



Design of a Digital Asset Pricing Model Based on Deep Reinforcement Learning in Cryptocurrency Markets

Ali Heydari^{1*}, Sara Niknam²

¹ Ph.D. in Financial Management, Kharazmi University, Tehran, Iran (Corresponding author), Email: ali.heidari@khu.ac.ir

² M.A. in Financial Management, Kharazmi University, Tehran, Iran

ARTICLE INFO

Article history:

Received:22/06/2025

Received in revised form:06/07/2025

Accepted:01/08/2025

Available online:16/08/2025

Keywords:

Digital Assets

Cryptocurrency Market

Deep Reinforcement Learning

Asset Pricing

Financial Artificial Intelligence

ABSTRACT

The rapid growth of cryptocurrency markets and the increasing role of digital assets in the global financial system have created new challenges in the valuation and pricing of these assets. Unlike traditional financial assets, cryptocurrencies lack clearly defined cash flows and conventional valuation criteria, and their prices are influenced by various factors, including market conditions, investor behavior, trading volume, and information-related variables. Therefore, developing innovative and intelligent models for pricing digital assets has become an important research issue. This study aims to design a digital asset pricing model using deep reinforcement learning in cryptocurrency markets. The primary research question is whether deep reinforcement learning can provide an efficient and accurate framework for pricing digital assets. In addition, the study examines the following hypotheses: the application of deep reinforcement learning improves the accuracy of digital asset pricing, enhances the model's adaptability to changing market conditions, and outperforms traditional asset pricing approaches.

From the perspective of purpose, this research is applied, while methodologically it is quantitative and model-based. Historical data related to cryptocurrency prices, trading volumes, and market indicators were collected and analyzed using deep reinforcement learning algorithms. The performance of the proposed model was evaluated through forecasting error metrics and efficiency assessment indicators. The findings indicate that the proposed model is capable of identifying complex and nonlinear patterns in cryptocurrency markets and, through continuous learning from the market environment, provides greater pricing accuracy than traditional methods. Furthermore, the results suggest that deep reinforcement learning can serve as an effective tool for financial decision-making and investment management in cryptocurrency markets. The study contributes to the growing literature on artificial intelligence in finance and provides a practical framework for improving digital asset valuation in highly dynamic financial environments.

Article Type: Research Paper

Journal of Intelligent Financial Management,
2025, Vol. 1, No.2, pp. 27- 41



Publish by:

Tolou-e Binsh-e Ayandeh Scientific Institute

©Authors

<https://doi.org/10.25843/JIFM.2025.8563.22284>

Cite: Heydari,A and Niknam,S . (2025). Design of a Digital Asset Pricing Model Based on Deep Reinforcement Learning in Cryptocurrency Markets. *Journal of Intelligent Financial Management*, 1(2), 27-41.



طراحی مدل قیمت گذاری دارایی های دیجیتال با استفاده از یادگیری تقویتی عمیق در بازار رمزارزها

علی حیدری^{۱*}، سارا نیکنام^۲

۱ و * - دکتری مدیریت مالی، دانشگاه خوارزمی، تهران، ایران (نویسنده مسئول)، ایمیل نویسنده مسئول: ali.heidari@khu.ac.ir

۲ - کارشناسی ارشد مدیریت مالی، دانشگاه خوارزمی، تهران، ایران

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۴/۰۱

تاریخ بازنگری: ۱۴۰۴/۰۴/۱۵

تاریخ پذیرش: ۱۴۰۴/۰۵/۱۰

تاریخ انتشار: ۱۴۰۴/۰۵/۲۵

کلیدواژه‌ها:

دارایی های دیجیتال

بازار رمزارزها

یادگیری عمیق

یادگیری تقویتی عمیق

قیمت گذاری دارایی

چکیده

رشد سریع بازار رمزارزها و افزایش نقش دارایی‌های دیجیتال در نظام مالی جهانی، چالش‌های جدیدی را در زمینه ارزش گذاری و قیمت‌گذاری این دارایی‌ها ایجاد کرده است. برخلاف دارایی‌های مالی سنتی، رمزارزها فاقد جریان‌های نقدی مشخص و معیارهای متعارف ارزش گذاری هستند و قیمت آن‌ها تحت تأثیر عوامل متعددی از جمله شرایط بازار، رفتار سرمایه‌گذاران، حجم معاملات و متغیرهای اطلاعاتی قرار می‌گیرد. از این رو، طراحی مدل‌های نوین و هوشمند برای قیمت‌گذاری این دارایی‌ها به یکی از مسائل مهم پژوهشی تبدیل شده است. پژوهش حاضر با هدف طراحی مدل قیمت‌گذاری دارایی‌های دیجیتال با استفاده از یادگیری تقویتی عمیق در بازار رمزارزها انجام شده است. سؤال اصلی پژوهش این است که آیا یادگیری تقویتی عمیق می‌تواند مدلی کارآمد و دقیق برای قیمت‌گذاری دارایی‌های دیجیتال ارائه دهد؟ همچنین این پژوهش به بررسی این فرضیه‌ها می‌پردازد که استفاده از یادگیری تقویتی عمیق موجب بهبود دقت قیمت‌گذاری دارایی‌های دیجیتال می‌شود، قابلیت سازگاری مدل با شرایط متغیر بازار را افزایش می‌دهد و عملکردی بهتر از روش‌های سنتی قیمت‌گذاری ارائه می‌کند. این تحقیق از نظر هدف کاربردی و از نظر روش، کمی و مبتنی بر مدل‌سازی است. داده‌های تاریخی مربوط به قیمت، حجم معاملات و شاخص‌های بازار رمزارزها جمع‌آوری شده و با استفاده از الگوریتم‌های یادگیری تقویتی عمیق مورد تحلیل قرار گرفته‌اند. برای ارزیابی عملکرد مدل نیز شاخص‌های خطای پیش‌بینی و معیارهای سنجش کارایی مورد استفاده قرار گرفته است. نتایج پژوهش نشان می‌دهد که مدل پیشنهادی قادر است الگوهای پیچیده و غیرخطی بازار رمزارزها را شناسایی کرده و با یادگیری مستمر از محیط بازار، دقت بیشتری در قیمت‌گذاری دارایی‌های دیجیتال نسبت به روش‌های سنتی ارائه دهد. همچنین یافته‌ها بیانگر آن است که یادگیری تقویتی عمیق می‌تواند به‌عنوان ابزاری مؤثر در تصمیم‌گیری‌های مالی و مدیریت سرمایه‌گذاری در بازار رمزارزها مورد استفاده قرار گیرد.

نوع مقاله: پژوهشی



© نویسندگان

استاد: حیدری، علی و نیکنام، سارا. (۱۴۰۴). طراحی مدل قیمت گذاری دارایی های دیجیتال با استفاده از یادگیری تقویتی عمیق در بازار رمزارزها. *مدیریت مالی هوشمند*، ۱(۲)، ۲۷-۴۱.

نشریه مدیریت مالی هوشمند، ۱۴۰۴، دوره ۱، شماره ۲، صفحه ۲۷-۴۱.

ناشر: موسسه علمی طلوع بینش آینده

<https://doi.org/10.25843/JIFM.2025.8563.22284>

۱- مقدمه

ظهور فناوری بلاک چین و گسترش دارایی‌های دیجیتال در دهه اخیر، ساختار بازارهای مالی را با تحولاتی بنیادین مواجه ساخته است. رمزارزها به‌عنوان مهم‌ترین مصداق دارایی‌های دیجیتال، با ایجاد بستری غیرمتمرکز برای انتقال و ذخیره ارزش، توانسته‌اند توجه سرمایه‌گذاران، نهادهای مالی و پژوهشگران را به خود جلب کنند. از زمان معرفی بیت‌کوین در سال ۲۰۰۹، بازار رمزارزها رشد چشمگیری را تجربه کرده و ارزش بازار آن در مقاطع مختلف به هزاران میلیارد دلار رسیده است. با وجود این رشد سریع، ماهیت نوظهور، نوسانات شدید قیمتی، عدم وجود ارزش ذاتی قابل اندازه‌گیری و تأثیرپذیری بالا از عوامل رفتاری و اطلاعاتی، موجب شده است که قیمت‌گذاری دارایی‌های دیجیتال به یکی از چالش‌های اساسی در حوزه مالی و اقتصاد تبدیل شود. برخلاف دارایی‌های سنتی مانند سهام و اوراق قرضه که چارچوب‌های نظری نسبتاً تثبیت‌شده‌ای برای ارزش‌گذاری آن‌ها وجود دارد، در بازار رمزارزها هنوز اجماع مشخصی درباره مدل‌های مناسب قیمت‌گذاری مشاهده نمی‌شود و همین امر ضرورت توسعه رویکردهای نوین و هوشمند را بیش از پیش آشکار ساخته است.

نظریه‌های کلاسیک مالی عمدتاً بر مفروضاتی نظیر عقلانیت کامل سرمایه‌گذاران، کارایی بازارها و توزیع نرمال بازدهی‌ها استوار هستند. مدل قیمت‌گذاری دارایی‌های سرمایه‌ای، نظریه آربیتراژ و سایر الگوهای متعارف ارزش‌گذاری در محیط‌هایی طراحی شده‌اند که اطلاعات نسبتاً متقارن بوده و رفتار بازار از الگوهای قابل پیش‌بینی‌تری تبعیت می‌کند. با این حال، بازار رمزارزها دارای ویژگی‌هایی نظیر معاملات بیست‌وچهارساعته، نقدشوندگی متغیر، تأثیرپذیری شدید از شبکه‌های اجتماعی، عدم قطعیت مقرراتی و رفتارهای سفته‌بازانه گسترده است که موجب می‌شود بسیاری از مفروضات مدل‌های سنتی در این بازار نقض شوند. مطالعات متعدد نشان داده‌اند که بازدهی و نوسانات رمزارزها از الگوهای غیرخطی، پیچیده و پویا پیروی می‌کنند و در بسیاری از موارد امکان مدل‌سازی آن‌ها با روش‌های آماری متعارف محدود است. (Millea, 2021) از این رو پژوهشگران به سمت استفاده از روش‌های مبتنی بر هوش مصنوعی و یادگیری ماشین برای تحلیل و پیش‌بینی رفتار این بازار حرکت کرده‌اند.

در سال‌های اخیر، یادگیری عمیق به‌عنوان یکی از پیشرفته‌ترین شاخه‌های هوش مصنوعی توانسته است قابلیت‌های چشمگیری در استخراج الگوهای پنهان از داده‌های بزرگ و پیچیده ارائه دهد. شبکه‌های عصبی عمیق با بهره‌گیری از لایه‌های متعدد پردازشی قادرند روابط غیرخطی میان متغیرها را شناسایی کرده و عملکردی فراتر از روش‌های سنتی در پیش‌بینی و طبقه‌بندی داده‌ها داشته باشند. در حوزه مالی نیز کاربرد مدل‌هایی نظیر شبکه‌های عصبی بازگشتی، حافظه بلندمدت کوتاه‌مدت (LSTM)، شبکه‌های کانولوشنی و مدل‌های ترکیبی رشد قابل‌توجهی یافته است. مطالعات مروری اخیر نشان می‌دهد که یادگیری عمیق در حوزه رمزارزها در موضوعاتی همچون پیش‌بینی قیمت، مدیریت پرتفوی، تحلیل حساب‌های قیمتی، شناسایی معاملات غیرعادی و ارزیابی ریسک کاربرد گسترده‌ای پیدا کرده است. (Fang et al., 2024) با این وجود، بخش عمده این پژوهش‌ها بر پیش‌بینی قیمت تمرکز داشته‌اند و کمتر به مسئله تصمیم‌گیری پویا و قیمت‌گذاری دارایی در شرایط عدم قطعیت پرداخته‌اند.

در این میان، یادگیری تقویتی به‌عنوان رویکردی متفاوت از یادگیری نظارت‌شده، امکان تصمیم‌گیری هوشمند در محیط‌های پویا و نامطمئن را فراهم می‌سازد. در یادگیری تقویتی، عامل هوشمند از طریق تعامل مستمر با محیط، دریافت پاداش و اصلاح سیاست‌های تصمیم‌گیری خود، به تدریج راهبردی بهینه را برای دستیابی به اهداف مشخص می‌آموزد. ترکیب یادگیری تقویتی با شبکه‌های عصبی عمیق منجر به شکل‌گیری یادگیری تقویتی عمیق شده است که توانایی بالایی در حل مسائل پیچیده با فضای حالت گسترده دارد. این فناوری در حوزه‌های متنوعی از جمله بازی‌های رایانه‌ای، رباتیک، مدیریت انرژی و اخیراً بازارهای مالی مورد استفاده قرار گرفته است. پژوهش‌های اخیر نشان داده‌اند که الگوریتم‌های یادگیری تقویتی عمیق قادرند در محیط‌های مالی پیچیده، راهبردهای معاملاتی مؤثری ایجاد کرده و در برخی موارد عملکردی بهتر از مدل‌های سنتی ارائه دهند (Yu, 2024; Millea, 2021).

بازار رمزارزها به دلیل نوسانات شدید، ساختار غیرایستا و حجم عظیم داده‌های تولیدشده، محیطی مناسب برای کاربرد یادگیری تقویتی عمیق محسوب می‌شود. در چنین بازاری، قیمت دارایی‌ها تحت تأثیر مجموعه‌ای از عوامل اقتصادی، فناوری، روان‌شناختی و اجتماعی قرار دارد و روابط میان این عوامل به‌صورت مستمر در حال تغییر است. الگوریتم‌های یادگیری تقویتی عمیق می‌توانند با یادگیری مستقیم از داده‌های بازار، الگوهای پویای قیمت را شناسایی کرده و سیاست‌هایی را برای ارزش‌گذاری و تصمیم‌گیری بهینه استخراج کنند. برخلاف مدل‌های ایستا که معمولاً بر مجموعه‌ای محدود از متغیرها متکی هستند، این الگوریتم‌ها قادرند هم‌زمان اطلاعات متعددی شامل داده‌های قیمتی، حجم معاملات، شاخص‌های تکنیکال، احساسات سرمایه‌گذاران و متغیرهای کلان اقتصادی را پردازش کنند. مطالعات تجربی اخیر نیز نشان داده‌اند که چارچوب‌های مبتنی بر یادگیری تقویتی عمیق در معاملات رمزارزها توانسته‌اند عملکردی مطلوب‌تر از شاخص‌های مرجع بازار ارائه دهند و بازدهی تعدیل‌شده بر مبنای ریسک بالاتری ایجاد کنند (Gort et al., 2022; Lucarelli & Borrotti, 2024).

یکی از مهم‌ترین چالش‌های موجود در قیمت‌گذاری دارایی‌های دیجیتال، نبود جریان‌های نقدی قابل پیش‌بینی و معیارهای ارزش‌گذاری سنتی است. در بازار سهام، سرمایه‌گذاران می‌توانند از شاخص‌هایی نظیر سودآوری شرکت، جریان نقدی آزاد و ارزش دفتری برای تعیین ارزش ذاتی استفاده کنند؛ اما در مورد بسیاری از رمزارزها چنین معیارهایی وجود ندارد یا از اهمیت کمتری برخوردار است. در نتیجه، قیمت‌ها بیش از آنکه بر مبنای بنیادی استوار باشند، از انتظارات سرمایه‌گذاران، میزان پذیرش فناوری، ویژگی‌های شبکه و شرایط بازار تأثیر می‌پذیرند. این ویژگی موجب می‌شود فرآیند قیمت‌گذاری به مسئله‌ای پیچیده و چندبعدی تبدیل شود که نیازمند مدل‌هایی با توانایی یادگیری تطبیقی و پویا است. یادگیری تقویتی عمیق با قابلیت سازگاری مداوم با شرایط متغیر بازار می‌تواند چارچوبی مناسب برای پاسخ به این چالش فراهم آورد.

علاوه بر این، توسعه اکوسیستم مالی غیرمتمرکز، قراردادهای هوشمند و بازارسازهای خودکار موجب شده است که مفهوم قیمت‌گذاری دارایی‌های دیجیتال ابعاد جدیدی پیدا کند. پژوهش‌های اخیر نشان می‌دهند که استفاده از یادگیری تقویتی عمیق در سازوکارهای بازارسازی و تأمین نقدینگی می‌تواند به بهبود کارایی بازار و کاهش انحرافات قیمتی منجر شود. در این چارچوب، عامل هوشمند نه تنها به پیش‌بینی روند قیمت می‌پردازد، بلکه به‌صورت فعال در فرآیند کشف قیمت مشارکت می‌کند و راهبردهای بهینه‌ای برای مدیریت ریسک و تخصیص منابع اتخاذ می‌نماید (Lim, 2024).

با وجود پیشرفت‌های قابل توجه در کاربرد یادگیری تقویتی عمیق در معاملات مالی، هنوز خلأهای پژوهشی مهمی در زمینه طراحی مدل‌های قیمت‌گذاری دارایی‌های دیجیتال وجود دارد. بخش عمده مطالعات موجود بر تولید سیگنال‌های معاملاتی یا بهینه‌سازی پرتفوی متمرکز بوده‌اند و کمتر به توسعه چارچوبی جامع برای برآورد ارزش و قیمت دارایی‌های دیجیتال پرداخته‌اند. همچنین بسیاری از مدل‌های ارائه‌شده با مشکلاتی نظیر بیش‌برازش، حساسیت به شرایط بازار و محدودیت در تعمیم‌پذیری مواجه هستند. از این‌رو طراحی مدلی که بتواند ضمن بهره‌گیری از قابلیت‌های یادگیری تقویتی عمیق، سازوکاری پایدار و قابل اتکا برای قیمت‌گذاری دارایی‌های دیجیتال ارائه کند، از اهمیت نظری و کاربردی بالایی برخوردار است (Gort et al., 2022).

بر این اساس، پژوهش حاضر با هدف طراحی مدل قیمت‌گذاری دارایی‌های دیجیتال مبتنی بر یادگیری تقویتی عمیق در بازار رمزارزها انجام می‌شود. این پژوهش تلاش دارد با ترکیب قابلیت‌های یادگیری عمیق در استخراج ویژگی‌های پیچیده بازار و توانایی یادگیری تقویتی در تصمیم‌گیری پویا، چارچوبی نوین برای ارزش‌گذاری دارایی‌های دیجیتال ارائه دهد. انتظار می‌رود نتایج این مطالعه علاوه بر توسعه ادبیات نظری حوزه مالی هوشمند، بتواند ابزار مناسبی برای سرمایه‌گذاران، مدیران دارایی، صرافی‌های رمزارزی و سیاست‌گذاران مالی در تحلیل و ارزیابی ارزش دارایی‌های دیجیتال فراهم سازد و زمینه را برای توسعه نسل جدیدی از مدل‌های مالی مبتنی بر هوش مصنوعی در اقتصاد دیجیتال مهیا کند.

۲- مبانی نظری

بازارهای مالی در دهه‌های اخیر تحت تأثیر تحولات فناورانه، به‌ویژه گسترش فناوری بلاک‌چین و دارایی‌های دیجیتال، دچار تغییرات بنیادین شده‌اند. دارایی‌های دیجیتال به‌عنوان نوعی از دارایی‌های مبتنی بر فناوری رمزنگاری، امکان انتقال، ذخیره و ثبت مالکیت را بدون نیاز به نهادهای متمرکز فراهم می‌کنند. این دارایی‌ها برخلاف دارایی‌های سنتی، ماهیت فیزیکی ندارند و ارزش آن‌ها عمدتاً از طریق تعامل عرضه و تقاضا، پذیرش شبکه‌ای، انتظارات سرمایه‌گذاران و عوامل رفتاری تعیین می‌شود. ظهور بیت‌کوین در سال ۲۰۰۹ نقطه آغاز رسمی این تحول بود و پس از آن هزاران رمزارز با کاربردهای متنوع وارد بازار شدند. ویژگی‌هایی مانند غیرمتمرکز بودن، شفافیت نسبی تراکنش‌ها، محدودیت عرضه در برخی

رمزارزها و وابستگی شدید به فناوری، این بازار را به یکی از پیچیده‌ترین و در عین حال جذاب‌ترین حوزه‌های مالی تبدیل کرده است (Corbet et al., 2022).

قیمت‌گذاری دارایی‌ها یکی از بنیادی‌ترین و پرکاربردترین حوزه‌های مالی مدرن محسوب می‌شود و هدف اصلی آن تبیین رابطه میان ریسک و بازده مورد انتظار دارایی‌ها است. در نظریه‌های مالی کلاسیک، فرض بر این است که سرمایه‌گذاران رفتاری عقلایی دارند، اطلاعات به‌سرعت و بدون هزینه در بازار منتشر می‌شود و قیمت‌ها تمامی اطلاعات موجود را منعکس می‌کنند. این مفروضات مبنای شکل‌گیری نظریه بازار کارا و مدل‌های سنتی قیمت‌گذاری دارایی‌ها بوده‌اند (Fama, 1970).

در این چارچوب، مدل قیمت‌گذاری دارایی‌های سرمایه‌ای (CAPM) که توسط شارپ (1964)، لینتر (1965) و موسین (1966) توسعه یافت، بیان می‌کند که بازده مورد انتظار یک دارایی تنها تابعی از ریسک سیستماتیک آن است. بر اساس این مدل، ریسک غیرسیستماتیک از طریق متنوع‌سازی پرتفوی حذف می‌شود و تنها ریسکی که باید توسط بازار پاداش داده شود، ریسک سیستماتیک اندازه‌گیری شده از طریق ضریب بتا است. CAPM برای دهه‌ها به‌عنوان یکی از مهم‌ترین ابزارهای ارزیابی دارایی‌ها، مدیریت سرمایه‌گذاری و محاسبه هزینه سرمایه مورد استفاده قرار گرفته است (Sharpe, 1964; Lintner, 1965).

با این حال، شواهد تجربی نشان داده‌اند که عوامل متعددی فراتر از بتا می‌توانند تغییرات بازده دارایی‌ها را توضیح دهند. در پاسخ به این محدودیت، نظریه قیمت‌گذاری آربیتراژ توسط راس (1976) ارائه شد. این نظریه بر خلاف CAPM، بازده دارایی‌ها را تحت تأثیر مجموعه‌ای از عوامل کلان اقتصادی و ریسک‌های سیستماتیک متعدد می‌داند. در APT فرض می‌شود که در بازارهای رقابتی فرصت‌های آربیتراژ پایدار وجود ندارد و قیمت دارایی‌ها به‌گونه‌ای تعدیل می‌شوند که بازده مورد انتظار آن‌ها با حساسیت نسبت به عوامل ریسک اقتصادی تعیین شود (Ross, 1976). انعطاف‌پذیری بالاتر APT موجب شده است که این مدل در تحلیل بازارهای پیچیده‌تر و چندعاملی کاربرد گسترده‌تری پیدا کند.

علاوه بر CAPM و APT، مدل‌های چندعاملی نظیر مدل سه‌عاملی فاما و فرنچ نیز توسعه یافتند که عواملی همچون اندازه شرکت و نسبت ارزش دفتری به ارزش بازار را در تبیین بازده سهام دخیل می‌دانند. (Fama & French, 1993) این مدل‌ها نشان دادند که ساختار ریسک در بازارهای مالی پیچیده‌تر از آن است که صرفاً با یک عامل سیستماتیک قابل توضیح باشد.

با وجود اهمیت و کاربرد گسترده این مدل‌ها، تمامی آن‌ها بر مجموعه‌ای از مفروضات محدودکننده استوار هستند؛ از جمله نرمال بودن توزیع بازده‌ها، ثبات ساختار بازار، نبود هزینه‌های معاملاتی، نقدشوندگی کافی دارایی‌ها و عقلانیت کامل سرمایه‌گذاران. در بازارهای نوظهور و به‌ویژه بازار رمزارزها، بسیاری از این مفروضات به‌طور جدی نقض می‌شوند. مطالعات نشان داده‌اند که بازده رمزارزها اغلب دارای چولگی، کشیدگی زیاد، نوسانات شدید و رفتارهای غیرخطی هستند که با توزیع نرمال سازگاری ندارند (Baur, Hong, & Lee, 2018). همچنین این بازارها تحت تأثیر عوامل رفتاری، احساسات سرمایه‌گذاران، اخبار شبکه‌های اجتماعی، عدم تقارن اطلاعاتی و تغییرات سریع فناوری قرار دارند که موجب فاصله گرفتن آن‌ها از فروض کلاسیک بازارهای کارا می‌شود (Corbet et al., 2020).

علاوه بر این، ویژگی‌هایی همچون معاملات ۲۴ ساعته، نبود نهادهای نظارتی متمرکز، تغییرات سریع نقدشوندگی و وابستگی شدید به انتظارات سرمایه‌گذاران باعث شده است که مدل‌های سنتی قیمت‌گذاری در توضیح رفتار قیمتی دارایی‌های دیجیتال با محدودیت‌های قابل توجهی مواجه شوند. از این‌رو، پژوهشگران در سال‌های اخیر به سمت توسعه مدل‌های جایگزین مبتنی بر مالی رفتاری، یادگیری ماشین و روش‌های غیرخطی حرکت کرده‌اند تا بتوانند پویایی‌های پیچیده بازار رمزارزها را بهتر تبیین کنند (Liu & Tsyvinski, 2021). در نتیجه، اگرچه CAPM و APT همچنان چارچوب‌های نظری مهمی برای درک رابطه ریسک و بازده محسوب می‌شوند، اما کاربرد آن‌ها در بازار رمزارزها نیازمند تعدیل مفروضات و در نظر گرفتن عوامل جدید اقتصادی، فناورانه و رفتاری است.

بازار رمزارزها به‌عنوان یک بازار نوظهور، دارای ویژگی‌هایی مانند نوسانات بسیار شدید، نبود ارزش ذاتی مشخص، نقدشوندگی غیر یکنواخت و وابستگی شدید به اخبار و احساسات است. مطالعات تجربی نشان داده‌اند که بازده رمزارزها دارای چولگی و کشیدگی بالا بوده و از الگوهای غیرخطی پیروی می‌کند. همچنین این بازار نسبت به شوک‌های اطلاعاتی بسیار حساس است و واکنش‌های بیش‌ازحد سرمایه‌گذاران در آن مشاهده می‌شود (Liu & Tsyvinski, 2021). این ویژگی‌ها موجب شده است که نظریه بازار کارا نیز در توضیح رفتار رمزارزها با محدودیت مواجه شود. بر اساس فرضیه بازار کارا، قیمت‌ها باید تمام اطلاعات موجود را منعکس کنند، اما شواهد نشان می‌دهد که در بازار رمزارزها فرصت‌های آربیتراژ و ناکارایی‌های موقت به‌طور مکرر رخ می‌دهد.

در کنار نظریه‌های کلاسیک، مالی رفتاری نیز تلاش کرده است رفتار غیرعقلایی سرمایه‌گذاران را توضیح دهد. در این رویکرد، عواملی مانند بیش‌اعتمادی، رفتار گله‌ای، ترس از دست دادن و واکنش بیش‌ازحد به اخبار نقش مهمی در شکل‌گیری قیمت‌ها دارند. در بازار رمزارزها، این عوامل بسیار برجسته‌تر از بازارهای سنتی هستند، زیرا سرمایه‌گذاران خرد سهم بالایی از معاملات را تشکیل می‌دهند و اطلاعات اغلب از طریق شبکه‌های اجتماعی منتشر می‌شود (Ante, 2023).

در سال‌های اخیر، رشد داده‌های بزرگ و پیچیدگی بازارهای مالی موجب شده است که روش‌های اقتصادسنجی سنتی جای خود را به رویکردهای مبتنی بر داده و هوش مصنوعی بدهند. یادگیری ماشین به‌عنوان یکی از مهم‌ترین شاخه‌های هوش مصنوعی، مجموعه‌ای از الگوریتم‌ها را شامل می‌شود که قادرند بدون برنامه‌ریزی صریح، از داده‌ها الگو استخراج کنند. این روش‌ها در حوزه‌های مختلف مالی از جمله پیش‌بینی قیمت، مدیریت ریسک، تشخیص تقلب و بهینه‌سازی پرتفوی کاربرد گسترده‌ای یافته‌اند (Bhatia & Chatterjee, 2024).

یادگیری عمیق یکی از پیشرفته‌ترین شاخه‌های یادگیری ماشین است که بر مبنای شبکه‌های عصبی مصنوعی چندلایه توسعه یافته و توانایی استخراج الگوهای پیچیده از حجم عظیمی از داده‌ها را دارد. برخلاف روش‌های سنتی یادگیری ماشین که اغلب نیازمند استخراج دستی ویژگی‌ها هستند، مدل‌های یادگیری عمیق قادرند به‌صورت خودکار ویژگی‌های معنادار را از داده‌های خام شناسایی و یاد بگیرند. این قابلیت موجب شده است که یادگیری عمیق در حوزه‌های مختلف از جمله پردازش زبان طبیعی، بینایی ماشین، تشخیص گفتار و به‌ویژه پیش‌بینی سری‌های زمانی مالی کاربرد گسترده‌ای پیدا کند (LeCun et al., 2015).

یکی از مهم‌ترین مزایای یادگیری عمیق، توانایی آن در مدل‌سازی روابط پیچیده، غیرخطی و پویای میان متغیرها است. بازارهای مالی، به‌ویژه بازار رمزارزها، تحت تأثیر عوامل متعدد اقتصادی، فناوری، روان‌شناختی و اجتماعی قرار دارند که تعامل میان آن‌ها اغلب غیرخطی و بسیار پیچیده است. در چنین شرایطی، مدل‌های آماری سنتی و حتی بسیاری از الگوریتم‌های کلاسیک یادگیری ماشین با محدودیت‌هایی در شناسایی الگوهای پنهان مواجه می‌شوند، در حالی که شبکه‌های عمیق می‌توانند این روابط را با دقت بیشتری استخراج و مدل‌سازی کنند (Goodfellow et al., 2016).

در میان معماری‌های مختلف یادگیری عمیق، شبکه‌های عصبی بازگشتی Recurrent Neural Networks یا RNN از نخستین مدل‌هایی بودند که برای تحلیل داده‌های دنباله‌ای و سری‌های زمانی مورد استفاده قرار گرفتند. این شبکه‌ها از طریق حفظ اطلاعات گذشته در ساختار داخلی خود، امکان مدل‌سازی وابستگی‌های زمانی را فراهم می‌کنند. با این حال، RNN‌های سنتی در مواجهه با وابستگی‌های بلندمدت با مشکل ناپدید شدن یا انفجار گرادیان روبرو هستند که توانایی یادگیری آن‌ها را کاهش می‌دهد (Bengio et al., 1994).

برای رفع این محدودیت، معماری حافظه بلندمدت کوتاه‌مدت Long Short-Term Memory یا LSTM معرفی شد که با بهره‌گیری از سازوکار دروازه‌های حافظه، امکان حفظ و انتقال اطلاعات در بازه‌های زمانی طولانی‌تر را فراهم می‌کند (Hochreiter & Schmidhuber, 1997). به دلیل توانایی بالای LSTM در شناسایی روندها و الگوهای زمانی پیچیده، این مدل به یکی از پرکاربردترین ابزارها در پیش‌بینی قیمت سهام، نرخ ارز و رمزارزها تبدیل شده است. مطالعات متعدد نشان داده‌اند که LSTM در بسیاری از موارد عملکرد بهتری نسبت به مدل‌های آماری سنتی مانند ARIMA و GARCH ارائه می‌دهد (Fischer & Krauss, 2018).

در سال‌های اخیر، معماری‌های مبتنی بر مکانیزم توجه و به‌ویژه مدل‌های ترنسفورمر تحول قابل توجهی در تحلیل داده‌های توالی‌محور ایجاد کرده‌اند. برخلاف شبکه‌های بازگشتی که داده‌ها را به‌صورت ترتیبی پردازش می‌کنند، ترنسفورمرها قادرند وابستگی‌های کوتاه‌مدت و بلندمدت را به‌صورت همزمان بررسی کرده و اهمیت نسبی هر بخش از داده را از طریق مکانیزم توجه تعیین کنند (Vaswani et al., 2017). این ویژگی باعث افزایش دقت پیش‌بینی، کاهش زمان آموزش و بهبود مقیاس‌پذیری مدل‌ها در مواجهه با داده‌های حجیم شده است.

کاربرد یادگیری عمیق در بازار رمزارزها از اهمیت ویژه‌ای برخوردار است؛ زیرا این بازار دارای ویژگی‌هایی نظیر نوسانات شدید، حجم بالای داده‌های لحظه‌ای، رفتار غیرخطی، عدم ایستایی سری‌های زمانی و حساسیت بالا به اخبار و احساسات سرمایه‌گذاران است. چنین ویژگی‌هایی موجب می‌شود که فرضیات بسیاری از مدل‌های کلاسیک مالی و آماری نقض شود. در مقابل، مدل‌های یادگیری عمیق به دلیل انعطاف‌پذیری بالا و توانایی استخراج الگوهای پنهان از داده‌های پیچیده، عملکرد مناسبی در پیش‌بینی روند قیمت رمزارزها از خود نشان داده‌اند (Fang et al., 2024).

علاوه بر داده‌های قیمتی و معاملات، پژوهش‌های اخیر نشان داده‌اند که ترکیب مدل‌های یادگیری عمیق با داده‌های حاصل از شبکه‌های اجتماعی، اخبار مالی، شاخص‌های احساسات بازار و داده‌های درون‌زنجیره‌ای می‌تواند دقت پیش‌بینی را به میزان قابل توجهی افزایش دهد. این رویکردهای چندمنبعی امکان درک بهتر رفتار سرمایه‌گذاران و شناسایی تغییرات ناگهانی بازار را فراهم می‌کنند و به همین دلیل به یکی از مهم‌ترین حوزه‌های تحقیقاتی در زمینه پیش‌بینی قیمت رمزارزها تبدیل شده‌اند (Nti et al., 2020; Fang et al., 2024).

در مجموع، یادگیری عمیق با ارائه ابزارهایی قدرتمند برای استخراج الگوهای پیچیده و مدل‌سازی روابط غیرخطی، توانسته است محدودیت‌های بسیاری از روش‌های سنتی پیش‌بینی مالی را برطرف کند. پیشرفت معماری‌هایی مانند LSTM، GRU و Transformer موجب شده است که این فناوری به یکی از مؤثرترین رویکردها در تحلیل و پیش‌بینی بازارهای مالی مدرن، به‌ویژه بازار رمزارزها، تبدیل شود.

با وجود موفقیت یادگیری عمیق در پیش‌بینی، این روش‌ها ذاتاً ماهیت ایستا دارند و برای تصمیم‌گیری پویا طراحی نشده‌اند. در واقع، پیش‌بینی قیمت به‌تنهایی برای سرمایه‌گذاری کافی نیست، بلکه نیاز به اتخاذ تصمیم بهینه در شرایط متغیر بازار وجود دارد. این مسئله موجب شده است که یادگیری تقویتی به‌عنوان یک چارچوب تصمیم‌گیری پویا مورد توجه قرار گیرد.

یادگیری تقویتی مدلی است که در آن یک عامل هوشمند از طریق تعامل با محیط و دریافت پاداش، یاد می‌گیرد که چگونه تصمیم‌های بهینه اتخاذ کند. این فرآیند معمولاً به‌صورت یک فرآیند تصمیم‌گیری مارکوف مدل‌سازی می‌شود. در این چارچوب، عامل در هر وضعیت یک عمل انجام می‌دهد و بر اساس آن پاداش دریافت می‌کند. هدف عامل، بیشینه‌سازی مجموع پاداش‌های بلندمدت است (Sutton & Barto, 2018).

ترکیب یادگیری عمیق و یادگیری تقویتی منجر به شکل‌گیری یادگیری تقویتی عمیق شده است. در این رویکرد، شبکه‌های عصبی عمیق برای تقریب تابع ارزش یا سیاست استفاده می‌شوند. الگوریتم‌هایی مانند Deep Q-Network (DQN)، Double DQN، Proximal Policy Optimization (PPO) و Deep Deterministic Policy Gradient (DDPG) از مهم‌ترین روش‌های این حوزه هستند. این الگوریتم‌ها توانسته‌اند مسائل پیچیده با فضای حالت بزرگ را حل کنند (Mnih et al., 2015; Lillicrap et al., 2016).

در حوزه مالی، یادگیری تقویتی عمیق به‌طور گسترده در معاملات الگوریتمی، مدیریت پرتفوی و تصمیم‌گیری سرمایه‌گذاری استفاده شده است. این مدل‌ها برخلاف روش‌های سنتی، به‌صورت پویا با شرایط بازار سازگار می‌شوند و می‌توانند استراتژی‌های معاملاتی تطبیقی ایجاد کنند. در بازارهای پرنوسان مانند رمزارزها، این ویژگی اهمیت بسیار زیادی دارد (Moody et al., 2022).

در سال‌های اخیر، پژوهش‌های متعددی به بررسی کاربرد یادگیری تقویتی در بازار رمزارزها پرداخته‌اند. Lucarelli و Borrotti (2020) نشان دادند که استفاده از Q-learning در مدیریت پرتفوی رمزارزی می‌تواند عملکرد بهتری نسبت به روش‌های سنتی داشته باشد. Zhang et al. (2020) نیز بیان کردند که مدل‌های یادگیری تقویتی در تخصیص دارایی‌های دیجیتال قادر به بهبود نسبت بازده به ریسک هستند. همچنین Gort et al. (2022) به مسئله مهم بیش‌برازش در مدل‌های DRL اشاره کرده و نشان دادند که بسیاری از نتایج مثبت ممکن است ناشی از خطاهای بک‌تست باشد.

در ادامه این مسیر، پژوهش‌های جدیدتر از الگوریتم‌هایی مانند PPO و SAC برای بهینه‌سازی معاملات رمزارزی استفاده کرده‌اند. نتایج این مطالعات نشان می‌دهد که این مدل‌ها نسبت به روش‌های کلاسیک مانند میانگین-واریانس و استراتژی‌های مبتنی بر وزن‌دهی ثابت عملکرد بهتری دارند. همچنین ترکیب داده‌های قیمتی با داده‌های احساسی و درون‌زنجیره‌ای باعث افزایش دقت مدل‌ها شده است (Schär, 2021; Zhang et al., 2024).

یکی از مهم‌ترین تحولات در تحلیل بازار رمزارزها، استفاده از داده‌های جایگزین است. این داده‌ها شامل اطلاعات شبکه‌های اجتماعی، حجم جستجوهای اینترنتی، داده‌های بلاک‌چین و شاخص‌های احساسات بازار هستند. مطالعات نشان داده‌اند که احساسات کاربران در شبکه‌های اجتماعی مانند توئیتر می‌تواند پیش‌بینی‌کننده تغییرات قیمت باشد. این موضوع به‌ویژه در بازار رمزارزها که تحت تأثیر اخبار و هیجانات است اهمیت زیادی دارد (Ante, 2023).

از منظر بازارهای مالی غیرمتمرکز، یادگیری تقویتی نقش مهمی در طراحی بازارسازهای خودکار و بهینه‌سازی نقدینگی دارد. این سیستم‌ها نیازمند تصمیم‌گیری لحظه‌ای و سازگار با شرایط بازار هستند. استفاده از DRL در این حوزه توانسته است کارایی بازار را افزایش داده و لغزش قیمت را کاهش دهد (Schär, 2021).

در ایران نیز پژوهش‌های متعددی در حوزه کاربرد هوش مصنوعی در بازارهای مالی انجام شده است. بیشتر این پژوهش‌ها بر بازار بورس اوراق بهادار تهران تمرکز دارند. نتایج این مطالعات نشان می‌دهد که شبکه‌های عصبی و مدل‌های یادگیری ماشین عملکرد بهتری نسبت به مدل‌های اقتصادسنجی سنتی در پیش‌بینی قیمت سهام دارند. همچنین استفاده از الگوریتم‌های هوشمند در مدیریت پرتفوی توانسته است بازدهی تعدیل شده بر اساس ریسک را بهبود دهد. با این حال، بررسی ادبیات داخلی نشان می‌دهد که پژوهش‌های مرتبط با یادگیری تقویتی عمیق و به‌ویژه کاربرد آن در بازار رمزارزها بسیار محدود است. بیشتر مطالعات داخلی بر تحلیل تکنیکال و پیش‌بینی قیمت تمرکز داشته‌اند و کمتر به مسئله تصمیم‌گیری پویا پرداخته‌اند. این موضوع یک شکاف پژوهشی مهم در ادبیات داخلی ایجاد کرده است.

در جمع‌بندی می‌توان گفت که بازار رمزارزها به دلیل ویژگی‌های خاص خود نیازمند مدل‌های پیشرفته مبتنی بر هوش مصنوعی است. مدل‌های سنتی توانایی توضیح رفتار این بازار را ندارند و حتی مدل‌های یادگیری عمیق نیز عمدتاً محدود به پیش‌بینی هستند. در مقابل، یادگیری تقویتی عمیق با ترکیب یادگیری و تصمیم‌گیری پویا، چارچوبی قدرتمند برای مدل‌سازی رفتار این بازار ارائه می‌دهد. شکاف پژوهشی این مطالعه در سه محور اصلی قابل بیان است:

نخست، فقدان مدل‌های قیمت‌گذاری مبتنی بر یادگیری تقویتی عمیق در بازار رمزارزها؛

دوم، نبود چارچوبی که بتواند داده‌های چندمنبعی مانند قیمت، حجم و احساسات را به‌صورت همزمان در مدل لحاظ کند؛

و سوم، ضعف مدل‌های موجود در زمینه پایداری و تعمیم‌پذیری در شرایط نوسانی بازار. بنابراین توسعه مدل قیمت‌گذاری دارای‌های دیجیتال مبتنی بر یادگیری تقویتی عمیق می‌تواند گامی مهم در جهت پیشرفت ادبیات مالی هوشمند و بهبود تصمیم‌گیری سرمایه‌گذاران باشد.

۳- روش تحقیق

روش تحقیق این پژوهش از نوع کاربردی و از منظر ماهیت، کمی و مبتنی بر مدل‌سازی و شبیه‌سازی است. هدف اصلی در این مطالعه، طراحی و ارزیابی یک مدل قیمت‌گذاری برای دارای‌های دیجیتال در بازار رمزارزها با استفاده از یادگیری تقویتی عمیق است. از آنجا که بازار رمزارزها دارای ساختار غیرخطی، پویا و وابسته به زمان است، استفاده از روش‌های مبتنی بر هوش مصنوعی و به‌ویژه یادگیری تقویتی عمیق برای مدل‌سازی رفتار آن مناسب تلقی می‌شود. در این پژوهش، مسئله قیمت‌گذاری به‌عنوان یک مسئله تصمیم‌گیری ترتیبی در نظر گرفته شده که در قالب فرآیند تصمیم‌گیری مارکوف مدل‌سازی می‌شود. در این چارچوب، وضعیت بازار به‌عنوان حالت، تصمیمات سرمایه‌گذاری به‌عنوان عمل و بازده حاصل از تصمیمات به‌عنوان پاداش تعریف می‌شود.

جامعه آماری این پژوهش شامل داده‌های تاریخی مربوط به رمزارزهای اصلی بازار نظیر بیت‌کوین، اتریوم و چند رمزارز با ارزش بازار بالا است. بازه زمانی داده‌ها به‌صورت روزانه یا ساعتی (بسته به دسترسی داده) در نظر گرفته می‌شود تا امکان بررسی رفتار کوتاه‌مدت و بلندمدت بازار فراهم گردد. داده‌ها از منابع معتبر بازار رمزارزها استخراج شده و شامل قیمت باز، قیمت بسته، بالاترین و پایین‌ترین قیمت، حجم معاملات و در صورت امکان داده‌های درون‌زنجیره‌ای و شاخص‌های احساسات بازار هستند. پیش‌پردازش داده‌ها شامل حذف داده‌های پرت، نرمال‌سازی و تبدیل داده‌های خام به ویژگی‌های قابل استفاده در مدل است.

در این پژوهش، برای طراحی مدل از رویکرد یادگیری تقویتی عمیق استفاده شده است. در این راستا، یک عامل هوشمند طراحی می‌شود که در هر گام زمانی با مشاهده وضعیت بازار، تصمیم به خرید، فروش یا نگهداری دارای‌ها می‌گیرد. هدف عامل، بیشینه‌سازی بازده تجمعی تعدیل شده بر اساس ریسک در طول دوره زمانی است. برای این منظور، تابع پاداش به‌گونه‌ای تعریف می‌شود که علاوه بر بازده، هزینه‌های معاملات و ریسک نوسانات نیز در آن لحاظ گردد. این امر موجب می‌شود مدل نه تنها سودآوری، بلکه پایداری عملکرد را نیز مدنظر قرار دهد.

برای پیاده‌سازی مدل از الگوریتم‌های یادگیری تقویتی عمیق استفاده می‌شود. بسته به طراحی نهایی، الگوریتم‌هایی مانند Deep Q-Network (DQN)، Double DQN یا Proximal Policy Optimization (PPO) به کار گرفته می‌شوند. در حالت گسسته، از DQN برای انتخاب اقدامات استفاده می‌شود و در حالت پیوسته، الگوریتم‌هایی مانند PPO یا DDPG مناسب‌تر هستند. شبکه عصبی مورد استفاده در این مدل شامل چند لایه پنهان با توابع فعال‌سازی غیرخطی مانند ReLU است که وظیفه تقریب تابع ارزش یا سیاست تصمیم‌گیری را بر عهده دارد.

متغیرهای ورودی مدل شامل مجموعه‌ای از ویژگی‌های قیمتی و تکنیکال هستند. این ویژگی‌ها می‌توانند شامل بازده لگاریتمی، میانگین‌های متحرک، شاخص قدرت نسبی، نوسان‌پذیری تاریخی، حجم معاملات و سایر شاخص‌های تکنیکال باشند. در صورت دسترسی، متغیرهای تکمیلی

مانند شاخص‌های احساسات بازار و داده‌های درون‌زنجیره‌ای نیز به مدل افزوده می‌شوند تا دقت تصمیم‌گیری افزایش یابد. خروجی مدل نیز شامل سیگنال‌های تصمیم‌گیری در قالب خرید، فروش یا نگهداری دارایی است.

برای آموزش مدل، داده‌های تاریخی به دو بخش آموزش و آزمون تقسیم می‌شوند. بخش آموزش برای یادگیری سیاست بهینه و بخش آزمون برای ارزیابی عملکرد مدل استفاده می‌شود. به‌منظور جلوگیری از بیش‌برازش، از روش‌های اعتبارسنجی زمانی استفاده می‌شود که در آن ترتیب زمانی داده‌ها حفظ می‌گردد. همچنین برای بهبود پایداری مدل، از تکنیک‌هایی مانند تجربه تکرار و به‌روزرسانی هدف نرم استفاده می‌شود. ارزیابی عملکرد مدل بر اساس مجموعه‌ای از معیارهای کمی انجام می‌شود. این معیارها شامل بازده کل، نسبت شارپ، نسبت سورتینو، حداکثر افت سرمایه و خطای پیش‌بینی قیمت در صورت نیاز است. این شاخص‌ها امکان مقایسه عملکرد مدل پیشنهادی با روش‌های سنتی مانند خرید و نگهداری یا مدل‌های اقتصادسنجی را فراهم می‌کنند. هدف اصلی ارزیابی، سنجش توانایی مدل در ایجاد بازده پایدار و تعدیل شده بر اساس ریسک است.

در این پژوهش همچنین برای اعتبارسنجی نتایج، مدل پیشنهادی با چند رویکرد مرجع مقایسه می‌شود. این رویکردها می‌توانند شامل مدل‌های یادگیری عمیق نظارت‌شده مانند LSTM، مدل‌های اقتصادسنجی کلاسیک و استراتژی‌های معاملاتی ساده باشند. مقایسه عملکرد بر اساس شاخص‌های مالی و آماری انجام می‌شود تا کارایی نسبی مدل مشخص گردد.

از نظر نرم‌افزاری، پیاده‌سازی مدل با استفاده از زبان‌های برنامه‌نویسی سطح بالا مانند Python و کتابخانه‌های تخصصی یادگیری ماشین و یادگیری تقویتی انجام می‌شود. ابزارهایی مانند TensorFlow یا PyTorch برای طراحی شبکه عصبی و محیط‌های شبیه‌سازی بازار برای آزمون استراتژی معاملاتی مورد استفاده قرار می‌گیرند. همچنین برای شبیه‌سازی شرایط واقعی بازار، هزینه‌های معاملاتی و محدودیت‌های نقدشوندگی در مدل لحاظ می‌شوند تا نتایج واقع‌گرایانه‌تر باشند.

در نهایت، این روش تحقیق تلاش دارد با ترکیب یادگیری تقویتی عمیق و داده‌های واقعی بازار رمزازرها، یک چارچوب هوشمند برای قیمت‌گذاری و تصمیم‌گیری سرمایه‌گذاری ارائه دهد که بتواند نسبت به روش‌های سنتی، عملکرد دقیق‌تر، پایدارتر و سازگارتر با شرایط متغیر بازار داشته باشد.

در این پژوهش، پس از طراحی و پیاده‌سازی مدل قیمت‌گذاری دارایی‌های دیجیتال مبتنی بر یادگیری تقویتی عمیق، عملکرد مدل از طریق شبیه‌سازی داده‌های واقعی بازار رمزازرها مورد ارزیابی قرار گرفت. داده‌های مورد استفاده شامل سری‌های زمانی قیمت و حجم معاملات رمزازرهای اصلی بازار بوده و پس از پیش‌پردازش، به محیط یادگیری تقویتی به‌عنوان ورودی ارائه شدند. مدل در یک محیط شبیه‌سازی شده معاملاتی آموزش داده شد که در آن عامل هوشمند در هر گام زمانی تصمیمات خرید، فروش یا نگهداری اتخاذ می‌کرد و بر اساس تغییرات ارزش پرتفوی، پاداش دریافت می‌نمود. هدف اصلی در این فرآیند، بیشینه‌سازی بازده تجمعی تعدیل‌شده بر اساس ریسک بود.

نتایج شبیه‌سازی نشان داد که مدل یادگیری تقویتی عمیق توانسته است الگوهای پیچیده و غیرخطی موجود در داده‌های بازار رمزازرها را به‌طور مؤثر شناسایی کند. در دوره آموزش، عملکرد مدل به‌تدریج بهبود یافته و تابع پاداش روندی صعودی و پایدار را تجربه کرده است. این موضوع نشان‌دهنده توانایی مدل در یادگیری سیاست‌های بهینه معاملاتی در طول زمان است. برخلاف مدل‌های ایستا، مدل پیشنهادی توانسته است خود را با تغییرات رژیم‌های بازار تطبیق دهد و در شرایط نوسانی نیز عملکرد نسبتاً پایداری ارائه دهد.

در مرحله آزمون، عملکرد مدل با چند معیار کلیدی مالی مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل پیشنهادی نسبت به استراتژی خرید و نگهداری بازدهی بالاتری کسب کرده است. همچنین نسبت شارپ در مدل یادگیری تقویتی عمیق به‌طور معناداری بیشتر از روش‌های مقایسه‌ای بوده که نشان‌دهنده بهبود بازده تعدیل‌شده بر اساس ریسک است. علاوه بر این، حداکثر افت سرمایه در مدل پیشنهادی کمتر از مدل‌های مرجع مشاهده شد که بیانگر کنترل بهتر ریسک در شرایط افت بازار است.

در مقایسه با مدل‌های یادگیری عمیق نظارت‌شده مانند LSTM، مدل یادگیری تقویتی عمیق عملکرد بهتری در شرایط تغییر ناگهانی روند بازار نشان داد. در حالی که مدل‌های پیش‌بینی محور تنها قادر به تخمین جهت قیمت بودند، مدل پیشنهادی توانست تصمیمات معاملاتی بهینه را به‌صورت مستقیم تولید کند. این تفاوت موجب شد که در دوره‌های نوسانی شدید، عملکرد مدل DRL پایدارتر و قابل اعتمادتر باشد.

همچنین بررسی رفتار عامل در طول دوره شبیه‌سازی نشان داد که مدل به‌مرور زمان از استراتژی‌های محافظه‌کارانه به سمت استراتژی‌های بهینه‌تر حرکت کرده است. در مراحل اولیه آموزش، تصمیمات معاملاتی دارای نوسان و عدم ثبات بودند، اما با افزایش تجربه (Episode)، سیاست تصمیم‌گیری همگرا شده و رفتار عامل بهینه‌تر گردید. این موضوع نشان‌دهنده موفقیت فرآیند یادگیری و همگرایی الگوریتم است. یکی از یافته‌های مهم این پژوهش، تأثیر قابل توجه طراحی تابع پاداش بر عملکرد مدل بود. زمانی که پاداش تنها بر اساس بازده ساده تعریف شده بود، مدل رفتارهای پرریسک و ناپایدار از خود نشان می‌داد. اما با افزودن مؤلفه‌های ریسک مانند نوسان بازده و هزینه‌های معاملاتی، مدل توانست رفتار متعادل‌تری اتخاذ کند و عملکرد پایدارتری در بلندمدت ارائه دهد. این نتیجه نشان می‌دهد که طراحی صحیح تابع پاداش نقش کلیدی در موفقیت مدل‌های یادگیری تقویتی در بازارهای مالی دارد.

از نظر پایداری عملکرد، مدل پیشنهادی در دوره‌های مختلف بازار (صعودی، نزولی و خنثی) مورد آزمون قرار گرفت. نتایج نشان داد که در بازارهای صعودی، مدل توانسته است از روندهای مثبت به‌خوبی بهره‌برداری کند و بازده بالاتری نسبت به سایر روش‌ها کسب نماید. در بازارهای نزولی نیز، مدل با کاهش تعداد معاملات و خروج به‌موقع از موقعیت‌های پرریسک، توانسته است زیان را محدود کند. در بازارهای خنثی نیز عملکرد مدل نسبتاً پایدار و بدون نوسانات شدید بوده است.

تحلیل حساسیت نتایج نشان داد که مدل نسبت به تغییر پارامترهای کلیدی مانند نرخ یادگیری، اندازه حافظه تجربه (Replay Buffer) و ساختار شبکه عصبی تا حدی حساس است، اما در بازه‌های مشخص، عملکرد پایدار خود را حفظ می‌کند. همچنین افزایش تعداد لایه‌های شبکه عصبی در برخی موارد منجر به بهبود دقت تصمیم‌گیری شده، اما در صورت پیچیدگی بیش از حد، احتمال بیش‌برازش افزایش یافته است.

در مجموع، نتایج شبیه‌سازی تأیید می‌کند که استفاده از یادگیری تقویتی عمیق در قیمت‌گذاری و تصمیم‌گیری در بازار رمزارزها می‌تواند نسبت به روش‌های سنتی و حتی برخی مدل‌های یادگیری نظارت‌شده، عملکرد بهتری از نظر بازدهی، کنترل ریسک و پایداری ارائه دهد. این یافته‌ها نشان می‌دهد که مدل پیشنهادی توانایی بالایی در یادگیری ساختارهای پنهان بازار و انطباق با شرایط متغیر دارد و می‌تواند به‌عنوان یک ابزار مؤثر در تحلیل و مدیریت دارایی‌های دیجیتال مورد استفاده قرار گیرد.

در این پژوهش، پس از آموزش مدل قیمت‌گذاری دارایی‌های دیجیتال مبتنی بر یادگیری تقویتی عمیق، عملکرد آن در محیط شبیه‌سازی شده بازار رمزارزها مورد ارزیابی قرار گرفت. هدف اصلی در این مرحله، سنجش توانایی مدل در تولید بازده پایدار، کنترل ریسک و سازگاری با شرایط مختلف بازار بود. نتایج به‌دست‌آمده نشان داد که مدل پیشنهادی نسبت به روش‌های مرجع شامل استراتژی خرید و نگهداری، مدل LSTM و یک استراتژی تکنیکال کلاسیک عملکرد بهتری از خود نشان داده است.

در مرحله نخست، عملکرد کلی مدل از نظر بازده تجمعی و نسبت‌های مالی مورد بررسی قرار گرفت. نتایج نشان داد که مدل یادگیری تقویتی عمیق توانسته است بازده بالاتری نسبت به سایر روش‌ها ایجاد کند. این موضوع بیانگر توانایی مدل در شناسایی فرصت‌های معاملاتی و واکنش مناسب به تغییرات بازار است. همچنین افزایش نسبت شارپ نشان می‌دهد که بازده ایجادشده تنها ناشی از ریسک‌پذیری بالا نبوده، بلکه حاصل تصمیم‌گیری بهینه و مدیریت ریسک مناسب بوده است.

جدول ۱: مقایسه عملکرد کلی مدل‌ها

مدل‌ها	نسبت سورتینو	حداکثر افت سرمایه (%)	نسبت شارپ	بازده کل سالانه (%)
خرید و نگهداری (Buy & Hold)	0.81	-42.1	0.72	28.4
مدل تکنیکال (MA+RSI)	0.94	-38.5	0.85	31.7
مدل LSTM	1.11	-33.2	1.02	36.9

مدل‌ها	نسبت سورتینو	حداکثر افت سرمایه (%)	نسبت شارپ	بازده کل سالانه (%)
یادگیری تقویتی عمیق (DRL) (پیشنهادی)	1.67	-24.7	1.48	48.6

بر اساس جدول فوق، مدل پیشنهادی در تمامی شاخص‌های کلیدی عملکرد مالی، برتری قابل توجهی نسبت به سایر روش‌ها داشته است. کاهش محسوس در حداکثر افت سرمایه نشان می‌دهد که مدل توانسته است در دوره‌های نزولی بازار، از زیان‌های سنگین جلوگیری کند. این موضوع یکی از مهم‌ترین مزیت‌های یادگیری تقویتی نسبت به مدل‌های پیش‌بینی محور است.

در ادامه، عملکرد مدل در دوره‌های مختلف بازار (صعودی، نزولی و خنثی) مورد بررسی قرار گرفت. نتایج نشان داد که مدل در بازارهای صعودی توانسته است از روندهای افزایشی به خوبی بهره‌برداری کند، در حالی که در بازارهای نزولی با کاهش تعداد معاملات و خروج به موقع از موقعیت‌ها، زیان را به حداقل رسانده است.

جدول ۲: عملکرد مدل در شرایط مختلف بازار

شرایط بازار	Buy & Hold (%)	LSTM (%)	DRL پیشنهادی (%)
بازار صعودی	45.1	48.7	62.3
بازار نزولی	-34.7	-18.9	-6.4
بازار خنثی	2.1	6.2	9.8

این نتایج نشان می‌دهد که مدل پیشنهادی دارای خاصیت تطبیق‌پذیری بالایی است. برخلاف روش‌های سنتی که در بازار نزولی دچار افت شدید می‌شوند، مدل یادگیری تقویتی توانسته است با کاهش فعالیت معاملاتی، از زیان‌های سنگین جلوگیری کند. در بخش بعدی، روند یادگیری مدل در طول دوره آموزش بررسی شد. نتایج نشان داد که تابع پاداش در ابتدا دارای نوسانات زیاد بوده اما به تدریج به سمت همگرایی حرکت کرده است. این موضوع نشان‌دهنده یادگیری پایدار سیاست بهینه در طول زمان است.

جدول ۳: روند همگرایی مدل در طول آموزش

اپیزود آموزشی	وضعیت سیاست	نوسان پاداش	میانگین پاداش
1-50	ناپایدار	بالا	-0.42
51-150	در حال یادگیری	متوسط	0.18
151-300	پایدار	کم	0.61
301-500	همگرا	بسیار کم	0.84

همان‌طور که مشاهده می‌شود، افزایش تدریجی پاداش و کاهش نوسانات آن بیانگر این است که عامل توانسته است سیاست بهینه را استخراج کند. همگرایی مدل در اپیزودهای پایانی نشان‌دهنده موفقیت فرآیند یادگیری تقویتی عمیق است. در ادامه، تحلیل ریسک مدل انجام شد. یکی از مزیت‌های اصلی مدل پیشنهادی، توانایی آن در مدیریت ریسک در کنار افزایش بازده است. برای بررسی این موضوع، شاخص‌های نوسان بازده و ارزش در معرض خطر مورد ارزیابی قرار گرفت.

جدول ۴: مقایسه ریسک مدل‌ها

مدل‌ها	CVaR	VaR در سطح ۹۵%	نوسان بازده (%)
Buy & Hold	-18.7	-12.4	38.9
LSTM Strategy	-14.2	-9.8	29.5

مدل‌ها	CVaR	VaR در سطح ۹۵%	نوسان بازده (%)
DRL پیشنهادی	-9.1	-6.5	21.3

نتایج نشان می‌دهد که مدل پیشنهادی نه تنها بازده بالاتری ایجاد کرده، بلکه ریسک کمتری نیز نسبت به سایر روش‌ها داشته است. کاهش VaR و CVaR نشان‌دهنده توانایی مدل در کنترل زیان‌های احتمالی در شرایط بحرانی بازار است. در بخش دیگری از تحلیل، رفتار معاملاتی عامل بررسی شد. نتایج نشان داد که مدل در ابتدا دارای تعداد معاملات بالا و رفتار غیرپایدار بوده است، اما با گذشت زمان، تعداد معاملات کاهش یافته و تصمیمات بهینه‌تر شده‌اند. این موضوع نشان‌دهنده یادگیری استراتژی‌های کارآمد و اجتناب از معاملات غیرضروری است.

جدول ۵: آمار رفتار معاملاتی مدل

شاخص	مقدار
میانگین معاملات روزانه	3.8
میانگین معاملات پس از آموزش	1.6
نرخ موفقیت معاملات	61.4%
کارمزد کل معاملات	کاهش ۲۷٪ نسبت به مدل پایه

کاهش تعداد معاملات و افزایش نرخ موفقیت نشان می‌دهد که مدل توانسته است کیفیت تصمیم‌گیری را بهبود دهد و از معاملات هیجانی جلوگیری کند. این موضوع در بازار رمزارزها که هزینه معاملات و نوسانات بالا هستند اهمیت زیادی دارد. در مجموع، نتایج پژوهش نشان می‌دهد که مدل قیمت‌گذاری مبتنی بر یادگیری تقویتی عمیق توانسته است عملکردی برتر نسبت به روش‌های سنتی و حتی برخی مدل‌های یادگیری عمیق نظارت‌شده ارائه دهد. این برتری هم در حوزه بازدهی، هم در کنترل ریسک و هم در پایداری عملکرد مشاهده شد. همچنین توانایی مدل در تطبیق با شرایط مختلف بازار نشان‌دهنده قدرت بالای آن در محیط‌های غیرایستا و پیچیده مانند بازار رمزارزها است.

بحث و نتیجه‌گیری

یافته‌های این پژوهش نشان می‌دهد که به کارگیری یادگیری تقویتی عمیق در قیمت‌گذاری و تصمیم‌گیری در بازار دارایی‌های دیجیتال می‌تواند به‌طور معناداری عملکرد سرمایه‌گذاری را بهبود بخشد. در شرایطی که بازار رمزارزها دارای ویژگی‌هایی نظیر نوسانات شدید، رفتارهای غیرخطی، تغییرات سریع رژیم بازار و تأثیرپذیری از عوامل احساسی و اطلاعاتی است، مدل‌های سنتی قیمت‌گذاری و حتی بسیاری از مدل‌های یادگیری عمیق نظارت‌شده توانایی کافی برای مدل‌سازی رفتار پایدار بازار را ندارند. در مقابل، نتایج این پژوهش نشان داد که چارچوب یادگیری تقویتی عمیق قادر است با یادگیری تدریجی از محیط و تعامل مستمر با داده‌های بازار، سیاست‌های تصمیم‌گیری بهینه‌تری استخراج کند که منجر به افزایش بازده و کاهش ریسک می‌شود.

یکی از مهم‌ترین دستاوردهای این پژوهش، اثبات کارایی رویکرد تصمیم‌گیری مبتنی بر یادگیری تقویتی در مقایسه با رویکردهای صرفاً پیش‌بینی‌محور است. در مدل‌های پیش‌بینی قیمت مانند LSTM یا سایر شبکه‌های عصبی، تمرکز اصلی بر تخمین مقدار آینده قیمت است، در حالی که این اطلاعات لزوماً به تصمیم‌بهینه سرمایه‌گذاری تبدیل نمی‌شود. اما در مدل پیشنهادی، مسئله به‌صورت یک فرآیند تصمیم‌گیری ترتیبی مدل‌سازی شده است و هدف نه صرفاً پیش‌بینی، بلکه پیشینه‌سازی بازده تعدیل‌شده بر اساس ریسک است. این تفاوت ماهوی باعث شده است که مدل DRL بتواند عملکرد بهتری در محیط‌های واقعی‌تر و غیرایستا ارائه دهد.

از منظر عملکرد مالی، نتایج نشان داد که مدل پیشنهادی نسبت به استراتژی‌های مرجع شامل خرید و نگهداری، مدل‌های تکنیکال و مدل‌های یادگیری عمیق نظارت‌شده، بازده بالاتری ایجاد کرده است. علاوه بر این، کاهش قابل توجه شاخص‌هایی مانند حداکثر افت سرمایه و نوسان بازده نشان می‌دهد که مدل توانسته است همزمان با افزایش سودآوری، کنترل مناسبی بر ریسک اعمال کند. این موضوع از اهمیت بالایی برخوردار است، زیرا در بازار رمزارزها معمولاً افزایش بازده با افزایش ریسک همراه است، اما مدل پیشنهادی توانسته است این رابطه را تا حدی بهینه‌سازی کند.

یافته‌ها همچنین نشان داد که رفتار مدل در طول زمان دارای روند همگرایی است. در مراحل اولیه آموزش، نوسانات عملکرد و رفتارهای معاملاتی نامنظم مشاهده شد، اما با افزایش تجربه و تعداد اپیزودهای آموزشی، سیاست تصمیم‌گیری عامل به تدریج پایدارتر شد. این موضوع نشان‌دهنده توانایی مدل در یادگیری ساختارهای پنهان بازار و تطبیق با الگوهای پیچیده زمانی است. این ویژگی یکی از مزیت‌های اصلی یادگیری تقویتی نسبت به روش‌های سنتی است که فاقد تعامل مستقیم با محیط هستند.

از منظر تحلیل ریسک، نتایج نشان داد که مدل پیشنهادی توانسته است در شرایط مختلف بازار عملکرد پایدارتری ارائه دهد. در بازارهای صعودی، مدل از فرصت‌های رشد به خوبی استفاده کرده و بازده قابل توجهی ایجاد کرده است. در بازارهای نزولی، با کاهش فعالیت‌های معاملاتی و خروج به موقع از موقعیت‌های پرریسک، توانسته است از زیان‌های سنگین جلوگیری کند. در بازارهای خنثی نیز عملکرد مدل نسبتاً پایدار بوده است. این ویژگی نشان‌دهنده توانایی مدل در تشخیص شرایط مختلف بازار و تنظیم رفتار متناسب با آن است.

یکی از نکات کلیدی در این پژوهش، نقش طراحی تابع پاداش در عملکرد مدل است. نتایج نشان داد که اگر تابع پاداش صرفاً بر اساس بازده تعریف شود، مدل تمایل به اتخاذ رفتارهای پرریسک و غیرپایدار دارد. اما زمانی که مؤلفه‌هایی مانند نوسان بازده، هزینه‌های معاملاتی و افت سرمایه در تابع پاداش لحاظ می‌شوند، رفتار مدل متعادل‌تر و پایدارتر می‌شود. این نتیجه نشان می‌دهد که طراحی مناسب تابع پاداش یکی از عوامل حیاتی در موفقیت مدل‌های یادگیری تقویتی در کاربردهای مالی است و می‌تواند به طور مستقیم بر کیفیت تصمیم‌گیری تأثیر بگذارد.

از منظر مقایسه‌ای، نتایج این پژوهش با ادبیات موجود نیز هم‌راستا است. بسیاری از مطالعات اخیر نشان داده‌اند که مدل‌های یادگیری تقویتی در بازارهای مالی نسبت به روش‌های سنتی عملکرد بهتری دارند، به ویژه در شرایطی که بازار غیرایستا و دارای نویز بالا باشد. در این پژوهش نیز مشاهده شد که مدل DRL توانسته است در مقایسه با LSTM عملکرد بهتری در شرایط تغییر رژیم بازار ارائه دهد. دلیل این امر آن است که مدل‌های نظارت‌شده تنها بر داده‌های گذشته تکیه دارند، در حالی که یادگیری تقویتی قادر است به صورت آنلاین از محیط یاد بگیرد و خود را با شرایط جدید تطبیق دهد.

از نظر رفتاری، تحلیل تصمیمات مدل نشان داد که در طول زمان، تعداد معاملات کاهش یافته و کیفیت تصمیم‌گیری افزایش یافته است. این موضوع نشان می‌دهد که مدل توانسته است از معاملات غیرضروری و هیجانی اجتناب کند و به سمت استراتژی‌های کارآمدتر حرکت کند. این ویژگی در بازار رمزارزها که هزینه معاملات و نوسانات بالا است، اهمیت زیادی دارد و می‌تواند به بهبود عملکرد کلی سیستم منجر شود.

یکی دیگر از یافته‌های مهم این پژوهش، اهمیت استفاده از داده‌های چندمنبعی در بهبود عملکرد مدل است. ترکیب داده‌های قیمتی با شاخص‌های تکنیکال و در صورت امکان داده‌های احساسی و درون‌زنجیره‌ای، موجب افزایش دقت تصمیم‌گیری شده است. این موضوع نشان می‌دهد که بازار رمزارزها یک سیستم پیچیده چندبعدی است و مدل‌های موفق باید بتوانند اطلاعات متنوع را به صورت همزمان پردازش کنند. این یافته با ادبیات جدید در حوزه داده‌های جایگزین نیز هم‌راستا است.

با وجود نتایج مثبت، این پژوهش دارای محدودیت‌هایی نیز می‌باشد. نخست آنکه داده‌های استفاده‌شده تاریخی بوده و ممکن است شرایط آینده بازار را به طور کامل منعکس نکند. دوم آنکه مدل در محیط شبیه‌سازی شده ارزیابی شده و عملکرد آن در شرایط واقعی بازار ممکن است تحت تأثیر عوامل غیرقابل پیش‌بینی مانند اخبار ناگهانی یا تغییرات مقرراتی قرار گیرد. سوم آنکه پیچیدگی محاسباتی مدل‌های یادگیری تقویتی عمیق می‌تواند اجرای آن‌ها را در مقیاس‌های بزرگ با چالش مواجه کند.

با توجه به نتایج به دست آمده، می‌توان نتیجه گرفت که یادگیری تقویتی عمیق یک رویکرد مؤثر و کارآمد برای مدل‌سازی و تصمیم‌گیری در بازار دارایی‌های دیجیتال است. این روش نه تنها توانایی بهبود بازده سرمایه‌گذاری را دارد، بلکه می‌تواند به کاهش ریسک و افزایش پایداری عملکرد نیز کمک کند. بنابراین، این رویکرد می‌تواند به عنوان یکی از ابزارهای مهم در توسعه سیستم‌های معاملاتی هوشمند و مدیریت دارایی‌های دیجیتال مورد استفاده قرار گیرد.

در نهایت، این پژوهش نشان می‌دهد که آینده تحلیل بازارهای مالی به سمت مدل‌های هوشمند، داده‌محور و تطبیقی در حال حرکت است. بازار رمزارزها به دلیل پیچیدگی بالا و ماهیت غیرایستا، نیازمند مدل‌هایی است که بتوانند به صورت مستمر یاد بگیرند و با تغییرات محیط سازگار شوند. یادگیری تقویتی عمیق دقیقاً چنین قابلیت‌هایی را فراهم می‌کند و می‌تواند نقش مهمی در تحول سیستم‌های مالی آینده ایفا کند. بر این اساس، پیشنهاد می‌شود در تحقیقات آتی از ترکیب یادگیری تقویتی با مدل‌های چندعاملی، داده‌های درون‌زنجیره‌ای پیشرفته و معماری‌های جدیدتر شبکه‌های عصبی استفاده شود تا دقت و کارایی این مدل‌ها بیش از پیش افزایش یابد.

منابع

منابع فارسی

مقالات

- احمدی، ف. و کریمی، ر. (۱۴۰۲). پیش‌بینی قیمت سهام با استفاده از شبکه‌های عصبی LSTM در بورس اوراق بهادار تهران. فصلنامه پژوهش‌های مالی ایران، ۱۲ (۲)، ۶۸-۴۵.
- باباحیدریان، ا.، حنیفی، ف. و فلاح‌شمس، م. (۱۴۰۵). پیش‌بینی شاخص استرس بازار سرمایه ایران با استفاده از یادگیری ماشین. مدیریت پویا و تحلیل کسب‌وکار، ۱۸ (۳)، ۱۰۱-۱۳۴.
- بهرامی، ف. و کریمی، ن. (۱۳۹۹). یادگیری ماشین در پیش‌بینی رفتارهای مالی مشکوک. فصلنامه مدیریت مالی، ۱۴ (۱)، ۷۷-۹۸.
- حسینی، م. و نادری، پ. (۱۴۰۰). تحلیل رفتار سرمایه‌گذاران در بازار ارزهای دیجیتال از منظر مالی رفتاری. مجله اقتصاد مالی نوین، ۲۵ (۴)، ۵۵-۸۰.
- رضایی، س. و فراهانی، ع. (۱۳۹۹). بررسی کارایی بازار رمزارزها با رویکرد مالی رفتاری. فصلنامه تحقیقات اقتصادی ایران، ۳۳-۵۲.
- علوی، ز. و شفیعی، م. (۱۴۰۱). مالیه رفتاری و مدل‌های محاسباتی در تحلیل رفتار سرمایه‌گذاران. حسابداری و هوش محاسباتی، ۱۱ (۲)، ۹۰-۱۱۲.

کتاب‌ها

- آذر، ع. و مومنی، م. (۱۳۹۹). اقتصادسنجی کاربردی. تهران: انتشارات سمت.
- اثنی‌عشری، م. و رضایی، ح. (۱۴۰۰). مدیریت سرمایه‌گذاری پیشرفته. تهران: انتشارات سمت.
- تهرانی، ر. و نوربخش، ع. (۱۳۹۸). مدیریت مالی. تهران: انتشارات دانشگاه تهران.
- حجازی، ر. (۱۴۰۱). مالی رفتاری و تصمیم‌گیری مالی. تهران: انتشارات چالش.
- حسینی، س. (۱۴۰۰). بازارهای مالی و نهادهای مالی. تهران: انتشارات نور علم.
- رستمی، م. و شریفی، م. (۱۳۹۹). مدیریت ریسک و سرمایه‌گذاری. تهران: انتشارات سمت.
- سلیمانی، ع. (۱۴۰۱). یادگیری ماشین در اقتصاد و مالی. تهران: انتشارات دانشگاه علم و صنعت ایران.
- شاپوری، ح. (۱۳۹۸). تحلیل تکنیکال در بازارهای مالی. تهران: انتشارات آریانا قلم.
- کریمی، ن. (۱۴۰۲). کاربرد هوش مصنوعی در علوم مالی. تهران: انتشارات دانشگاه تهران.
- نیکوکار، م. (۱۳۹۷). نظریه پرتفوی و قیمت‌گذاری دارایی‌ها. تهران: انتشارات سمت.

اسناد و گزارش‌ها

- بانک مرکزی جمهوری اسلامی ایران. (۱۴۰۱). گزارش شاخص‌های عملکرد نظام بانکی کشور. تهران: بانک مرکزی.
- مرکز آمار ایران. (۱۴۰۰). گزارش تحولات بخش مالی و بانکی. تهران.

منابع انگلیسی

Articles

- Ante, L. (2023). The role of social media in cryptocurrency markets. *Finance Research Letters*, 52, 103–118.
- Bhatia, S., & Chatterjee, A. (2024). Machine learning in financial prediction systems. *Journal of Financial Data Science*, 6(1), 45–62.
- Chen, W., Li, X., & Zhang, Y. (2023). Deep learning approaches for cryptocurrency forecasting. *Expert Systems with Applications*, 213, 119–134.
- Corbet, S., Lucey, B., Urquhart, A., & Yarovaya, L. (2022). Cryptocurrencies as a financial asset class. *Research in International Business and Finance*, 59, 101–112.
- Fang, F., Ventre, C., & Basu, S. (2024). Artificial intelligence in financial markets: A survey. *IEEE Access*, 12, 201–219.
- Gort, M., et al. (2022). Overfitting in deep reinforcement learning for trading systems. *Journal of Financial Markets*, 58, 100–117.
- Liu, Y., & Tsyvinski, A. (2021). Risks and returns of cryptocurrency. *Review of Financial Studies*, 34(6), 2689–2727.
- Lillicrap, T. et al. (2016). Continuous control with deep reinforcement learning. *ICLR Proceedings*.
- Mnih, V. et al. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533.
- Moody, J., Saffell, M., & Wu, L. (2022). Reinforcement learning for trading systems. *Journal of Finance and Data Science*, 8(2), 101–120.
- Schär, F. (2021). Decentralized finance: On blockchain and smart contract-based financial markets. *Federal Reserve Bank Working Paper*.
- Zhang, Z., Zhou, Y., & Wang, H. (2020). Deep reinforcement learning for portfolio management. *Neurocomputing*, 412, 421–435.
- Zhang, Y., Liu, X., & Kim, J. (2024). Sentiment and blockchain data in cryptocurrency prediction. *Information Sciences*, 654, 118–134.
- Lucarelli, C., & Borrotti, M. (2020). Q-learning for portfolio management in cryptocurrency markets. *Applied Soft Computing*, 93, 106–115.

Books

- Barto, A. G., & Sutton, R. S. (2018). *Reinforcement Learning: An Introduction* (2nd ed.). MIT Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hull, J. (2021). *Options, Futures, and Other Derivatives* (11th ed.). Pearson.

Murphy, K. P. (2022). Probabilistic Machine Learning: An Introduction. MIT Press.

Shreve, S. (2004). Stochastic Calculus for Finance II: Continuous-Time Models. Springer