad (4)$$

$$fOX\backslash best = fOX\backslash sorted, 1 \quad (5)$$

که در آن $OX1, sorted$ جمعیت مرتب شده بر اساس شایستگی، $idxsorted$ اندیس‌های اعضای مرتب شده، $OX1, best$ موقعیت بهترین عضو و $fOX1, best$ مقدار شایستگی بهترین عضو است.

در هر تکرار الگوریتم ۶ مرحله زیر را انجام می‌دهد:

مرحله اول: تولید فرزند (Order Crossover)

$$parent_1, parent_2 = TournamentSelection(OX\backslash sorted, tournament_size) \quad (6)$$

$$offspring = OrderCrossover(parent_1, parent_2) \quad (7)$$

که در آن $parent_1, parent_2$ والدین انتخاب شده و $offspring$ فرزند تولید شده می‌باشد.

مرحله دوم: جهش با پرش (Levy Flight for Mutation)

برای ایجاد تغییرات تصادفی، جهش لوی به صورت زیر روی فرزند اعمال می‌شود:

$$offspring\ levy = offspring + 0.01 \times step \times (offspring - lb) \quad (8)$$

مرحله سوم: بررسی حدود مجاز (Boundary Checking)

موقعیت فرزند طوری تنظیم می‌شود که در بازه مجاز باقی بماند.

$$offspring\ bounded = \min(\max(offspring\ levy, lb), ub) \quad (9)$$

مرحله چهارم: ارزیابی شایستگی فرزندان (Fitness Evaluation of Offspring)
شایستگی هر فرزند به صورت زیر محاسبه می‌شود که در آن fOX_i شایستگی فرزند Ox_i است.

$$OX\ combined = \{OX \setminus sorted, OX\} \quad (10)$$

مرحله پنجم: به‌روزرسانی جمعیت و موقعیت بهینه:
جمعیت جدید از ترکیب جمعیت فعلی و فرزندان تشکیل شده و بر اساس شایستگی مرتب می‌شود:

$$fitness\ combined = \{fOX\ sorted, fOX\} \quad (11)$$

$$OX \setminus sorted, fitness\ sorted = sort(fitness\ combined) \quad (12)$$

در صورتی که عضوی با شایستگی بهتر یافت شود، موقعیت بهینه به‌روزرسانی می‌شود:

$$if\ fitness_{\{sorted, 1\}} < f_{\{OX_{\{1, best\}}\}} \quad (13)$$

$$OX \setminus best = OX \setminus sorted, 1\} \quad (14)$$

$$fOX \setminus best = fitness\ sorted, 1\} \quad (15)$$

مرحله ششم: بهترین مقدار راه‌حل (Best Solution)

در هر تکرار، مقدار بهترین شایستگی ثبت می‌شود تا منحنی همگرایی به‌روزرسانی گردد:

$$best - solution\ t = fOX1best \quad (16)$$

الگوریتم ساخت اهرام جیزه

الگوریتم ساخت اهرام جیزه (Giza Pyramid Construction) یک الگوریتم فراابتکاری الهام‌گرفته از فرآیندهای باستانی ساخت اهرام مصر است که به شبیه‌سازی حرکت و جابجایی بلوک‌های سنگی بزرگ توسط کارگران روی سطوح شیبدار می‌پردازد. در این الگوریتم، راه‌حل‌ها با موقعیت کارگران و بلوک‌های سنگی مرتبط هستند، چرا که کارگران مسئول هل دادن بلوک‌ها در امتداد رمپ می‌باشند. الگوریتم مبتنی بر معادلات حرکت جسمی روی سطح شیبدار است، که نیروهای وارد بر بلوک سنگی را در راستای محورهای X و Y شیب‌دار تعریف می‌کند.

نیروهای گرانش موثر نیز در این چارچوب محاسبه می‌شوند. همچنین احتمال جایگزینی و تغییر موقعیت کارگران در طول فرآیند، برای تنوع‌بخشی به جستجو و بهبود کیفیت راه‌حل‌ها لحاظ شده است. این الگوریتم با مدل‌سازی دقیق نیروها و حرکت بلوک‌ها در فضای مسئله، توانایی بهینه‌سازی مسائل پیچیده و بزرگ‌مقیاس را دارا می‌باشد.

f_k نیروی اصطکاک جنبشی است و از آنجایی که بلوک سنگ در آستانه جابجایی است، f_k را می‌توان از رابطه زیر به دست آورد.

$$f_k = \mu_k mg \cos \theta \quad (17)$$

که m جرم بلوک سنگ، g گرانش زمین، زاویه‌ای است که سطح شیب دار با افق ایجاد می‌کند، و k ضریب اصطکاک جنبشی است. از آنجایی که ما روی محور x قرار داریم، طبق قانون دوم نیوتن یعنی $\sum \vec{F} = m\vec{a}$ ، داریم:

$$-mg \sin \theta - f_k = ma \quad (18)$$

که a شتاب است. با قرار دادن رابطه ۱۷ و ۱۸، شتاب بلوک سنگ به سمت بالا در سطح شیب‌دار به دست می‌آید.

$$a = -g(\sin \theta + \mu_k \cos \theta) \quad (19)$$

بنابراین، در اینجا به یک معادله حرکت مستقل از زمان تحت شتاب ثابت نیاز داریم که با استفاده از معادله زیر می‌توان جابجایی یک بلوک سنگ را روی سطح شیب‌دار محاسبه کرد

$$d = \frac{v_0^2}{2g(\sin \theta + \mu_k \cos \theta)} \quad (20)$$

که d مقدار جابجایی است. همانطور که قبلاً ذکر شد g گرانش زمین است که مقدار آن 9.8 است. زاویه θ زاویه‌ای است که رمپ با افق ایجاد می‌کند. v_0 سرعت اولیه بلوک سنگ است و در الگوریتم با یک عدد تصادفی توزیع شده یکنواخت در هر تکرار تعیین می‌شود.

$$v_0 = rand(0,1) \quad (21)$$

در واقع، $rand(0,1)$ یک عدد تصادفی بین ۰ و ۱ است، یعنی $0 < v_0 = rand(0,1) < 1$. همچنین μ_k ضریب جنبشی اصطکاک بین بلوک سنگ و سطح شیب دار است و در الگوریتم با عدد تصادفی توزیع شده یکنواخت تعیین می‌شود.

$$\mu_k = rand[\mu_{k_min}, \mu_{k_max}] \quad (22)$$

در الگوریتم، حداقل μ_k و ماکزیمم μ_k از قبل تعیین شده‌اند، سپس یک عدد تصادفی بین $\mu_{k_min} \leq \mu_k \leq \mu_{k_max}$ ، به عبارت دیگر، این دو مقدار در هر تکرار در نظر گرفته می‌شود. به عبارت دیگر، است. دلیل تصادفی بودن میزان اصطکاک، صیقلی نبودن سطح رمپ است و به دلیل ناهمواری احتمالی در برخی قسمت‌ها، ممکن است اصطکاک کم یا زیاد شود. ایده اصلی الگوریتم این است که کارگرانی که بلوک سنگ را هل می‌دهند دائماً در حال حرکت یا تکان هستند تا بهترین تسلط و کنترل بر روی بلوک سنگ را به دست آورند. رابطه (۲۰) مقدار جابجایی بلوک سنگ را نسبت به موقعیت قبلی آن تعیین می‌کند. این رابطه با کمی تغییر برای تعیین موقعیت جدید کارگر استفاده می‌شود. برای کارگر اصطکاک در نظر گرفته نمی‌شود. در این رابطه x مقدار حرکت کارگر است.

$$x = \frac{v_0^2}{2g \sin \theta} \quad (23)$$

پس از محاسبه تغییرات جابجایی بلوک سنگ و حرکت کارگر از طریق روابط (۲۰) و (۲۳)، از حاصل این دو معادله می‌توان موقعیت جدیدی به دست آورد. این موقعیت جدید یک راه حل جدید است.

$$\vec{p} = (\vec{p}_i + d) x \vec{e}_i \quad (24)$$

\vec{p}_i موقعیت فعلی است، d مقدار جابجایی بلوک سنگ است (رابطه (۲۰))، x مقدار حرکت کارگر است (رابطه (۲۳))، و \vec{e}_i یک بردار تصادفی است که توزیع یکنواخت، عادی یا Lévy دارد. گاهی در حین ساخت اهرام، کارگر توانایی خود را از دست می‌داد یا قدرت خود را از دست می‌داد و در نتیجه دیگری جایگزین او می‌شد. این عملیات جایگزینی در الگوریتم با

احتمال پنجاه درصد (به طور پیش فرض) انجام می‌شود. بنابراین، پنجاه درصد احتمال دارد که یک کارگر با دیگری در هر تکرار جایگزین شود. استفاده از عملیات جایگزینی بسیار شبیه به اپراتور متقاطع یکنواخت است. فرض می‌شود اگر راه‌حل‌های اولیه مسئله $\phi = (\varphi_1, \varphi_2, \varphi_3, \dots, \varphi_n)$ باشد و راه‌حل‌های تولید شده با استفاده از رابطه (۲۴)، $\psi = (\psi_1, \psi_2, \psi_3, \dots, \psi_n)$ با احتمال پنجاه درصد باشد، برخی از راه‌حل‌های اولیه با راه‌حل‌های تولید شده جایگزین می‌شوند. بنابراین راه‌حل‌های جدیدی $Z = (\xi_1, \xi_2, \xi_3, \dots, \xi_n)$ خواهیم داشت.

$$\xi_k = \begin{cases} \psi_k, & \text{if } \text{rand}[0,1] \leq 0.5 \\ \varphi_k, & \text{otherwise} \end{cases} \quad (25)$$

الگوریتم بهینه‌ساز شاهین آتشین

الگوریتم FHO بر اساس رفتار شکار منحصر به فرد شاهین‌های قهوه‌ای (شاهین آتشین) طراحی شده است که از آتش به عنوان ابزار شکار استفاده می‌کنند. این پرندگان با حمل چوب‌های شعله‌ور و گسترش آتش، طعمه‌ها را وحشت‌زده و مجبور به فرار می‌کنند، که امکان شکار آسان‌تر را فراهم می‌سازد در الگوریتم، این رفتار طبیعی مدل‌سازی شده و تعدادی راه‌حل کاندید به عنوان موقعیت شاهین‌ها و طعمه‌ها تعریف می‌شود FHO. با حفظ تعادل مناسب میان اکتشاف (کاوش فضای جستجو) و بهره‌برداری (تمرکز روی مناطق با کیفیت)، به عنوان یک روش فراابتکاری کارآمد برای حل مسائل پیچیده بهینه‌سازی شناخته می‌شود.

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_i \\ \vdots \\ X_N \end{bmatrix} = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^j & \dots & x_1^d \\ x_2^1 & x_2^2 & \dots & x_2^j & \dots & x_2^d \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_i^1 & x_i^2 & \dots & x_i^j & \dots & x_i^d \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_N^1 & x_N^2 & \dots & x_N^j & \dots & x_N^d \end{bmatrix} \quad (26)$$

$$x_i^j(0) = x_{i,\min}^j + \text{rand} \cdot (x_{i,\max}^j - x_{i,\min}^j), \begin{cases} i = 1, 2, \dots, N. \\ j = 1, 2, \dots, d. \end{cases} \quad (27)$$

که در آن X_i نشان دهنده راه حل i ام در فضای جستجو است؛ d نشان دهنده بعد مسئله در نظر گرفته شده است. N تعداد کل کاندیداهای راه حل در فضای جستجو است. x_i^j زمین متغیر تصمیم از i امین راه حل کاندید است. $x_i^j(0)$ موقعیت اولیه کاندیداهای راه حل را نشان می‌دهد. $x_{i,\max}^j$ و $x_{i,\min}^j$ حداقل و حداکثر کران زمین متغیر تصمیم از i امین راه حل کاندید هستند. و $rand$ یک عدد تصادفی توزیع شده یکنواخت در محدوده $[0, 1]$ است. به منظور تعیین مکان‌های شاهین‌های آتش در فضای جستجو، ارزیابی تابع هدف برای کاندیداهای راه حل مسئله بهینه‌سازی انتخاب شده را در نظر می‌گیرد. برخی از کاندیداهای راه حل با مقادیر تابع هدف بهتر به عنوان شاهین‌های آتش انتخاب می‌شوند، در حالی که بقیه کاندیداهای راه حل طعمه هستند.

$$PR = \begin{bmatrix} PR_1 \\ PR_2 \\ \vdots \\ PR_K \\ \vdots \\ PR_M \end{bmatrix}, K = 1, 2, \dots, m, \quad (29)$$

$$FH = \begin{bmatrix} FH_1 \\ FH_2 \\ \vdots \\ FH_l \\ \vdots \\ FH_n \end{bmatrix}, l = 1, 2, \dots, n, \quad (28)$$

که در آن PR_K نشان دهنده k امین طعمه در فضای جستجو با توجه به تعداد کل شکار FH_l (m) است. و FH_l نشان دهنده l امین شاهین آتش با در نظر گرفتن تعداد کل شاهین آتش (n) در فضای جستجو است. در مرحله بعدی الگوریتم، فاصله کل بین شاهین‌های آتش و طعمه محاسبه می‌شود. در نتیجه نزدیکترین طعمه به هر پرنده مشخص می‌شود تا قلمرو مؤثر این پرنده‌گان مشخص شود و D_k^l با استفاده از رابطه زیر تعیین می‌شود:

$$D_k^l = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \begin{cases} l = 1, 2, \dots, n \\ k = 1, 2, \dots, m \end{cases} \quad (30)$$

که در آن D_k^l فاصله کلی بین شاهین آتشین l ام و k امین طعمه است. m تعداد کل طعمه‌ها در فضای جستجو است. n تعداد کل شاهین‌های آتش در فضای جستجو است. و $(x1, y1)$ و $(x2, y2)$ مختصات شاهین آتش و طعمه را در فضای جستجو نشان می‌دهند.

در الگوریتم FHO، پس از تعیین فاصله شاهین‌های آتش به طعمه‌ها، هر شاهین قلمروی خود را با نزدیک‌ترین طعمه تعیین می‌کند. شاهین‌هایی که عملکرد بهتری دارند، طعمه‌های نزدیک‌تر و مناسب‌تری را انتخاب می‌کنند و در شکار موفق‌ترند. در مرحله بعد، شاهین‌ها چوب‌های سوزان را از آتش اصلی جمع‌آوری و در قلمرو خود پرتاب می‌کنند تا طعمه‌ها را به فرار وادار کنند. برخی شاهین‌ها نیز به دنبال استفاده از چوب‌های سوزان قلمروهای دیگر هستند. این دو رفتار (پرتاب چوب سوزان در قلمرو خود و استفاده از قلمروهای دیگر) به عنوان مکانیزم‌های به‌روزرسانی موقعیت در حلقه جستجوی اصلی الگوریتم مدل‌سازی می‌شوند که تعادل بین اکتشاف و بهره‌برداری را تضمین می‌کند.

$$FH_l^{new} = FH_l + (r_1 \times GB - r_2 \times FH_{Near}), \quad l = 1, 2, \dots, n, \quad (31)$$

که در آن FH_l^{new} بردار موقعیت جدید l امین شاهین‌های آتش است (FH_l). GB بهترین راه حل سراسری در فضای جستجو است که به عنوان آتش اصلی در نظر گرفته می‌شود. FH_{Near} یکی از دیگر شاهین‌های آتش در فضای جستجو است. و r_1 و r_2 اعداد تصادفی به طور یکنواخت در محدوده $(0, 1)$ است که برای تعیین حرکات شاهین‌های آتش به سمت آتش اصلی و تعیین مناطق قلمروی سایر شاهین‌های آتش استفاده می‌شوند. در مرحله بعدی الگوریتم، حرکت طعمه در داخل قلمرو هر شاهین آتش یک جنبه کلیدی از رفتار حیوانات برای فرآیند به‌روزرسانی موقعیت در نظر گرفته می‌شود. هنگامی که یک چوب در حال سوختن توسط یک شاهین آتش رها می‌شود، طعمه تصمیم می‌گیرد پنهان شود، فرار کند یا به اشتباه به سمت شاهین آتش می‌دود.

$$PR_q^{new} = PR_q + (r_3 \times FH_l - r_4 \times SP_l) \begin{cases} l = 1, 2, \dots, n \\ q = 1, 2, \dots, r \end{cases} \quad (32)$$

که در آن PR_q^{new} بردار موقعیت جدید q امین طعمه است (PR_q) که توسط l امین شاهین آتش (FH_l) احاطه شده است. GB بهترین راه حل سراسری در فضای جستجو است که به عنوان آتش اصلی در نظر گرفته می‌شود. SP_l مکانی امن در زیر قلمرو l امین شاهین آتش است. و r_3 و r_4 اعداد تصادفی به طور یکنواخت در محدوده (0, 1) برای تعیین حرکات شکار به سمت شاهین آتش و مکان امن توزیع شده‌اند. علاوه بر این، طعمه ممکن است به سمت قلمرو دیگر شاهین‌های آتش حرکت کند در حالی که این احتمال وجود دارد که طعمه‌ها به کمین‌های نزدیک به شاهین‌های آتش نزدیک شوند یا حتی سعی کنند در مکان امن تری خارج از قلمرو شاهین‌های آتشی که به دام آن‌ها افتاده‌اند پنهان شوند.

$$PR_q^{new} = PR_q + (r_5 \times FH_{Alter} - r_6 \times SP) \begin{cases} l = 1, 2, \dots, n \\ q = 1, 2, \dots, r \end{cases} \quad (33)$$

که در آن PR_q^{new} بردار موقعیت جدید q امین طعمه است (PR_q) است که توسط l امین شاهین آتش (FH_l) احاطه شده است. FH_{Alter} یکی دیگر از شاهین‌های آتش در فضای جستجو است. SP مکانی امن در خارج از قلمرو l امین شاهین آتش است. r_5 و r_6 اعداد تصادفی به طور یکنواخت در محدوده (0, 1) برای تعیین حرکات طعمه‌ها به سمت دیگر شاهین‌های آتش و مکان امن خارج از قلمرو آن‌ها، توزیع شده‌اند. با توجه به اینکه مکان امن در طبیعت مکانی است که اکثر حیوانات برای دور هم جمع شدن در آن جمع می‌شوند تا در هنگام خطر ایمن و سالم بمانند، نمایش ریاضی SP_l و SP به صورت زیر است:

$$SP_l = \frac{\sum_{q=1}^r PR_q}{r} \begin{cases} l = 1, 2, \dots, n \\ q = 1, 2, \dots, r \end{cases} \quad (34)$$

$$SP = \frac{\sum_{k=1}^m PR_k}{m} \quad k = 1, 2, \dots, m \quad (35)$$

که در آن PR_q q امین طعمه است که توسط l امین شاهین آتش (FH_l) احاطه شده است. PR_q k امین طعمه در فضای جستجو است.

یافته‌های پژوهش

نتایج این مطالعه نشان داد که هر دو رویکرد پیشنهادی (FHO-GPC) و الگوریتم MO توانایی پیش‌بینی کوتاه‌مدت (۵روزه) قیمت بیت کوین را دارا هستند، اما مدل مبتنی بر الگوریتم MO به طور معناداری عملکرد بهتری در شاخص‌های ارزیابی از خود نشان داد. به طور کلی، مقدار RMSE در مدل MO به میزان قابل توجهی کمتر از مدل ترکیبی FHO-GPC بود که بیانگر دقت بالاتر در برآورد مقادیر واقعی است. علاوه بر این، مقدار MAE کاهش یافته و R^2 مقادیر نزدیک‌تری به عدد یک به دست آورد که نشان‌دهنده قدرت توضیح‌دهندگی بیشتر مدل است. همچنین، شاخص‌های RSE و EVS نیز برتری نسبی الگوریتم MO را در تبیین واریانس داده‌ها و کاهش خطا تأیید کردند. از منظر تحلیلی، این نتایج را می‌توان به ماهیت جستجوی تدریجی و پایدار الگوریتم MO نسبت داد که موجب اجتناب از بهینه‌های محلی و پوشش جامع‌تر فضای جستجو می‌شود. در مقابل، اگرچه الگوریتم ترکیبی FHO-GPC به واسطه ترکیب جستجوی سراسری (FHO) و بهینه‌سازی موضعی (GPC) توانست همگرایی شبکه را تسریع بخشد، اما در برخی مراحل با نوسان بیشتر و حساسیت به شرایط اولیه مواجه شد و نتایج پایدارتری نسبت به MO ارائه نکرد. از منظر نظری، یافته‌های این پژوهش با بخشی از ادبیات پیشین که بر برتری مدل‌های ترکیبی تأکید دارند، در تضاد قرار گرفته و نشان می‌دهد که در بازارهایی با شرایط بحرانی و پرنوسان، الگوریتم‌های تک‌عاملی پایدار مانند MO می‌توانند عملکرد دقیق‌تری داشته باشند. در عین حال، این نتایج همسو با مطالعاتی است که بر اهمیت الگوریتم‌های مبتنی بر جستجوی پایدار و انعطاف‌پذیر در مواجهه با داده‌های پرتلاطم تأکید دارند. از منظر کاربردی، برتری الگوریتم MO در این پژوهش بیانگر آن است که استفاده از این رویکرد می‌تواند در بازارهای مالی پرنوسان مانند بازار رمزارزها، ابزاری مؤثر برای مدیریت ریسک سرمایه‌گذاری، بهبود تصمیم‌گیری مالی و افزایش دقت پیش‌بینی در شرایط عدم قطعیت اقتصادی باشد. در بستر اقتصاد ایران، که با نوسانات ارزی، تحریم‌ها و محدودیت‌های ساختاری مواجه است، چنین

الگوریتمی می‌تواند ارزش عملی بیشتری در کاهش زیان‌های احتمالی و ارتقای کارایی تصمیم‌گیری‌های مالی داشته باشد.

اجرای مدل و بررسی نتایج

در این پژوهش سعی داریم عملکرد الگوریتم ترکیبی (FHO-GPC) و (MO) را در بازه زمانی کوتاه‌مدت (۵ روزه)، با استفاده از شبکه عصبی مصنوعی بهینه‌سازی شده جهت پیش‌بینی روند قیمتی بیت‌کوین را بررسی کنیم. روند کار به این صورت است که ابتدا داده‌ها در نرم‌افزار MATLAB پیش‌پردازش می‌شوند. پس از نرمال‌سازی داده‌ها و رفع مقادیر گم‌شده، مجموعه داده آماده ارائه به شبکه عصبی مصنوعی می‌شود. سپس شبکه عصبی مصنوعی برای پیش‌بینی قیمت به کمک الگوریتم‌های فوق بهینه‌سازی می‌گردد. در پایان، عملکرد هر الگوریتم در بهینه‌سازی شبکه عصبی و دقت پیش‌بینی قیمت با استفاده از معیارهای ارزیابی و اعتبارسنجی بررسی خواهد شد.

- پیش‌پردازش داده‌ها: پیش‌پردازش داده‌ها به‌عنوان مرحله‌ای کلیدی در یادگیری ماشین، شامل آماده‌سازی داده‌های خام از طریق شناسایی و رفع مقادیر گم‌شده، حذف داده‌های پرت، نرمال‌سازی و تقسیم‌بندی است تا داده‌ها به شکلی استاندارد و قابل استفاده برای آموزش مدل‌ها تبدیل شوند.
- داده‌های ناموجود: داده‌های ناموجود زمانی رخ می‌دهند که برخی ویژگی‌ها مقدار معتبر نداشته باشند و این امر معمولاً ناشی از نویز، خطای ثبت یا ناقص بودن داده است. برای مدیریت آن‌ها می‌توان از روش‌هایی مانند حذف نمونه‌ها، جایگذاری دستی، استفاده از مقادیر ثابت یا جایگزینی با میانگین ویژگی بهره‌گرفت.
- داده‌های پرت: داده‌های پرت مقادیری هستند که به‌طور چشمگیری از الگوی کلی داده‌ها فاصله دارند و می‌توانند دقت مدل‌های یادگیری ماشین را کاهش دهند. برای مدیریت آن‌ها در پیش‌پردازش، معمولاً از روش‌هایی مانند حذف داده‌های پرت یا جایگزینی با مقادیر میانگین استفاده می‌شود تا اثر مخرب آن‌ها کاهش یابد.

- نرمال سازی داده‌ها: نرمال سازی روشی برای هم ترازسازی مقادیر ویژگی‌ها و کاهش اثر تفاوت مقیاس‌ها در مدل سازی است. در این پژوهش، داده‌ها با استفاده از روش مین-مکس به بازه‌ی ۰ تا ۱ تبدیل شدند تا دقت و سرعت الگوریتم بهبود یابد. این فرایند با رابطه (۲۵) انجام شد که در آن مقادیر ورودی بر اساس حداقل و حداکثرشان مقیاس گذاری شده و به بازه‌ی [۰،۱] منتقل شدند.

$$XN = a + \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (b - a) \quad (36)$$

- تقسیم بندی داده‌ها: در یادگیری ماشین، معمولاً داده‌ها به دو بخش تقسیم می‌شوند: داده‌های آموزش و داده‌های آزمایش. در این پژوهش، ۸۰ درصد ابتدایی داده‌ها به عنوان داده‌های آموزش و ۲۰ درصد پایانی آن‌ها به عنوان داده‌های آزمایش در نظر گرفته شده است.

روش کار به این صورت است که در ابتدا یک شبکه عصبی مشخص تعریف می‌شود. در این شبکه، تعداد نورون‌های ورودی برابر با تعداد متغیرهای مستقل است. برای لایه پنهان، تعدادی ثابت از نورون‌ها تعیین می‌شود و در لایه نهایی نیز تعداد نورون‌های خروجی با توجه به خروجی‌های مورد نظر مشخص می‌گردد. پس از ساخت شبکه عصبی، وزن‌ها و بایاس‌ها به صورت تصادفی مقداردهی می‌شوند. به منظور بهره‌گیری از الگوریتم‌های فراابتکاری برای آموزش و به‌روزرسانی وزن‌ها و بایاس‌ها، باید آموزش شبکه عصبی را به‌عنوان یک تابع (اختلاف بین خروجی‌های واقعی و خروجی‌های شبکه عصبی) تعریف کرد و هدف بهینه‌سازی (کاهش) این تابع در فضایی با ابعاد M است که M برابر با مجموع وزن‌ها و بایاس‌های شبکه عصبی ایجاد شده می‌باشد. سپس، مسئله بهینه‌سازی به‌دست آمده می‌تواند با استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری حل شود و این الگوریتم‌ها برای بهینه‌سازی وزن‌ها و بایاس‌های شبکه عصبی فراخوانی می‌شوند. در هر مرحله از الگوریتم، بهترین وزن‌ها و بایاس‌ها انتخاب می‌شوند و در نهایت بهترین نتیجه در میان تمامی پاسخ‌ها به‌عنوان جواب بهینه الگوریتم ارائه می‌گردد. این مقادیر به عنوان وزن‌ها و بایاس‌های شبکه عصبی در نظر گرفته می‌شوند و وزن‌ها به‌روزرسانی

می‌شوند. در نهایت، شرط پایان مورد بررسی قرار می‌گیرد و در صورت برقراری این شرط، الگوریتم خاتمه می‌یابد. شرایط پایانی معمولاً به دو صورت تعریف می‌شود: ۱- خطای حداقل مربعات شبکه (RMSE) از یک آستانه مشخص کمتر باشد ۲- تعداد تکرارهای از پیش تعیین شده. در نهایت، با تحقق این شرایط، به شبکه عصبی با وزن‌ها و بایاس‌های بهینه دست می‌یابیم.

برای آموزش شبکه عصبی مصنوعی با بهره‌گیری از الگوریتم‌های بهینه‌سازی فرابتنکاری وزن‌ها و بایاس‌های هر نورون مصنوعی در شبکه در بردارهای تصادفی تولید می‌شوند به گونه‌ای که شبکه عصبی کمترین خطا را بر روی داده‌های آموزشی داشته باشد. طول این بردار برابر با مجموع وزن‌ها و بایاس‌های لازم برای ایجاد شبکه عصبی است. به‌طور کلی، به‌ازای هر عضو جمعیت تولیدشده در الگوریتم‌های بهینه‌سازی فرابتنکاری، بردارهای تصادفی حاوی مقادیر وزن‌ها و بایاس‌ها ایجاد شده و سپس با استفاده از تابع هدف (RMSE) کیفیت این شبکه‌های عصبی از لحاظ خطای بین مقادیر واقعی و پیش‌بینی شده ارزیابی می‌شود. در انتهای الگوریتم‌های بهینه‌سازی، شبکه عصبی بهینه با کمترین میزان خطا به دست می‌آید.

تابع هدفی که در شبکه‌های عصبی مصنوعی به کار می‌رود، در رابطه زیر نشان داده شده است. در این تابع، Z نمایانگر مقدار واقعی قیمت، \bar{Z} بیانگر قیمت پیش‌بینی شده قیمت توسط شبکه عصبی و n نشان‌دهنده تعداد کل داده‌ها است. در فرایند بهینه‌سازی وزن‌های شبکه‌های عصبی مصنوعی، هدف به دست آوردن مجموعه‌ای از وزن‌هاست که با استفاده از آن‌ها در شبکه عصبی، تفاوت بین خروجی‌های واقعی و خروجی‌های تولیدشده توسط شبکه بر روی داده‌های موجود به حداقل ممکن برسد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_i - \bar{z}_i)^2} \quad (37)$$

با توجه به این که داده‌های قیمت تشکیل‌دهنده یک سری زمانی هستند، برای پیش‌بینی قیمت‌های آینده، متغیرهای ورودی به الگوریتم‌های یادگیری ماشین، شامل مقادیر قیمت‌ها در روزهای گذشته خواهند بود. به عبارت دیگر، ورودی‌های مدل‌های یادگیری ماشین شامل قیمت‌ها

در روزهای پیشین است که این فرآیند به عنوان ایجاد تأخیر زمانی در پارامترهای ورودی شناخته می‌شود.

لذا به منظور پیش‌بینی قیمت بیت‌کوین، در ابتدا تأخیر زمانی بر روی متغیرهای، قیمت رمز ارز در هنگام باز شدن^۱، قیمت بالایی رمز ارز^۲، قیمت پایینی رمز ارز^۳، حجم معاملات^۴ و ارزش بازار^۵ ارز لحاظ می‌شود که به صورت $X - a$ مشخص می‌شود که X پارامتر ورودی و a تعداد روز تأخیر می‌باشد. در این تحقیق ورودی‌های مدل‌های یادگیری ماشین، میزان قیمت رمز ارز بیت‌کوین در هنگام باز شدن، قیمت بالایی رمز ارز، قیمت پایینی رمز ارز، حجم معاملات و ارزش بازار در ۱، ۲، ۳، ۴ و ۵ روز قبل یعنی $(X - 1, X - 2, X - 3, X - 4, X - 5)$ است، به عبارتی میزان تأخیرها را ۱، ۲، ۳، ۴ و ۵ روز قبل در نظر گرفته‌ایم و متغیر خروجی میزان متغیر قیمت نهایی رمز ارز^۶ در ۵ روز بعد یعنی $X + 5$ است که قصد داریم آن را پیش‌بینی کنیم. به عبارت دیگر میزان متغیر قیمت رمز ارز در ۵ روز آینده را تابعی از میزان متغیرهای ورودی در ۱، ۲، ۳، ۴ و ۵ روز قبل در نظر گرفته‌ایم که این عبارت در رابطه زیر نمایش داده شده است. با توجه به اینکه ۵ متغیر ورودی هر کدام ۵ تأخیر بر روی آن‌ها لحاظ شده‌اند، لذا در پژوهش حاضر ۲۵ متغیر ورودی و ۱ متغیر خروجی داریم.

$$X + 5 = f(X - 1, X - 2, X - 3, X - 4, X - 5) \quad (38)$$

معیارهای ارزیابی و اعتبارسنجی

در این پژوهش، کارایی الگوریتم ترکیبی FHO-GPC و الگوریتم MO در رابطه با روند قیمت بیت‌کوین در بازه زمانی کوتاه مدت پنج روزه با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) مورد بررسی قرار گرفته است و برای ارزیابی از معیارهای معتبر به شرح موارد زیر استفاده شده است. در این روابط، X_{imeas} ، X_{ipred} ، \bar{X} ، n به ترتیب برابر با تعداد متغیر اندازه-

1. Open
2. High
3. Low
4. Volume
5. Market Cap
6. Close

گیری شده، مقدار میانگین متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

ضریب تعیین

ضریب تعیین^۱ که با R^2 نمایش داده می‌شود، قدرت توضیح دهنده‌گی مدل را نشان می‌دهد. ضریب تعیین نشان می‌دهد که چند درصد از تغییرات متغیر وابسته توسط متغیرهای مستقل توضیح داده می‌شود. ضریب تبیین بیان‌کننده بخشی از کل واریانس مقادیر مشاهده‌ای است که توسط مقادیر شبیه‌سازی شده توجیه می‌شود. ضریب تبیین بین صفر تا یک تغییر می‌کند و مقدار بهینه آن یک است و این حالت مربوط به زمانی است که در آن مقادیر شبیه‌سازی شده دقیقاً مشابه مقادیر مشاهداتی باشد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_{imeas} - x_{ipred})^2}{\sum_{i=1}^n (x_{imeas} - \bar{x})^2} \quad (39)$$

میانگین مربعات خطا

میانگین مربعات خطا^۲ (MSE) روشی برای برآورد میزان خطاست که در واقع تفاوت بین مقادیر تخمینی و آنچه تخمین زده شده، است. این شاخص که مقداری همواره نامنفی دارد، هرچه قدر مقدار آن به صفر نزدیکتر باشد، نشان‌دهنده میزان کمتر خطاست. مقدار این شاخص به صورت زیر بیان می‌شود:

$$MSE = \frac{1}{n} \times \sum_{i=1}^n [(x_{imeas} - x_{ipred})^2] \quad (40)$$

مجدور میانگین مربعات خطا

مجدور میانگین مربعات خطا^۳ (RMSE) در واقع مجدور شاخص میانگین مربعات خطاست. این شاخص به عنوان معیاری از خطای مطلق بین متغیر شبیه‌سازی و مشاهده‌ای است. مقدار

1. Determination Coefficient
2. Mean Squared Error (MSE)
3. Root Mean Squared Error (RMSE)

این شاخص آماری بین صفر تا بی نهایت متغیر است. هر چه مقدار این شاخص کمتر باشد شبیه سازی بهتری صورت گرفته است و مقدار بهینه آن صفر است.

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n [(x_{imeas} - x_{ipred})^2]} \quad (41)$$

میانگین قدر مطلق خطا

میانگین قدر مطلق خطا^۱ (MAE) میانگین اختلاف بین مقدار پیش‌بینی شده و مقدار واقعی در تمام موارد آزمایش است. این خطای متوسط پیش‌بینی است. هر چه مقدار این شاخص کمتر باشد شبیه سازی بهتری صورت گرفته است و مقدار بهینه آن صفر است.

$$MAE = \frac{1}{n} \times \sum_{i=1}^n |x_{imeas} - x_{ipred}| \quad (42)$$

مربع خطای نسبی

مربع خطای نسبی^۲ (RSE) نشان‌دهنده‌ی عدم تناسب مدل با داده‌های موجود است. به عبارت ساده‌تر، اگر مقدار RSE به صفر نزدیک باشد، مدل شما به خوبی متناسب با داده‌ها است. در غیر این صورت آنگاه مدل دارای تناسب خوبی با داده‌ها نمی‌باشد.

$$RSE = \frac{\sum_{i=1}^n (x_{ipred} - x_{imeas})^2}{\sum_{i=1}^n (\bar{x}_{meas} - x_{imeas})^2} \quad (43)$$

واریانس تبیین شده

در آمار، واریانس تبیین شده^۳ (EVS)، معیاری است که نشان می‌دهد یک مدل ریاضی تا چه اندازه قادر است تغییرات (پراکندگی) داده‌های مشاهده‌شده را توضیح دهد. مقدار ایده‌آل واریانس تبیین شده برابر با ۱ است که بیانگر تطابق کامل مدل با داده‌ها است؛ مقادیر کمتر از این نشان‌دهنده عملکرد ضعیف‌تر مدل در تبیین واریانس داده‌ها می‌باشد.

-
1. Mean Absolute Error (MAE)
 2. Relative Squared Error (RSE)
 3. Explained Variance Score

$$EVS = 1 - \frac{Var\{x_{imeas} - x_{ipred}\}}{Var\{x_{imeas}\}} \quad (44)$$



پیش‌بینی قیمت رمز ارز بیت کوین در بازه زمانی کوتاه مدت ۵ روز آینده

پیش‌بینی قیمت بیت کوین در بازه زمانی کوتاه‌مدت پنج روزه با استفاده از شبکه عصبی مصنوعی بهینه‌سازی‌شده توسط الگوریتم‌های GPC و FHO در نرم‌افزار MATLAB انجام شد. نمودارهای همگرایی طی ۱۰۰ تکرار، کاهش تابع هدف را نشان می‌دهد که بیانگر بهبود مداوم عملکرد مدل در بهینه‌سازی پارامترها است. نمودارهای پراکنش نتایج پیش‌بینی در فازهای آموزش و آزمون ترسیم شده‌اند که در آن محور X مقادیر واقعی و محور Y مقادیر پیش‌بینی شده قیمت بیت کوین را نشان می‌دهد. خط مشکی نشان‌دهنده نیمساز ربع اول است و هرچه نقاط پراکنده به این خط نزدیک‌تر باشند، دقت پیش‌بینی بالاتر و سازگاری مدل با داده‌های واقعی بیشتر است. شکل ۶ تطبیق مقادیر واقعی (رنگ آبی) و پیش‌بینی شده (رنگ قرمز) را در هر دو فاز آموزش و آزمایش نمایش می‌دهد؛ نزدیکی بیشتر این دو نمودار نشان‌دهنده عملکرد دقیق‌تر و قابلیت اطمینان بالاتر مدل بهینه‌سازی‌شده است.

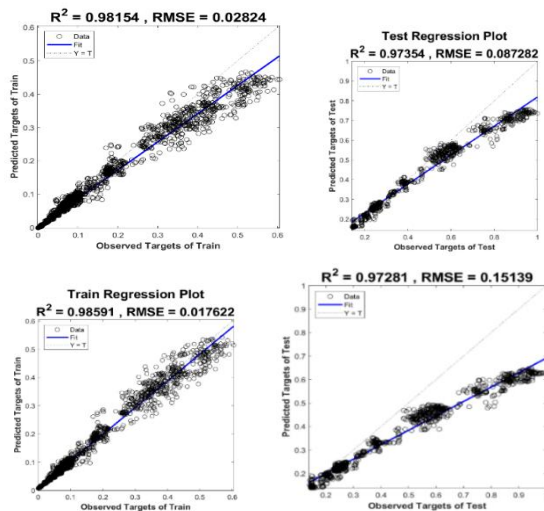
جدول ۱. نتایج الگوریتم‌ها در بازه زمانی کوتاه مدت ۵ روز آینده

| الگوریتم | مرحله | R2 | RMSE | MSE | MAE | RSE | EVS |
|----------|-------|---------|----------|------------|----------|----------|---------|
| MO | Train | 0.98591 | 0.017622 | 0.00031054 | 0.01127 | 0.016743 | 0.87507 |
| | Test | 0.97354 | 0.087282 | 0.0076182 | 0.057489 | 0.11639 | 0.71026 |

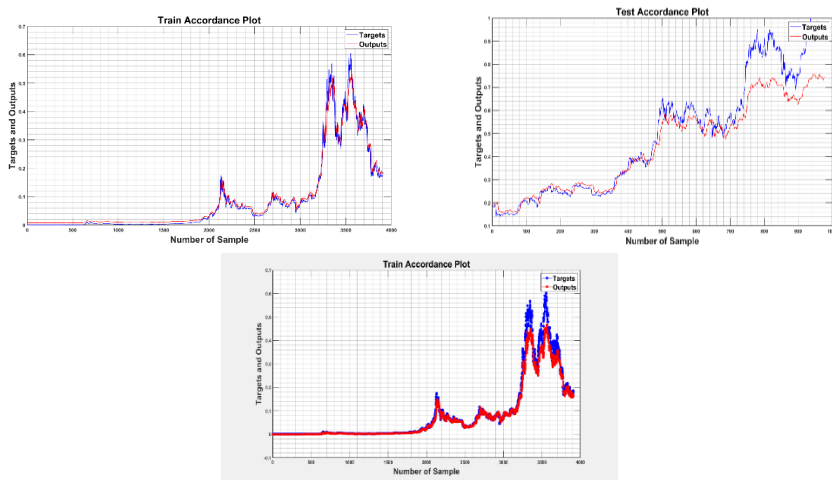
| الگوریتم | مرحله | R2 | RMSE | MSE | MAE | RSE | EVS |
|----------|-------|---------|---------|------------|----------|----------|---------|
| FHO-GPC | Train | 0.98154 | 0.02824 | 0.00079747 | 0.011958 | 0.042997 | 0.80577 |
| | Test | 0.97281 | 0.15139 | 0.02292 | 0.11237 | 0.35016 | 0.60023 |



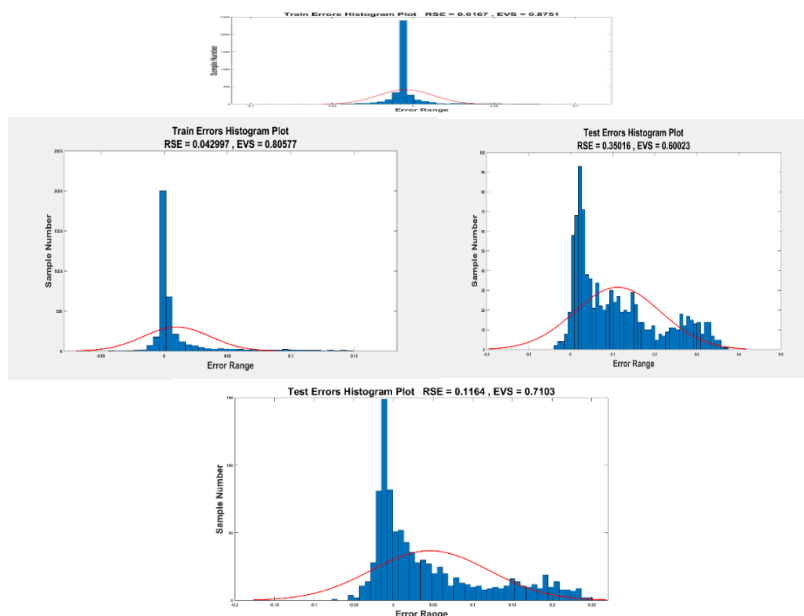
شکل ۴. نمودار همگرایی الگوریتم‌ها برای بهینه‌سازی شبکه عصبی مصنوعی



شکل ۵. نمودار پراکنش مقادیر واقعی و پیش‌بینی شده قیمت بیت کوین توسط مدل‌ها (۵ روز آینده)



شکل ۶. نمودار مقایسه مقادیر واقعی و پیش‌بینی شده قیمت بیت کوین توسط مدل‌ها (۵ روز آینده)



شکل ۷. نمودار هیستوگرام خطای مقادیر واقعی و پیش‌بینی شده قیمت بیت کوین توسط مدل‌ها

نتیجه‌گیری و پیشنهادها

نتایج این پژوهش نشان داد که الگوریتم بهینه‌ساز گاومیش مشکی (MO) در مقایسه با مدل ترکیبی شاهین آتشین-ساخت اهرام جیزه (FHO-GPC) عملکرد دقیق‌تری در پیش‌بینی کوتاه‌مدت قیمت بیت کوین ارائه می‌دهد. این برتری با کاهش معنادار شاخص‌های خطا مانند RMSE و MAE و همچنین افزایش قابل توجه ضریب تعیین (R^2) تأیید شد. علاوه بر این، شاخص‌های RSE و EVS نیز نشان دادند که الگوریتم MO توانایی بالاتری در تبیین تغییرات سری‌های زمانی بیت کوین دارد. از منظر تحلیلی، این نتایج بیانگر آن است که ماهیت جستجوی تدریجی و پایدار الگوریتم MO، که مانع از گرفتار شدن در بهینه‌های محلی می‌شود، موجب پوشش جامع‌تر فضای جستجو و ارائه عملکرد باثبات‌تر در مواجهه با داده‌های پرتلاطم و غیرایستا گردید. در مقابل، مدل ترکیبی FHO-GPC با وجود آنکه سرعت همگرایی را افزایش داد، اما به دلیل حساسیت بالا به شرایط اولیه و وابستگی به کیفیت جستجوی سراسری، نتایج پایدارتری

نسبت به MO ارائه نکرد. مقایسه با پژوهش‌های پیشین نشان می‌دهد که یافته‌های این تحقیق همسو با نتایج صیادی نژاد و همکاران (۱۴۰۲) است که بر ضرورت استفاده از مدل‌های غیرخطی و پیشرفته در پیش‌بینی قیمت بیت کوین تأکید داشتند. همچنین، نتایج حاضر یافته‌های سایر مقالات استفاده شده در پیشینه را تکمیل می‌کند، زیرا نشان می‌دهد استفاده از الگوریتم‌های فراابتکاری در بهینه‌سازی پارامترهای شبکه‌های عصبی می‌تواند دقت مدل‌های ترکیبی را بهبود بخشد. در عین حال، بخشی از یافته‌های عزیز نژاد و همکاران (۱۴۰۱) اصلاح شد؛ برخلاف آن‌ها که مدل‌های مشارکتی مبتنی بر یادگیری ماشین را دقیق‌ترین روش دانسته بودند، این مطالعه نشان داد که در شرایط پرنوسان بازار رمزارز، الگوریتم تک‌عاملی پایدار MO عملکرد بهتری ارائه می‌دهد. همچنین، این نتایج با پژوهش شهبانزی و همکاران (۲۰۲۲) همراستا است که بر اهمیت مدل‌های یادگیری ماشین در کاهش خطای پیش‌بینی تأکید داشتند.

از منظر نظری، این پژوهش شکاف مهمی در ادبیات پیش‌بینی مالی را پر کرده است. مقایسه مستقیم بین الگوریتم‌های تک‌عاملی و ترکیبی در شرایط بحرانی و پرنوسان کمتر انجام شده بود و یافته‌های حاضر نشان می‌دهد که الگوریتم‌های تک‌عاملی پایدار مانند MO می‌توانند در برخی بسترها دقت و قابلیت اطمینان بیشتری نسبت به مدل‌های ترکیبی داشته باشند. از منظر کاربردی نیز، این نتایج اهمیت بالایی برای سرمایه‌گذاران، مدیران پرتفوی و سیاست‌گذاران مالی دارد؛ زیرا دقت بالاتر الگوریتم MO می‌تواند به طراحی ابزارهای هوشمند مدیریت ریسک، کاهش عدم اطمینان در تصمیم‌گیری‌های سرمایه‌گذاری و بهبود تخصیص منابع کمک نماید. اهمیت این موضوع در اقتصاد ایران، که با نوسانات شدید نرخ ارز، تحریم‌های اقتصادی و عدم قطعیت‌های سیاستی مواجه است، دوچندان خواهد بود. با وجود این دستاوردها، این پژوهش محدودیت‌هایی نیز دارد. نخست، تمرکز بر یک دارایی دیجیتال (بیت کوین) موجب می‌شود نتایج لزوماً به سایر رمزارزها یا بازارهای مالی تعمیم‌پذیر نباشد. دوم، مدل صرفاً بر داده‌های تاریخی قیمت و حجم متکی است و متغیرهای کلان اقتصادی و رفتاری در آن لحاظ نشده‌اند. سوم، افق بررسی محدود به کوتاه‌مدت (۵ روزه) بود.

بر این اساس، پیشنهاد می‌شود در تحقیقات آینده:

۱. کارایی الگوریتم MO در ترکیب با سایر الگوریتم‌های فراابتکاری بررسی گردد تا مدل‌های ترکیبی پایدارتر توسعه یابند.
 ۲. متغیرهای کلان اقتصادی مانند نرخ بهره و تورم به مدل افزوده شوند تا قدرت توضیح‌دهندگی آن افزایش یابد.
 ۳. عملکرد الگوریتم‌ها در پیش‌بینی سایر رمزارزها یا دارایی‌های مالی با ماهیت متفاوت ارزیابی گردد.
 ۴. بازه‌های زمانی میان‌مدت و بلندمدت نیز تحلیل شود تا قابلیت تعمیم‌پذیری نتایج در افق‌های مختلف بررسی گردد.
- در مجموع، این پژوهش نشان داد که الگوریتم MO می‌تواند به‌عنوان ابزاری کارآمد و پایدار در پیش‌بینی کوتاه‌مدت قیمت دارایی‌های دیجیتال در شرایط بحران اقتصادی و نوسانات شدید بازارهای نوظهور مورد استفاده قرار گیرد. این یافته نه تنها بر ادبیات علمی حوزه هوش مصنوعی و مالی می‌افزاید، بلکه از منظر عملی نیز می‌تواند به توسعه سیستم‌های هوشمند پیش‌بینی و مدیریت ریسک در بازارهای مالی کمک کند.

فهرست منابع

- الهام، ع.، فاطمه، خ.، و بهزاد، ه. (۱۴۰۱). طراحی مدلی مشارکتی با استفاده از الگوریتم‌های هوش مصنوعی به منظور پیش‌بینی قیمت بیت‌کوین. دومین کنفرانس مکانیک، برق، مهندسی هوافضا و علوم مهندسی. بازیابی از <https://civilica.com/doc/1448408/>
- صیادی، ن. س.، اسماعیل‌زاده، ع.، و رضایی، م. (۱۴۰۲). ارائه مدل پیش‌بینی بازدهی بیت‌کوین با استفاده از روش هیبریدی یادگیری عمیق-الگوریتم تجزیه سیگنال (CEEMD-DL). اقتصاد مالی، ۱۷(۶۲)، ۲۱۷-۲۳۸.
- محمدی نژاد پاشاکی، محمدباقر & اقبال نیا، محمد. (۱۴۰۲). بررسی و تحلیل اثر تحریم های اقتصادی در سرریز نوسان به بازارهای سهام، ارز و سکه طلا. پژوهش‌های راهبردی بودجه و مالیه. 4(2), 149-173.
- <https://dor.isc.ac/dor/20.1001.1.27171809.1402.4.2.5.7>
- جوهری، شیماء، شعبانی، احمد & قائمی اصل، مهدی. (۱۴۰۳). بررسی سرریزی بازدهی در سه بازار ارز، رمز ارز و بورس تهران با به کار گیری مدل خود رگرسیون برداری با پارامترهای متغیر طی زمان (TVP- VAR). پژوهش‌های راهبردی بودجه و مالیه. 5(1), 31-56.
- <https://dor.isc.ac/dor/20.1001.1.27171809.1403.5.1.2.9>
- Al Hwaitat, A. K., & Fakhouri, H. N. (2024). The OX Optimizer: A novel optimization algorithm and its application in enhancing support vector machine performance for attack detection. *Symmetry*, 16(8), 966. <https://doi.org/10.3390/sym16080966>
- Azizi, M., Talatahari, S., & Gandomi, A. H. (2023). Fire Hawk Optimizer: A novel metaheuristic algorithm. *Artificial Intelligence Review*, 56(1), 287–363. <https://doi.org/10.1007/s10462-022-10183-7>
- Harifi, S., Mohammadzadeh, J., Khalilian, M., & Ebrahimnejad, S. (2021). Giza Pyramids Construction: An ancient-inspired metaheuristic algorithm for optimization. *Evolutionary Intelligence*, 14(4), 1743–1761. <https://doi.org/10.1007/s12065-021-00574-4>
- Hussein, N., & Abdulazeez, A. M. (2024). Bitcoin price prediction using hybrid LSTM-GRU models. *International Journal of Computer Science*, 13(1), 1–15.
- Shahbazi, Z., & Byun, Y.-C. (2022). Knowledge discovery on cryptocurrency exchange rate prediction using machine learning pipelines. *Sensors*, 22(5), 1740. <https://doi.org/10.3390/s22051740>
- Ajiga, D. I., et al. (2024). Machine learning for stock market forecasting: A review of models and accuracy. *Journal of Finance and Data Science*, 6(2), 112–124.
- T., X., et al. (2024). Applying machine learning algorithms to predict the stock price trend in the stock market: The case of Vietnam. *Journal of Economic Studies*, 11(1), 33–49.

