



Forecasting the Price of Cryptocurrencies Using Meta-Learning Algorithms

Saeed Nikparvar¹ | Farid Ahmadi^{2✉} | Hashem Kalbkhani³

1. MSc. of IT and Computer Engineering, Urmia University of Technology, Urmia, Iran.
2. E-mail: saeed.nik75@gmail.com Associate Professor of Electrical Engineering, Urmia University of Technology, Urmia, Iran. (Corresponding Author). E-mail: f.ahmadi@uut.ac.ir
3. Associate Professor of Electrical Engineering, Urmia University of Technology, Urmia, Iran. E-mail: h.kalbkhani@uut.ac.ir

Article Info

Article type:

Research Article

Article history:

Received

20 August 2024

Received in revised form

2 October 2024

Accepted

20 December 2024

Keywords:

Optimization, Prediction, Bitcoin price, Meta-learning, XGBoost.

ABSTRACT

Background: With the development and change of the surrounding world, earning and trading have also transformed, so Bitcoin and other similar cryptocurrencies can be an alternative to the common currencies of the world in the future. Therefore, its price prediction will be essential in investing in these cryptocurrencies. Researchers have proposed various methods to improve the accuracy of Bitcoin price prediction. Examining the results of these approaches shows that no significant result has been achieved in predicting the price of Bitcoin.

Objective: This research, relying on machine learning and data mining, proposes new models to predict the price of Bitcoin.

Methodology: The core of the proposed models is the XGBoost algorithm, which is in the category of meta-learning algorithms. To increase the efficiency of the XGBoost parameter setting model in the form of an optimization problem, the definition and values of the target parameters were searched using the Harris Hawks algorithm. The second proposed model is also based on the LSTM algorithm, which combines the XGBoost algorithm with the LSTM algorithm.

Findings and Originality: The first proposed model reaches the highest prediction accuracy with an R^2 index of 99.32 for 30 falcons. The second proposed model with 70 LSTM blocks reaches the highest level of accuracy with an R^2 index of 74.86. The first proposed model is more accurate in price prediction than the second proposed model and other models, so with the RMSE index, the error rate in the first proposed model reaches 0.0086.

Cite this article: Nikparvar, S. Ahmadi, F. and Kalbkhani, H. (2024). Forecasting the Price of Cryptocurrencies Using Meta-Learning Algorithms. Iranian Journal of Wargaming, 7(14), 135- 158.

DOI: 10.22034/ijwg.2024.472660.1090





پیش‌بینی قیمت رمز ارزها با استفاده از الگوریتم‌های فرا یادگیری

سعید نیک‌پرور^۱ | فرید احمدی^۲ | هاشم کلب‌خانی^۳

۱. کارشناسی ارشد مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی ارومیه، ارومیه، ایران.
 ۲. دانشیار مهندسی برق، دانشگاه صنعتی ارومیه، ارومیه، ایران. (نویسنده مسئول)، رایانامه: f.ahmadi@uut.ac.ir
 ۳. دانشیار مهندسی برق، دانشگاه صنعتی ارومیه، ارومیه، ایران. رایانامه: h.kalbkhani@uut.ac.ir
- رایانامه: saeed.nik75@gmail.com

اطلاعات مقاله چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۵/۲۰

تاریخ بازنگری: ۱۴۰۳/۰۷/۱۱

تاریخ پذیرش: ۱۴۰۳/۰۹/۳۰

کلیدواژه‌ها: بهینه‌سازی، پیش‌بینی، قیمت بیت-کوین، فرا یادگیری، XGBoost

زمنه: با پیشرفت و تغییر دنیای پیرامون، کسب درآمد و داد و ستد نیز دچار دگرگونی شده است به‌نحوی که بیت‌کوین و دیگر رمز ارزهای مشابه در آینده می‌توانند جایگزینی برای ارزهای رایج دنیا باشند. از این رو پیش‌بینی قیمت آن‌ها نقش بسیار مهمی در سرمایه‌گذاری بر روی این رمز ارزها خواهد داشت. پژوهشگران روش‌های مختلفی برای بهبود دقت پیش‌بینی قیمت بیت‌کوین پیشنهاد کرده‌اند. بررسی نتایج این رویکردها نشان می‌دهد تاکنون نتیجه چشمگیری در پیش‌بینی قیمت بیت‌کوین حاصل نشده است.

هدف: در این پژوهش با تکیه بر یادگیری ماشین و داده‌کاوی، مدل‌های جدیدی برای پیش‌بینی قیمت بیت‌کوین پیشنهاد شده است.

روش پژوهش: هسته اصلی مدل‌های پیشنهادی الگوریتم XGBoost است که در دسته الگوریتم‌های فرا یادگیری است. برای افزایش کارایی مدل تنظیم پارامترهای XGBoost در قالب یک مسئله بهینه‌سازی تعریف و مقادیر پارامترهای هدف با استفاده از الگوریتم شاهین هریس جستجو شد. مدل پیشنهادی دوم نیز مبتنی بر الگوریتم LSTM است که الگوریتم XGBoost با الگوریتم LSTM ترکیب می‌شود. یافته‌ها و نتیجه‌گیری: مدل پیشنهادی اول به‌ازای ۳۰ شاهین به بالاترین دقت پیش‌بینی با شاخص R^2 به ۹۹/۳۲ می‌رسد. مدل پیشنهادی دوم با ۷۰ بلوک LSTM به بالاترین میزان دقت با شاخص R^2 به ۷۴/۸۶ می‌رسد. مدل پیشنهادی اول میزان دقت بیشتری در پیش‌بینی قیمت نسبت به مدل پیشنهادی دوم و سایر مدل‌ها را دارد، به‌نحوی که با شاخص RMSE نرخ خطا در مدل پیشنهادی اول به ۰/۰۰۸۶ می‌رسد.

استناد: نیک‌پرور، سعید؛ احمدی، فرید و کلب‌خانی، هاشم. (۱۴۰۳). پیش‌بینی قیمت رمز ارزها با استفاده از الگوریتم‌های فرا یادگیری. دوفصلنامه بازی جنگ، ۷(۱۴)، ۱۳۵-۱۵۸.

DOI: 10.22034/ijwg.2024.472660.1090



ناشر: دانشگاه فرماندهی و ستاد ارتش جمهوری اسلامی ایران

مقدمه

بر اساس نظرات کارشناسان، بیت‌کوین^۱ و دیگر رمز ارزهای^۲ مشابه می‌توانند در آینده جایگزینی برای ارزهای رایج دنیا باشند (Hossain, 2021)؛ لذا پیش‌بینی قیمت آن نقش بسزایی در بانک‌داری نوین و سرمایه‌گذاری خواهد داشت. پژوهشگران با علم بر این مسئله و درک اهمیت موضوع، روش‌های مختلفی برای بهبود دقت پیش‌بینی قیمت بیت‌کوین پیشنهاد کرده‌اند (Chen et al., 2020). تحقیق در حوزه پیش‌بینی قیمت رمز ارزها با استفاده از الگوریتم‌های یادگیری ماشین به دلیل نوسانات شدید و بی‌ثباتی‌های بازار رمز ارزها از اهمیت زیادی برخوردار است. رمز ارزها به‌عنوان یک کلاس دارایی نوظهور به‌طور فزاینده‌ای توجه سرمایه‌گذاران و تحلیلگران مالی را جلب کرده‌اند و استفاده از مدل‌های پیش‌بینی مبتنی بر الگوریتم‌های آموزشی می‌تواند به کشف الگوهای پیچیده در داده‌ها و تقویت تصمیم‌گیری‌های سرمایه‌گذاری کمک کند. بر اساس تحقیقات انجام شده، این الگوریتم‌ها قابلیت شناسایی ارتباطات غیرخطی و تعاملات بین متغیرهای مختلف را دارند که می‌تواند به کاهش ریسک و افزایش بازدهی در سرمایه‌گذاری‌های مربوط به رمز ارزها منجر شود (Zhang & Zohren, 2018)؛ به‌علاوه، این مطالعات می‌توانند به توسعه ابزارهای بهینه‌سازی استراتژی‌های تجاری و مدیریت پورتفولیو در شرایط متغیر بازار کمک کنند. استفاده از شبکه‌های عصبی، ماشین بردار پشتیبان (SVM^۳)، درخت تصمیم (DT^۴) و ... از جمله این روش‌ها بوده است. بررسی نتایج این رویکردها نشان می‌دهد که علیرغم مدل‌سازی مسئله پیش‌بینی قیمت با یادگیری ماشین، تاکنون نتیجه چشم‌گیری در پیش‌بینی قیمت بیت‌کوین و عرصه بلاک‌چین حاصل نشده است. نسل بعدی این الگوریتم‌ها به یادگیری عمیق مشهور است (Ji et al., 2019). این الگوریتم‌ها دقت بالایی در مسائل طبقه‌بندی دارند، ولی باید در نظر داشت که برای مجموعه داده‌هایی با نمونه کم مناسب نبوده و با پیچیدگی محاسباتی بالایی همراه هستند.

در این پژوهش به‌منظور پیش‌بینی نوسانات قیمت بیت‌کوین از رویکرد فرا یادگیری^۵ و الگوریتم XGBoost استفاده خواهد شد. از قابلیت‌های ویژه این الگوریتم می‌توان به موارد زیر اشاره کرد:

1. Bitcoin
2. Cryptocurrency
3. Support vector machine (SVM)
4. Decision tree (DT)
5. Meta-learning

- کاهش نسبی گره‌های برگ که برای بهبود تعمیم مدل استفاده می‌شود.
 - تقویت گرادیان نیوتنی که یک مسیر مستقیم به سمت کمینه نسبت به گرادیان نزولی فراهم می‌کند که آن را بسیار سریع‌تر می‌کند.
 - با اضافه کردن یک پارامتر تصادفی‌سازی اضافی، استحکام گروه را بهبود می‌بخشد. با توجه به قابلیت‌های اشاره‌شده می‌توان انتظار داشت که پیچیدگی محاسباتی فرایند پیش‌بینی نوسانات قیمتی بیت‌کوین با روش XGBoost کاهش پیدا کند؛ این در حالی است که کاهش خطای پیش‌بینی نیز دور از انتظار نخواهد بود.
- لازم به ذکر است که در این تحقیق به پیش‌بینی قیمت بیت‌کوین با استفاده از روش پیشنهادی اقدام شده است. دلیل این انتخاب نیز از این رو است که پیش‌بینی قیمت بیت‌کوین می‌تواند به پیش‌بینی سایر رمز ارزها نیز کمک کند؛ زیرا بیت‌کوین به‌عنوان بزرگ‌ترین و پیشروترین رمز ارز تأثیر قابل‌توجهی بر بازار کلی رمز ارزها دارد و تغییرات قیمت آن معمولاً بر سایر ارزها تأثیر می‌گذارد (Demir et al. 2020). بسیاری از ارزهای دیگر به لحاظ قیمتی با بیت‌کوین همبستگی‌های بالایی دارند (Li et al. 2021). علاوه بر این، مدل‌های پیش‌بینی که برای تحلیل قیمت بیت‌کوین استفاده می‌شوند، می‌توانند به‌طور مؤثری با کمی تعدیل برای سایر رمز ارزها نیز به کار روند (Sharma et al. 2021).

مبانی نظری و پیشینه‌های پژوهش

بررسی کارهای پیشین نشان می‌دهد که پژوهشگران مدل‌های مختلفی را برای پیش‌بینی قیمت بیت‌کوین بررسی کرده‌اند. برخی از مدل‌های پایه یادگیری ماشین مانند SVM (Rathan et al., 2019) DT (Poyser, 2019)^۱، شبکه‌های بیزین^۱ (Karasu et al., 2018) و... استفاده کرده‌اند. در این دسته، مدل‌های مبتنی بر یادگیری گروهی نیز قرار دارند. برخی نیز استفاده از مدل‌های یادگیری عمیق مانند شبکه‌های عصبی تلفیقی (CNN^۲) (Yogeshwaran et al., 2019) و حافظه کوتاه‌مدت طولانی (LSTM^۳) (Lahmiri & Bekiros, 2019) را پیشنهاد داده‌اند. در مدل‌های مبتنی بر یادگیری ماشین، مدل‌های مبتنی بر فرا یادگیری نیز مطرح شده است. پژوهشگرانی هم بوده‌اند که مدل‌های مبتنی

1. Bayesian

2. Convolutional neural network (CNN)

3. Long short-term memory (LSTM)

بر احتمال مانند $ARIMA^1$ (Derbentsev et al., 2019) و $GARCH^2$ (Aras, 2021) را توصیه کرده‌اند. این در حالی است که مدل‌های مبتنی بر استنتاج فازی نیز پیشنهاد شده است. علاوه بر این مدل‌ها برخی نیز فرایند پیش‌بینی را بر اساس احساسات کاربران انجام داده‌اند. در این مدل‌ها نخست ویژگی‌های مدنظر از متن‌ها و نظرات کاربران استخراج شده و در ادامه فرایند یادگیری ماشین انجام می‌گیرد.

جدول ۱، مدل‌هایی که اخیراً برای پیش‌بینی قیمت بیت‌کوین ارائه شده است را مقایسه می‌کند. بر اساس این مقایسه، می‌توان پیچیدگی محاسباتی مدل‌های پیش‌بینی، مصرف حافظه، نرخ خطای پیش‌بینی و نهایتاً آموزش مدل را از چالش‌های مطرح در این حوزه عنوان کرد. بر همین اساس باید تلاش شود مدلی که برای پیش‌بینی قیمت بیت‌کوین ارائه می‌شود؛ ضمن کاهش زمان اجرا، خطای پیش‌بینی کمتری نیز داشته باشد. با مروری بر کارهای پیشین مشاهده می‌شود که بخشی از تحقیقات انجام‌شده تقریباً دارای پیچیدگی بالایی هستند و برای داده‌های پویا کارایی پایینی دارند. در همین راستا در ادامه به معرفی روش‌های پیشنهادی می‌پردازیم که در مقایسه با سایر روش‌ها یک نوآوری در پیش‌بینی قیمت است. این روش‌ها دارای پیچیدگی محاسباتی کمتری بوده و باعث کاهش نرخ بررسی می‌شوند.

جدول (۱) مقایسه کارهای پیشین برای پیش‌بینی قیمت بیت‌کوین

نویسندگان	روش	محاسن	معایب
(Chang et al., 2021)	سری زمانی مبتنی بر CNN	کاهش خطای پیش‌بینی و مناسب برای داده‌های کلان	پیچیدگی محاسباتی بالا
(Aras, 2021)	سری زمانی مبتنی بر GARCH	کاهش خطای پیش‌بینی و مناسب برای داده‌های کلان	پیچیدگی محاسباتی بالا
(Li et al., 2019)	تحلیل احساسات	پیش‌بینی قیمت بر اساس احساسات کاربران	وابستگی نتایج به میزان داده‌های آموزشی
(Yogeshwaran et al., 2019)	یادگیری عمیق (LSTM)	کاهش خطای پیش‌بینی و مناسب برای داده‌های کلان	نیازمند مصرف حافظه
(Lahmiri & Bekiros, 2019)	یادگیری عمیق (CNN)	کاهش خطای پیش‌بینی و مناسب برای داده‌های کلان	پیچیدگی محاسباتی بالا
(Kwon et al., 2019)	سری زمانی مبتنی بر LSTM	کاهش خطای پیش‌بینی و مناسب برای داده‌های کلان	نیازمند مصرف حافظه

1. Autoregressive integrated moving average (ARIMA)

2. Generalized autoregressive conditional heteroskedasticity (GARCH)


نویسندگان	روش	محاسن	معایب
(Ji et al., 2019)	مدل‌های مختلف یادگیری عمیق	کاهش خطای پیش‌بینی	پیچیدگی محاسباتی بالا
(Poyser, 2019)	سری زمانی مبتنی بر شبکه بیزین	پیش‌بینی برای حالت‌های ناشناخته	وابستگی نتایج به حجم داده‌های آموزشی
(Saad et al., 2019)	مدل‌های یادگیری ماشین	کاهش خطای پیش‌بینی	وابستگی نتایج به میزان داده‌های آموزشی
(Bohte & Rossini, 2019)	سری زمانی مبتنی بر شبکه بیزین	پیش‌بینی برای حالت‌های ناشناخته	وابستگی نتایج به حجم داده‌های آموزشی
(Valencia et al., 2019)	تحلیل احساسات و ماشین بردار پشتیبان	پیش‌بینی قیمت بر اساس احساسات کاربران	وابستگی نتایج به حجم داده‌های آموزشی
(Kim et al., 2019)	سری زمانی مبتنی بر ARIMA	مناسب برای داده‌های ایستا و کلان	عدم کارایی برای داده‌های پویا
(Jelinek et al., 2019)	سری زمانی مبتنی بر استنتاج فازی	پیش‌بینی برای حالت‌های ناشناخته	وابستگی نتایج به قوانین فازی
(Shu & Zhu, 2020)	سری‌های زمانی چندسطحی	کاهش خطای پیش‌بینی و مناسب برای داده‌های کلان	پیچیدگی محاسباتی بالا
(Wirawan et al., 2019)	سری زمانی مبتنی بر ARIMA	مناسب برای داده‌های ایستا و کلان	عدم کارایی برای داده‌های پویا

روش‌شناسی پژوهش

روش ارائه‌شده در این پژوهش متمرکز بر XGBoost و LSTM است. الگوریتم XGBoost یکی از محبوب‌ترین و پرکاربردترین الگوریتم‌ها در فرا یادگیری است که در چندین پژوهش استفاده شده است. الگوریتم XGBoost نوعی پیاده‌سازی گرادینان تقویت‌شده درختان تصمیم است و برای سرعت و کارایی بیشتر طراحی شده است. با توجه به توانایی بالای مدل XGBoost در هرس کردن بهینه درخت و همچنین قابلیت استفاده از روش جستجوی شبکه‌ای برای بهینه‌سازی ابرپارامترهای^۱ مدل، در پژوهش پیشنهادی فرایند پیش‌بینی نوسانات بیت‌کوین با تکیه بر الگوریتم XGBoost انجام می‌شود. در (Wu et al., 2022)، الگوریتم XGBoost برای پیش‌بینی قیمت ۱۴ رمز ارز استفاده شده است. در (Sekhar et al., 2022)، عملکرد LSTM و XGBoost به صورت جداگانه مورد ارزیابی قرار گرفته است. همچنین XGBoost و شاخص‌های تکنیکال برای پیش‌بینی قیمت رمز ارزها استفاده شده

1. Hyperparameters

است (Hafid et al., 2024). در پژوهش‌های مزبور از الگوریتم‌های بهینه‌سازی برای تنظیم پارامترهای XGBoost یا ترکیب آن با سایر روش‌های یادگیری ماشین برای بهبود دقت پیش‌بینی استفاده نشده است که در این پژوهش به آن‌ها پرداخته می‌شود. فرا یادگیری با الگوریتم LSTM نیز این امکان را می‌دهد که علاوه بر یادگرفتن، به روزرسانی‌هایی نیز در مدل فراهم کند. یک نکته مهم در XGBoost این است که پردازش موازی را در سطح گره پیاده می‌کند و از تقویت گرادیان قوی‌تر و سریع‌تری بهره‌مند است. با تنظیم پارامترهای کنترلی در الگوریتم XGBoost، بیش برآزش کاهش پیدا می‌کند و با استفاده از تکنیک‌های مختلف منظم‌سازی، عملکرد کلی را بهبود می‌بخشد. شکل (۱) نشان می‌دهد که XGBoost با تشکیل درخت‌های مختلف و متفاوت فرایند یادگیری ماشین را انجام می‌دهد.



شکل (۱) ساختار اولیه برای الگوریتم XGBoost

الگوریتم XGBoost شامل تعدادی پارامتر است که برخی از این پارامترها در خروجی مدل تأثیرگذار است. برای این منظور تنظیم پارامترهای XGBoost در قالب یک مسئله بهینه‌سازی تعریف شده و مقادیر پارامترهای هدف با رویکرد فرااکتشافی جستجو می‌شود. الگوریتم‌های مختلفی در سال‌های اخیر برای مسائل بهینه‌سازی پیشنهاد شده است که هریک محاسن و معایبی دارد. یکی از این الگوریتم‌ها، بهینه‌ساز شاهین هریس (HHO¹) است که در سال ۲۰۱۹ معرفی شده و نتایج مؤثری از آن در مقاله‌های مختلف ثبت شده است. بر همین اساس مدل XGBoost-HHO یکی از رویکردهای پیشنهادی پژوهش برای

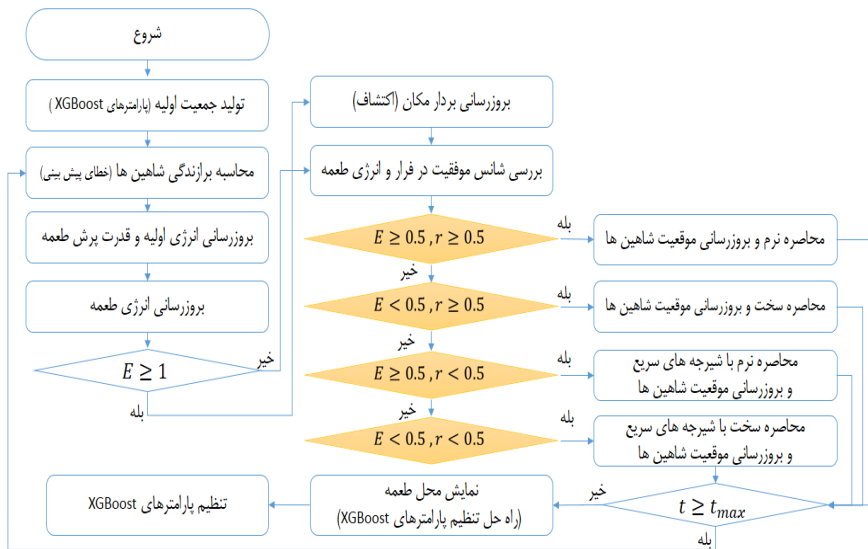
1. Harris hawks optimizer (HHO)

پیش‌بینی قیمت بیت‌کوین خواهد بود. از دیگر مدل‌های فرا یادگیری، الگوریتم LSTM است؛ این مدل با برخورداری از حافظه، عملکرد مؤثری در مسائل پیش‌بینی از خود نشان داده است، اما بررسی‌ها نشان می‌دهد که ترکیب آن با الگوریتم‌های پایه یادگیری ماشین می‌تواند پیش‌بینی آن را افزایش دهد. این در حالی است که XGBoost یکی از الگوریتم‌های پایه و کارآمد یادگیری ماشین است. بر همین اساس مدل XGBoost-LSTM مدل پیشنهادی دوم پژوهش برای پیش‌بینی قیمت بیت‌کوین خواهد بود.

مدل پیشنهادی اول مبتنی بر الگوی فرا اکتشافی

مدل پیشنهادی اول پژوهش، ترکیب الگوریتم XGBoost با بهینه‌ساز شاهین هریس است. این الگوریتم برگرفته از کلونی شاهین‌های قهوه‌ای هریس است که یکی از باهوش‌ترین پرندگان طبیعت است. در مدل پیشنهادی اول، مسئله تنظیم پارامترهای XGBoost به الگوریتم بهینه‌سازی شاهین هریس نگاشته شده و الگوریتم بهینه‌سازی شاهین هریس با تکیه بر عملگرهای خود به دنبال یافتن بهترین مقادیر برای این پارامترها است. در این ساختار هر عضو شاهین‌ها که بیانگر یک عضو از جمعیت اولیه الگوریتم است، به صورت یک بردار مدل‌سازی می‌شود. طول این بردار برابر با تعداد پارامترهای الگوریتم XGBoost خواهد بود. این بردارها به صورت تصادفی و برابر با دامنه تعریف شده برای مسئله تولید می‌شوند. سپس به ازای هر عضو جمعیت اولیه، تابع برازندگی فراخوانی شده و ارزش هر راه‌حل، محاسبه می‌شود. در این پژوهش از شاخص میانگین اندازه خطا (MAE)¹ برای تابع برازندگی استفاده شده است. سپس در بین راه‌حل‌ها، بهترین راه‌حل به عنوان آگاه‌ترین شاهین از محل طعمه انتخاب شده و برای نسل‌های بعدی سایر شاهین‌ها با این شاهین به‌روزرسانی می‌شوند. مجدد برازندگی راه‌حل‌ها محاسبه شده و برترین شاهین انتخاب می‌شود. این فرایند تا برقراری شرط خاتمه ادامه یافته و در نسل پایانی، شاهینی که بالاترین مقدار برازندگی (در این پژوهش کمترین خطای پیش‌بینی قیمت بیت‌کوین) را داشته باشد به عنوان جواب مسئله طرح شده انتخاب می‌شود. شکل (۲) بلوک دیاگرام مدل پیشنهادی اول پژوهش را نشان می‌دهد. همچنین جدول (۲) پارامترهای استفاده شده در این الگوریتم را معرفی می‌کند.

1. Mean absolute error (MAE)



شکل (۲) بلوک دیاگرام مدل پیشنهادی اول مبتنی بر XGBoost و HHO

جدول (۲) پارامترهای استفاده‌شده در فرایند شبیه‌سازی روش پیشنهادی

پارامتر	توضیحات
$x(t)$	بردار موقعیت فعلی شاهین‌ها
$x(t + 1)$	موقعیت شاهین‌ها در تکرار بعدی
$x_{rabbit}(t)$	موقعیت طعمه
r_1, r_2, r_3, r_4, q	اعداد تصادفی در بازه (۰ و ۱) هستند که در هر تکرار به‌روزرسانی می‌شوند.
UB و LB	محدوده بالا و پایین متغیرها
$X_{rand}(t)$	انتخاب تصادفی یک شاهین از جمعیت فعلی
$X_m(t)$	موقعیت متوسط جمعیت فعلی شاهین‌ها
E	نشانگر انرژی هدررفته توسط طعمه
T	حداکثر تعداد تکرارها
E_0	انرژی اولیه طعمه
r	شانس موفقیت طعمه در فرار
$\Delta x(t)$	تفاوت بین موقعیت قبلی و موقعیت فعلی خرگوش در تکرار t
J	قدرت پرش تصادفی خرگوش در تمامی مراحل فرار

هر شاهین راه‌حلی بالقوه برای تنظیم پارامترها است؛ لذا هر شاهین به صورت یک بردار مدل می‌شود. رابطه (۱) مدل‌سازی ریاضی شاهین هریس را نشان می‌دهد.

$$\mathbf{x}_i = [x_i^1, x_i^2, \dots, x_i^{nv}] \quad (1)$$

در رابطه (۱) پارامتر nv بیانگر تعداد پارامترهای موردنظر برای تنظیم در XGBoost و شماره i معرف شاهین در جمعیت اولیه است. همچنین جمعیت اولیه شاهین‌ها نیز به صورت یک ماتریس می‌تواند مدل شود. رابطه (۲) ماتریس جمعیت اولیه در مدل پیشنهادی اول را معرفی می‌کند.

$$M_{HHO} = \begin{bmatrix} A_{1,1} & \dots & A_{1,d} \\ \vdots & \ddots & \vdots \\ A_{n,1} & \dots & A_{n,d} \end{bmatrix} \quad (2)$$

برازندگی شاهین‌های هریس در روش پیشنهادی می‌تواند به صورت ماتریس مدل‌سازی شود. رابطه (۳) این مدل‌سازی را معرفی می‌کند. ماتریس ایجاد شده یک ستون و به تعداد شاهین‌های قهوه‌ای سطر دارد.

$$M_f = \begin{bmatrix} f(A_{1,1}, A_{1,2}, \dots, A_{1,d}) \\ \vdots \\ f(A_{n,1}, A_{n,2}, \dots, A_{n,d}) \end{bmatrix} \quad (3)$$

هر سطر در رابطه (۳) معرف برازندگی هر کدام از شاهین‌ها است که یک راه‌حل برای تنظیم پارامترهای XGBoost هستند. توابع مختلفی برای تخمین خطا وجود دارد. یکی از توابع کارآمد برای این منظور MAE است. در مدل پیشنهادی اول با تکیه بر این تابع ارزش هر عضو جمعیت اولیه محاسبه خواهد شد. رابطه (۴) تابع برازندگی مدل پیشنهادی اول را نشان می‌دهد.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4)$$

در میان جمعیت شاهین‌ها، راه‌حلی که بالاترین میزان برازندگی را داشته باشد به‌عنوان شاهین برتر شناخته می‌شود. برای به‌روزرسانی انرژی اولیه طعمه و قدرت پرش طعمه در این گام بر اساس روابط (۵) و (۶) انرژی اولیه و قدرت پرش طعمه به‌روزرسانی می‌گردد. این مقادیر در محاسبه میزان انرژی طعمه و موفقیت طعمه در گریز (ایجاد تنوع جمعیت شاهین‌ها و تولید راه‌حل‌های جدید برای تنظیم پارامترهای XGBoost) استفاده خواهند شد.

$$E_0 = 2r_5 - 1 \quad (5)$$

$$J = 2(1 - r_5) \quad (۶)$$

که در آن r_5 یک عدد تصادفی در بازه (۰ و ۱) است.

برای به‌روزرسانی انرژی طعمه با استفاده از رابطه (۷) میزان انرژی طعمه به‌روزرسانی می‌شود. مقدار این پارامتر تأثیر بسزایی در فاز اکتشاف و استخراج مسئله تنظیم پارامترهای XGBoost خواهد داشت. بر اساس مقدار آن الگوریتم شاهین هریس استراتژی‌های مختلفی را برای رسیدن به بهینه سراسری انتخاب می‌کند.

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad (۷)$$

که t معرف تکرار جاری الگوریتم است. اگر مقدار پارامتر ($E \geq 1$) باشد، الگوریتم در فاز اکتشاف قرار خواهد داشت. در این فاز مکان شاهین‌های قهوه‌ای با استفاده از رابطه (۸) به‌روزرسانی می‌شود.

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3 (LB + r_4 (UB - LB)) & q < 0.5 \end{cases} \quad (۸)$$

اگر مقدار پارامتر ($E < 1$) باشد، الگوریتم وارد فاز استخراج یا بهره‌برداری خواهد شد. چهار استراتژی برای نزدیک شدن و شکار طعمه توسط شاهین هریس اتخاذ می‌شود. برای اتخاذ استراتژی موردنظر، الگوریتم دو پارامتر r و E را مورد ارزیابی قرار می‌دهد. فرایند محاسبه E در گام‌های قبلی موردبحث قرار گرفت ولی مقدار پارامتر r یک عدد تصادفی در بازه (۰ و ۱) است. در ادامه هریک از این استراتژی‌ها با روابط مربوطه معرفی شده است.

الف) اگر ($r \geq 0.5$) و ($E \geq 0.5$) محاصره نرم انجام‌شده، بردار مکانی شاهین‌ها با استفاده از فرمول (۹) به‌روزرسانی می‌شود.

$$X(t+1) = \Delta X(t) - E |J X_{rabbit}(t) - X(t)| \quad (۹)$$

ب) اگر ($r \geq 0.5$) و ($E < 0.5$) محاصره سخت انجام‌شده، بردار مکانی شاهین‌ها با استفاده از فرمول (۱۰) به‌روزرسانی می‌شود.

$$X(t+1) = X_{rabbit}(t) - E |\Delta X(t)| \quad (۱۰)$$

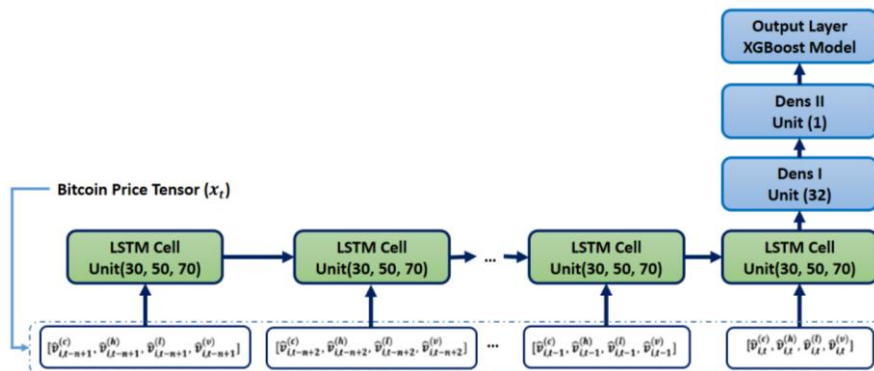
ج) اگر ($r < 0.5$) و ($E \geq 0.5$) با استفاده از شیرجه‌های سریع محاصره نرم انجام‌شده، بردار مکانی شاهین‌ها با استفاده از رابطه (۱۱) به‌روزرسانی می‌شود.

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (۱۱)$$

د) اگر $(r < 0.5)$ و $(E < 0.5)$ با استفاده از شیرجه‌های سریع محاصره سخت انجام شده، بردار مکانی شاهین‌ها با استفاده از رابطه (۱۱) به‌روزرسانی می‌شود. پس از آنکه الگوریتم شاهین هریس یک تکرار اجرا شد، الگوریتم وارد نسل بعدی شده و در این نسل تمامی فرایندهای الگوریتم بهینه‌سازی دوباره اجرا می‌شود. این امر تا برقراری شرط خاتمه، ادامه می‌یابد. شرط خاتمه در روش پیشنهادی دفعات اجرای الگوریتم بهینه‌سازی خواهد بود؛ یعنی بعد از n دور اجرا الگوریتم متوقف خواهد شد. در دور نهایی شاهین برتر معرف موقعیت مکانی خرگوش یا طعمه است. در روش پیشنهادی طعمه همان انتخاب راه‌حل بهینه برای تنظیم پارامترهای XGBoost است.


مدل پیشنهادی دوم مبتنی بر شبکه عصبی حافظه طولانی کوتاه‌مدت

مدل پیشنهادی دوم پژوهش، ترکیب الگوریتم XGBoost با شبکه‌های حافظه کوتاه‌مدت طولانی است. در این مدل، الگوریتم LSTM روابط پنهان ویژگی‌ها را استخراج کرده و در ادامه این ویژگی‌ها به‌منظور کاهش پیچیدگی محاسباتی، کاهش داده می‌شوند. سپس فرایند پیش‌بینی قیمت بیت‌کوین با XGBoost انجام می‌شود. شکل (۳) بلوک دیاگرام مدل دوم پیشنهادی را نشان می‌دهد.



شکل (۳) بلوک دیاگرام مدل پیشنهادی دوم

شبکه‌های LSTM، نوعی از شبکه‌های عصبی بازگشتی (RNN^1) هستند که توانایی یادگیری وابستگی‌های بلندمدت را دارند. شبکه LSTM دارای ساختار مشابه RNN هستند. ماژول تکرار در این شبکه دارای ساختار متفاوتی است. در شبکه LSTM به جای داشتن یک لایه شبکه عصبی واحد، چهار لایه وجود دارد که با یکدیگر تعامل دارند. شبکه عصبی RNN یک ورودی و خروجی دارد (شکل ۴-الف)، ولی شبکه LSTM دارای دو ورودی و خروجی است (شکل ۴-ب).



شکل (۴) ساختارهای LSTM و RNN

بلوک‌های حافظه در شبکه LSTM شامل سلول‌های حافظه با اتصال به خود هستند که حالت سلول زمانی از شبکه را علاوه بر واحدهای تکثیرپذیر خاص که با عنوان دروازه^۲ شناسایی می‌شوند، برای کنترل جریان اطلاعات، ذخیره‌سازی می‌کنند [۲۰]. شبکه عصبی بازگشتی فقط می‌تواند تعداد محدودی از وابستگی‌های کوتاه‌مدت را یاد بگیرد. شبکه LSTM می‌تواند وابستگی‌های بلندمدت را به درستی یاد بگیرد. در حقیقت هدف از طراحی شبکه‌های LSTM، حل کردن مشکل وابستگی بلندمدت است [۲۱]. الگوریتم LSTM می‌تواند اطلاعات جدیدی را به سلول حالت اضافه یا اطلاعات آن را حذف کند که توسط دروازه‌ها انجام می‌شود [۲۱]. دروازه‌ها از یک لایه سیگموئید^۳ به همراه یک عملگر ضرب نقطه‌ای تشکیل شده‌اند [۲۲]. خروجی لایه سیگموئید عددی بین صفر و یک است که نشان می‌دهد چه مقدار از ورودی باید به خروجی ارسال شود. مقدار صفر یعنی هیچ

1. Recurrent neural network (RNN)

2. Gate

3. Sigmoid

اطلاعاتی نباید به خروجی ارسال شود درحالی که مقدار یک یعنی تمام ورودی به خروجی ارسال شود. درگذر زمان در حافظه بلندمدت اطلاعاتی ذخیره می‌شود و یا اطلاعاتی از آن حذف می‌شود.

در LSTM قدم اول تصمیم در مورد اطلاعاتی است که باید از سلول حالت پاک شوند. این تصمیم توسط یک لایه سیگموئید به نام دروازه فراموشی^۱ انجام می‌شود. این دروازه با توجه به مقادیر h_{t-1} و x_t برای هر عدد، مقدار صفر یا یک را در سلول حالت C_{t-1} به خروجی می‌برد. مقدار یک یعنی به صورت کامل مقدار حال حاضر سلول حالت C_{t-1} را به C_t ببرد و مقدار صفر یعنی به صورت کامل اطلاعات سلول حالت کنونی C_{t-1} پاک شده و هیچ مقداری از آن را به C_t نرود. رابطه (۱۲) این فرایند را مدل سازی کرده است.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (12)$$

قدم بعدی این است که تصمیم گرفته شود چه اطلاعات جدیدی باید در سلول حالت ذخیره شود. این تصمیم دارای دو بخش است، ابتدا یک لایه سیگموئید به نام دروازه ورودی^۲ وجود دارد که تصمیم می‌گیرد چه مقادیری به روز شوند. مرحله بعدی یک لایه \tanh است که برداری از مقادیر به نام \tilde{C}_t می‌سازد که می‌توان آن‌ها را به سلول حالت اضافه کرد. رابطه (۱۳) این فرایند در شبکه LSTM را مدل سازی کرده است.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (13)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

در ادامه باید برای سلول حالت قدیمی یعنی C_{t-1} حالت جدید سلول یعنی C_t به روزرسانی شود. برای این منظور مقدار قبلی سلول حالت (C_{t-1}) در f_t ضرب شده و $i_t \tilde{C}_t$ به آن اضافه می‌شود.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (14)$$

گام آخر تصمیم‌گیری در مورد ارسال اطلاعات به خروجی است. خروجی مبتنی بر مقدار سلول حالت است، ولی از فیلتر مشخصی عبور خواهد کرد. برای این منظور نخست، لایه سیگموئید تصمیم می‌گیرد که کدام بخش سلول حالت به خروجی ارسال شود. سپس،

1. Forget gate
2. Input gate


مقدار سلول حالت (پس از به‌روزرسانی در مراحل قبلی) به لایه \tanh (تا مقادیر بین ۱- و ۱+ باشند) داده شده و مقدار آن در خروجی لایه سیگموئید قبلی ضرب می‌شود؛ تا بدین ترتیب بخش‌هایی که مد نظر است؛ به خروجی ارسال شود.

$$\begin{aligned} O_t &= \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t &= O_t \times \tanh(C_t) \end{aligned} \quad (۱۵)$$

یافته‌های پژوهش

مجموعه داده

مجموعه داده پژوهش از پایگاه مالی تحت وب Yahoo گردآوری شده است. پایگاه مالی مذکور به‌عنوان یک پایگاه مالی آنلاین، دسترسی رایگان به داده‌های متنوع مالی، به‌روزرسانی‌های مستمر و اطلاعات تاریخی را فراهم می‌کند. این پایگاه ابزارهای تحلیلی مفیدی دارد و شامل بازارهای مختلف از جمله ارزهای دیجیتال و کالاها است. همچنین، API آن امکان استخراج خودکار داده‌ها را برای تحلیل‌های پیشرفته تسهیل می‌کند. مجموعه داده این پژوهش مشتمل بر داده‌های رمز ارز بیت‌کوین برای سال‌های ۲۰۱۴ لغایت ۲۰۲۲ به مدت ۲۹۸۷ روز است. در این مجموعه داده هر نمونه با پنج ویژگی قیمت بسته‌شدن (بسته)، بالاترین قیمت (بالا)، پایین‌ترین قیمت (پایین)، قیمت آغاز معامله (باز) و حجم روزانه رمز ارز (حجم) توصیف شده است. هر نمونه نیز مربوط به یک روز معاملاتی برای بیت‌کوین است که ۷۰ درصد به‌عنوان داده آموزش و ۳۰ درصد به‌عنوان داده ارزیابی مورد استفاده قرار می‌گیرد. سری زمانی‌های استفاده‌شده در شکل (۵) نمایش داده شده است.



شکل (۵) تغییرات قیمت از سال ۲۰۱۴ لغایت ۲۰۲۲

شاخص‌های ارزیابی

برای ارزیابی مدل پیشنهادی در این پژوهش از چهار شاخص، شامل میانگین مربعات خطا (1MSE)، ریشه MSE (2RMSE)، میانگین اندازه خطا (3MAE) و ضریب R^2 ، استفاده خواهد شد که در روابط (۱۶) الی (۱۹) معرفی شده‌اند. این شاخص‌ها از عمومی‌ترین معیارهای سنجش کارایی الگوریتم‌ها در مسائل پیش‌بینی و تخمین هستند.

$$MSE = \frac{1}{N} \sum_{k=1}^N (t_k - y_k)^2 \quad (16)$$

$$RMSE = \sqrt{\frac{\sum_{k=1}^N (t_k - y_k)^2}{N}} \quad (17)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (18)$$

$$R^2 = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (19)$$

بررسی عملکرد مدل ترکیبی XGBoost-HHO

تنظیم پارامترهای XGBoost یک مسئله NP Hard است چون در زمان چندجمله‌ای بر حسب اندازه ورودی مسئله (زمان معقول) قابل حل نیست؛ بنابراین برای حل آن از الگوریتم بهینه‌سازی شاهین هریس استفاده شد. اما باید در نظر داشت که الگوریتم‌های بهینه‌سازی مبتنی بر جمعیت خود دارای دو پارامتر کنترلی تأثیرگذار هستند که مقدار آن‌ها می‌تواند در خروجی مدل‌ها، مؤثر باشد. این پارامترها تعداد جمعیت اولیه و تعداد نسل‌ها (تکرار الگوریتم) هستند. با در نظر داشتن موارد موصوف در این آزمایش، عملکرد مدل پیشنهادی اول، پژوهش به‌ازای تعداد مختلف جمعیت اولیه و تعداد نسل‌های الگوریتم مورد بررسی قرار می‌گیرد. نتایج این بخش، ملاکی برای تنظیم پارامترهای الگوریتم بهینه‌سازی شاهین هریس بوده و پس از تنظیم، عملکرد مدل نهایی به‌ازای شاخص‌های ارزیابی پژوهش مورد تجزیه و تحلیل قرار می‌گیرد.

1. Mean squared error (MSE)

2. Root mean squared error (RMSE)

3. Mean absolute error (MAE)

در این آزمایش، روش پیشنهادی پژوهش با ۱۰، ۲۰ و ۳۰ شاهین اجرا شده و نتایج در شاخص R^2 که دقت مدل در پیش‌بینی قیمت بیت‌کوین را نشان می‌دهد، مورد تجزیه و تحلیل قرار گرفته است.

با توجه به این که ماهیت الگوریتم‌های بهینه‌سازی، تصادفی بوده و تولید تصادفی جمعیت اولیه باعث می‌شود در هر آزمایش نتایج مختلفی حاصل شود؛ لذا به ازای هر تعداد از جمعیت اولیه، آزمایش‌ها ۱۰ مرتبه تکرار شده و بیشترین، کمترین و میانگین نتایج ثبت می‌شود. جدول (۳) نتایج این بررسی را نشان می‌دهد. لازم به ذکر است؛ برای انجام این آزمایش تعداد نسل‌های الگوریتم به صورت پیش‌فرض بر روی ۱۰۰ تنظیم شده است.

جدول (۳) بررسی تأثیر جمعیت اولیه شاهین‌های هریس در شاخص R^2 مدل پیشنهادی اول

تعداد شاهین	کمترین	بیشترین	میانگین
۱۰	۹۵/۵۴	۹۷/۷۰	۹۶/۶۶
۲۰	۹۷/۲۹	۹۹/۰۱	۹۸/۴۷
۳۰	۹۸/۱۲	۹۹/۸۸	۹۹/۳۲

بررسی نتایج گویای آن است که روش پیشنهادی به ازای ۳۰ شاهین بالاترین دقت پیش‌بینی را تولید می‌کند به نحوی که میانگین شاخص با آن به ۹۹/۳۲ می‌رسد. این در حالی است که میانگین شاخص با ۱۰ شاهین هریس، بدترین نتیجه است.

به نظر می‌رسد با افزایش جمعیت اولیه بتوان به افزایش دقت پیش‌بینی نیز امیدوار بود، ولی باید در نظر داشت که افزایش جمعیت اولیه باعث افزایش پیچیدگی محاسباتی روش پیشنهادی شده و این فرایند در تعدادهای بالاتر جمعیت اولیه بیشتر نمود پیدا می‌کند؛ لذا باید از تعداد زیاد و نامتعارف جمعیت اولیه تا حد ممکن اجتناب کرد.

در آزمایش بعد، روش پیشنهادی با ۵۰، ۱۰۰ و ۱۵۰ نسل (دفعات تکرار الگوریتم بهینه‌سازی شاهین هریس) اجرا شده است. جدول (۴) نتایج این بررسی را نشان می‌دهد. لازم به ذکر است؛ برای انجام این آزمایش، جواب آزمایش قبل در نظر گرفته شده و تعداد جمعیت اولیه بر روی ۳۰ شاهین تنظیم شده است.

جدول (۴) بررسی تأثیر تعداد نسل‌های الگوریتم شاهین هریس در شاخص R^2 مدل پیشنهادی اول

تعداد نسل	کمترین	بیشترین	میانگین
۵۰	۹۷/۵۵	۹۸/۴۲	۹۸/۱۱
۱۰۰	۹۸/۱۲	۹۹/۸۸	۹۹/۳۲
۱۵۰	۹۸/۳۵	۹۹/۸۸	۹۹/۳۷

بررسی نتایج گویای آن است که روش پیشنهادی به‌ازای ۱۰۰ و ۱۵۰ نسل دقت بالایی (اختلاف ناچیز) در پیش‌بینی قیمت بیت‌کوین حاصل می‌کند. به‌نحوی که میانگین شاخص با ۱۰۰ نسل به ۹۹/۳۲ و با ۱۵۰ نسل به ۹۹/۳۷ می‌رسد. این در حالی است که میانگین شاخص با ۵۰ نسل، بدترین نتیجه است. با توجه به این که اختلاف بین ۱۰۰ نسل و ۱۵۰ نسل در پیش‌بینی قیمت، ناچیز بوده و افزایش تعداد نسل‌ها با پیچیدگی محاسباتی، مدل پیشنهادی ارتباط مستقیم دارد (هرچه تعداد نسل‌ها بیشتر، پیچیدگی محاسباتی بالاتر)؛ لذا از اختلاف ناچیز پیش‌بینی قیمت صرف‌نظر کرده و تعداد نسل‌های الگوریتم بهینه‌سازی شاهین هریس بر روی ۱۰۰ تنظیم می‌شود.

برای پیش‌بینی قیمت بیت‌کوین، پارامترهای الگوریتم بهینه‌سازی مطابق با نتایج آزمایش‌های قبل تنظیم شده و این الگوریتم نیز پارامترهای XGBoost را تنظیم می‌کند. چنین رویکردی باعث افزایش کارایی مدل XGBoost در پیش‌بینی قیمت بیت‌کوین خواهد بود. بر اساس نتایج آزمایش‌های قبلی مدل ترکیبی XGBoost-HHO مطابق جدول (۵) بهترین عملکرد خود را دارد.

جدول (۵) ارزیابی مدل پیشنهادی اول در شاخص‌های ارزیابی مختلف

MAE	RMSE	MSE	R^2
۱۲/۴۷	۱۶/۹۴	۲۸/۷۰	۹۹/۸۸

بررسی عملکرد مدل ترکیبی XGBoost-LSTM

در این آزمایش عملکرد الگوریتم ترکیبی XGBoost-LSTM بر پیش‌بینی قیمت بیت‌کوین مورد تجزیه و تحلیل قرار گرفته است، اما باید در نظر داشت که در مدل‌های مبتنی بر LSTM، تعداد بلوک‌ها بر نتایج مدل تأثیرگذار است. بر همین اساس لازم است

مطابق با ساختار مجموعه داده تعداد بهینه بلوک‌های LSTM بررسی شده و سپس عملکرد مدل ارزیابی شود.

با در نظر داشتن این مسئله، عملکرد الگوریتم ترکیبی XGBoost-LSTM به‌ازای تعداد مختلفی از بلوک‌های LSTM بررسی شده و نتایج ثبت شده است. جدول (۶) نتایج این بررسی را نشان می‌دهد. نتایج گویای آن است که مدل پیشنهادی با ۷۰ بلوک LSTM بالاترین میزان شاخص R^2 در پیش‌بینی قیمت بیت‌کوین را دارد.

جدول (۶) بررسی تأثیر تعداد بلوک‌های LSTM بر شاخص R^2 در مدل پیشنهادی دوم

تعداد بلوک	کمترین	بیشترین	میانگین
۳۰	۵۴/۳۸	۵۸/۳۳	۵۷/۰۸
۵۰	۵۸/۹۱	۶۰/۱۷	۵۹/۲۵
۷۰	۷۲/۴۴	۷۵/۳۲	۷۴/۸۶

در این بخش با استناد به نتایج آزمایش قبل، تعداد بهینه بلوک‌های LSTM در مدل پیشنهادی پژوهش تنظیم شده و فرایند پیش‌بینی قیمت بیت‌کوین آزمایش می‌شود. برای انجام این آزمایش تعداد بلوک‌های LSTM برابر با ۷۰ در نظر گرفته شده است. جدول (۷) نتایج این بررسی را نشان می‌دهد.

جدول (۷) ارزیابی مدل پیشنهادی دوم در شاخص‌های ارزیابی مختلف

مدل	R^2	MSE	RMSE	MAE
مدل پیشنهادی دوم	۷۵/۳۲	۴۶/۳۳	۲۱/۵۲	۱۳/۱۷

مقایسه عملکرد مدل‌های پیشنهادی با الگوریتم‌های مشابه

در این بخش، عملکرد مدل‌های پیشنهادی با مدل‌های مشابه مقایسه شده است. در (Oyedele et al. 2023) پژوهشگران معاملات بیت‌کوین را از اول جولای سال ۲۰۲۱ تا دوم مارس سال ۲۰۲۱ گردآوری کرده و عملکرد مدل‌های مختلف بر روی این مجموعه را مقایسه کرده‌اند. مجموعه نمونه‌ها در مجموعه داده این بخش ۲۴۵ است.

جدول (۸) خطای پیش‌بینی قیمت بیت‌کوین با مدل‌های پیشنهادی پژوهش و دیگر مدل‌های مشابه را نشان می‌دهد. بررسی نتایج الگوریتم‌های مختلف در جدول (۸) گویای آن است که رویکردهای پیاده‌سازی شده در (Oyedele et al. 2023) و (Dutta et al.)

2020) کمترین خطای پیش‌بینی قیمت را دارند. به‌نحوی که با شاخص RMSE نرخ خطا به ۰/۰۲ و ۰/۰۳ می‌رسد. در حالی مدل پیشنهادی اول پژوهش در این شاخص با خطای ۰/۰۰۸۶ و مدل پیشنهادی دوم با خطای ۰/۰۱۲ نوسانات بیت‌کوین را پیش‌بینی می‌کند. این یافته، کارآمدی مدل‌های پیشنهادی پژوهش را تأیید می‌کند.

جدول (۸) مقایسه مدل‌های پیشنهادی با الگوریتم‌های مشابه

RMSE	Year	Reference	Model
32.86	2020	(Chowdhury et al., 2020)	GBM
0.03	2019	(Dutta et al., 2020)	ANN
0.02	2019	(Dutta et al., 2020)	LSTM
2750.00	2019	(Lahmiri & Bekiros, 2019)	LSTM
8800.00	2019	(Lahmiri & Bekiros, 2019)	GRNN
156.30	2020	(Mudassir et al., 2020)	Stacked ANN
219.59	2020	(Mudassir et al., 2020)	LSTM
0.03	2020	(Oyedele et al., 2023)	Optimized CNN
0.02	2020	(Oyedele et al., 2023)	Optimized GRU
0.0086	2023	مدل پیشنهادی اول	XGBoost-HHO
0.012	2023	مدل پیشنهادی دوم	XGBoost-LSTM

نتیجه‌گیری و پیشنهادها

در این پژوهش با تکیه بر یادگیری ماشین و داده‌کاوی، مدل‌های جدیدی برای پیش‌بینی قیمت بیت‌کوین پیشنهاد شد. هسته اصلی مدل‌های پیشنهادی الگوریتم XGBoost است. در مدل پیشنهادی اول، تنظیم پارامترهای XGBoost در قالب یک مسئله بهینه‌سازی تعریف و مقادیر پارامترهای هدف با رویکرد فرااکتشافی جستجو شد.

در مدل پیشنهادی دوم الگوریتم XGBoost با الگوریتم LSTM ترکیب و مدلی جدید برای پیش‌بینی قیمت بیت‌کوین ارائه شد. روش‌های پیشنهادی در محیط نرم‌افزاری پایتون پیاده‌سازی شده و کارایی آن در شاخص‌های ارزیابی R^2 ، MSE، RMSE و MAE مورد تجزیه و تحلیل قرار گرفت. بررسی نتایج نشان داد که:

- مدل پیشنهادی اول، XGBoost-HHO، برای ۳۰ شاهین بالاترین دقت پیش‌بینی را دارد به‌نحوی که مقدار R^2 آن به ۹۹/۳۲ می‌رسد. همچنین این مدل برای ۱۰۰ و ۱۵۰ نسل دقت بالایی در پیش‌بینی قیمت بیت‌کوین حاصل می‌کند. با توجه به این که اختلاف بین

۱۰۰ و ۱۵۰ نسل در پیش‌بینی قیمت، ناچیز است برای کاهش پیچیدگی محاسباتی، تعداد نسل‌های الگوریتم بهینه‌سازی شاهین هریس بر روی ۱۰۰ تنظیم می‌شود.

- مدل پیشنهادی دوم، XGBoost-LSTM، با ۷۰ بلوک LSTM بالاترین دقت در پیش‌بینی قیمت بیت‌کوین را دارد.

- در مقایسه با کارهای پیشین که کمترین نرخ خطای پیش‌بینی با آن‌ها (در شاخص RMSE) ۰/۰۲ بوده است، هر دو مدل پیشنهادی پژوهش خطای پیش‌بینی کمتری دارند، خطای مدل اول در شاخص RMSE برابر با ۰/۰۰۸۶ و خطای مدل دوم برابر با ۰/۰۱۲ است.

مدل مبتنی بر LSTM نسبت به الگوریتم‌های مشابه خطای پیش‌بینی کمتری داشت؛ ولی در مقایسه با مدل پیشنهادی اول خطای بالاتری دارد. پیشنهاد می‌شود در کارهای آینده مدل پیشنهادی دوم با ساختارهای متفاوت نیز پیاده‌سازی شود و کارایی آن موردسنجش قرار گیرد. در این میان می‌توان به موازی‌سازی مدل پیشنهادی اشاره کرد. در این پژوهش صرفاً سه پارامتر کنترلی الگوریتم XGBoost با رویکرد فرااکتشافی تنظیم شد. با این‌که نتایج مؤثری نیز حاصل شد؛ ولی می‌توان پارامترهای دیگر را نیز در قالب یک مسئله بهینه‌سازی تنظیم کرد.

نتایج این تحقیق می‌تواند به سرمایه‌گذاران، معامله‌گران و تحلیلگران مالی کمک کند تا تصمیمات بهتری اتخاذ کنند و ریسک‌ها را مدیریت نمایند. همچنین، مدیران ریسک می‌توانند استراتژی‌های مؤثرتری توسعه دهند و محققان و دانشگاه‌ها از آن به‌عنوان مبنای نظری برای تحقیقات آینده استفاده کنند. شرکت‌های فناوری مالی (FinTech) می‌توانند ابزارهایی برای پیش‌بینی قیمت‌ها ایجاد کنند و نهادهای قانونی می‌توانند سیاست‌های مناسبی برای نظارت بر بازار تدوین کنند. در کل، این تحقیق به بهبود استراتژی‌های تصمیم‌گیری در بازار رمز ارزها کمک می‌کند.

قدردانی

از همه بزرگوارانی که در تهیه و تدوین این پژوهش ما را یاری رساندند، صمیمانه سپاسگزاریم.

منابع

- Aras, S. (2021). On improving GARCH volatility forecasts for Bitcoin via a meta-learning approach. *Knowledge-Based Systems*, 230, 107393 .
- Bohte, R. & Rossini, L. (2019). Comparing the forecasting of cryptocurrencies by Bayesian time-varying volatility models. *Journal of Risk and Financial Management*, 12(3), 150.
- Chang, S.H. Hsu, C.W. Li, H.Y. Zeng, W.S. & Ho, J.M. (2021). Short-Term Stock Price-Trend Prediction Using Meta-Learning. 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC).
- Chen, Z. Li, C. & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395.
- Chowdhury, R. Rahman, M. A. Rahman, M. S. & Mahdy, M. (2020). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning. *Physica A: Statistical Mechanics and its Applications*, 551, 124569.
- Demir, E. Gozgor, G. & Lau, C. K. M. (2020). "The role of Bitcoin in the market: Does it have a unique feature?" *Finance Research Letters**, 32, 101145.
- Derbentsev, V. Datsenko, N. Stepanenko, O. & Bezkorovainyi, V. (2019). Forecasting cryptocurrency prices time series using machine learning approach. SHS Web of Conferences.
- Dutta, A. Kumar, S. & Basu, M. (2020). A gated recurrent unit approach to bitcoin price prediction. *Journal of Risk and Financial Management*, 13(2), 23.
- Hafid, A. Ebrahim, M. Alfatemi, A. Rahouti, M. & Oliveira, D. (2024). Cryptocurrency Price Forecasting Using XGBoost Regressor and Technical Indicators. *arXiv preprint arXiv:2407.11786*.
- Hossain, M. S. (2021). What do we know about cryptocurrency? Past, present, future. *China Finance Review International*, 11(4), 552-572.
- Jelinek, S. Poledica, A. Petrović, B. & Milošević, P. (2019). Forecasting Cryptocurrency Time Series Using Fuzzy Transform, Fourier Transform and Fuzzy Inference System. 11th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT 2019).
- Ji, S. Kim, J. & Im, H. (2019). A comparative study of bitcoin price prediction using deep learning. *Mathematics*, 7(10), 898.
- Karasu, S. Altan, A. Saraç, Z. & Hacıoğlu, R. (2018). Prediction of Bitcoin prices with machine learning methods using time series data. 2018 26th signal processing and communications applications conference (SIU).
- Kim, H.M. Bock, G.W. & Lee, G. (2019). Predicting ethereum prices using machine learning and block chain information.

- Kwon, D.H. Kim, J.B. Heo, J.S. Kim, C.M. & Han, Y.H. (2019). Time series classification of cryptocurrency price trend based on a recurrent LSTM neural network. *Journal of Information Processing Systems*, 15(3), 694-706.
- Lahmiri, S. & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118, 35-40.
- Li, T. R. Chamrajnagar, A. S. Fong, X. R. Rizik, N. R. & Fu, F. (2019). Sentiment-based prediction of alternative cryptocurrency price fluctuations using gradient boosting tree model. *Frontiers in Physics*, 7, 98.
- Li, Y. Wang, J. & Sun, Y. (2021). "Dynamic correlations among Bitcoin and other cryptocurrencies: A wavelet analysis." *Finance Research Letters*, 38, 101530.
- Mudassir, M. Bennbaia, S. Unal, D. & Hammoudeh, M. (2020). Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach. *Neural computing and applications*, 1-15.
- Oyedele, A. A. Ajayi, A. O. Oyedele, L. O. Bello, S. A. & Jimoh, K. O. (2023). Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction. *Expert Systems with Applications*, 213, 119233.
- Poyser, O. (2019). Exploring the dynamics of Bitcoin's price: a Bayesian structural time series approach. *Eurasian Economic Review*, 9(1), 29-60.
- Rathan, K. Sai, S. V. & Manikanta, T. S. (2019). Crypto-currency price prediction using decision tree and regression techniques. 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI).
- Saad, M. Choi, J. Nyang, D. Kim, J. & Mohaisen, A. (2019). Toward characterizing blockchain-based cryptocurrencies for highly accurate predictions. *IEEE Systems Journal*, 14(1), 321-332.
- Sekhar, P. C. Padmaja, M. & Sarangi, B. (2022). Prediction of Cryptocurrency using LSTM and XGBoost. 2022 IEEE International Conference on Blockchain and Distributed Systems Security (ICBDS).
- Sharma, G. D. Rajput, S. & Kumar, V. (2021). "Predicting bitcoin price with LSTM and GARCH models." *Journal of Forecasting*. doi:10.1002/for.2905.
- Shu, M. & Zhu, W. (2020). Real-time prediction of Bitcoin bubble crashes. *Physica A: Statistical Mechanics and its Applications*, 548, 124477.
- Valencia, F. Gómez-Espinosa, A. & Valdés-Aguirre, B. (2019). Price movement prediction of cryptocurrencies using sentiment analysis and machine learning. *Entropy*, 21(6), 589.
- Wirawan, I. M. Widiyaningtyas, T. & Hasan, M. M. (2019). Short term prediction on bitcoin price using ARIMA method. 2019 International Seminar on Application for Technology of Information and Communication (iSemantic).

- Wu, J. Guo, X. Fang, M. & Zhang, J. (2022). Short term return prediction of cryptocurrency based on XGBoost algorithm. 2022 International Conference on Big Data, Information and Computer Network (BDICN).
- Yogeshwaran, S. Kaur, M. J. & Maheshwari, P. (2019). Project based learning: predicting bitcoin prices using deep learning. 2019 IEEE global engineering education conference (EDUCON).
- Zhang, Y. & Zohren, S. (2018). Deep learning for forecasting cryptocurrency prices. *UCL Economics*.