



Comparative Analysis of Support Vector Regression Against Classical, Machine Learning, and Deep Learning Models for Bitcoin Price Forecasting

Reza Maaboudi¹✉ and Soheila Aghaei²

1. Associate Professor, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University, Boroujerd, Iran (Corresponding author). Email: 1979maaboudi@gmail.com
2. M.A. Student in Economics, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University, Boroujerd, Iran. Email: stusheilaaghace@abru.ac.ir

Article Info

Article type:
Research Article

Keywords:

Bitcoin price forecasting,
Machine learning,
Support Vector Regression
Algorithm

ABSTRACT

The present study aims to model and forecast Bitcoin prices using the Support Vector Regression (SVR) model, based on daily price data from July 13, 2010, to January 29, 2026. To this end, seven principal components—derived from fundamental and technical variables influencing Bitcoin prices—were first extracted using the Principal Component Analysis (PCA) approach and subsequently utilized as input features for the model. Following this, the SVR model was employed alongside nine rival models, including ARIMA and GARCH, machine learning algorithms (RF and XGBOOST), and deep learning models (LSTM, GRU, RNN, MLP and CNN), to model Bitcoin market prices. The results, based on a comparison of error metrics, correlation coefficients, and the Theil statistic, indicate that the SVR model outperforms the other investigated models in forecasting the Bitcoin price index. Furthermore, the findings from the Diebold-Mariano, Wilcoxon, Hansen-Lunde-Nason, Giacomini-White, and variance-corrected Diebold-Mariano tests confirm the statistically significant superiority of the proposed model over the rival models, thereby reinforcing the validity of the results derived from the error metrics. These findings demonstrate that the SVR model, due to its high capability in modeling the non-linear and noisy behaviors of the Bitcoin market, is capable of providing more accurate and stable forecasts. The efficacy of the SVR model in Bitcoin price forecasting highlights the transformative potential of machine learning in wealth management and market volatility reduction, offering a scientific basis for the development of risk management tools and regulatory frameworks for the digital asset market.



© Author(s) retain the copyright and full publishing rights.

Publisher: University of Qom.

ارزیابی تطبیقی عملکرد رگرسیون بردار پشتیبان در برابر الگوهای کلاسیک، یادگیری ماشین و

یادگیری عمیق در پیش‌بینی قیمت بیت‌کوین

رضا معبودی^۱ و سهیلا آقایی^۲

۱. دانشیار، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت الله بروجردی (ره)، بروجرد، ایران (نویسنده مسئول). رایانامه: 1979maaboudi@gmail.com
 ۲. دانشجوی کارشناسی ارشد، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت الله العظمی بروجردی، بروجرد، ایران. رایانامه: stusoheilaaghace@abru.ac.ir

اطلاعات	چکیده
مقاله	
نوع مقاله:	هدف پژوهش حاضر، مدل‌سازی و پیش‌بینی قیمت بیت‌کوین با استفاده از الگوی SVR و داده‌های روزانه قیمت بیت‌کوین در بازه زمانی ۱۳ جولای ۲۰۱۰ تا ۲۹ ژانویه ۲۰۲۶ است؛ بدین منظور، نخست با استفاده از رویکرد مؤلفه‌های اصلی، هفت مؤلفه از متغیرهای بنیادی و تکنیکال مؤثر بر قیمت بیت‌کوین استخراج شد و به‌عنوان ویژگی‌های ورودی مدل استفاده گردید. سپس، مدل رگرسیون بردار پشتیبان، همراه با نه مدل رقیب، شامل مدل‌های ARIMA و GARCH، الگوریتم‌های یادگیری ماشین (XGBOOST، RF) و مدل‌های یادگیری عمیق (MLP، RNN، GRU، LSTM و CNN) برای مدل‌سازی قیمت بازار بیت‌کوین به‌کار گرفته شدند. نتایج ناشی از مقایسه معیارهای خطا، ضریب همبستگی و تایل نشان داد که در پیش‌بینی شاخص قیمت بیت‌کوین، مدل SVR نسبت به سایر مدل‌های مورد بررسی عملکرد بهتری دارد. یافته‌های آزمون‌های دایبولد-ماریانو، ویلکاکسون، هانسن-لوند-ناسون، جیاکومینی-وایت و دایبولد-ماریانو با تصحیح واریانس نیز برتری معنادار آماری مدل پیشنهادی را نسبت به مدل‌های رقیب تأیید کردند که اعتبار یافته‌های حاصل از معیارهای خطا را تقویت می‌کند. این یافته‌ها نشان می‌دهد که الگوی SVR به‌دلیل توانایی بالا در مدل‌سازی رفتارهای غیرخطی و نویزی بازار بیت‌کوین، قادر به ارائه پیش‌بینی‌های دقیق‌تر و پایدارتر است. توانمندی الگوی SVR در پیش‌بینی قیمت بیت‌کوین، نشان‌دهنده ظرفیت تحول‌آفرین یادگیری ماشین در مدیریت سرمایه و کاهش نوسانات بازار است و می‌تواند مبنایی علمی برای توسعه ابزارهای مدیریت ریسک و تنظیم‌گری بازار دارایی‌های دیجیتال فراهم آورد.
کلیدواژه‌ها:	
پیش‌بینی قیمت بیت‌کوین، یادگیری ماشین، الگوریتم رگرسیون بردار پشتیبان	



مقدمه

در سال‌های اخیر و با رشد سریع رمزارزها، ساختار اقتصاد، بازارهای مالی و شیوه‌های پرداخت به‌طور اساسی در حال تغییر است. به‌گونه‌ای که بازارهای مالی دیجیتال در سراسر جهان گسترش پیدا کرده‌اند و این روند نشان می‌دهد نظام مالی به‌سمت جامعه‌ای بدون پول نقد حرکت می‌کند (بدوفسکا و همکاران^۱، ۲۰۲۵؛ لوانتسی و همکاران^۲، ۲۰۲۵). رمزارزها نوعی پول مجازی و دیجیتال‌اند که بر پایه فناوری بلاک‌چین ایجاد می‌شوند (بوذری و همکاران، ۲۰۲۵). این فناوری با استفاده از سازوکارهای رمزنگاری ایمن، امکان جعل، هک و تقلب را به حداقل می‌رساند. همچنین، رمزارزها به‌صورت غیرمتمرکز عمل می‌کنند و توسط بانک مرکزی صادر نمی‌شوند. مجموعه این ویژگی‌ها سبب شده است که رمزارزها روزبه‌روز محبوبیت بیشتری پیدا کنند (حمایل و عودا^۳، ۲۰۲۱). در این میان، بیت‌کوین به‌عنوان شناخته‌ترین و پرمعامله‌ترین رمزارز، در سال ۲۰۰۸ توسط ساتوشی ناکاموتا^۴ معرفی شد (جاکواریت و همکاران^۵، ۲۰۲۱). بیت‌کوین یک رمزارز مبتنی بر رمزنگاری است که از طریق شبکه همتا به همتا فعالیت می‌کند (هو و همکاران، ۲۰۲۱). این رمزارز مستقل از بانک مرکزی است و طراحی متن باز آن باعث می‌شود هیچ فرد یا نهادی مالکیت و کنترل کامل بر آن را نداشته باشد؛ به‌همین دلیل، افراد می‌توانند آزادانه در این شبکه فعالیت کنند (مانگلا^۶، ۲۰۱۹). بیت‌کوین به‌عنوان یک پدیده مالی نوین، عملکردی مشابه پول فیزیکی دارد. کاربران در این سیستم، ارزهای دیجیتال را به‌صورت الکترونیکی و از طریق شبکه‌های همتا به همتا^۷ مبادله می‌کنند تا کالاها یا خدمات مورد نیاز خود را خریداری کنند (پابوچو و همکاران^۸، ۲۰۲۳). علاوه‌براین، بیت‌کوین نقش محوری در توسعه امور مالی غیرمتمرکز ایفا می‌کند و به‌عنوان دارایی سفته‌بازانه، ابزار ذخیره ارزش دیجیتال و گزینه‌ای برای تنوع‌بخشی به پرتفوی شناخته می‌شود (دودک و همکاران^۹، ۲۰۲۵). با این حال، بازارهای ارز دیجیتال؛ به‌ویژه بیت‌کوین با نوسانات قابل توجهی روبه‌رو می‌شوند. این نوسانات که ناشی از عواملی مانند عدم قطعیت مقررات، تبلیغات رسانه‌ای، شوک‌های بیرونی، نوظهور بودن بازار و تغییرات عرضه و تقاضا است (کوهن و آیچه^{۱۰}، ۲۰۲۵)، در عمل پیش‌بینی قیمت بیت‌کوین را دشوار می‌سازد. علاوه بر این، وجود نویز و عدم قطعیت شدید در داده‌های بیت‌کوین و همچنین وابستگی‌های پیچیده میان متغیرهای مختلف بازارهای مالی، تشخیص الگوهای پایدار را دشوار می‌سازد و تعاملات غیرقابل پیش‌بینی میان عوامل مختلف، فرآیند پیش‌بینی را پیچیده‌تر می‌کند (چودری و همکاران^{۱۱}، ۲۰۲۰؛ پابوچو، ۲۰۲۳؛ شهبازی و بیون^{۱۲}، ۲۰۲۲). نمونه‌ای از این مسئله، تأثیر احساسات سرمایه‌گذاران است که تحت تأثیر پوشش رسانه‌ای می‌تواند سبب افزایش یا کاهش قیمت بیت‌کوین شود (اومول و انکه^{۱۳}، ۲۰۲۵). از این‌رو، مدل‌سازی و پیش‌بینی دقیق قیمت بیت‌کوین می‌تواند در کاهش ریسک‌ها و زیان‌های احتمالی فعالان بازار رمزارز مفید باشد. در این زمینه، الگوریتم‌های یادگیری ماشین از جمله ابزارهای کارآمدی هستند که در کنار الگوهای رقیب، در حوزه پیش‌بینی قیمت بیت‌کوین مطرح شده‌اند. یادگیری ماشین با افزایش دقت، کارایی و توان سازگاری با داده‌های سری زمانی، چشم‌انداز روشن‌تری برای پیش‌بینی در بازارهای ارز دیجیتال ایجاد می‌کند. در حالی که روش‌های آماری سنتی اغلب بر پایه فرضیات سخت‌گیرانه و ساختارمند بنا شده‌اند و قادر به پردازش داده‌های بدون ساختار نیستند، الگوریتم‌های یادگیری ماشین می‌توانند

¹ Będowska et al.

² Levantesi et al.

³ Hamayel & Owda

⁴ Satoshi Nakamoto

⁵ Jaquart et al

⁶ Ho et al.

⁷ Mangla

⁸ Peer-to-Peer

⁹ Pabuçcu et al.

¹⁰ Dudek et al.

¹¹ Cohen & Aiche

¹² Chowdhury et al.

¹³ Shahbazi & Byun

¹⁴ Omole & Enke

داده‌های با تواتر بالا را به صورت لحظه‌ای پردازش کنند (کوهن و آیچه، ۲۰۲۵؛ ساری و ایندرابودیمان^۱، ۲۰۲۴؛ جاینتسیدی و کلودیآ^۲، ۲۰۲۵). این قابلیت به الگوریتم‌های یادگیری ماشین امکان می‌دهد تا روابط پیچیده، غیرخطی و الگوهای پنهانی که توسط تحلیل‌گران و یا مدل‌های متعارف نادیده گرفته می‌شوند را کشف و استخراج کنند. از دیگر مزایای یادگیری ماشین، ادغام داده‌های متنوع است؛ به گونه‌ای که علاوه بر شاخص‌های اقتصادی سنتی مانند نرخ بهره، تورم و تولید ناخالص داخلی، قادر به پردازش داده‌های بدون ساختار حاصل از مقالات خبری، شبکه‌های اجتماعی و رویدادهای ژئوپلیتیک نیز هستند. این رویکرد جامع، دید گسترده‌تری از پویایی‌های بازار و احساسات سرمایه‌گذاران در بازارهای ارز دیجیتال مانند بیت کوین ارائه می‌دهد (آدیگبا و همکاران^۳، ۲۰۲۵). در میان رویکردهای مختلف یادگیری ماشین، رگرسیون بردار پشتیبان (SVR)^۴ به دلیل ساختار بهینه‌ساز و اتکای مستقیم به داده‌های مشاهده‌شده، قادر است الگوهای غیرخطی و نوسانات پیچیده بازار دارایی‌ها را با دقت قابل قبولی شناسایی کند. با وجود پیشرفت‌های گسترده در حوزه مدل‌سازی مالی، تا آنجایی که جستجو شد در مطالعات داخل کشور از الگوی رگرسیون بردار پشتیبان برای پیش‌بینی رفتار بازار بیت کوین استفاده نشده است. به عنوان مثال، در میان مطالعات داخلی که از قرابت بیشتری با پژوهش حاضر برخوردار هستند، در پیش‌بینی قیمت بیت کوین از الگوریتم‌های مختلفی مانند مدل‌های ترکیبی یادگیری عمیق با میانگین متحرک خودرگرسیونی یکپارچه (ARIMA) (محمد شریفی و همکاران، ۱۴۰۰)، XGBOOST (قربانی و همکاران، ۱۴۰۱) و شبکه عصبی مصنوعی^۵ (ANN) و رگرسیون چرخشی مارکوف (MSR) (نظیفی نایینی و همکاران، ۱۴۰۴) استفاده کرده‌اند. این خلأ پژوهشی در حالی وجود دارد که ماهیت پرنوسان، غیرخطی و چندبعدی بازار بیت کوین نیازمند رویکردهایی است که قدرت استخراج الگوهای پیچیده و پنهان را داشته باشند. با توجه به توضیحات فوق، پرسش اصلی پژوهش این است که آیا مدل رگرسیون بردار پشتیبان قادر است دقت و کارایی پیش‌بینی قیمت بیت کوین را نسبت به مدل‌های کلاسیک سری‌های زمانی، سایر الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق بهبود دهد؟

در راستای پاسخ به این سؤال، پژوهش حاضر با بهره‌گیری از مؤلفه‌هایی مبتنی بر متغیرهای قیمتی و تکنیکال، توانایی شناسایی روندها و نوسانات پیچیده بازار بیت کوین را نسبت به روش‌های پیشین ارتقا می‌دهد. این مؤلفه‌ها، با ادغام چندین متغیر قیمتی و تکنیکال اطلاعات بیشتری را نسبت به مدل‌های سنتی ارائه می‌کند و امکان استخراج الگوهای پنهان بازار را فراهم می‌سازد. علاوه بر این، پارامترهای مدل با رویکرد بهینه‌بیزی تعیین می‌شوند و بهترین وقفه مدل نیز با استفاده از شبکه عصبی کانولوشنی تک‌بعدی انتخاب می‌شود که دقت پیش‌بینی و انعطاف‌پذیری مدل در مواجهه با نوسانات بازار را افزایش می‌دهد. ترکیب این ویژگی‌ها، علاوه بر ارتقای قابلیت پیش‌بینی، کاربرد پیشرفته‌تری از یادگیری ماشین و تحلیل داده‌ها ارائه می‌دهد و پژوهش حاضر را نسبت به مدل‌های کلاسیک و سایر الگوریتم‌های پیش‌بینی متمایز می‌سازد.

ادبیات موضوع و پیشینه پژوهش

فرضیه‌های بازار کارا و مالی رفتاری

براساس فرضیه بازار کارا، شرط کارایی در بازارهای مالی زمانی برقرار است که سرمایه‌گذاران رفتاری عقلایی داشته باشند و بدون هزینه و به صورت نامحدود به اطلاعات دسترسی داشته باشند. به بیان دیگر، این فرضیه بیان می‌کند که تمام اطلاعات مرتبط با بازارهای سرمایه در قیمت دارایی‌ها منعکس می‌شود. از این رو، در عمل تلاش برای کسب بازدهی بالاتر از متوسط بازار بی‌اثر است. فرضیه بازار کارا براساس میزان انعکاس اطلاعات، به سه فرم کارایی ضعیف، نیمه‌قوی و قوی تقسیم می‌شود. بر مبنای شکل کارایی ضعیف، قیمت‌ها تمامی اطلاعات مربوط به قیمت‌ها و بازده‌های گذشته را منعکس می‌کنند؛ از این رو، استفاده از اطلاعات تاریخی یا تحلیل تکنیکال به‌طور مستمر امکان کسب بازده غیرعادی را فراهم نمی‌کند. در شکل نیمه‌قوی، فرض بر این است که

¹ Sari & Indrabudiman

² Giantsidi & Claudia

³ Adedigba et al.

⁴ Support Vector Regression

⁵ Artificial Neural Network

قیمت‌ها نه تنها اطلاعات تاریخی، بلکه تمام اطلاعات منتشر شده و در دسترس عموم را نیز به سرعت و بدون سوگیری منعکس می‌کنند. در نهایت، شکل قوی بازار کارا بیان می‌کند که همه اطلاعات، اعم از عمومی و خصوصی، به طور کامل در قیمت دارایی‌ها منعکس می‌شوند. بر اساس فرضیه بازار کارا، نوسانات قیمت دارایی‌ها عمدتاً ناشی از ورود اطلاعات جدید به بازار است. از آنجا که اطلاعات جدید ماهیتی غیرقابل پیش‌بینی دارند، تغییرات قیمت نیز به صورت تصادفی رخ می‌دهد و قیمت دارایی‌ها به سرعت به اطلاعات جدید واکنش نشان می‌دهند. بنابراین، در بازارهای کارا نوسانات قیمت منعکس‌کننده تعدیل بازار نسبت به اطلاعات جدید است و به نتایج حاصل از رفتارهای هیجانی یا خطاهای نظام‌مند سرمایه‌گذاران مربوط نمی‌شود (بوت و کسوما، ۲۰۲۶).

با این حال، پژوهش‌های گسترده‌ای در حوزه مالی رفتاری این مفروضات را به چالش کشیده‌اند. مفهوم عقلانیت محدود که توسط سایمون^۲ مطرح شد، بیان می‌کند که سرمایه‌گذاران از نظر توانایی‌های شناختی محدود هستند و همواره نمی‌توانند اطلاعات را به صورت بهینه پردازش کنند. همچنین افراد در شرایط عدم قطعیت از میان‌برهای ذهنی استفاده می‌کنند که این موضوع می‌تواند سبب بروز سوگیری‌های نظام‌مند در قضاوت و تصمیم‌گیری شود. در واقع، وجود این سوگیری‌های شناختی و تأثیر احساسات سبب می‌شود که سرمایه‌گذاران در بسیاری از موارد از رفتار کاملاً عقلایی مورد انتظار در فرضیه بازار کارا فاصله بگیرند. نظریه مالی رفتاری توضیحات جایگزینی برای بروز این ناهنجاری‌ها و انحراف‌ها ارائه می‌کند و بر عواملی تأکید دارد که در فرضیه بازار کارا کمتر مورد توجه قرار گرفته‌اند. از مهم‌ترین این عوامل می‌توان به رفتار گله‌ای و احساسات حاکم بر بازار اشاره کرد. بر اساس نظریه مالی رفتاری، احساسات سرمایه‌گذاران مانند خوش‌بینی، بدبینی، ترس و طمع می‌تواند موجب انحراف قیمت دارایی‌ها از ارزش بنیادی آن‌ها شود. در دوره‌های خوش‌بینی، افزایش تقاضا ناشی از انتظارات مثبت ممکن است قیمت‌ها را به سطوحی بالاتر از ارزش ذاتی برساند و زمینه شکل‌گیری حباب‌های قیمتی را فراهم کند. در مقابل، در دوره‌های بدبینی و ترس، افزایش فشار فروش می‌تواند موجب کاهش قیمت‌ها به سطوحی کمتر از ارزش واقعی شود. از این‌رو، احساسات بازار یکی از عوامل مهم در تبیین نوسانات قیمت دارایی‌ها، به‌ویژه در کوتاه‌مدت و میان‌مدت، محسوب می‌شود. رفتار گله‌ای زمانی رخ می‌دهد که سرمایه‌گذاران بدون اتکا به ارزش‌های بنیادین، صرفاً از رفتار سایر معامله‌گران در بازارهای مالی پیروی می‌کنند. به عبارت دیگر، زمانی اقدام به خرید یا فروش می‌کنند که سایرین نیز در حال خرید یا فروش باشند. چنین رفتاری می‌تواند منجر به شکل‌گیری حباب‌های قیمتی شود؛ وضعیتی که قیمت دارایی‌ها بسیار بالاتر از ارزش ذاتی آن‌ها قرار می‌گیرد (جهانگیر و همکاران، ۲۰۲۵). مفهوم مهم دیگر، آربیتراژ محدود است. حتی اگر سرمایه‌گذاران حرفه‌ای متوجه قیمت‌گذاری نادرست دارایی‌ها شوند، انجام آربیتراژ در دنیای واقعی همواره با ریسک، هزینه و محدودیت‌های مختلف همراه است. در نتیجه، ناهماهنگی‌های قیمتی ناشی از رفتارهای غیرعقلایی ممکن است برای مدتی ادامه یابد؛ زیرا معامله‌گران آربیتراژی یا سرمایه کافی برای مقابله با روندهای غیرمنطقی بازار را در اختیار ندارند یا تمایلی به پذیرش ریسک ناشی از مقابله با رفتار جمعی سرمایه‌گذاران ندارند. این دیدگاه‌ها توضیح می‌دهند که چرا بازارها ممکن است، دست‌کم در کوتاه‌مدت و میان‌مدت، از کارایی کامل فاصله بگیرند و قیمت دارایی‌ها به دلیل تأثیر سوگیری‌های رفتاری، احساسات سرمایه‌گذاران و محدودیت‌های موجود، لزوماً منعکس‌کننده ارزش واقعی آن‌ها نباشند (اونگار و استن، ۲۰۲۵).

مدل‌های پیش‌بینی بازارهای مالی مبتنی بر اقتصادسنجی، یادگیری ماشین و یادگیری عمیق

یادگیری ماشین یکی از مهم‌ترین شاخه‌های هوش مصنوعی است که برخلاف روش‌های سنتی آماری - که بر مفروضات از پیش تعیین‌شده و روابط عمدتاً خطی میان متغیرها متکی هستند - قادر است روابط پیچیده، غیرخطی و پنهان میان متغیرها را شناسایی کند و از آن‌ها برای پیش‌بینی رویدادهای آینده استفاده کند. از این‌رو، در سال‌های اخیر یادگیری ماشین به یکی از مهم‌ترین ابزارهای تحلیل داده‌های مالی، مدیریت سرمایه‌گذاری، معاملات الگوریتمی، مدیریت ریسک و پیش‌بینی قیمت دارایی‌های مالی

¹ Butet & Kesuma

² Simon

³ Jahangir et al.

⁴ Ungar & Stan

تبدیل شده است (پتتیک و همکاران^۱، ۲۰۲۴؛ احمد و همکاران^۲، ۲۰۲۲). در پیش‌بینی متغیرهای مالی، یادگیری ماشین عمدتاً در قالب یادگیری نظارت‌شده^۳ به کار گرفته می‌شود. در این رویکرد، مدل با استفاده از مجموعه‌ای از داده‌های تاریخی، شامل متغیرهای ورودی و مقادیر واقعی متغیر هدف، آموزش می‌بیند تا بتواند الگوی ارتباط میان آن‌ها را فرا بگیرد و برای داده‌های جدید پیش‌بینی انجام دهد. متغیرهای ورودی می‌توانند شامل قیمت‌های گذشته، بازده، حجم معاملات، شاخص‌های تکنیکال، متغیرهای اقتصاد کلان، اخبار مالی، احساسات استخراج‌شده از شبکه‌های اجتماعی و حتی داده‌های جست‌وجوی کاربران در اینترنت باشند؛ در حالی که متغیر هدف معمولاً قیمت یا بازده آینده دارایی مالی است. همچنین، آماده‌سازی داده‌ها، انتخاب ویژگی‌های مناسب، تقسیم داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون، و تنظیم ابرپارامترها از مهم‌ترین مراحل توسعه مدل‌های یادگیری ماشین هستند که نقش مهمی در کاهش بیش‌برازش و افزایش قابلیت تعمیم مدل دارند (ناصره و ردی^۴، ۲۰۲۳؛ هتون و همکاران^۵، ۲۰۲۳). SVR، نسخه رگرسیونی ماشین بردار پشتیبان است که بر پایه نظریه یادگیری آماری توسعه یافته و یکی از شناخته‌شده‌ترین الگوریتم‌های یادگیری ماشین نظارت‌شده محسوب می‌شود. این الگوریتم با حل یک مسئله بهینه‌سازی محدب، تابعی را برآورد می‌کند که ضمن حفظ توانایی تعمیم به داده‌های جدید، خطای پیش‌بینی را نیز کنترل می‌کند. برخلاف بسیاری از روش‌های سستی که مستلزم فرض شکل مشخصی از رابطه میان متغیرهای ورودی و خروجی هستند، SVR قادر است با بهره‌گیری از توابع هسته، روابط پیچیده و غیرخطی را مدل‌سازی کند (هنریک و همکاران^۶، ۲۰۱۸). از مهم‌ترین مزایای SVR می‌توان به به کارگیری اصل کمینه‌سازی ریسک ساختاری، مقاومت مناسب در برابر بیش‌برازش، کاهش وابستگی به فروض سخت‌گیرانه درباره توزیع داده‌ها و توانایی مدل‌سازی روابط غیرخطی اشاره کرد. این ویژگی‌ها سبب شده است که SVR در مسائل مختلف رگرسیون، به‌ویژه در پیش‌بینی سری‌های زمانی مالی، از جمله قیمت سهام، نرخ ارز و ارزهای دیجیتال، کاربرد گسترده‌ای داشته باشد. با توجه به نوسانات شدید، ناهمسانی واریانس، روابط غیرخطی و پیچیدگی ذاتی بازار ارزهای دیجیتال، استفاده از SVR می‌تواند چارچوبی مناسب برای مدل‌سازی و پیش‌بینی متغیر مورد مطالعه فراهم کند (بزار و آلبوکرکی^۷، ۲۰۱۷؛ وانگ و همکاران^۸، ۲۰۲۰). به منظور ارزیابی عملکرد رگرسیون بردار پشتیبان، نتایج آن با مجموعه‌ای از مدل‌های رقیب مقایسه می‌شود. با وجود پیشرفت‌های چشمگیر هوش مصنوعی، مدل‌های کلاسیک سری زمانی همچنان به عنوان معیارهای مرجع در بسیاری از مطالعات پیش‌بینی مالی مورد استفاده قرار می‌گیرند. دلیل این موضوع، سادگی ساختار، قابلیت تفسیر بالا و پشتوانه نظری قوی این مدل‌ها است که امکان مقایسه عملکرد روش‌های جدید با رویکردهای متعارف را فراهم می‌کند. از این رو، در پژوهش حاضر، سه مدل اقتصادسنجی خودرگرسیونی (AR)، ARIMA و ناهمسانی واریانس شرطی تعمیم‌یافته (GARCH) به عنوان مدل‌های مرجع انتخاب شده‌اند. مدل خودرگرسیونی یکی از ساده‌ترین و پرکاربردترین مدل‌های سری زمانی است که فرض می‌کند مقدار فعلی یک متغیر به مقادیر گذشته همان متغیر وابسته است. این مدل به دلیل سادگی، قابلیت تفسیر بالا و هزینه محاسباتی پایین، همچنان در بسیاری از مطالعات مالی برای ارزیابی عملکرد سایر مدل‌ها استفاده می‌شود. با این حال، از آنجایی که مدل AR تنها روابط خطی را مدل‌سازی می‌کند، در شناسایی وابستگی‌های پیچیده و غیرخطی موجود در داده‌های مالی با محدودیت مواجه است. به منظور رفع بخشی از این محدودیت‌ها، مدل میانگین متحرک خودرگرسیونی یکپارچه توسعه یافت. این مدل با ترکیب مؤلفه‌های خودرگرسیونی، میانگین متحرک و تفاضل‌گیری، امکان مدل‌سازی سری‌های زمانی ناپایستا را فراهم می‌کند و همچنان یکی از پرکاربردترین مدل‌های اقتصادسنجی در پیش‌بینی متغیرهای

¹ Pattnaik et al.² Ahmed et al.³ Supervised Learning⁴ Nazareth & Reddy⁵ Htun et al.⁶ Henrique et al.⁷ Bezerra & Albuquerque⁸ Wang et al.

مالی محسوب می‌شود. با وجود این، ARIMA نیز همانند AR عمدتاً مبتنی بر روابط خطی است و در مدل‌سازی الگوهای پیچیده عملکرد محدودی دارد (میتراوی و همکاران^۱، ۲۰۲۳؛ کانگ و همکاران^۲، ۲۰۲۶).

یکی دیگر از مدل‌های اقتصادسنجی، مدل GARCH است که به‌طور ویژه برای مدل‌سازی نوسانات بازارهای مالی توسعه یافته است. یکی از ویژگی‌های مهم داده‌های مالی، خوشه‌بندی نوسانات است؛ به این معنا که دوره‌های پرتلاطم معمولاً با دوره‌های پرتلاطم و دوره‌های آرام با دوره‌های آرام همراه هستند. مدل GARCH قادر است این ویژگی را به‌خوبی مدل‌سازی کند و به‌همین دلیل، در مدیریت ریسک، قیمت‌گذاری مشتقات مالی و پیش‌بینی نوسانات کاربرد گسترده‌ای دارد. با این حال، این مدل نیز عمدتاً بر روابط خطی استوار بوده و در شناسایی تعاملات غیرخطی میان متغیرها با محدودیت‌هایی مواجه است (گارسیا مدینا و همکاران^۳، ۲۰۲۴). ضعف مدل‌های کلاسیک در مدل‌سازی رفتار پیچیده بازارهای مالی، زمینه توسعه الگوریتم‌های یادگیری ماشین را فراهم کرده است. یکی از موفق‌ترین این الگوریتم‌ها، جنگل تصادفی (RF)^۴ است که بر پایه مجموعه‌ای از درخت‌های تصمیم و روش تجمیع بوت‌استرپ^۵ عمل می‌کند. این الگوریتم در برابر نویز، داده‌های پرت، هم‌خطی متغیرها و بیش‌برازش مقاومت بالایی داشته و بدون نیاز به تعیین شکل تابع، قادر به شناسایی روابط پیچیده و غیرخطی میان متغیرها است. به‌همین دلیل، جنگل تصادفی در پیش‌بینی ارزش‌های دیجیتال کاربرد گسترده‌ای یافته است (گرادوویچ و همکاران^۶، ۲۰۲۳). الگوریتم XGBoost نیز یکی از قدرتمندترین روش‌های یادگیری ماشین مبتنی بر درخت تصمیم است که با استفاده از تقویت گرادیانی، منظم‌سازی، بهینه‌سازی تابع هدف و انتخاب ویژگی، دقت پیش‌بینی بالایی ارائه می‌دهد. توانایی این الگوریتم در کنترل بیش‌برازش و مدیریت داده‌های با ابعاد بالا، آن را به یکی از پرکاربردترین مدل‌ها در مسائل پیش‌بینی مالی تبدیل کرده است (حفید و همکاران^۷، ۲۰۲۴).

علاوه بر الگوریتم‌های یادگیری ماشین، شبکه‌های عصبی مصنوعی نیز به‌دلیل توانایی در یادگیری روابط پیچیده، غیرخطی و چندبعدی، جایگاه ویژه‌ای در پیش‌بینی متغیرهای مالی پیدا کرده‌اند. این شبکه‌ها بدون نیاز به تعریف صریح روابط ریاضی، از طریق فرایند یادگیری داده‌محور، الگوهای پنهان موجود در داده‌ها را استخراج کرده و پیش‌بینی انجام می‌دهند. یکی از ساده‌ترین انواع شبکه‌های عصبی، پرسپترون چندلایه (MLP)^۸ است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده و با استفاده از الگوریتم پس‌انتشار خطا آموزش می‌بیند. مدل MLP توانایی بالایی در مدل‌سازی روابط غیرخطی دارد، اما به‌دلیل فقدان ویژگی حافظه زمانی، وابستگی میان مشاهدات متوالی را به‌طور مستقیم در نظر نمی‌گیرد. با افزایش اهمیت داده‌های ترتیبی، شبکه‌های عصبی بازگشتی (RNN)^۹ توسعه یافتند. برخلاف MLP، در RNN اطلاعات مراحل قبلی به مراحل بعدی منتقل می‌شود و شبکه قادر است وابستگی‌های زمانی میان مشاهدات را یاد بگیرد. با این حال، این شبکه‌ها در یادگیری وابستگی‌های بلندمدت با مشکل محو شدن^{۱۰} و انفجار گرادیان مواجه هستند. برای رفع این محدودیت، شبکه حافظه بلندمدت کوتاه‌مدت (LSTM)^{۱۱} معرفی شد. این شبکه با بهره‌گیری از سلول حافظه و دروازه‌های ورودی^{۱۲}، فراموشی^{۱۳} و خروجی^{۱۴}، قادر است اطلاعات مهم را برای بازه‌های زمانی طولانی حفظ کرده و اطلاعات غیرضروری را حذف کند (ناصره و ردی، ۲۰۲۳). به‌همین دلیل، LSTM یکی از موفق‌ترین مدل‌های یادگیری عمیق در پیش‌بینی سری‌های زمانی مالی و به‌ویژه پیش‌بینی قیمت بیت‌کوین محسوب می‌شود.

^۱ Mtiraoui et al.

^۲ Kang et al.

^۳ García-Medina et al.

^۴ Random Forest

^۵ Bootstrap Aggregating (Bagging)

^۶ Gradojevic et al.

^۷ Hafid et al.

^۸ Multi-Layer Perceptron

^۹ Recurrent Neural Network

^{۱۰} Vanishing

^{۱۱} Long Short-Term Memory

^{۱۲} Input Gate

^{۱۳} Forget Gate

^{۱۴} Output Gate

در ادامه، شبکه واحد بازگشتی دروازه‌دار (GRU)^۱ به‌عنوان نسخه‌ای ساده‌تر از LSTM معرفی شد. مدل GRU با کاهش تعداد پارامترهای قابل آموزش، ضمن حفظ توانایی یادگیری وابستگی‌های زمانی، سرعت آموزش بالاتر و هزینه محاسباتی کمتری دارد. مطالعات تجربی نشان داده‌اند که عملکرد این مدل در بسیاری از مسائل پیش‌بینی مالی بسیار نزدیک به LSTM است، در حالی که از نظر کارایی محاسباتی مزیت بیشتری دارد. علاوه بر شبکه‌های بازگشتی، شبکه‌های عصبی کانولوشنی (CNN)^۲ نیز امروزه در تحلیل داده‌های مالی مورد استفاده قرار می‌گیرند. اگرچه این شبکه‌ها در ابتدا برای پردازش تصاویر توسعه یافتند، اما توانایی آن‌ها در استخراج ویژگی‌های محلی، الگوهای تکرارشونده و ساختارهای پنهان موجود در سری‌های زمانی، موجب شده است که در تحلیل داده‌های مالی چندمتغیره و استخراج ویژگی‌های مؤثر برای پیش‌بینی نیز عملکرد مطلوبی داشته باشند (سیبی و همکاران،^۳ ۲۰۲۳).

انتخاب مدل‌های رقیب در این پژوهش با هدف پوشش طیف کاملی از رویکردهای پیش‌بینی سری‌های زمانی مالی انجام شده است. مدل‌های AR، ARIMA و GARCH به‌عنوان معیارهای مرجع اقتصادسنجی انتخاب شدند، زیرا به‌ترتیب توانایی مدل‌سازی وابستگی‌های خطی، سری‌های زمانی نایستا و نوسانات شرطی را داشته و همچنان پرکاربردترین مدل‌های پایه در ادبیات مالی محسوب می‌شوند. در میان الگوریتم‌های یادگیری ماشین، RF و XGBoost به‌دلیل توانایی در مدل‌سازی روابط غیرخطی، مقاومت در برابر بیش‌برازش، مدیریت داده‌های با ابعاد بالا و عملکرد موفق در مطالعات پیش‌بینی مالی انتخاب شدند. همچنین، شبکه‌های عصبی MLP، RNN، LSTM و GRU و CNN به‌منظور مقایسه معماری‌های مختلف یادگیری عمیق در نظر گرفته شدند؛ به‌گونه‌ای که MLP به‌عنوان شبکه پایه، RNN برای یادگیری وابستگی‌های زمانی، LSTM و GRU برای مدل‌سازی وابستگی‌های بلندمدت و CNN برای استخراج ویژگی‌های محلی و الگوهای پنهان از داده‌های سری زمانی انتخاب شدند. بنابراین، این مجموعه، طیفی از مدل‌های خطی، غیرخطی، مبتنی بر درخت و مبتنی بر شبکه‌های عصبی را در بر می‌گیرد و امکان مقایسه جامع عملکرد آن‌ها را در پیش‌بینی متغیر مورد مطالعه فراهم می‌سازد.

فرضیه پژوهش

با توجه به محدودیت‌ها و ضعف‌های مدل‌های کلاسیک سری‌های زمانی مانند ARIMA در مواجهه با داده‌های پرنوسان، غیرخطی و دارای ساختار پیچیده قیمت بیت‌کوین و همچنین وجود محدودیت سایر الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق در استخراج وابستگی‌ها و الگوهای پیچیده در داده‌های مالی، این پژوهش بر این فرض استوار است که مدل SVR به‌دلیل توانایی مدل‌سازی روابط غیرخطی بدون نیاز به فروض از پیش تعیین‌شده، انعطاف‌پذیری بالا و اجرای اصل کمینه‌سازی ریسک ساختاری، قادر است الگوهای پیچیده و نوسانات بازار بیت‌کوین را به‌طور مؤثرتری شناسایی کند. از این‌رو، انتظار می‌رود SVR در مقایسه با مدل‌های کلاسیک سری‌های زمانی، سایر الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق، دقت و کارایی بالاتری در پیش‌بینی قیمت بیت‌کوین ارائه دهد.

پیشینه پژوهش

مانگلا و همکاران (۲۰۱۹) با بهره‌گیری از مدل‌های یادگیری ماشین شامل رگرسیون لجستیک^۴، ماشین بردار پشتیبان، شبکه عصبی بازگشتی و مدل سنتی میانگین متحرک خودرگرسیون تلفیقی قیمت آینده بیت‌کوین را پیش‌بینی کردند. نتایج حاکی از آن است که میانگین متحرک خودرگرسیون تلفیقی برای پیش‌بینی‌های کوتاه مدت روزانه عملکرد مناسبی دارد، اما در پیش‌بینی‌های بلند مدت از دقت کافی و لازم برخوردار نیست. در مقابل، مدل‌های یادگیری ماشین نسبت به مدل‌های سنتی دقت و عملکرد بالاتری را ارائه کردند.

^۱ Gated Recurrent Unit

^۲ Convolutional Neural Network

^۳ Seabe. et al.

^۴ Logistic Regression

چن و همکاران^۱ (۲۰۲۰) با بهره‌گیری از رویکردهای یادگیری ماشین شامل جنگل تصادفی، تقویت گرادیانی^۲، تحلیل تمایز درجه دوم^۳، ماشین بردار پشتیبان و شبکه حافظه بلندمدت کوتاه‌مدت، قیمت بیت کوین را روی دو مجموعه داده روزانه و با فواصل ۵ دقیقه‌ای پیش‌بینی کردند. یافته‌ها نشان می‌دهند روش‌های آماری مانند رگرسیون لجستیک و تحلیل تمایز خطی^۴ برای پیش‌بینی قیمت روزانه با ویژگی‌های با بعد بالا بهترین عملکرد را داشتند و دقت ۶۶ درصد را به‌دست آوردند، در حالی که مدل‌های یادگیری ماشین برای پیش‌بینی قیمت با فواصل ۵ دقیقه‌ای عملکرد بهتری نشان دادند و دقت آن‌ها به ۶۷/۲ درصد رسید.

لاهمیری و بکیروس^۵ (۲۰۲۰) با به‌کارگیری رویکردهای آماری و یادگیری ماشین شامل رگرسیون بردار پشتیبان، رگرسیون گاوسی-پواسون^۶، مدل‌های الگوریتمی مانند درخت‌های رگرسیون^۷، نزدیک‌ترین همسایه^۸ و ساختارهای شبکه عصبی مصنوعی (شامل شبکه‌های پیش‌خور^۹، شبکه‌های با رگولاریزاسیون بیزی^{۱۰} و شبکه‌های تابع پایه شعاعی^{۱۱})، روند حرکتی قیمت بیت کوین را پیش‌بینی و بررسی کردند. یافته‌ها نشان می‌دهند شبکه‌های با رگولاریزاسیون بیزی در پیش‌بینی قیمت بیت کوین دقت بالایی دارد و همگرایی آن سریع و بدون مانع است. شبکه‌های عصبی به‌دلیل پردازش موازی قادرند تصمیم‌گیری تحلیگران را در حضور روابط ورودی-خروجی و سیگنال‌های پرنویز به‌طور مؤثری شبیه‌سازی کنند.

جاکوارت و همکاران (۲۰۲۱) با استفاده از مدل‌های یادگیری ماشین، قیمت بیت کوین را در افق‌های زمانی ۱ تا ۶۰ دقیقه پیش‌بینی کردند. نتایج نشان می‌دهد مدل‌های شبکه عصبی بازگشتی و طبقه‌بندی‌های گرادیان بوستینگ نسبت به مدل‌های رقیب عملکرد بهتری دارند. همچنین، با افزایش افق زمانی، دقت پیش‌بینی به‌طور قابل توجهی بهبود می‌یابد.

پابوچو و همکاران (۲۰۲۳) با به‌کارگیری رویکردهای یادگیری ماشین شامل ماشین بردار پشتیبان، شبکه عصبی مصنوعی و جنگل تصادفی قیمت بیت کوین را روی دو مجموعه داده پیوسته و گسسته پیش‌بینی کردند. یافته‌ها نشان می‌دهند الگوی جنگل تصادفی در داده‌های پیوسته کمترین خطا را دارد. در حالی که شبکه عصبی مصنوعی در مجموعه داده‌های گسسته عملکرد بهتری از خود نشان داده است.

پروینی^{۱۲} و همکاران (۲۰۲۵) با استفاده از مدل رگرسیون بردار پشتیبان مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات^{۱۳}، قیمت پایانی سه رمز ارز بیت کوین، اتریوم و ریپل را پیش‌بینی کردند. نتایج نشان داد مدل PSO-SVR در مقایسه با مدل‌های مبتنی بر شبکه عصبی، شامل پرسپترون چندلایه، حافظه بلندمدت کوتاه‌مدت و حافظه بلندمدت دوسویه، از دقت بالاتری در پیش‌بینی قیمت رمزارزها برخوردار است.

آدیگبا و همکاران (۲۰۲۵) با به‌کارگیری الگوریتم‌های یادگیری ماشین و یادگیری عمیق، روند حرکتی قیمت ۳۰ رمز ارز را مدل‌سازی کردند. نتایج نشان می‌دهد مدل‌های گرادیان بوستینگ و تقویت گرادیانی نسبت به مدل‌های رگرسیون بردار پشتیبان و شبکه‌های حافظه بلندمدت کوتاه‌مدت در تمامی رمز ارزها عملکرد بهتری دارند.

لنگیل و همکاران^{۱۴} (۲۰۲۵) با استفاده از الگوهای یادگیری ماشین نظارت‌شده، تقویتی و مدل‌های ترکیبی قیمت بیت کوین را پیش‌بینی کردند. یافته‌ها حاکی است مدل‌های ترکیبی دقت پیش‌بینی و سودآوری معاملات را در بازارهای نوسانی به‌طور چشمگیری

¹ Chen et al.

² XGBoost

³ Linear Discriminant Analysis

⁴ Quadratic Discriminant Analysis

⁵ Lahmiri & Bekiros

⁶ GRP

⁷ Regression Trees

⁸ K-Nearest Neighbor

⁹ Feedforward Neural Networks

¹⁰ Bayesian Regularized Neural Networks

¹¹ Radial Basis Function Networks

¹² Parvini

¹³ PSO-SVR

¹⁴ Lengyel et al.

افزایش می دهند. در حالی که الگوهای یادگیری تقویتی به بهینه سازی پویا پرتفوی و ارزیابی بازه تعدیل شده براساس ریسک کمک می کنند.

دنگ^۱ (۲۰۲۵) در پژوهشی عملکرد سه مدل رگرسیون خطی، ماشین بردار پشتیبان و حافظه بلندمدت کوتاه مدت را برای پیش بینی قیمت بیت کوین بررسی کرد. همچنین، به منظور بهبود دقت پیش بینی، از مدل ترکیبی انباشته^۲ نیز استفاده شده است. نتایج نشان داد مدل حافظه بلندمدت کوتاه مدت در پیش بینی نوسانات قیمت بیت کوین عملکرد دقیق تری نسبت به مدل های رگرسیون خطی و ماشین بردار پشتیبان دارد. همچنین، مدل انباشته با بهره گیری از قابلیت های هر سه روش، روند بازار را جامع تر شناسایی می کند و پیش بینی های دقیق تر و کاربردی تری برای سرمایه گذاران ارائه می دهد.

وانگ و هوانگ^۳ (۲۰۲۶) با استفاده از یک چارچوب ترکیبی مبتنی بر پایه رگرسیون بردار پشتیبان و مجموعه ای از داده های راهبردی تکنیکال قیمت چهار رمز ارز بیت کوین، اتریوم، ریپل و لایت کوین را طی دوره زمانی ۲۰۱۸ تا ۲۰۲۰ پیش بینی کردند. نتایج نشان داد مدل SVR تعادل مناسبی بین دقت پیش بینی و کارایی محاسباتی، به ویژه در شرایط نوسان متوسط بازار، برقرار می کند. همچنین، نتایج آزمون راهبردهای معاملاتی نشان داد سیگنال های تولید شده توسط مدل SVR در برخی شرایط بازار عملکرد بهتری نسبت به روش های سنتی تحلیل تکنیکال دارند، هرچند کارایی آن در رمزارزهای با نوسان بسیار زیاد، مانند بیت کوین، با محدودیت هایی همراه است.

بشیری و پاریاب (۱۳۹۹) با استفاده از مجموعه داده های ۱۰ رمز ارز، یک مجموعه داده جدید با در نظر گرفتن قیمت نهایی هر رمزارز برای تعیین جهت و صحت قیمت بیت کوین را با استفاده از داده کاوی تشکیل دادند که این روش با استفاده از الگوریتم های یادگیری ماشین انجام گرفته است. نتایج حاکی است الگوریتم های ماشین بردار پشتیبان، جنگل تصادفی، گرادیان تقویتی و شبکه عصبی مقدار صحت ۵۲/۱۶۷۵ درصد را ثبت کردند.

محمد شریفی و همکاران (۱۴۰۰) با بهره گیری از ترکیب الگوریتم های یادگیری عمیق با ARIMA، قیمت بیت کوین را طی دوره زمانی ۲۰۱۴ تا ۲۰۱۹ را پیش بینی کردند. نتایج نشان می دهد مدل GRU-ARIMA در مقایسه با سایر الگوریتم های ترکیبی از دقت و عملکرد بهتری برخوردار است.

قربانی و همکاران (۱۴۰۱) با استفاده از الگوریتم های یادگیری ماشین قیمت بیت کوین را طی دوره زمانی ۲۰۲۱ تا ۲۰۲۲ پیش بینی کردند. یافته ها نشان می دهند الگوریتم XGBOOST در مقایسه با سایر الگوریتم ها دقت قابل قبولی در بازار بیت کوین ارائه می دهد و قادر است روند تغییرات قیمت بیت کوین را پیش بینی نماید.

عزیزی (۱۴۰۱) با استفاده از الگوریتم های شبکه های عصبی کانولوشنی، شبکه های حافظه بلندمدت کوتاه مدت و واحد بازگشتی دروازه دار قیمت بیت کوین را پیش بینی کرد. یافته ها نشان می دهند شبکه های عصبی CNN، LSTM و GRU قیمت بیت کوین را در بازه های زمانی مختلف و با مجموعه داده های متفاوت به خوبی پیش بینی می کنند و می توانند برای مدیریت پرتفوی و سرمایه گذاری در این بازار و در نتیجه کسب سود، مفید باشند.

اسدپور و رضایی (۱۴۰۲) روشی مبتنی بر شبکه های عصبی و الگوریتم های هوش مصنوعی برای پیش بینی قیمت بیت کوین ارائه کردند. نتایج نشان داد که استفاده از اطلاعات ۱۵ و ۲۰ روز گذشته، با دقت ۳۶/۹۷ و ۹۶/۷۶ درصد، بهترین عملکرد را در پیش بینی قیمت بیت کوین داشته و انتخاب مناسب ویژگی های ورودی نیز موجب کاهش حجم محاسباتی مدل شده است.

نظیفی نایینی و همکاران (۱۴۰۴) با استفاده از شبکه عصبی مصنوعی و رگرسیون چرخشی مارکوف قیمت بیت کوین را طی دوره زمانی ۲۰۱۴ تا ۲۰۲۵ را پیش بینی کردند. نتایج حاکی است شبکه عصبی پیش بینی دقیقی ارائه می دهد که در آن شاخص S&P500 بیشترین تأثیر را دارد. علاوه بر این نتایج حاصل از مدل مارکوف نیز نشان می دهد بیت کوین در بلندمدت عمدتاً در

¹ Deng

² Stacked Model

³ Wang & Huang

وضعیت کم‌نوسان قرار دارد و نرخ بهره آمریکا و EUR/USD از متغیرهای مؤثر هستند. این یافته‌ها برای سرمایه‌گذاران بلندمدت و معامله‌گران کوتاه‌مدت کاربرد راهبردی داشته و ضرورت توجه هم‌زمان به متغیرهای کلان اقتصادی و شاخص‌های فنی را برجسته می‌سازد.

آرمن و همکاران (۱۴۰۴) با استفاده از الگوریتم جستجوی گرانشی و شبکه عصبی مصنوعی، قیمت بیت کوین را در دوره قبل و پس از همه‌گیری کووید-۱۹ پیش‌بینی و شبیه‌سازی کردند. به‌همین منظور، متغیرهایی شامل تعداد معاملات روزانه بیت کوین، سختی استخراج شبکه بیت کوین، تعداد بیت کوین در گردش، قیمت روزانه طلا، شاخص S&P500، شاخص قیمت سهام بورس نیویورک، نرخ برابری دلار و یورو، تعداد پست‌های منتشرشده در توییتر و تعداد جست‌وجوی واژه‌های مرتبط با بیت کوین در گوگل، به‌عنوان عوامل مؤثر بر قیمت بیت کوین در نظر گرفته شده‌اند. نتایج حاکی است بر اساس معیارهای دقت برازش، به‌ویژه میانگین درصد خطای مطلق، مدل کاب-داگلاس در هر دو دوره، قبل و پس از همه‌گیری کووید-۱۹، عملکرد بهتری نسبت به سایر مدل‌ها داشته و به‌عنوان مدل برتر انتخاب شده است. همچنین، دقت شبیه‌سازی این مدل پس از همه‌گیری افزایش یافته است. علاوه بر این، نتایج شبکه عصبی مصنوعی بیانگر خطای پیش‌بینی حدود یک درصد و در نتیجه دقت پیش‌بینی نزدیک به ۹۹ درصد است که نشان‌دهنده توان بالای این روش در پیش‌بینی قیمت بیت کوین است.

مرور پیشینه پژوهش نشان می‌دهد پیش‌بینی قیمت بیت کوین و سایر دارایی‌های دیجیتال عمدتاً با استفاده از مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق انجام شده است. اگرچه این روش‌ها در برخی مطالعات توانسته‌اند دقت قابل قبولی در پیش‌بینی قیمت ارائه دهند، اما نتایج پژوهش‌های پیشین نشان می‌دهد که هیچ‌یک از رویکردهای موجود به‌تنهایی قادر به ارائه یک چارچوب پایدار و جامع برای پیش‌بینی در شرایط پیچیده بازار بیت کوین نیستند. دلیل اصلی این محدودیت را می‌توان در ویژگی‌های خاص این بازار، از جمله نوسانات شدید، رفتار غیرخطی، تغییرات سریع ساختار بازار و تأثیرپذیری هم‌زمان از عوامل تکنیکال، بنیادی و محیطی جست‌وجو کرد. به‌گونه‌ای که استفاده صرف از داده‌های تاریخی قیمت یا تعداد محدودی از شاخص‌های ورودی، ممکن است موجب از دست رفتن بخشی از اطلاعات مؤثر و کاهش توانایی مدل در شناسایی روابط پنهان و الگوهای پیچیده بازار شود. علاوه بر این، بررسی مطالعات پیشین نشان می‌دهد که بسیاری از پژوهش‌ها بر انتخاب الگوریتم پیش‌بینی تمرکز داشته و کمتر به فرایند ایجاد ویژگی‌های مؤثر، تعیین ساختار زمانی مناسب داده‌ها و تنظیم بهینه پارامترهای مدل توجه کرده‌اند. در حالی که عملکرد مدل‌های یادگیری ماشین و یادگیری عمیق به‌شدت تحت تأثیر کیفیت ویژگی‌های ورودی، انتخاب وقفه زمانی مناسب و تنظیم دقیق پارامترهای مدل قرار دارد. بنابراین، شکاف موجود در ادبیات را می‌توان در نبود یک چارچوب یکپارچه دانست که بتواند هم‌زمان اطلاعات بنیادی و تکنیکال را در قالب مؤلفه‌های جدید استخراج کرده، ساختار زمانی مناسب را تعیین نموده و پارامترهای مدل را به‌صورت هوشمند بهینه‌سازی کند. در پژوهش حاضر، برای پاسخ به این شکاف، مؤلفه‌هایی مبتنی بر متغیرهای بنیادی و تکنیکال ایجاد شده است که در مقایسه با داده‌های اولیه، اطلاعات غنی‌تری از رفتار بازار ارائه داده و توانایی مدل در تشخیص روند و نوسانات قیمت را افزایش می‌دهد. همچنین، با تعیین وقفه بهینه و بهره‌گیری از روش بهینه‌سازی بیزی برای تنظیم پارامترهای مدل، تلاش شده است محدودیت ناشی از انتخاب‌های ثابت و غیر بهینه در فرایند مدل‌سازی کاهش یابد. این ترکیب از مهندسی ویژگی، تعیین ساختار زمانی مناسب و تنظیم هوشمند پارامترها، امکان استخراج بهتر الگوهای غیرخطی و پنهان بازار بیت کوین را فراهم می‌سازد و پژوهش حاضر را از رویکردهای متداول مبتنی بر داده‌های خام و تنظیمات از پیش تعیین‌شده متمایز می‌کند.

روش‌شناسی پژوهش

پژوهش حاضر از روش کتابخانه‌ای و اسنادی برای جمع‌آوری اطلاعات و داده‌های مورد نیاز استفاده می‌کند. جامعه آماری پژوهش بازار بیت کوین است و داده‌های مورد استفاده از سایت شبکه اطلاع رسانی سکه طلا و ارز^۱ استخراج شده‌اند. برای تجزیه و تحلیل داده‌ها، اجرای مدل و پیاده‌سازی الگوهای مختلف از نرم‌افزار پایتون (نسخه ۳،۱۲) استفاده می‌شود. به‌منظور پیش‌بینی

^۱ <https://www.tgju.org/>

قیمت و تحلیل روندهای بازار بیت کوین، نخست شاخص‌های تکنیکال براساس چهار ویژگی قیمتی شامل قیمت بازگشایی، حداکثر، حداقل و قیمت پایانی محاسبه می‌شوند تا علاوه بر افزایش قدرت تشخیص روند قیمت، شرایط اشباع خرید یا فروش بازار به صورت شفاف و دقیق قابل تشخیص باشد. سپس با استفاده از تحلیل مؤلفه‌های اصلی، مؤلفه‌های دارای اطلاعات مشترک حذف و مؤلفه‌های اثرگذار انتخاب می‌شوند و به عنوان ویژگی‌های ورودی مدل مورد استفاده قرار می‌گیرند. مرحله بعدی به تعیین وقفه بهینه مدل‌ها و تخمین بهینه پارامترهای مورد نیاز اختصاص دارد. برای این منظور، با بهره‌گیری از شبکه عصبی کانولوشنی تک بعدی، وقفه بهینه برای مدل‌های یادگیری عمیق و یادگیری ماشین تعیین می‌گردد؛ پارامترهای مدل نیز با استفاده از رویکرد بیزی تعیین می‌شوند تا تخمین پارامترها دقیق و انعطاف پذیر باشد و دقت پیش بینی قیمت بیت کوین افزایش یابد. در ادامه، با استفاده از داده‌های مربوط به مؤلفه‌های انتخاب شده، رگرسیون بردار پشتیبان همراه با الگوها و الگوریتم‌های رقیب شامل مدل کلاسیک سری زمانی، سایر الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق اجرا می‌شوند تا علاوه بر مدل سازی رفتار نوسانی بازار، شناسایی روندها و کشف الگوهای اصلی، امکان مقایسه الگوها نیز میسر شود.

در مرحله ارزیابی، عملکرد مدل‌ها بر اساس معیارهای خطا، شاخص‌های ضریب همبستگی و تایل مقایسه و تحلیل می‌شوند تا از توانایی شناسایی رفتار و دقت پیش بینی قیمت بازار بیت کوین اطمینان حاصل شود. افزون بر این، به منظور اعتبارسنجی و تست مقاومت الگوها، از آزمون‌های دایبولد-ماریانو^۱، ویلکاکسون^۲، هانسن-لوند-ناسون^۳، جیاکومینی-وایت^۴ و دایبولد-ماریانو با تصحیح واریانس^۵ بهره برده می‌شود. در نهایت، با استفاده از بهترین مدل شناسایی شده، قیمت بازار بیت کوین پیش بینی می‌شود و قابلیت مدل در شرایط واقعی سنجیده می‌شود.

مدل مورد استفاده در پژوهش

مدل رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان یکی از روش‌های قدرتمند یادگیری ماشین نظارت شده است که با نداشت متغیرهای مستقل مربوط به N مشاهده به فضایی با ابعاد بالاتر، امکان مدل سازی روابط پیچیده و غیرخطی را فراهم می‌کند. این روش اگرچه ریشه در الگوریتم طبقه بندی ماشین بردار پشتیبان دارد، اما در مسائل رگرسیونی به جای تعیین گروه‌ها، مقدار واقعی متغیر هدف را پیش بینی می‌کند.

در حالت کلی رگرسیون بردار پشتیبان با استفاده از داده‌های آموزشی $\{(y_k, x_k)\}_{k=1}^N$ و با بهره‌گیری از توابع هسته، یک مدل خطی را در فضای نگاشت شده تشکیل می‌دهد. x بردار متغیرهای پیش بینی و y طبقه بندی نمونه است. در این فرایند، جداسازی کلاس‌ها با استفاده از ابرصفحه بهینه انجام می‌شود. x_k بردار ویژگی‌ها و $y_k \in \{-1, 1\}$ بر چسب کلاس باشد. ابر صفحه طبقه بندی به صورت زیر تعریف می‌شود:

$$W^T \phi(X_k) + b = 0 \quad (1)$$

w بردار وزن، b مقادیر بایاس، $\phi(X_k)$ تابع نگاشت ویژگی و c پارامتر مدل است.

برای این که نمونه‌ها به درستی تفکیک شوند، شرایط زیر باید برقرار باشد:

$$W^T \phi(X_k) + b \geq 1, y_k = 1 \quad (2)$$

$$W^T \phi(X_k) + b \leq -1, y_k = -1 \quad (3)$$

این شرایط تضمین می‌کنند که هر نمونه به درستی در سمت مناسب مرز تصمیم قرار گیرد و مدل بتواند نمونه‌های مثبت و منفی را بدون خطا از هم تفکیک کند.

این دو قید به صورت فشرده تر، به شکل زیر بازنویسی می‌شوند:

¹ Diebold-Mariano test

² Wilcoxon signed-rank test

³ Hansen-Lunde-Nason test

⁴ Giacomini-White test

⁵ Diebold-Mariano test with variance correction

$$y_k[W^T \phi(x_k) + b] \geq 1 \quad (4)$$

تابع $\phi(0): \mathbb{R}^n \rightarrow \mathbb{R}^{n_k}$ متغیرهای مستقل با ابعاد بالا را نگاشت می‌کند و براساس آن قادر است نمونه‌ها را براساس هر کلاس به صورت خطی تفکیک کند.

در حالی که در مدل طبقه‌بندی انتظار می‌رود جداسازی کامل نمونه‌ها در دو کلاس $\{-1$ و $1\}$ امکان‌پذیر باشد، در عمل حتی در فضای نگاشت شده نیز چنین جداسازی کامل همواره ممکن نیست. به همین دلیل، متغیر خطای $\varepsilon \geq 0$ به عنوان حاشیه تحمل معرفی می‌شود تا مدل نسبت به خطاهای کوچک انعطاف‌پذیرتر عمل کند. در این صورت قید (4) به فرم زیر بازنویسی می‌شود:

$$y_k[W^T \phi(x_k) + b] \geq 1 - \varepsilon_k \quad (5)$$

برای یافتن ابرصفحه بهینه، رگرسیون بردار پشتیبان مسئله‌ای از نوع بهینه‌سازی محدب را حل می‌کند تابع هدف، ترکیبی از دو بخش است:

۱- کمینه‌سازی نرم وزن‌ها $|W|^2$ برای بیشینه‌سازی حاشیه؛

۲- کمینه‌سازی مجموع خطاها با تنظیم پارامتر C؛

مسئله نهایی به صورت زیر تعریف می‌شود:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{k=1}^N \varepsilon_k \quad (6)$$

مراحل انجام پژوهش

مرحله اول: تحلیل اولیه داده‌ها و محاسبه شاخص‌های تکنیکال

برای مدل‌سازی و پیش‌بینی، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای آزمون کارایی مدل استفاده می‌شوند و با استفاده از روش Z-score داده‌ها استانداردسازی می‌شوند تا تأثیر واحدها و مقیاس‌های ناهم‌هنگ در میان شاخص‌های مختلف حذف شود. با توجه به داده‌های اختصاص‌یافته به آموزش، متغیرهای قیمتی و شاخص‌های تکنیکال شامل: میانگین متحرک همگرا - واگرا (MACD)^۱، خط سیگنال (MACD_signal)^۲، هیستوگرام (MACD_hist)^۳ آن، شاخص قدرت نسبی (RSI)^۴، نوسان‌گر تصادفی (KDJ)^۵، شاخص بایا (BIAS)^۶، شاخص ویلیامز (WILLR)^۷ و نرخ تغییر قیمت (ROC)^۸ محاسبه می‌شوند. انتخاب شاخص‌های تکنیکال مورد استفاده در این پژوهش با هدف استخراج ابعاد مختلف رفتار قیمتی بیت‌کوین شامل روند، مومنتوم، سرعت تغییرات قیمت و نقاط احتمالی بازگشت انجام شده است. با توجه به ویژگی‌های خاص بازار ارزهای دیجیتال، از جمله نوسانات شدید، رفتار غیرخطی و تغییرات سریع روند، استفاده از مجموعه‌ای متنوع از شاخص‌های تکنیکال می‌تواند اطلاعات مکملی درباره وضعیت بازار در اختیار مدل‌های پیش‌بینی قرار دهد. مطالعات اخیر نشان داده‌اند که ترکیب شاخص‌های تکنیکال با مدل‌های یادگیری ماشین می‌تواند توانایی مدل در شناسایی الگوهای پیچیده موجود در بازار ارزهای دیجیتال را افزایش دهد. شاخص MACD، MACD_signal و MACD_hist آن به منظور استخراج اطلاعات مرتبط با جهت، قدرت و تغییرات روند انتخاب شده‌اند. MACD با استفاده از رابطه میان میانگین‌های متحرک، تغییرات مومنتوم و احتمال تغییر جهت روند را نشان می‌دهد، در حالی که MACD_signal و MACD_hist اطلاعات دقیق‌تری درباره شدت حرکت قیمت و نقاط احتمالی تقاطع روند فراهم می‌کنند. RSI به عنوان یکی از مهم‌ترین شاخص‌های مومنتوم، برای اندازه‌گیری شدت حرکت قیمت و شناسایی شرایط اشباع خرید و فروش به کار گرفته شده است. این شاخص می‌تواند اطلاعاتی درباره قدرت روند جاری و احتمال بازگشت قیمت ارائه دهد. همچنین، KDJ با بررسی موقعیت قیمت پایانی نسبت به دامنه تغییرات

¹ Moving Average Convergence Divergence

² MACD Signal Line

³ MACD Histogram

⁴ Relative Strength Index

⁵ Stochastic Oscillator

⁶ Bias Indicator

⁷ Williams %R

⁸ Rate of Change

قیمت، برای استخراج اطلاعات مربوط به حرکات کوتاه مدت بازار و شناسایی نقاط احتمالی تغییر روند استفاده می شود. خطوط K ، D و J در شاخص KDJ نیز به دلیل توانایی در نمایش تغییرات مومنتوم و شناسایی نقاط بازگشت کوتاه مدت قیمت در مدل وارد شده اند. خط K واکنش سریع تری نسبت به تغییرات قیمت دارد، خط D با هموارسازی نوسانات، روند پایدارتر را نشان می دهد و خط J حساسیت بیشتری نسبت به تغییرات مومنتوم دارد. به دلیل نوسانات بالا و تغییرات سریع قیمت در بازار بیت کوین، این شاخص ها می توانند اطلاعات ارزشمندی درباره رفتار کوتاه مدت بازار فراهم کنند. BIAS برای اندازه گیری میزان انحراف قیمت جاری از میانگین متحرک و بررسی فاصله قیمت از روند معمول بازار مورد استفاده قرار گرفته است. این شاخص می تواند در شناسایی شرایطی که قیمت از مسیر معمول خود فاصله گرفته و احتمال اصلاح یا بازگشت وجود دارد، مؤثر باشد. همچنین، WILLR برای ارزیابی موقعیت قیمت نسبت به محدوده بیشترین و کمترین قیمت در یک دوره مشخص و تشخیص شرایط اشباع خرید و فروش انتخاب شده است. در نهایت، ROC به عنوان معیاری برای سنجش سرعت و شتاب تغییرات قیمت وارد مدل شده است. این شاخص می تواند اطلاعاتی درباره قدرت حرکت های صعودی و نزولی و تغییرات سریع قیمت ارائه دهد که در بازار پرنوسان بیت کوین اهمیت زیادی دارد. در مجموع، انتخاب این مجموعه از شاخص های تکنیکال با هدف پوشش همزمان جنبه های مختلف رفتار بازار شامل روند، مومنتوم، انحراف قیمت و سرعت تغییرات آن انجام شده است تا مدل پیش بینی بتواند اطلاعات جامع تری از رفتار تاریخی بیت کوین دریافت کند (گراووجویچ و همکاران، ۲۰۲۳).

مرحله دوم: تحلیل مؤلفه های اصلی و کاهش ابعاد

برای کاهش ابعاد تکراری و بهبود عملکرد مدل در این پژوهش از تحلیل مؤلفه های اصلی (PCA) استفاده می شود و به منظور جلوگیری از نشت داده، PCA صرفاً بر روی داده های آموزشی اعمال می شود. هدف از به کارگیری رویکرد تحلیل مؤلفه ها استخراج ویژگی های کلیدی و حذف هم پوشانی اطلاعات میان متغیرهای همبسته است. جدول شماره (۱) نتایج تحلیل مؤلفه های اصلی را به اختصار بیان می کند.


جدول ۱. تحلیل مؤلفه های اصلی

مؤلفه اصلی	نسبت واریانس توضیح داده شده	واریانس تجمعی
PC1	۴۲/۷۶۰۸۲۶	۴۲/۷۶۰۸۲۶
PC2	۲۳/۹۸۴۹۱۴	۶۶/۷۴۵۷۴۱
PC3	۱۳/۲۱۰۷۳۹	۷۹/۹۵۶۴۷۹
PC4	۷/۰۲۳۹۹۰۳	۸۶/۹۸۰۳۸۳
PC5	۵/۸۹۰۰۳۶	۹۲/۸۷۰۴۱۹
PC6	۳/۸۵۲۳۵۰	۹۶/۷۲۲۷۶۹
PC7	۱/۸۳۱۸۷۰	۹۸/۵۵۴۶۳۹
PC8	۱/۴۳۶۱۲۳	۹۹/۹۹۰۷۶۲
PC9	۰/۰۰۶۵۴۲	۹۹/۹۹۷۳۰۴
PC10	۰/۰۰۲۶۹۶	۱۰۰
PC11	.	۱۰۰
PC12	.	۱۰۰
PC13	.	۱۰۰

مأخذ: یافته های پژوهش

همان گونه که مشاهده می شود هفت مؤلفه اول بیشترین اطلاعات را در بازار بیت کوین ارائه می کنند. سهم واریانس توضیح داده شده این مؤلفه ها به ترتیب حدود ۴۲، ۲۳، ۱۳، ۷، ۵، ۳ و ۱ درصد است و در مجموع حدود ۹۸ درصد از واریانس کل داده ها را

پوشش می‌دهند. در واقع، بیشترین اطلاعات ساختاری داده‌ها با این هفت مؤلفه حفظ می‌شود و سایر مؤلفه‌ها به دلیل هم‌پوشانی اطلاعاتی و ارائه اطلاعات تکراری حذف می‌شوند. همچنین، تحلیل همبستگی ارائه شده در شکل شماره (۱) بخش پیوست، نتایج حاصل از تحلیل مؤلفه اصلی تأیید می‌کند و نشان می‌دهد که این هم‌پوشانی اطلاعاتی می‌تواند موجب افزایش پیچیدگی مدل و کاهش کارایی محاسباتی شود. بنابراین، استفاده از این هفت مؤلفه اصلی نه تنها باعث بهبود عملکرد تعمیم مدل می‌شود، بلکه از پیچیدگی و نویز داده‌ها نیز می‌کاهد.



نمودار ۱. تحلیل واریانس مؤلفه‌ها

برای پیش‌بینی قیمت پایانی بیت‌کوین، هفت مؤلفه اصلی استخراج شده به عنوان ویژگی‌های ورودی مدل استفاده می‌شوند.

مرحله سوم: تعیین وقفه بهینه مدل‌های یادگیری عمیق و یادگیری ماشین

در پیش‌بینی سری‌های زمانی، تعیین وقفه بهینه نقش کلیدی در افزایش دقت مدل دارد، زیرا مشاهدات گذشته بر مقادیر آینده تأثیر می‌گذارند و انتخاب تعداد مناسب وقفه باعث شناسایی درست وابستگی‌های کوتاه‌مدت و بلندمدت می‌شود. از این رو، انتخاب روش مناسب برای تعیین وقفه بهینه موضوعی مهم و اساسی است. به همین دلیل، در این مطالعه با بهره‌گیری از مدل‌های شبکه عصبی کانولوشنی تک‌بعدی وقفه بهینه تعیین می‌شود. شبکه عصبی کانولوشنی تک‌بعدی به صورت ضمنی عمل می‌کند. به این معنا که CNN به جای انتخاب صریح وقفه‌های خاص، یک پنجره پیوسته با اندازه مشخص را تعریف و از تمام نقاط درون آن پنجره با وزن‌دهی یادگرفته شده استفاده می‌کند. بنابراین، CNN نمی‌تواند به صورت مستقیم بهترین وقفه را به صورت گسسته و قابل تفسیر استخراج کند؛ بلکه اندازه کرنل و عمق شبکه به طور خودکار تعداد وقفه‌های مؤثر الگو را تعیین می‌کند (نیگام^۱، ۲۰۲۵؛ هوراتیچ و باریچ^۲، ۲۰۲۵). علاوه بر این، برای تعیین وقفه بهینه مدل‌های یادگیری عمیق و یادگیری ماشین، از دو معیار استاندارد آکائیک و شوارتز-بیزین نیز استفاده می‌شود. هدف از به کارگیری هم‌زمان این روش‌ها، تأیید نتایج شبکه عصبی کانولوشنی و افزایش اطمینان از صحت مرتبه وقفه است.


مرحله چهارم: اعمال الگوریتم‌های مختلف برای پیش‌بینی قیمت بیت‌کوین

در این مرحله نخست مدل‌های مورد استفاده در پژوهش ارزیابی می‌شوند. برای این منظور، نتایج مدل‌های پیش‌بینی با استفاده از شاخص‌های تایل، ضریب همبستگی و معیارهای خطا با یکدیگر مقایسه می‌شوند. در نهایت، با استفاده از آزمون‌های دایوولد-

¹ Nigam

² Horvatic & Baric

ماریانو، ویلکاکسون، هانسن-لوندانسون، جیاکومینی-وایتو دایبولد-ماریانو با تصحیح واریانس کارایی مدل‌ها مورد سنجش قرار می‌گیرد. در این پژوهش، کلیه پارامترهای مدل‌های یادگیری عمیق با استفاده از رویکرد بهینه‌سازی بیزی تنظیم می‌شوند. در ادامه در نمودار شماره (۲) مدل مفهومی پژوهش حاضر ارائه می‌شود.



نمودار ۲. مدل مفهومی پژوهش

مأخذ: یافته‌های پژوهش

با توجه به این که حفظ توالی زمانی برای داده‌های سری زمانی ضروری است، تقسیم داده‌ها به صورت تصادفی صورت نگرفته است. در این پژوهش، از ابتدای ۱۳ جولای سال ۲۰۱۰ تا ۹ ژانویه ۲۰۲۳ برای بازه آزمون و از ۱۰ ژانویه ۲۰۲۳ تا ۲۹ ژانویه ۲۰۲۶ برای بازه تست مدل در نظر گرفته شده است. جدول شماره (۲) آمار توصیفی داده‌ها را به اختصار گزارش می‌کند.

جدول ۲. آمار توصیفی داده‌ها


ویژگی آماری	پیش‌بینی قیمت پایانی بیت‌کوین
میانگین	۱۹۹۲۵/۳۴۱۳۴۱
میانه	۵۷۸۸/۳۰۴۱۵۰
انحراف معیار	۲۹۸۰۰/۷۶۹۱۰۶
حداقل	۰/۰۵۶۴۰۰
حداکثر	۱۲۵۱۶۰/۱۸۰۰۰۰

مأخذ: یافته‌های پژوهش

همان گونه که مشاهده می‌شود انحراف معیار نسبت به میانگین تفاوت معنی‌داری دارد که نشان می‌دهد مؤلفه‌های قیمت با نوسانات بسیار شدید و ریسک بالا همراه بوده است. وجود روزهایی با سودهای کلان میانگین را بهبود بخشیده، اما رفتار کلی بازار را می‌توان نوسانی و غیرقابل پیش‌بینی توصیف کرد. این یافته، لزوم استفاده از مدل‌های پیش‌بینی قدرتمند برای درک و مدل‌سازی این پیچیدگی و نوسان را بیش از پیش توجیه می‌کند.

نتایج وقفه بهینه مدل‌های یادگیری عمیق و یادگیری ماشین

به‌منظور پیش‌بینی قیمت بازار بیت‌کوین، ابتدا وقفه بهینه مدل‌های یادگیری عمیق و یادگیری ماشین با استفاده از شبکه عصبی کانولوشنی تک‌بعدی تعیین می‌شود. نمودار شماره (۳) نتایج وقفه بهینه را گزارش می‌کند.



نمودار ۳. تعیین وقفه بهینه مدل‌های یادگیری عمیق و یادگیری ماشین

مأخذ: یافته‌های پژوهش

با توجه به نتایج نمودار شماره (۳) بهترین وقفه برای مدل‌های یادگیری عمیق و یادگیری ماشین، وقفه ۵ روز است که دارای کمترین خطای ریشه میانگین مربعات برابر ۰/۱۴۸۵۹۱ است. نمودار شماره (۱) در بخش پیوست انتخاب وقفه بهینه را با استفاده از معیارهای اطلاعاتی آکائیک و شوارتز بیزین گزارش می‌کند که مطابق با هر دو معیار، طول وقفه بهینه ۵ است.

نتایج پیش‌بینی قیمت بازار بیت‌کوین

به‌منظور پیش‌بینی قیمت بازار بیت‌کوین، یافته‌های الگوهای مختلف برپایه معیارهای مختلف خطای پیش‌بینی، شاخص‌های تایل و ضریب همبستگی با یکدیگر مقایسه می‌شوند. جدول شماره (۳) نتایج حاصل از مدل‌سازی و پیش‌بینی قیمت بازار بیت‌کوین را بر اساس مدل‌های پژوهش برای دوره زمانی ۱۱۱۴ روز نشان می‌دهد.

جدول ۳. نتایج پیش‌بینی قیمت بیت‌کوین

MODEL	MSE	RMSE	MAE	MAPE	CORRELEATION	THEILS U
AR(4)	۱۵/۹۲۶۷۲۷	۳/۹۹۰۸۳۰	۳/۳۴۳۳۲۲	۷۵/۹۹۹۳	-۰/۰۴۵۴	۰/۷۸۰۷
ARIMA	۱۸/۴۳۴۶۶۳	۴/۲۹۳۵۶۱	۳/۶۳۶۵۸۵	۸۳/۵۶	-۰/۰۳۱۴	۰/۸۷۸۰
GARCH	۶/۱۱۲۹۸۷	۲/۴۷۳۴۴۵	۱/۷۵۱۰۴۹	۳۴/۷۹	-۰/۰۰۲۵	۰/۹۱۷۴
RF	۳/۰۲۹۰۱۷	۱/۷۴۰۴۰۷	۱/۱۸۰۹۹۱	۲۱/۷۲	-۰/۸۸۶۵	۰/۲۲۹۸
SVR	۰/۰۱۵۷۰۱	۰/۱۲۵۳۰۶	۰/۰۸۹۰۹۸	۲/۶۵	-۰/۹۹۸۳	۰/۰۱۳۸
XGBOOST	۲/۶۲۷۵۷۴	۱/۶۲۷۵۷۴	۱/۰۷۶۶۳۵	۱۹/۸۸	-۰/۸۹۴۶	۰/۲۱۰۱
RNN	۳/۴۷۱۳۸۱	۱/۸۶۳۱۶۴	۱/۳۳۹۲۲۴	۳۴/۸۰	-۰/۹۴۱۵	۰/۲۵۲۱
MLP	۰/۰۳۷۷۵۸	۰/۱۹۴۲۱۵	۰/۱۴۳۴۹۵	۴/۲۰	-۰/۹۹۶۴	۰/۰۲۱۳
GRU	۲/۰۳۴۷۲۹	۱/۴۲۶۴۳۹	۱/۰۰۷۰۷۸	۱۸/۴۸	-۰/۹۶۷۱	۰/۱۸۳۰
CNN	۰/۱۶۰۸۶۸	۰/۴۰۱۰۸۳	۰/۲۹۷۵۲۰	۸/۲۳	-۰/۹۹۰۳	۰/۰۴۰۶
LSTM	۳/۸۸۴۰۰۶	۱/۹۷۰۷۸۸	۱/۴۲۸۰۶۳	۲۶/۹۷	-۰/۹۲۰۶	۰/۲۶۹۵

مأخذ: یافته‌های پژوهش

معیارهای خطای پیش‌بینی حاکی از آن‌اند که مدل‌های کلاسیک سری زمانی AR، ARIMA و GARCH نسبت به سایر الگوها عملکرد ضعیفی دارند که نشان‌دهنده ضعف در مدل‌سازی پیچیدگی‌های بازار ارزهای دیجیتال بیت‌کوین است. در واقع، این الگوها به دلیل ساختار خطی قادر به درک نوسانات بازار بیت‌کوین نیستند. در مقابل، مدل‌های یادگیری ماشین و یادگیری عمیق عملکرد بهتری را به خود اختصاص داده‌اند و مقایسه معیارهای خطا نشان می‌دهد که پیش‌بینی آن‌ها بسیار دقیق‌تر از مدل‌های سنتی است. در بین مدل‌های یادگیری ماشین و یادگیری عمیق کم‌ترین خطا به مدل SVR تعلق دارد. علاوه بر این، شاخص تایل برتری مدل SVR را نسبت به مدل‌های کلاسیک، یادگیری عمیق و یادگیری ماشین تأیید می‌کند. شاخص تایل به عنوان یک معیار مقایسه‌ای، خطای پیش‌بینی را نسبت به تغییرات واقعی سنجیده و با توجه به نسبت خطا به مقدار واقعی، دقت مدل را ارزیابی می‌کند. مقدار کم‌تر شاخص تایل نشان‌دهنده نزدیکی پیش‌بینی‌ها به مقادیر واقعی و عملکرد بهتر مدل است. همچنین، شاخص ضریب همبستگی نیز نشان می‌دهد مدل SVR توانسته است روند تغییرات قیمت بیت‌کوین را به طور قابل توجهی دنبال کند. همبستگی بالای ۹۹ درصد بیانگر این است که جهت و نوسانات پیش‌بینی شده توسط مدل با نوسانات واقعی بازار هم‌راستا است. نتایج نشان می‌دهد که بازار بیت‌کوین به دلیل ماهیت غیرخطی خود، توسط مدل SVR بهتر پیش‌بینی می‌شود. این مدل قادر است رفتار غیرخطی بازار بیت‌کوین را در نظر گیرد؛ به همین دلیل می‌تواند پیش‌بینی دقیق‌تری نسبت به سایر مدل‌ها داشته باشد. به منظور درک بیشتر توانایی و کارآمدی مدل SVR با واقعیت، قیمت بیت‌کوین برپایه دلار نیز در بازه زمانی اختصاص یافته به آزمون، مدل‌سازی و پیش‌بینی شد. نتایج حاصل از محاسبات معیارهای خطا، همبستگی و شاخص تایل در جدول شماره (۱) بخش پیوست گزارش شده است. مقایسه بین الگوهای مختلف نشان می‌دهد که همچنان SVR نسبت به الگوهای رقیب از ویژگی‌های آماری مناسب‌تری برخوردار است. ویژگی داده‌ها در بازه زمانی آزمون حاکی است حداقل و حداکثر قیمت بیت‌کوین به ترتیب ۱۷۹۴۳/۹ دلار در تاریخ ۱۰ ژانویه ۲۰۲۳ و ۱۲۵۱۶۰/۲۸ دلار در تاریخ ۶ اکتبر ۲۰۲۵ است. میانگین قیمت بیت‌کوین در این دوره ۶۶۶۲۵/۴۵ دلار است که بیانگر نوسانات قابل توجه بازار در این بازه زمانی است. مقدار MAE در مدل SVR نزدیک به ۱۳۸۸ دلار است که بر پایین بودن اختلاف بین مقادیر پیش‌بینی شده و قیمت واقعی دلالت دارد. این معیار بیانگر آن است که مدل در اغلب روزها توانسته قیمت بیت‌کوین را با دقت مناسبی پیش‌بینی کند و عملکردی پایدار داشته باشد. مقدار MAPE برابر با ۲/۱۱ درصد نشان می‌دهد که میزان خطای مدل نسبت به سطح واقعی قیمت بیت‌کوین بسیار پایین است. به بیان دیگر، اگرچه مقدار خطا به صورت عددی ممکن است بزرگ به نظر برسد، اما در مقایسه با میانگین قیمت بازار که بیش از ۶۶ هزار دلار بوده، این اختلاف درصد بسیار کوچکی را تشکیل می‌دهد و از قابلیت پیش‌بینی مناسب مدل حکایت می‌کند. مقدار RMSE نزدیک ۲۰۳۹ دلار است که از MAE بزرگ‌تر است و نشان می‌دهد مدل در برخی بازه‌های زمانی پرتلاطم با خطاهای بزرگ‌تری مواجه شده است. از آنجا که، RMSE نسبت به خطاهای شدید حساسیت بیشتری دارد، اختلاف میان این دو معیار بیانگر آن است که بخش عمده پیش‌بینی‌های مدل دقیق و پایدار بوده‌اند، اما در زمان وقوع شوک‌های قیمتی یا نوسانات شدید بازار، میزان خطا افزایش یافته است. از سوی دیگر، بالا بودن ضریب همبستگی نیز بیانگر آن است که مدل SVR توانسته روند کلی بازار را تقریباً به طور کامل دنبال کند. این مقدار بسیار بالا نشان می‌دهد مدل در تشخیص جهت حرکت قیمت، اعم از روندهای صعودی و نزولی، عملکرد بسیار دقیقی داشته و رفتار واقعی بازار را به خوبی بازتاب داده است. به طور کلی، نتایج نشان می‌دهد مدل SVR توانسته با دقت بالایی رفتار بازار بیت‌کوین را مدل‌سازی کند. خطای پایین در شرایط عادی، درصد خطای اندک نسبت به سطح قیمت و همبستگی بسیار زیاد با روند واقعی بازار، همگی نشان‌دهنده قابلیت اطمینان بالای این مدل در پیش‌بینی قیمت بیت‌کوین هستند.

نتایج آزمون‌های صحت‌سنجی مدل‌های پیش‌بینی قیمت بازار بیت‌کوین


در پژوهش حاضر، به منظور بررسی وجود تفاوت بین خطاهای الگوها، با استفاده از آزمون‌های دایبولد-ماریانو، ویلکاکسون، هانسن-لوند-ناسون، جیاکومینی-وایت و دایبولد-ماریانو با تصحیح واریانس، معناداری تفاوت خطاهای پیش‌بینی الگوهای رقیب با روش SVR آزمون شده است. نتایج این آزمون‌ها در جدول شماره (۴) به صورت اختصار بیان می‌شود.

جدول ۴. نتایج آزمون‌های صحت‌سنجی مدل‌های پیش‌بینی قیمت بازار بیت‌کوین

MODEL	DM	P-V	DM-HAC	P-V	HLN	P-V	W	P-V	GW	P-V
SVR & MLP	-۹/۸۰۳۳۰	۰/۰۰۰	-۸/۲۷۹۳	۰/۰۰۰	-۸/۲۷۵۵۰	۰/۰۰۰	۱۶۳۸۹۷	۰/۰۰۰	۸۴۲۴۷/۴۴	۰/۰۰۰
SVR & XGBOOST	-۲۱/۸۴۳۳	۰/۰۰۰	-۱۷/۸۲۰۰	۰/۰۰۰	-۱۷/۸۰۲۸	۰/۰۰۰	۸۸۹۲	۰/۰۰۰	۴۸۶۴۱/۳۸	۰/۰۰۰
SVR & RF	-۵۰/۸۰۸۳	۰/۰۰۰	-۳۷/۷۴۹۲	۰/۰۰۰	-۳۷/۷۳۳۹	۰/۰۰۰	۱۳۹۷۷	۰/۰۰۰	۲۶۸۱۰۹/۸۷	۰/۰۰۰
SVR & LSTM	-۲۷/۶۳۲۳	۰/۰۰۰	-۱۹/۵۵۹۸۰	۰/۰۰۰	-۱۹/۵۵۲۳	۰/۰۰۰	۴۹۹۲	۰/۰۰۰	۸۰۰۸۵/۳۳	۰/۰۰۰
SVR & GARCH	-۱۱/۲۴۱۰	۰/۰۰۰	-۱۰/۴۴۹۱	۰/۰۰۰	-۱۰/۴۳۹۷	۰/۰۰۰	۴۱۰	۰/۰۰۰	۱۲۹۰۱۶/۱۹	...
SVR & RNN	-۱۲/۶۹۱۷	۰/۰۰۰	-۹/۱۳۱۰	۰/۰۰۰	-۹/۱۲۶۰	۰/۰۰۰	۱۲۸۳۹۶	۰/۰۰۰	۷۹۳۷/۹۶	۰/۰۰۰
SVR & CNN	-۷۲/۸۸	۰/۰۰۰	-۳۶/۴۹۹۵	۰/۰۰۰	-۲/۲۴	۰/۰۲۴۷	۱۸۴۷	۰/۰۰۰	۱۶۸۱۳۶۹/۸۷	۰/۰۰۰
SVR & GRU	-۲۵/۴۲	۰/۰۰۰	-۱۸/۰۶۵۱	۰/۰۰۰	-۱۸/۰۵۴۵۰	۰/۰۰۰	۱۱۲۳۹	۰/۰۰۰	۴۱۶۲۹/۶۶	۰/۰۰۰
SVR & ARIMA	-۲۶/۰۲	۰/۰۰۰	-۱۸/۴۲۲۱	۰/۰۰۰	-۱۸/۴۱۵۰	۰/۰۰۰	۷	۰/۰۰۰	۱۰۱۶۴۳/۷۴	۰/۰۰۰
SVR & AR(1)	-۳۳/۸۱۸۸	۰/۰۰۰	-۲۳/۹۴۵۱	۰/۰۰۰	-۲۳/۹۳۴۳	۰/۰۰۰	۸۷	۰/۰۰۰	۱۳۲۸۸۶/۳۴	۰/۰۰۰

مأخذ: یافته‌های پژوهش

نتایج آزمون‌های دایبولد-ماریانو، ویلکاکسون، هانسن-لوند-ناسون، جیاکومینی-وایت و دایبولد-ماریانو با تصحیح واریانس نشان می‌دهد فرضیه صفر مبتنی بر برابری خطاهای پیش‌بینی مدل‌های مختلف در برابر مدل SVR در سطح معناداری ۵ درصد برای مدل‌های SVR، LSTM، MLP، RNN، GRU، ARIMA و RF رد شده است. در نتیجه، تفاوت خطاهای پیش‌بینی از نظر آماری معنادار است. بنابراین، نتایج نشان می‌دهد، مدل SVR از نظر دقت پیش‌بینی نسبت به سایر مدل‌های رقیب مطرح شده در پژوهش حاضر، عملکرد دقیق‌تری دارد. نمودار شماره (۴)، قیمت واقعی و پیش‌بینی شده بازار بیت‌کوین بر اساس مدل SVR را نشان می‌دهد.



نمودار ۴. قیمت واقعی و پیش‌بینی بازار بیت‌کوین

همان‌گونه که مشاهده می‌شود، مقادیر پیش‌بینی شده توسط مدل SVR به دقت روند واقعی قیمت بیت‌کوین را پیش‌بینی کرده‌اند و از لحاظ الگوی کلی حرکت، هم‌پوشانی قابل توجهی با داده‌های واقعی دارند. این نتایج بیانگر آن است که مدل SVR به خوبی توانسته است الگوهای رفتاری غیرخطی بیت‌کوین را پوشش دهد. همچنین، فاصله اطمینان ۹۵ درصد نیز این نتایج را تأیید می‌کند که پیش‌بینی‌های مدل در بیشتر نقاط درون بازه اطمینان قرار دارند؛ به گونه‌ای که عدم قطعیت مدل در محدوده قابل قبولی قرار دارد.

ارزیابی مدل با استفاده از Walk-Forward Validation

به منظور اعتبارسنجی مدل SVR، از روش Walk-Forward Validation استفاده گردید. نتایج این روش در جدول شماره (۵) گزارش شده است.

جدول ۵. نتایج اعتبارسنجی Walk-Forward Validation

مدل	MSE	RMSE	MAE	MAPE	ضریب همبستگی	آماره تایل
SVR	۰/۰۱۵۷۰۱	۰/۱۲۵۳۰۶	۰/۰۸۹۰۹۸	۲/۵۶	۰/۹۹۸۳	۰/۰۱۳۸
Walk-Forward Validation	۰/۰۱۴۲۱۶	۰/۱۱۹۲۳۰	۰/۰۸۴۷۴۵	۲/۵۸	۰/۹۹۲۱	۰/۰۱۳۲

مأخذ: یافته‌های پژوهش

مدل SVR بر اساس روش ارزیابی معتبر Walk-Forward Validation عملکرد قابل قبولی دارد. این مدل علاوه بر دقت در پیش‌بینی، پایداری و ثبات قابل قبولی از خود نشان می‌دهد و خطاها به خوبی کنترل شده‌اند. نسبت RMSE به MAE (۰/۱۱۹) در مقابل (۰/۰۸۴) که حدود ۱/۴ است، بیانگر توزیع نرمال خطاها و عدم وجود خطاهای پرت و شدید است. مقدار MAPE برابر ۲/۵۸ درصد است که بسیار پایین‌تر از آستانه ۵ درصد است. علاوه بر این، ضریب همبستگی ۰/۹۹۲۱ نشان‌دهنده دقت و همبستگی تقریباً کامل بین مقادیر واقعی و پیش‌بینی شده است. بنابراین، می‌توان به خروجی مدل در طول زمان اعتماد کرد و انتظار انحرافات شدید و غیرمنتظره را نداشت. در نتیجه، این مدل برای کاربردهای عملی که نیاز به پیش‌بینی‌های قابل اتکا با نوسانات کنترل شده دارند، گزینه‌ای مناسب محسوب می‌شود.

مقایسه یافته‌های پژوهش با نتایج مطالعات پیشین نشان می‌دهد که مدل‌های مبتنی بر یادگیری ماشین و یادگیری عمیق در مقایسه با مدل‌های اقتصادسنجی، عملکرد مطلوب‌تری در پیش‌بینی قیمت بیت‌کوین دارند.

جدول ۶. مقایسه پژوهش حاضر با مطالعات پیشین در حوزه پیش‌بینی قیمت بیت‌کوین

مطالعه	روش	یافته‌های اصلی	شباهت	تمایز
مانگلا و همکاران (۲۰۱۹)	۱- رگرسیون لجستیک. ۲- ماشین بردار پشتیبان. ۳- شبکه عصبی بازگشتی. ۴- مدل خودرگرسیو یکپارچه میانگین متحرک.	۱- برتری الگوریتم‌های یادگیری ماشین نسبت به مدل‌های سنتی اقتصادسنجی. ۲- ضعف مدل‌های سنتی در پیش‌بینی بلندمدت.	۱- استفاده از الگوریتم‌های یادگیری ماشین برای پیش‌بینی قیمت بیت‌کوین. ۲- شناسایی روابط غیرخطی و نوسانات بازار.	۱- عدم استفاده از شاخص‌های تکنیکال. ۲- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی قیمت.
چن و همکاران (۲۰۲۰)	۱- جنگل تصادفی. ۲- گرادیان بوستینگ. ۳- ماشین بردار پشتیبان. ۴- حافظه بلندمدت کوتاه‌مدت.	۱- عملکرد مطلوب الگوریتم‌های یادگیری ماشین. ۲- تأثیر افق زمانی بر دقت پیش‌بینی قیمت بیت‌کوین.	۱- استفاده از الگوریتم‌های یادگیری ماشین برای پیش‌بینی قیمت بیت‌کوین.	۱- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی قیمت. ۲- عدم استفاده از شاخص‌های تکنیکال.

پروینی و همکاران (۲۰۲۴)	۱- رگرسیون بردار پشتیبان مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات.	۱- برتری الگوریتم رگرسیون بردار پشتیبان مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات در پیش‌بینی قیمت بیت کوین نسبت به سایر مدل‌ها. ۲- توانایی الگوریتم در شناسایی الگوهای پیچیده در قیمت بیت کوین.	۱- استفاده از الگوریتم رگرسیون بردار پشتیبان برای پیش‌بینی قیمت بیت کوین. ۲- عدم استفاده از شاخص‌های تکنیکال.
آدیگبا و همکاران (۲۰۲۵)	۱- گرادیان بوستینگ. ۲- تقویت گرادینانی پیشرفته. ۳- رگرسیون بردار پشتیبان.	۱- برتری الگوریتم‌های مبتنی بر گرادیان بوستینگ نسبت به رگرسیون بردار پشتیبان و حافظه بلندمدت کوتاه‌مدت.	۱- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی. ۲- عدم استفاده از شاخص‌های تکنیکال.
وانگ و هوانگ (۲۰۲۶)	۱- چارچوب ترکیبی مبتنی بر رگرسیون بردار پشتیبان.	۱- ایجاد تعادل مناسب بین دقت پیش‌بینی و کارایی محاسباتی. ۲- عملکرد بهتر نسبت به تحلیل تکنیکال سنتی.	۱- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی. ۲- استفاده از شاخص‌های تکنیکال.
محمد شریفی و همکاران (۱۴۰۰)	۱- مدل ترکیبی واحد بازگشتی دروازه‌ای - میانگین متحرک خودرگرسیونی یکپارچه. ۲- شناسایی روابط غیرخطی.	۱- برتری مدل ترکیبی واحد بازگشتی دروازه‌ای - میانگین متحرک خودرگرسیونی یکپارچه نسبت به سایر مدل‌های ترکیبی. ۲- شناسایی روابط غیرخطی.	۱- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی. ۲- عدم استفاده از شاخص‌های تکنیکال.
قربانی و همکاران (۱۴۰۱)	۱- تقویت گرادینانی پیشرفته.	۱- عملکرد مطلوب الگوریتم تقویت گرادینانی پیشرفته در پیش‌بینی قیمت بیت کوین. ۲- شناسایی روابط غیرخطی.	۱- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی. ۲- عدم استفاده از شاخص‌های تکنیکال.
نایی و همکاران (۱۴۰۴)	۱- شبکه عصبی مصنوعی. ۲- رگرسیون چرخشی مارکوف.	۱- عملکرد مطلوب شبکه عصبی مصنوعی در شناسایی روابط غیرخطی.	۱- عدم تعیین وقفه بهینه در مدل‌سازی و پیش‌بینی. ۲- عدم استفاده از شاخص‌های تکنیکال.

مأخذ: یافته‌های پژوهش

همان‌گونه که در جدول شماره (۶) مشاهده می‌شود، الگوریتم‌های یادگیری ماشین و یادگیری عمیق نسبت به مدل‌های اقتصادسنجی از دقت بالاتری برخوردار هستند؛ زیرا این الگوریتم‌ها توانایی شناسایی روابط پیچیده و غیرخطی میان متغیرها را دارند و برخلاف مدل‌های اقتصادسنجی که عمدتاً بر فرضی نظیر خطی بودن روابط، ایستایی داده‌ها و مشخص بودن ساختار مدل استوار هستند، می‌توانند بدون نیاز به این فرض، الگوهای پنهان موجود در داده‌های با تواتر بالا و پیچیده را استخراج کنند. علاوه بر این، بازار بیت کوین تحت تأثیر عوامل متعدد اقتصادی، مالی، تکنیکال و رفتاری قرار دارد و رفتار آن از نوسانات شدید و پویایی بالایی

برخوردار است؛ از این رو، مدل های یادگیری ماشین و عمیق با قابلیت یادگیری از داده ها و انطباق با تغییرات محیط، عملکرد مناسب تری در پیش بینی قیمت این دارایی نسبت به مدل های اقتصادسنجی از خود نشان می دهند.

نتایج و پیشنهادها

نتایج حاکی از آن است که مدل رگرسیون بردار پشتیبان نسبت به مدل های رقیب استفاده شده در پژوهش از کمترین خطای پیش بینی قیمت بیت کوین برخوردار است. افزون بر این، شاخص های ارزیابی دقت، از جمله آماره تایل و ضریب همبستگی، حاکی از آن است که مدل هیبریدی SVR توانسته است هم حرکتی و تطابق معناداری میان مقادیر واقعی و پیش بینی شده قیمت بیت کوین ایجاد کند. اعتبار آماری این برتری با بهره گیری از مجموعه جامع آزمون های مقایسه دقت پیش بینی شامل آزمون دایوولد-ماریانو، ویلکاکسون هانسن-لوند-ناسون، جیاکومینی-وایت و نسخه اصلاح شده آزمون دایوولد-ماریانو تأیید شد؛ به گونه ای که فرض برابری دقت پیش بینی در تمامی آزمون ها رد گردید. از این رو، فرضیه پژوهش مبنی بر عملکرد بهتر و برتری مدل رگرسیون بردار پشتیبان نسبت به مدل های کلاسیک سری های زمانی، سایر الگوریتم های یادگیری ماشین و مدل های یادگیری عمیق تأیید شد. این موضوع بیانگر آن است که در بازارهای ارز دیجیتال به ویژه بیت کوین که ماهیتی پر تلاطم، غیرخطی و به شدت نوسانی دارند، استفاده از مدل هایی که قادر به شناسایی الگوهای پیچیده و غیرخطی هستند، ضروری و لازم است؛ قابلیتی که الگوهای کلاسیک از آن برخوردار نیستند (سیوا و همکاران^۱، ۲۰۲۴؛ کووک^۲، ۲۰۲۳). علاوه بر این، به کارگیری روش بیزی در فرایند برآورد مدل ها نقش مهمی در بهبود عملکرد پیش بینی ایفا می کند؛ زیرا با به کارگیری این روش امکان انتخاب بهینه پارامترها فراهم و از بیش برآزش مدل جلوگیری می شود. همچنین، تعیین وقفه بهینه با استفاده از شبکه عصبی کانولوشنی تک بعدی منجر می شود که ساختار پویای سری زمانی قیمت بیت کوین به صورت دقیق تری مدل سازی شود و الگوهای رفتاری نهفته در داده ها به شکل کارآمد استخراج گردند. افزون بر این، بهره گیری از داده های متغیر قیمتی بازار نظیر قیمت بازگشایی، حداقل، حداکثر و قیمت پایانی و استخراج شاخص های تکنیکال مرتبط با رفتار سرمایه گذاران، روند بازار و احساس معامله گران، موجب افزایش جامعیت ورودی های مدل و در نهایت ارتقای دقت پیش بینی مدل می شود. در مجموع، می توان گفت ترکیب سه مؤلفه اساسی شامل بهینه سازی بیزی پارامترها، تعیین وقفه متناسب با ماهیت سری زمانی و به کارگیری هم زمان داده های متغیرهای قیمتی و تکنیکال، موجب می شود عملکرد مدل پیشنهادی در پیش بینی قیمت بیت کوین نسبت به سایر روش ها به طور معناداری بهبود یابد و نتایج حاصل، قابلیت اتکای بیشتری برای تحلیل آینده بازار فراهم می آورد. یافته های پژوهش با نتایج مطالعه آدیگبا و همکاران (۲۰۲۵) و لنگیل و همکاران (۲۰۲۵) همخوانی دارد که نشان می دهند مدل های یادگیری ماشین در بازار بیت کوین نسبت به سایر مدل ها از دقت بیشتری برخوردار هستند.

نتایج پژوهش نشان داد مدل پیشنهادی می تواند نوسانات قیمت بیت کوین را با دقت بالاتری نسبت به روش های رقیب پیش بینی کند. چنین ابزاری می تواند برای نهادهای ناظر مالی در پایش ریسک بازار سرمایه و طراحی هشدارهای زودهنگام مفید باشد. همچنین، به کارگیری این مدل می تواند مبنایی برای تحلیل منافع و مخاطرات احتمالی ورود نهادهای عمومی به حوزه مدیریت دارایی های مالی فراهم کند. براین اساس، یافته های پژوهش توصیه های سیاستی مهمی برای سیاست گذاران و نهادهای ناظر مالی در ایران به ویژه بانک مرکزی و سازمان بورس اوراق بهادار به همراه دارد.

نخست، به بانک مرکزی و سازمان بورس اوراق بهادار توصیه می شود با به کارگیری مدل SVR در سامانه های نظارتی در دسترس، امکان رصد مستمر حباب های قیمتی و پایش ریسک نوسانات شدید در بازارهای مالی را فراهم آورند. بهره برداری و کاربست چنین ابزارهایی می تواند با فراهم ساختن بستر لازم برای مدیریت هوشمند انتظارات فعالان بازار و طراحی سیاست های کارآ، به تقویت ثبات بازارهای مالی کمک کند.

¹ Siva et al

² Kwok

دوم، سازمان بورس اوراق بهادار پیشنهاد می‌شود با توسعه سامانه‌های تحلیلی داده‌محور و بلادرنگ^۱ که برپایه جریان‌های قیمتی و شاخص‌های تکنیکال عمل می‌کنند، از الگوهای پیش‌بینی مبتنی بر یادگیری عمیق به‌عنوان ابزاری مکمل برای رصد لحظه‌ای بازار سرمایه بهره ببرد. استقرار چنین زیرساختی، توانمندی نهاد ناظر را در شناسایی سریع تغییرات شاخص‌های بازار سهام و ارزیابی دقیق‌تر ریسک به‌طور ملموس ارتقا می‌دهد و در نهایت در واکنش به تحولات بازار به تصمیم‌گیری‌های مبتنی بر شواهد، سرعت و چابکی بیشتری می‌بخشد در این صورت توانمندی سیاست‌گذاران بازار در شناسایی تغییرات شاخص‌های بازار سهام و کیفیت ارزیابی ریسک و در نتیجه پیامدهای تصمیم‌گیری‌های مبتنی بر شواهد با واکنش سریع‌تر به تحولات بازار افزایش می‌یابد.

سوم، به سیاست‌گذاران حوزه مالی پیشنهاد می‌شود با توسعه ظرفیت‌های تحلیل پیشرفته در نهادهای ناظر، علاوه بر ارتقای شفافیت بازار و افزایش اعتماد سرمایه‌گذاران، مبنای علمی برای تنظیم‌گری تدریجی و هوشمند بازار بیت‌کوین ایجاد کنند. در این چارچوب، استفاده از مدل‌های پیش‌بینی پیشرفته امکان تفکیک نوسانات عادی بازار از شوک‌های غیرعادی و رفتارهای سفته‌بازی را فراهم کرده و ابزار مؤثری برای مدیریت ریسک‌های ناشی از نوسانات شدید قیمت در اختیار سیاست‌گذاران قرار می‌دهد.

این پژوهش در مدل‌سازی و پیش‌بینی قیمت بازار بیت‌کوین با محدودیت‌هایی مواجه است که توجه و رفع آن‌ها می‌تواند به ارتقای مطالعات آتی منجر شود. نخست، عدم استفاده از داده‌های زنجیره‌ای (On-chain) نظیر حجم تراکنش‌ها و کارمزدها که اطلاعات ارزشمندی درباره فعالیت شبکه بیت‌کوین ارائه می‌دهند؛ دوم، چشم‌پوشی از داده‌های احساسات بازار مانند اخبار و توییت‌ها به دلیل عدم دسترسی به زیرساخت‌های پردازش زبان طبیعی؛ سوم، عدم اعتبارسنجی تفکیکی مدل در بازه‌های زمانی جداگانه با رژیم‌های متفاوت بازار (گاوی و خرسی) که عملکرد واقعی مدل را در شرایط مختلف بازار نمایان می‌سازد؛ چهارم، عدم مقایسه الگوی پژوهش با معماری‌های پیشرفته یادگیری عمیق نظیر Transformer و مدل‌های مبتنی بر سازوکار توجه (Attention-based) که ممکن است نتایج بهتری را ارائه دهند.

منابع

- آرمن، ع.، منصوری، ام.، و بهروز، ع. (۱۴۰۴). شبیه‌سازی عوامل مؤثر بر قیمت بیت‌کوین با بهره‌گیری از الگوریتم هوش مصنوعی جمعی GSA و شبکه عصبی مصنوعی. *اقتصاد مالی*، ۱۹ (۴)، ۳۳-۱.
- بشیری، م.، و پاریاب، س. ح. (۱۳۹۹). پیش‌بینی قیمت بیت‌کوین با استفاده از الگوریتم‌های یادگیری ماشین. *اقتصاد کاربردی*، ۱۰ (۳۴)، ۱-۱۴.
- محمد شریفی، ا. ص.، خلیلی دامغانی، ک.، عبدی، و سردار، س. (۱۴۰۰). پیش‌بینی قیمت بیت‌کوین با استفاده از مدل ترکیبی ARIMA و یادگیری عمیق. *مطالعات مدیریت صنعتی*، ۱۹ (۶۱)، ۱۲۷-۱۴۶.
- اسدپور، م.، و رضایی، ع. (۱۴۰۲). پیش‌بینی قیمت ارز دیجیتال با استفاده از شبکه عصبی GRU. *اقتصاد پولی مالی*، ۳۰ (۲۶)، ۳۱-۶۸.
- عزیزی، ز. (۱۴۰۱). مدیریت و بررسی پیش‌بینی قیمت ارزهای دیجیتال بیت‌کوین با استفاده از شبکه‌های عصبی عمیق در بستر بلاک‌چین. *پژوهش‌های نوین در مدیریت کارآفرینی و توسعه کسب‌وکار*، ۱۸ (۳)، ۱-۱۴.
- قربانی، ع.، ربانی، ی.، کامرانی راد، ر.، و فلسفی، پ. (۱۴۰۱). پیش‌بینی تغییرات قیمت بیت‌کوین با استفاده از تحلیل احساسات در شبکه‌های اجتماعی و سلب‌ریتی‌ها به همراه رویکرد داده‌کاوی. *مدل‌سازی اقتصادسنجی*، ۷ (۳)، ۱۶۳-۱۸۲.

¹ Real Time

نظیفی نایینی، م.، بخشی دستجردی، ر.، و حسینی غفار، س.ع. (۱۴۰۴). تحلیل روند و پیش بینی قیمت بیت کوین: یک تحلیل مقایسه ای از مدل های خطی و غیر خطی. پژوهش ها و چشم اندازها در اقتصاد، ۲۵ (۴)، ۱۵۷-۱۸۸.

Adedigba, D., Agbolade, D., & Hasan, R. (2025). Machine learning approaches to cryptocurrency trading optimization: a comparative analysis of predictive models. *Discover Artificial Intelligence*, 5(1), 1-28. <https://doi.org/10.1007/s44163-025-00519-y>.

Ahmed, S., Alshater, M. M., El Ammari, A., & Hammami, H. (2022). Artificial intelligence and machine learning in finance: A bibliometric review. *Research in International Business and Finance*, 61, 101646. <https://doi.org/10.1016/j.ribaf.2022.101646>

Arman, S. A., Mansouri, S. A., & Behrouz, A. (2025). Simulation of factors affecting Bitcoin price using the Gravitational Search Algorithm (GSA) and Artificial Neural Network. *Financial Economics*, 19(4), 1-33. (in persian).

Asadpour, M., & Rezaei, A. (2023). Predicting cryptocurrency prices using the GRU neural network. *Monetary and Financial Economics*, 30(26), 31-68. (in persian).

Azizi, Z. (2022). Management and forecasting of Bitcoin cryptocurrency prices using deep neural networks on the blockchain platform. *Modern Research in Entrepreneurship Management and Business Development*, 18(3), 1-14. (in persian).

Bashiri, M., & Paryab, S. H. (2020). Predicting Bitcoin prices using machine learning algorithms. *Applied Economics*, 10(34), 1-14. (in persian).

Będowska-Sójka, B., Wójcik, P., & Pele, D. T. (2025). Early warning systems for cryptocurrency markets: Predicting 'zombie' assets using machine learning. *The North American Journal of Economics and Finance*, 102543. <https://ssrn.com/abstract=4942031>.

Bezerra, P. C. S., & Albuquerque, P. H. M. (2017). Volatility forecasting via SVR-GARCH with mixture of Gaussian kernels. *Computational Management Science*, 14(2), 179-196. <https://doi.org/10.1007/s10287-016-0267-0>.

Boozary, P., Sheykhani, S., & GhorbanTanhaei, H. (2025). Forecasting the Bitcoin price using the various Machine Learning: A systematic review in data-driven marketing. *Systems and Soft Computing*, 7, 200209. <https://doi.org/10.1016/j.sasc.2025.200209>.

Butet, R., & Kesuma, S. A. (2026). Efficient Market Hypothesis: A Systematic Literature Review. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 2127-2132. <https://doi.org/10.31004/riggs.v4i4.3549>

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. <https://doi.org/10.1016/j.cam.2019.112395>.

Chowdhury, R., Rahman, M. A., Rahman, M. S., & Mahdy, M. R. C. (2020). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning. *Physica A: Statistical Mechanics and its Applications*, 551, 124569. <https://doi.org/10.1016/j.physa.2020.124569>.

- Cohen, G., & Aiche, A. (2025). Intelligent forecasting in bitcoin markets. *Finance Research Letters*, 71, 106487. <https://doi.org/10.1016/j.frl.2024.106487>.
- Deng, B. (2025). A Comparative Analysis of Bitcoin Price Forecasting Approaches Using Machine Learning Techniques. <https://doi.org/10.5220/0013214500004568>
- Dudek, G., Kasprzyk, M., & Pełka, P. (2025). Multivariate Forecasting of Bitcoin Volatility with Gradient Boosting: Deterministic, Probabilistic, and Feature Importance Perspectives. *Expert Systems with Applications*, 130404. <https://doi.org/10.1016/j.eswa.2025.130404>.
- García-Medina, A., & Aguayo-Moreno, E. (2024). LSTM–GARCH hybrid model for the prediction of volatility in cryptocurrency portfolios. *Computational Economics*, 63(4), 1511-1542. <https://doi.org/10.1007/s10614-023-10373-8>
- Giantsidi, S., & Claudia, T. Deep Learning for Financial Forecasting: A Review of Recent Advancements. Available at SSRN 5263710. <https://doi.org/10.1016/j.iref.2025.104719>.
- Ghorbani, A., Rabbani, Y., Kamrani Rad, R., & Falsafi, P. (2022). Predicting Bitcoin price changes using sentiment analysis on social media and celebrities along with data mining approach. *Econometric Modeling*, 7(3), 163-182.(in persian)
- Gradojevic, N., Kukolj, D., Adcock, R., & Djakovic, V. (2023). Forecasting Bitcoin with technical analysis: A not-so-random forest?. *International Journal of Forecasting*, 39(1), 1-17. <https://doi.org/10.1016/j.ijforecast.2021.08.001>
- Hafid, A., Ebrahim, M., Rahouti, M., & Oliveira, D. (2024, November). Cryptocurrency price forecasting using XGBoost regressor and technical indicators. In 2024 IEEE International Performance, Computing, and Communications Conference (IPCCC) (pp. 1-6). <https://doi.org/10.48550/arXiv.2407.11786>
- Hamayel, M. J., & Owda, A. Y. (2021). A novel cryptocurrency price prediction model using GRU, LSTM and bi-LSTM machine learning algorithms. *Ai*, 2(4), 477-496. <https://doi.org/10.3390/ai2040030>.
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2018). Stock price prediction using support vector regression on daily and up to the minute prices. *The Journal of finance and data science*, 4(3), 183-201. <https://doi.org/10.1016/j.jfds.2018.04.003>.
- Ho, A., Vatambeti, R., & Ravichandran, S. K. (2021). Bitcoin price prediction using machine learning and artificial neural network model. *Indian Journal of Science and Technology*, 14(27), 2300-2308. <https://doi.org/10.17485/IJST/v14i27.878>.
- Horvatic, D., & Baric, D. (2025). Deep convolutional interpreter for time series. *arXiv*, 1-15. <https://doi.org/10.48550/arXiv.2501.04339>
- Htun, H. H., Biehl, M., & Petkov, N. (2023). Survey of feature selection and extraction techniques for stock market prediction. *Financial Innovation*, 9(1), 26. <https://doi.org/10.1186/s40854-022-00441-7>

- Jahangir, R., Tuna, G., Koç, H., & Abbas, M. H. (2025). Financial literacy, investor sentiment, and Bitcoin returns: Panel evidence from the Eurozone. *Borsa Istanbul Review*. <https://doi.org/10.1016/j.bir.2025.09.006>
- Jaquart, P., Dann, D., & Weinhardt, C. (2021). Short-term bitcoin market prediction via machine learning. *The journal of finance and data science*, 7, 45-66. <https://doi.org/10.1016/j.jfds.2021.03.001>.
- Kang, H., Kang, Y., Ryu, D., & Webb, R. I. (2026). Bitcoin forecasting with machine learning and on-chain information. *Investment Analysts Journal*, 1-13. <https://doi.org/10.1080/10293523.2026.2616575>
- Kwok, T. (2023). An empirical analysis of forecasting bitcoin and gold price using Arima model. *Adv. Econ. Manage. Polit. Sci.* 46, 164–174. <https://doi.org/10.54254/2754-1169/46/20230335>
- Lahmiri, S., & Bekiros, S. (2020). Intelligent forecasting with machine learning trading systems in chaotic intraday Bitcoin market. *Chaos, Solitons and Fractals*, 133, 109641. <https://doi.org/10.1016/j.chaos.2020.109641>
- Levantesi, S., Piscopo, G., & Roviello, A. (2025). Cryptocurrency in global dynamics: Analyzing the Crypto Volatility Index and financial markets with machine learning. *Physica A: Statistical Mechanics and its Applications*, 130770. <https://doi.org/10.1016/j.physa.2025.130770>.
- Lengyel, P., Pancsira, J., & Füzesi, I. (2025). Machine Learning Integration in Cryptocurrency Trading: A Systematic Review of Fintech Implications. <https://doi.org/10.21203/rs.3.rs-7411123/v1>.
- Mangla, N., Bhat, A., Avabratha, G., & Bhat, N. (2019). Bitcoin price prediction using machine learning. *International Journal of Information and Computing Science*, 6(5), 318-320.
- Mohammad Sharifi, A., Khalili Damghani, K., Abdi, S., & Sardar, S. (2021). Predicting Bitcoin price using a hybrid model of ARIMA and deep learning. *Industrial Management Studies*, 19(61), 127-146. (in persian).
- Mtiraoui, A., Boubaker, H., & BelKacem, L. (2023). A hybrid approach for forecasting bitcoin series. *Research in International Business and Finance*, 66, 102011. <https://doi.org/10.1016/j.ribaf.2023.102011>
- Nazareth, N., & Reddy, Y. V. R. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219, 119640. <https://doi.org/10.1016/j.eswa.2023.119640>
- Nazifi Naeini, M., Bakhshi Dastjerdi, R., & Hosseini Ghaffar, S. A. (2025). Trend analysis and Bitcoin price prediction: A comparative analysis of linear and nonlinear models. *Economic Research and Perspectives*, 25(4), 157-188. (in persian).
- Nigam, S. (2025). Forecasting time series using convolutional neural network with multiplicative neuron. *Applied Soft Computing*, 174, 112921. <https://doi.org/10.1016/j.asoc.2025.112921>.
- Omole, O., & Enke, D. (2025). Using machine and deep learning models, on-chain data, and technical analysis for predicting bitcoin price direction and magnitude. *Engineering Applications of Artificial Intelligence*, 154, 111086. <https://doi.org/10.1016/j.engappai.2025.111086>.

- Pabuçcu, H., Ongan, S., & Ongan, A. (2023). Forecasting the movements of Bitcoin prices: an application of machine learning algorithms. *arXiv preprint arXiv:2303.04642*. <https://doi.org/10.3934/QFE.2020031>.
- Parvini, N., Ahmadian, D., & Ballestra, L. V. (2025). Forecasting cryptocurrency prices using support vector regression enhanced by particle swarm optimization. *Computational Economics*, 66(4), 3167-3196. <https://doi.org/10.1007/s10614-024-10809-9>
- Pattnaik, D., Ray, S., & Raman, R. (2024). Applications of artificial intelligence and machine learning in the financial services industry: A bibliometric review. *Heliyon*, 10(1). <https://doi.org/10.1016/j.heliyon.2023.e23492>
- Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting cryptocurrency prices using LSTM, GRU, and bi-directional LSTM: a deep learning approach. *Fractal and Fractional*, 7(2), 203. <https://doi.org/10.3390/fractalfract7020203>
- Sari, Y., & Indrabudiman, A. (2024). The role of artificial intelligence (AI) in financial risk management. *Formosa Journal of Sustainable Research*, 3(9), 2073-2082. <https://doi.org/10.55927/fjsr.v3i9.11436>
- 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>.
- Simon, H. A. (1955). A behavioral model of rational choice. *The quarterly journal of economics*, 99-118.
- Siva, R., Subrahmanian, B., & Chaturya, K. (2024). Analyzing the machine learning methods to predict Bitcoin pricing. *World Journal of Advanced Research and Reviews*, 21(1), 1288-1294. <https://doi.org/10.30574/wjarr.2024.21.1.0074>.
- Ungar, K., & Stan, S. E. (2025). The Efficient Market Hypothesis Under Pressure from Behavioral Realities: An Empirical Perspective on Abnormal Returns. In International conference KNOWLEDGE-BASED ORGANIZATION (Vol. 31, No. 2, pp. 101-109). Nicolae Balcescu Land Forces Academy. <https://doi.org/10.2478/kbo-2025-0055>
- Wang, G. J., Ma, X. Y., & Wu, H. Y. (2020). Are stablecoins truly diversifiers, hedges, or safe havens against traditional cryptocurrencies as their name suggests? *Research in International Business and Finance*, 54, 101225. <https://doi.org/10.1016/j.ribaf.2020.101225>.
- Wang, S. W., & Huang, C. Y. (2026). A Hybrid SVR-Based Framework for Cryptocurrency Price Forecasting and Strategy Backtesting. *Applied Artificial Intelligence*, 40(1), 2612793. <https://doi.org/10.1080/08839514.2026.2612793>

پیوست

جدول ۱. نتایج مدل‌سازی پیش‌بینی قیمت بیت‌کوین (برحسب دلار)

MODEL	MSE	RMSE	MAE	MAPE	CORRELEATION	THEILS U
AR(1)	۳۳۶۲۸۲۰۰۶۱/۳۴	۵۷۹۸۹/۸۳	۴۸۵۸۱/۰۲۹۵	۶۴/۴۹	-۰/۰۴۵۴	۰/۶۴۰۶
ARIMA	۳۸۶۲۱۶۷۱۶۰/۶۹۵	۶۲۱۴۶/۳۴	۵۲۴۳۰/۳۰۶	۷۰/۲۹	-۰/۹۳۲۱	۰/۷۱۶۰
GARCH	۶۰۶۱۴۳۵۴۳۲	۲۴۶۱۹۹۸	۱۷۳۹۸۴۸	۳۹۲/۰۵	۰/۰۰۴۰	۰/۹۱۶۶
RF	۶۳۴۶۹۸۱۴۲/۰۸۸	۲۵۱۹۳/۲۱	۱۷۰۳۱/۳۷	۱۸/۹۷	۰/۸۸۸۵	۰/۲۰۱۰
SVR	۴۱۵۷۳۵۹/۳۶	۲۰۳۸/۹۶	۱۳۸۷/۵۴۷	۲/۱۱	۰/۹۹۸۰	۰/۰۱۳۹

XGBOOST	۵۲۶۷۴۳۰۲۱/۱۸۸	۲۲۹۵۰/۸۸	۱۵۱۲۰/۴۱	۱۶/۸۱	۰/۸۹۷۶	۰/۱۷۸۵
RNN	۵۲۴۸۳۰۴۰۱۲/۴۱	۷۲۴۴۵/۵۷	۶۵۲۰۰/۵۷	۹۸/۰۴	۰/۹۴۱۵	۰/۹۷۵۳
MLP	۴۷۸۰۵۸۹۷/۲۸	۶۹۱۴۴/۱۸	۵۸۰۱/۳۸	۱۰/۳۱	۰/۹۹۷۳	۰/۰۴۵۶
GRU	۵۰۰۷۹۱۳۴۷۱/۲۹	۷۰۷۶۶/۶۱۲۷	۶۳۳۳۰/۲۸	۹۴/۲۵	۰/۹۶۷۱	۰/۹۲۹۳
CNN	۹۵۱۸۰۴۶۵/۴۳	۹۷۵۶/۰۴۸	۷۸۶۴/۴۳	۱۱/۹۳	۰/۹۹۷۰	۰/۰۶۳۰
LSTM	۵۲۳۴۹۶۱۷۰/۳۱	۷۳۰۴۰/۸۷	۶۵۸۶۱/۸۲	۹۹/۳۹	۰/۱۷۴۳	۰/۹۹۲۲

مأخذ: یافته‌های پژوهش

جدول ۲. نتایج وقفه بهینه برای مدل ARIMA

AIC	وقفه بهینه
-۱۵۲۵۱/۷۸۰۱	(۱،۱)
-۱۵۲۵۰/۳۹۲۴	(۴،۱)
۱۵۲۶۱/۰۶۸۱	(۸،۱)
-۱۵۳۱۵/۰۷۴۳	(۱۴،۱)
-۱۵۳۱۳/۵۷۶۹	(۱۵،۱)

مأخذ: یافته‌های پژوهش

جدول ۳. نتایج وقفه بهینه مدل GARCH

AIC	وقفه بهینه
-۱۵۲۹۶/۲۱	(۲ و ۲)
-۱۱۶۸۰۴/۳۶	(۵ و ۳)
-۸۸۵۹/۱۰	(۵ و ۱)

مأخذ: یافته‌های پژوهش

جدول ۴. نتایج وقفه بهینه برای مدل AR

BIC	AIC	تعداد وقفه
-۱۵۲۴۳/۹۰۵۳	-۱۵۲۵۶/۷۳۸۳	۱
-۱۵۲۳۵/۵۶۳۳	-۱۵۲۵۴/۸۱۲۷	۲
-۱۵۲۲۸/۶۶۹۹	-۱۵۲۵۴/۳۳۵۹	۳
-۱۵۲۴۹/۲۹۴۴	-۱۵۲۵۶/۸۶۲۰	۴
-۱۵۲۱۷/۳۴۴۸	-۱۵۲۱۷/۸۴۳۷	۵

مأخذ: یافته‌های پژوهش

جدول ۵. نتایج پارامترهای بهینه یادگیری ماشین


مقدار بهینه	پارامتر	مدل
۲۰۴	n_estimators	RandomForest
۹۱	max_depth	
۱۰	min_samples_split	
۱	min_samples_leaf	
۰/۷۱۶۲۲	max_features	
۴/۱۲	C	SVR
۰/۱۶۰۹	Epsilon	
auto	Gamma	
linear	Kernel	
۵۴۴	n_estimators	XGBOOST
۲	max_depth	
۰/۰۳	learning_rate	
۰/۹۸	Subsample	
۰/۵۳۵۶	colsample_bytree	

مأخذ: یافته‌های پژوهش

جدول ۶. نتایج پارامترهای بهینه یادگیری عمیق

مدل	پارامتر	مقدار بهینه
MLP	hidden1	۴۹
	hidden2	۴۱
	Dropout	۰/۲
	learning_rate	۰/۰۰۳
	batch_size	۳۲
	Epochs	۵۳
RNN	rnn_units	۱۰۰
	Dropout	۰/۳۵
	learning_rate	۰/۰۰۶
	batch_size	۶۴
	Epochs	۱۰۴
	Early Stopping	۷۷
LSTM	lstm_units	۱۱۳
	Dropout	۰/۱
	learning_rate	۰/۰۰۰۸
	batch_size	۶۴
	Epochs	۵۳
	Filters	۳۱
CNN	dense_units	۳۳
	Dropout	۰/۲
	Lr	۰/۰۰۰۲
	batch_size	۶۴
	Epochs	۱۴۶
	Early Stopping	۲۸
GRU	gru_units	۱۰۵
	Dropout	۰/۳
	learning_rate	۰/۰۰۰۷
	batch_size	۶۴
	Epochs	۱۴۵
	Early Stopping	۴۸

مأخذ: یافته‌های پژوهش




نمودار ۱. نتایج انتخاب لگ براساس معیارهای آکائیک و شوارتز بیزین

SVR Prediction vs Actual (Original Scale - No Normalization)
RMSE = 2038.96, MAE = 1387.55



نمودار ۲. مقدار واقعی و پیش‌بینی شده قیمت بازار بیت‌کوین (برحسب دلار)



شکل ۱. نقشه حرارتی