Shahid Bahonar University of Kerman

Journal of Accounting Knowledge

Print ISSN: 2008 - 8914 Online ISSN: 2476 - 292X

Iranian Accounting Association

Designing an Optimal Model for Predicting Stock Liquidity Using the Random Forest

Abdolreza Ghasempour[1], **Ahmad Khodamipour**[2], **Hadis Zeinali**[3] and **Amirhossein Taebi Noghondari**[4]

1. Department of Accounting, Ke.C., Islamic Azad University, Kerman, Iran. **Email:** abdolrezaghasempour@iau.ac.ir
2. **Corresponding Author**, Department of Accounting, Faculty of Management and Economics, Shahid Bahonar University of Kerman, Kerman, Iran. **Email:** khodamipour@uk.ac.ir
3. Department of Accounting, Ke.C., Islamic Azad University, Kerman, Iran. **Email:** hadisazeinali@iau.ac.ir
4. Department of Accounting, Ke.C., Islamic Azad University, Kerman, Iran. **Email:** amirtaebi@iau.ac.ir

Article Info

Article Type:
Research Article.

Article History:
Received: 13 May 2025
Received in revised form: 20 September 2025
Accepted: 21 September 2025
Available online:

***Keywords*:**
Forecasting,
Liquidity,
Stocks,
Random Forest Algorithm.

JEL Classification:
C53, M40.

A B S T R A C T

Objective: Stock markets are inherently volatile and risky due to their dynamic nature, financial complexities, and the limited understanding of price determination among many investors. This study aims to design an optimal predictive model for stock liquidity to provide practical support for investors with insufficient knowledge of these complex dynamics

Method: A hybrid approach combining data analysis, machine learning, and predictive modeling was employed. Data related to stock liquidity were collected and preprocessed from various scientific sources. The Random Forest algorithm was then applied to develop an optimal model for predicting stock liquidity.

Results: The findings demonstrate that the Random Forest algorithm can provide a relatively accurate and efficient model for predicting stock liquidity. Beta, rate of change, and volatility in stock returns (Rmc) were identified as the most influential factors affecting liquidity. The model achieved higher predictive accuracy compared to previous approaches, as evidenced by its low mean squared error (MSE).

Conclusion: The low MSE confirms the suitability of the Random Forest algorithm for predicting stock liquidity. The results of this study can assist investors and financial analysts in making more informed and precise decisions.

Cite this article: Ghasempour, A., Khodamipour, A., Zeinali, H., & Taebi Noghondari, A. (2025). Designing an optimal model for predicting stock liquidity using the random forest. *Journal of Accounting Knowledge*, 16(*), *-*.

Publisher: Shahid Bahonar University of Kerman.

Introduction

Financial markets, and in particular stock exchanges, have long been recognized as complex adaptive systems that are subject to multifaceted dynamics and interactions. Their complexity stems not only from the inherent volatility and uncertainty of asset prices but also from the interdependence of economic fundamentals, firm-level characteristics, investor behavior, and regulatory interventions. One of the most critical constructs in financial economics is liquidity, a concept that has been extensively debated in the literature due to its central role in ensuring the smooth functioning of capital markets. Liquidity refers to the ease and efficiency with which assets can be traded without causing significant price disturbances, and it is directly associated with market efficiency, transaction costs, and the ability of investors to adjust their portfolios in response to new information. The importance of liquidity extends beyond theoretical discussions; it carries tangible implications for corporate valuation, investor decision-making, and financial stability. Illiquid markets are prone to higher transaction costs, increased volatility, and greater vulnerability to systemic shocks, thereby undermining investor confidence. Conversely, markets characterized by higher liquidity attract domestic and foreign investment, foster efficient capital allocation, and enhance the overall resilience of financial systems. Given these broad implications, accurate and timely prediction of stock liquidity has emerged as a pressing concern for both academics and practitioners. While developed markets have been extensively studied, emerging markets such as Iran's capital market present unique challenges. These challenges include structural inefficiencies, data limitations, regulatory constraints, and behavioral peculiarities of investors. Existing models of liquidity prediction, which are often built upon linear assumptions and traditional econometric techniques, may fail to capture the nonlinear, multidimensional, and complex relationships that define such markets. Against this backdrop, the present study addresses a critical gap in the literature by proposing an optimized machine learning framework, specifically a Random Forest regression model, to predict stock liquidity in Iran's capital market. By integrating qualitative and quantitative methodologies, this study not only identifies relevant determinants of liquidity but also constructs a robust and generalizable predictive model that offers theoretical, methodological, and practical contributions.

Method

The research employed a sequential mixed-methods design, consisting of a qualitative exploration followed by quantitative modeling. This design was motivated by the need to ground the machine learning model in contextually relevant variables while ensuring methodological rigor. In the first phase, a systematic literature review was conducted across international and domestic databases to compile a comprehensive list of potential determinants of liquidity. The review included theoretical models of market microstructure, empirical studies on liquidity drivers, and comparative analyses of emerging and developed markets. To contextualize these findings for Iran's capital market, semi-structured interviews were conducted with financial experts, regulators, and market analysts.

These interviews provided valuable insights into market-specific factors such as regulatory policies, investor behavior, and firm-level characteristics that might not be adequately captured in global studies. As a result of this process, an initial pool of over seventy variables was systematically narrowed down to forty-seven measurable variables deemed relevant and feasible within the Iranian context. In the second phase, the study adopted a Random Forest regression algorithm to develop the predictive framework. Random Forest, an ensemble learning method, was chosen for several reasons:

Robustness to overfitting: By averaging across multiple decision trees, Random Forest minimizes the variance of predictions and prevents overfitting.

Capacity to model nonlinear relationships: Unlike linear regression models, Random Forest can capture complex, nonlinear interactions between independent variables and liquidity.

Interpretability through feature importance: The algorithm provides measures of variable importance, thereby allowing researchers to identify the most influential determinants of liquidity.

Scalability: Random Forest handles high-dimensional datasets effectively, making it suitable for financial markets characterized by large numbers of potential predictors..

Sampling Procedures

The empirical analysis was based on data from firms listed on the Tehran Stock Exchange (TSE) between 2018 and 2022 (1397–1401 in the Iranian calendar). The population consisted of 666 firms, from which a final sample of 171 firms was derived after applying rigorous screening criteria. Firms with incomplete financial statements, irregular trading activity, or missing market data were excluded to ensure consistency and accuracy. Data were collected from reputable sources including Rahavard Novin, Tadbir Pardaz, and the official TSE website, all of which are widely recognized for their reliability among researchers and practitioners. The dataset encompassed both firm-specific financial indicators (such as Return on Assets, Return on Equity, and leverage) and market-based indicators (such as Beta, volatility measures, and trading volume). This dual focus allowed for a holistic examination of the determinants of liquidity.

Sample Size, Power, and Precision

Several methodological refinements were employed to maximize the predictive power of the model:

Data preprocessing: Outliers were identified and treated, missing values were addressed through imputation, and variables were standardized to ensure comparability.

Balancing techniques: The dataset was subject to class imbalance in terms of liquidity levels. To address this, the Synthetic Minority Oversampling Technique (SMOTE) was applied, which generated synthetic samples of minority cases to improve model training.

Hyperparameter tuning: The performance of Random Forest depends on parameters such as the number of trees, maximum depth, and minimum samples per split. An exhaustive search using GridSearchCV was conducted to identify the optimal combination of hyperparameters.

Model validation: To assess generalizability, K-Fold Cross-Validation was employed. This technique divides the dataset into K subsets, sequentially using each subset as a validation set while the remaining K−1 subsets are used for training. This procedure ensures that all data points contribute to both training and validation, reducing bias and variance.

Evaluation metrics included Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and the Coefficient of Determination (R^2). These complementary measures allowed for a comprehensive assessment of both accuracy and explanatory power.

Results

The empirical findings confirmed the efficacy of the Random Forest model in predicting stock liquidity with a high degree of accuracy. The model's low error metrics (MSE, MAE, RMSE) and high R^2 values indicated strong predictive performance and robust explanatory capacity. The feature importance analysis revealed a hierarchy of influential determinants. At the top of this hierarchy were Beta, reflecting market sensitivity, and Rmc, capturing return volatility. These results are consistent with the theoretical understanding that liquidity is closely linked to risk and uncertainty. Following these, firm-level financial indicators such as Return on Equity (ROE), realized returns, leverage ratios, and Return on Assets (ROA) emerged as significant predictors. The importance of these variables underscores the dual role of both market-based and firm-specific factors in shaping liquidity. In addition to confirming established relationships, the model also highlighted nuanced interactions among variables. For instance, the interplay between leverage and volatility was found to exert an amplified effect on liquidity, suggesting that firms with high leverage and high return volatility are particularly

vulnerable to liquidity constraints. Such insights would have been difficult to capture using traditional linear models, demonstrating the added value of machine learning approaches.

Conclusions

This study provides compelling evidence that Random Forest regression is a suitable and powerful tool for forecasting stock liquidity in the Iranian market. The use of a mixed-methods design—qualitative identification of variables followed by quantitative machine learning modeling—ensured both contextual relevance and methodological rigor. From a theoretical perspective, the study contributes to the literature on market microstructure and liquidity by introducing a machine learning framework that accounts for nonlinearity, multidimensionality, and complex variable interactions. Methodologically, the research demonstrates the utility of Random Forest in financial prediction tasks, offering a replicable model that can be adapted to other emerging markets. From a practical standpoint, the findings carry significant implications:

For investors: Improved liquidity forecasts can inform portfolio management strategies, risk assessment, and trading decisions.

For corporate managers: Understanding the determinants of liquidity can guide financial policies, such as capital structure decisions, that enhance stock attractiveness.

For policymakers and regulators: Reliable liquidity prediction models can assist in market surveillance, policy design, and crisis management. Looking forward, the study suggests several avenues for further research. Future investigations could explore hybrid machine learning models, such as gradient boosting methods (e.g., XGBoost, LightGBM) or deep learning architectures, to potentially enhance predictive accuracy and interpretability. Moreover, incorporating alternative data sources—such as investor sentiment extracted from social media, macroeconomic indicators, or high-frequency trading data—could enrich the predictive framework. Comparative analyses between Iran and other emerging markets would also provide valuable insights into the generalizability of the findings. In sum, by combining qualitative rigor with advanced quantitative modeling, this study establishes a comprehensive framework for predicting stock liquidity in emerging markets. It underscores the promise of machine learning as both a methodological innovation and a practical tool in financial research.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

The financial and market data used in this study were obtained from publicly accessible and subscription-based sources, including Rahavard Novin, Tadbir Pardaz, and the official website of the Tehran Stock Exchange (TSE). Processed datasets supporting the findings of this research are available from the corresponding author upon reasonable request.

Acknowledgements

The authors thank all participants in this study.

Ethical Considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Conflict of Interest

The authors declare no conflict of interest.

مجله دانش حسابداری
شاپا چاپی: ۸۹۱۴-۲۰۰۸ شاپا الکترونیکی: ۲۴۷۶-۲۹۲X
دانشگاه شهید باهنر کرمان
انجمن حسابداری ایران

طراحی الگوی بهینه پیش‌بینی نقدشوندگی سهام از طریق مدل جنگل تصادفی

عبدالرضا قاسمپور[۱]، احمد خدامی‌پور[۲]✉، حدیث زینلی[۳] و امیرحسین تائبی نقندری[۴]

۱. گروه حسابداری، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران. **رایانامه:** abdolrezaghasempour@iau.ac.ir
۲. **نویسنده مسئول**، گروه حسابداری، دانشکده مدیریت و اقتصاد، دانشگاه شهید باهنر کرمان، کرمان، ایران. **رایانامه:** khodamipour@uk.ac.ir
۳. گروه حسابداری، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران. **رایانامه:** hadisazeinali@iau.ac.ir
۴. گروه حسابداری، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران. **رایانامه:** amirtaebi@iau.ac.ir

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی.

تاریخ‌ها:
تاریخ دریافت: ۱۴۰۴/۲/۲۳
تاریخ بازنگری: ۱۴۰۴/۶/۲۹
تاریخ پذیرش: ۱۴۰۴/۶/۳۰
تاریخ انتشار برخط:

واژه‌های کلیدی:
پیش‌بینی،
نقدشوندگی،
سهام،
الگوریتم جنگل تصادفی.

طبقه‌بندی JEL:
C53, M40.

چکیـــده

هدف: بازارهای سهام به دلیل پویایی، پیچیدگی‌های مالی و درک ضعیف افراد در تعیین قیمت، بسیار پرنوسان و پرخطر هستند. بنابراین هدف این پژوهش طراحی الگویی است که بتواند قیمت سهام را پیش‌بینی کرده تا به سرمایه‌گذارانی که دانش کافی برای درک پویایی‌های پیچیده موجود در ارزیابی و پیش‌بینی قیمت سهام ندارند، کمک بهینه نماید.

روش: این پژوهش از یک روش ترکیبی بهره می‌برد که شامل تحلیل داده‌ها، یادگیری ماشین و الگوسازی پیش‌بینی است. ابتدا داده‌های مربوط به نقدشوندگی سهام از مجموعه دادگان علمی مختلف جمع‌آوری و پیش‌پردازش شده، سپس از الگوریتم جنگل تصادفی یادگیری ماشین برای شناسایی و طراحی الگوی بهینه نقدشوندگی سهام استفاده شده است.

یافته‌ها: در این پژوهش، با استفاده ازالگوریتم جنگل‌های تصادفی، سعی شده است تا حد امکان الگویی دقیق و کارا برای پیش‌بینی نقدشوندگی سهام تدوین شود. یافته‌ها نشان می‌دهند که ویژگی‌های بتا و میزان تغییرات و نوسانات در بازدهی سهام بیشترین تأثیر را بر نقدشوندگی سهام داشته و الگوی به دست آمده با دقت بالاتری نسبت به الگوهای قبلی می‌تواند این نقدشوندگی را پیش‌بینی کند. مقدار پایین خطای مربعی میانگین نیز نشان‌دهنده افزایش دقت پیش‌بینی‌ها است.

نتیجه‌گیری: خطای مربعی میانگین پایین الگو، تأیید می‌کند الگوی جنگل‌های تصادفی انتخاب مناسبی برای پیش‌بینی نقدشوندگی سهام بوده است. این نتایج می‌توانند به سرمایه‌گذاران و تحلیل‌گران مالی در اتخاذ تصمیمات بهتر و دقیق‌تر کمک کنند.

استناد: قاسمپور، عبدالرضا؛ خدامی‌پور، احمد؛ زینلی، حدیث و تائبی نقندری، امیرحسین (۱۴۰۴). طراحی مدل بهینه پیش‌بینی نقدشوندگی سهام از طریق مدل جنگل تصادفی. *مجله دانش حسابداری*، ۱۶(*)، *-*. https://doi.org.

ناشر: دانشگاه شهید باهنر کرمان.

۱- مقدمه

بازارهای سهام در دنیای امروز به‌عنوان یکی از مهم‌ترین بسترهای گردآوری سرمایه و تخصیص بهینه منابع مالی شناخته می‌شوند و نقشی بنیادین در پویایی اقتصاد جهانی ایفا می‌کنند. پیشرفت زیرساخت‌های فناوری اطلاعات و گسترش معاملات برخط، حضور فعال سرمایه‌گذاران حقیقی و حقوقی را در این بازارها به‌طور چشمگیری افزایش داده است (باتیا و همکاران[۱]، ۲۰۲۴). یکی از مسائل اساسی در چنین محیطی، موضوع نقدشوندگی اوراق بهادار است که در فرآیند تصمیم‌گیری مالی، قیمت‌گذاری دارایی‌ها و مدیریت ریسک اهمیت ویژه‌ای دارد (آمیهود و نوح[۲]، ۲۰۲۱).

ن نقدشوندگی در ادبیات مالی به توانایی تبدیل سریع دارایی به وجه نقد بدون افت قابل‌توجه در ارزش اطلاق می‌شود. سهامی که معاملات پرتکرارتری دارند، به‌طور معمول با ریسک پایین‌تری همراه بوده و به ارتقای شفافیت و کارایی بازار کمک می‌کنند (گوینکو و همکاران[۳]، ۲۰۰۹). پژوهش‌های اخیر بیانگر آن‌اند که نقدشوندگی علاوه‌بر اینکه شاخصی برای سلامت بازار تلقی می‌شود، می‌تواند به‌عنوان ابزاری برای ارزش‌گذاری و حتی پیش‌بینی روند آتی قیمت‌ها نیز به کار گرفته شود (کارتیا و همکاران[۴]، ۲۰۲۱). در نقطه مقابل، کاهش نقدشوندگی منجر به افزایش هزینه تأمین مالی، شدت نوسانات و تضعیف فرآیند کشف قیمت خواهد شد.

با وجود اهمیت این مفهوم، پیش‌بینی نقدشوندگی کاری دشوار و چندوجهی است. متغیرهای کلان اقتصادی، تغییرات نرخ بهره، سیاست‌های پولی و حتی احساسات بازار، اثرات همزمان و بعضاً متناقضی بر آن دارند. اگرچه نظریه‌هایی مانند «فرضیه بازار کارا» و «تصادفی بودن حرکات قیمتی» (فاما[۵]، ۱۹۷۰). امکان پیش‌بینی را رد می‌کنند، اما مطالعات تجربی و پیشرفت‌های اخیر در حوزه فناوری داده‌کاوی، خلاف این ادعا را نشان داده‌اند (جریبی و همکاران[۶]، ۲۰۲۳). بویژه، ظهور یادگیری ماشین[۷] و الگوریتم‌های هوشمند در سال‌های اخیر، تحول چشم‌گیری در تحلیل داده‌های مالی ایجاد کرده است. این مدل‌ها توانایی شناسایی الگوهای پنهان و غیرخطی را دارند که الگوهای سنتی آماری قادر به شناسایی آنها نیستند. مدل‌هایی نظیر جنگل تصادفی[۸]، مدل تقویت درخت تصمیم و تقویت گرادیان[۹] و شبکه‌های عصبی بازگشتی[۱۰] با بهره‌گیری از داده‌های با فرکانس بالا[۱۱] و ویژگی‌های نقدشوندگی مانند نسبت گردش، شکاف قیمتی، و عمق سفارشات، دقت پیش‌بینی نقدشوندگی را به‌طور چشمگیری افزایش داده‌اند (خنگ و همکاران[۱۲]، ۲۰۲۱).

بر این اساس، پژوهش حاضر در نظر دارد با ترکیب مدل‌های غیرخطی یادگیری ماشین و ویژگی‌های ساختاری بازار سهام، الگویی کارآمد و انعطاف‌پذیر برای پیش‌بینی نقدشوندگی در بازار سرمایه ایران ارائه کند. در این مسیر، به‌کارگیری ترکیب الگوریتم جنگل تصادفی و شبکه عصبی LSTM، به‌عنوان ابزاری برای پر کردن فاصله میان رویکردهای نظری (همچون فرضیه بازار کارا) و شواهد تجربی رفتار بازار، مدنظر قرار گرفته است. همچنین، استفاده از داده‌های چندبعدی و بهره‌گیری از روش‌های نوین بهینه‌سازی مدل، از نوآوری‌های اصلی این تحقیق محسوب می‌شود.

---

[1] Bhatia
[2] Amihud & Noh
[3] Goyenko
[4] Hasbrouck & Saar
[5] Fama
[6] Jeribi,
[7] ML
[8] Random Forest
[9] XGBoost
[10] RNN
[11] High-Frequency Data
[12] Khang

۲- مبانی نظری و پیشینه پژوهش

در سال‌های اخیر انتقادات متعددی نسبت به نظریه‌های سنتی از جمله «فرضیه بازار کارا» مطرح شده است، زیرا شواهد عملی نشان می‌دهد که رفتار فعالان بازار همیشه بر اساس عقلانیت کامل شکل نمی‌گیرد. همین موضوع زمینه‌ساز شکل‌گیری دیدگاه‌های نوین برای تبیین رفتارهای پیچیده و گاه غیرقابل پیش‌بینی بازار شده است. به عنوان نمونه، اندرو لو[۱] در سال ۲۰۰۴ نظریه «بازار سازگار»[۲] را ارائه کرد. مطابق این نظریه، کارایی بازار ثابت و ایستا نبوده بلکه متغیر و وابسته به شرایط محیطی است. سرمایه‌گذاران با اتکا به تجربیات گذشته و با سازگاری در برابر تحولات بازار، راهبردهای خود را تغییر داده و تصمیم‌های تازه‌ای اتخاذ می‌کنند؛ در نتیجه برخلاف فرضیه بازار کارا، امکان پیش‌بینی روندها در برخی موقعیت‌ها وجود دارد (لو، ۲۰۰۴). همچنین بر اساس نظریه‌های قیمت‌گذاری دارایی، دارایی‌های پرریسک‌تر باید بازده‌های بالاتری را محقق کنند. با این حال، نظریه‌های موجود قادر به توضیح تعداد قابل‌توجهی از الگوهای مشاهده‌شده در بازده‌های سهم که از آنها با عنوان خلاف قاعده بازار یاد می‌شود، نیستند (احمدوند و همکاران، ۱۴۰۳). از سوی دیگر، نظریه «مالی رفتاری»[۳] با بهره‌گیری از روان‌شناسی شناختی، توضیح می‌دهد که تصمیم‌گیری‌های سرمایه‌گذاران تحت تأثیر خطاهای ذهنی و واکنش‌های هیجانی قرار دارد. سوگیری‌هایی مانند اعتمادبه‌نفس بیش از حد، تقلید از رفتار جمعی و ترس از زیان، می‌تواند منجر به رفتارهای غیرکارا در بازار شود و همین امر فرصت‌هایی برای تحلیل و پیش‌بینی به وجود آورد (باربریس و تیلر[۴]، ۲۰۰۳). در همین راستا، نظریه «آشوب» بیان می‌کند که گرچه حرکات بازار در ظاهر تصادفی به نظر می‌رسند، اما در واقعیت از الگوهای غیرخطی و پیچیده پیروی می‌کنند که با ابزارهای ریاضی همچون تحلیل فراکتالی و سیستم‌های دینامیکی قابل شناسایی است(پیترز[۵]، ۱۹۹۴). همچنین، گراسمن و استیگلیتز[۶] (۱۹۸۰) در نظریه «اطلاعات ناقص»[۷]استدلال کردند اگر بازارها کاملاً کارا عمل کنند، انگیزه‌ای برای گردآوری و پردازش اطلاعات باقی نمی‌ماند. بنابراین وجود نویز و عدم تقارن اطلاعاتی موجب انحراف قیمت‌ها از ارزش ذاتی شده و این امر شرایطی برای پیش‌بینی‌پذیری فراهم می‌کند. در کنار این دیدگاه‌ها، نظریه «مالی رفتاری تطبیقی»[۸] نیز مطرح است که ترکیبی از روان‌شناسی رفتاری و رویکرد تکاملی است. بر اساس این نظریه، رفتار سرمایه‌گذاران در گذر زمان و تحت تأثیر یادگیری، تجربه و فشارهای محیطی تغییر می‌کند و بازارها به طور مداوم در حال سازگاری هستند (شیلر[۹]، ۲۰۰۳).

از منظر بازار سرمایه، «نقدشوندگی» یکی از مهم‌ترین ویژگی‌های دارایی‌های مالی محسوب می‌شود. بازاری که از نقدشوندگی بالا برخوردار باشد، امکان معامله سریع با حداقل هزینه و نوسان قیمتی اندک را فراهم می‌کند (آمیهود و مندلسون[۱۰]، ۱۹۸۶). با توجه به ماهیت چندبُعدی این مفهوم، نقدشوندگی از جنبه‌های متفاوتی مورد بررسی قرار می‌گیرد : ۱- بُعد معاملاتی[۱۱] که به حجم و تعداد دفعات معاملات و فاصله زمانی آنها می‌پردازد (چوردیا و همکاران[۱۲]، ۲۰۰۵). ۲- بُعد قیمتی[۱۳] که بر شکاف بین قیمت خرید و فروش و تأثیر سفارش‌ها بر قیمت تأکید دارد (آمیهود[۱۴]، ۲۰۰۲). ۳- بعد زمانی[۱۵] که سرعت اجرای سفارش‌ها در بازار را مدنظر قرار می‌دهد. به دلیل همین چندبعدی بودن، ارائه یک معیار جامع

[1] Andrew Lo
[2] Adaptive Market Hypothesis - AMH
[3] Behavioral Finance
[4] Barberis & Thaler
[5] Peters
[6] Grossman & Stiglitz
[7] Noisy Rational Expectations Theory
[8] Adaptive Behavioral Finance
[9] Shiller
[10] Amihud & Mendelson
[11] Transaction-Based
[12] Chordia
[13] Price-Based
[14] Amihud
[15] Time-Based

برای اندازه‌گیری نقدشوندگی دشوار است. در پژوهش‌های پیشین، معیارهای گوناگونی پیشنهاد شده‌اند؛ از جمله تعداد و ارزش روزانه معاملات، تعداد شرکت‌های معامله‌شده، نسبت حجم معاملات به ارزش کل بازار، تعداد خریداران و دفعات خرید (تقوی و بیابانی، ۱۳۸۲). برخی مطالعات نیز ابعاد نقدشوندگی را در قالب چهار جنبه «زمان»، «سختی»، «عمق» و «جهندگی بازار» طبقه‌بندی کرده‌اند. به عنوان مثال پژوهشگرانی چون فریدل و مارتل[1] (۲۰۰۶)، لنگ و مافت[2] (۲۰۱۱)، سلیم حداد[3] (۲۰۱۲)، صلواتی و رسائیان[4] (۱۳۸۶)، سلطانی و بهرامی (۱۳۹۱)، ایزدی‌نیا و رسائیان (۱۳۸۹) از اختلاف قیمت پیشنهادی خرید و فروش سهام، به عنوان معیار نقدشوندگی سهام در پژوهش‌های خود استفاده نمودند. داتار، نایک و رادکلیف (۱۹۹۸) نسبت گردش را که آمیهود و مندلسون (۱۹۸۶) پیشنهاد نموده‌اند، به عنوان شاخصی برای نقدشوندگی استفاده کرده‌اند. اسعدی و شادمهر (۱۳۹۴) جهت سنجش متغیر نقدشوندگی از سه معیار شکاف نسبی قیمت سهام، میانگین عمق قیمتی سهام و گردش سهام استفاده نمودند. بادآور نهندی و ملکی‌نژاد (۱۳۸۹) نقدشوندگی سهام در زمان انتشار گزارشهای مالی در بورس اوراق بهادار تهران را مطالعه نمودند و نشان دادند که بین میانگین شکاف نسبی قیمت قبل و بعد از انتشار گزارش‌های مالی و میان میانگین عمق قیمتی سهام قبل و بعد از انتشار گزارش‌های مالی تفاوت هست، درحالی‌که بین میانگین دفعات گردش سهام قبل و بعد از انتشار گزارش‌های مالی تفاوتی وجود ندارد. همچنین هو[5] (۱۹۹۷) با بررسی داده‌های بورس اوراق بهادار توکیو طی سال‌های ۱۹۷۶ تا ۱۹۹۳، به این نتیجه رسید سهام با گردش بالاتر، به طور مقطعی بازده مورد انتظار پایین‌تری دارند. مدل مورد استفاده او نسخه‌ای تعدیل‌شده از الگوی هزینه معاملات آمیهود و مندلسون (۱۹۸۶)بود که گردش سهام را شاخص فراوانی معاملات سرمایه‌گذاران در نظر می‌گرفت. آمیهود و مندلسون (۱۹۸۶) اختلاف قیمت پیشنهادی خرید و فروش سهام را به عنوان شاخص نقدشوندگی معرفی کردند. یافته‌های آنان نشان داد که این اختلاف قیمتی رابطه مستقیمی با بازده مورد انتظار سرمایه‌گذاران دارد؛ به بیان دیگر، هرچه فاصله بین قیمت خرید و فروش بیشتر باشد، سرمایه‌گذاران انتظار بازده بالاتری خواهند داشت. شفیعی و همکاران(۱۴۰۴) نشان دادند که افشای اطلاعات زیست محیطی، اجتماعی و حاکمیتی تأثیر مثبت و معناداری بر نقدشوندگی سهام دارد؛ یعنی با افزایش افشای اطلاعات زیست محیطی، اجتماعی و حاکمیتی، نقدشوندگی سهام نیز افزایش می‌یابد. در ادامه دی[6] (۲۰۰۵) بررسی کرد که چگونه رشد بازارهای جهانی می‌تواند بر نقدشوندگی تأثیر بگذارد و آیا این عامل، تعیین‌کننده بازده‌های مقطعی بورس‌ها به شمار می‌رود یا خیر. او نقدشوندگی را از طریق نرخ گردش سهام (نسبت ارزش معاملات به ارزش بازار شرکت) اندازه‌گیری کرده و با استفاده از رگرسیون ترکیبی نشان داد که عواملی مانند سال، اندازه شرکت، نوع معامله، رقابت در جریان سفارش‌ها و نرخ رشد اقتصادی نقش بسزایی در تعیین نقدشوندگی ایفا می‌کنند. بر اساس نتایج، سرمایه‌گذاران از بازارهایی با نرخ گردش بالاتر، بازده بیشتری انتظار دارند. همچنین نحوه قیمت‌گذاری سهام نیز در میزان نقدشوندگی آنها مؤثر می‌باشد، بدین معنا که شرکت‌ها باید ارزیابی و قیمت‌گذاری عرضه اولیه عمومی سهامشان را با دقت فراوانی انجام دهند؛ زیرا اگر ارزش سهام بعد از عرضه اولیه افزایش داشته باشد، این امر موجب استقبال بیشتر مردم از خرید بعدی سهام(نقدشوندگی بیشتر سهام) شرکت‌ها می‌گردد، اما اگر ارزش سهام بعد از عرضه اولیه افزایش نیابد و یا اینکه کاهش یابد، این امر موجب ضررو زیان سرمایه‌گذاران می‌گرددو برنامه‌های بعدی فروش سهام با شکست مواجه

[1] Frieder & Martell
[2] Lang & Maffett
[3] Salim Hadad
[4] Datar, Naik & Radcliffe
[5] Hu
[6] Dey

خواهد شد (هوشیار و همکاران، ۱۴۰۲). ناروایسین و استانکویسین (۲۰۱۴) با بررسی بازارهای حوزه بالتیک دریافتند که نقدشوندگی سهام در استونی تحت تأثیر اهرم مالی بالا، نقدشوندگی دارایی‌ها و سودآوری شرکت قرار دارد، در حالی که در لتونی، اندازه شرکت و بازده دارایی‌ها اثرگذارترین عوامل محسوب می‌شوند. همچنین سابرامانیام و همکاران (۲۰۱۶)، نشان دادند که حضور سهامداران نهادی دولتی و غیردولتی می‌تواند بر نقدشوندگی سهام اثرگذار باشد. در این راستا، نقدشوندگی تحت تأثیر دو دسته عوامل اصلی قرار می‌گیرد: عوامل درون‌شرکتی مانند اندازه، سودآوری، شفافیت اطلاعات، ساختار مالکیت و میزان شناوری سهام (بوباکر و همکاران[1]، ۲۰۱۷) و عوامل بیرونی شامل شرایط کلان اقتصادی، نوسانات بازار، تغییرات نرخ بهره، اخبار سیاسی و مقررات (چوردیا و همکاران[2]، ۲۰۰۱).از سوی دیگر چونگ[3] و همکاران (۲۰۱۷) با استفاده از روش‌هایی همچون تحلیل مؤلفه‌های اصلی، رمزگذار خودکار و ماشین محدود بولتزمن، یک شبکه عصبی عمیق[4] سه‌لایه برای پیش‌بینی سهام طراحی کردند. آنها نشان دادند که این شبکه‌های عصبی، عملکردی بهتر از مدل‌های رگرسیون خطی در پیش‌بینی سری‌های زمانی قیمت سهام دارند. در همین حوزه مالاگرینو[5] و همکاران (۲۰۱۸) با بهره‌گیری از شبکه‌های بیزی به تحلیل شاخص بورس برزیل[6] پرداختند. نتایج مطالعه آنها که بر اساس رویدادهای خارجی مانند روند بسته‌شدن سایر بازارها انجام شد، دقتی معادل ۷۱ درصد برای این روش گزارش کردند. چانگ و هوانگ[7] (۲۰۲۴) نیز از الگوریتم‌های ژنتیک در ترکیب با تحلیل بنیادی و بهینه‌سازی تکرارشونده برای شناسایی راهبردهای انتخاب سهام و تخصیص سرمایه بهره گرفتند. یافته‌ها نشان داد که روش پیشنهادی آنها، حتی در شرایط صعودی یا نزولی بازار، می‌تواند به سرمایه‌گذاران در اتخاذ تصمیم‌های دقیق و کسب سود بیشتر کمک کند. همچنین لیو و سوزوکی[8] (۲۰۲۴) ارتباط بین نقدشوندگی سهام، محدودیت‌های مالی و نوآوری را در شرکت‌های کوچک و متوسط چین بررسی کرده و به این نتیجه رسیدند افزایش نقدشوندگی می‌تواند توان نوآوری این شرکت‌ها را تقویت کند. در مطالعه دیگری ستی و تری-پاتی[9] (۲۰۲۴) مدلی نوین برای تخمین نقدشوندگی و بازده سهام در بازار هند با استفاده از نسخه اصلاح‌شده الگوی قیمت گذاری دارایی‌های سرمایه‌ای تعدیل‌شده[10] مبتنی بر نقدشوندگی ارائه دادند. یافته‌های آنها نشان داد که تحلیل سری‌های زمانی نقدشوندگی منجر به بروز اثر نامتقارن بازگشت نقدشوندگی می‌شود. همچنین، عدم نقدشوندگی و اجزای تفکیک‌شده آن اثر معناداری بر نوسانات شرطی بازار دارد.

به طور کلی، پیش‌بینی نقدشوندگی و رفتار بازار سهام یک چالش جدی در تحلیل سری‌های زمانی محسوب می‌شود؛ چرا که بازارهای مالی ذاتاً سیستم‌هایی غیرخطی، پیچیده، پرتلاطم و متأثر از متغیرهای متعددی نظیر رویدادهای سیاسی، اخبار شرکتی، شرایط اقتصادی، نرخ‌های بهره و احساسات سرمایه‌گذاران هستند. طبق نظریه قدم زدن تصادفی[11] و بازار مالی کارا[12] حرکت‌های قیمتی تصادفی هستند و هیچ سرمایه‌گذاری نمی‌تواند صرفاً بر اساس داده‌های تاریخی یا فعلی، بازدهی بیش از میانگین بازار کسب کند؛ بنابراین امکان پیش‌بینی وجود نخواهد داشت (اوسار و دریفس[13]، ۲۰۰۰). با این وجود، بسیاری از پژوهشگران و فعالان بازار این فرض را به چالش کشیده‌اند و بر این باورند که متغیرهایی نظیر قیمت

[1] Boubaker
[2] Chordia
[3] Chong
[4] DNN
[5] Malagrino
[6] iBovespa
[7] Chang & Huang
[8] Liu & Suzuki
[9] Sethy & Tripathy
[10] LCAPM
[11] Random Walk Hypothesis
[12] Efficient Market Hypothesis
[13] Oussar & Dreyfus

سهام، نقدشوندگی، شاخص‌های بازار و حتی قیمت ابزارهای مشتقه تا حدی قابل پیش‌بینی هستند (چانگ[1] و همکاران، ۲۰۱۷). از همین رو، ارائه و آزمون مدل‌های گوناگون برای تحلیل رفتار بازار سهام مورد توجه محققان قرار گرفته است . در این میان، شبکه‌های عصبی به دلیل ویژگی‌های غیرخطی و ناپارامتریک، قابلیت برآورد تعداد زیادی پارامتر و انعطاف بالا در مدل‌سازی، جایگاه ویژه‌ای یافته‌اند. این روش‌ها توانایی تخمین روابط پیچیده بدون نیاز به فروض اولیه را دارند و در تحلیل‌های چندمتغیره و تعمیم‌یافته بسیار موفق عمل می‌کنند. همین امر باعث شده است که شبکه‌های عصبی در سال‌های اخیر به ابزار مؤثری برای پیش‌بینی بازارهای مالی تبدیل شوند (محبی و همکاران، ۲۰۲۱). تحلیل سری‌های زمانی نیز یکی از حوزه‌های مهم در علوم مختلف، بویژه امور مالی است که در آن پیش‌بینی دقیق آینده اهمیت حیاتی دارد. روش‌های کلاسیک سری زمانی در شناسایی روندهای خطی، غیرخطی و الگوهای فصلی توانمند هستند، اما هنگام مواجهه با بی‌نظمی‌ها یا پیچیدگی داده‌ها با محدودیت روبه‌رو می‌شوند. پیشرفت‌های اخیر در یادگیری ماشین، چارچوبی انعطاف‌پذیر برای تحلیل سری‌های زمانی فراهم کرده‌اند. این روش‌ها با در نظر گرفتن روابط غیرخطی و ویژگی‌های متنوع داده‌ها، قدرت پیش‌بینی بالایی دارند (ماکریداکیس[2] و همکاران، ۲۰۱۸). به عنوان نمونه نادری و اسماعیل‌زاده مقری (۱۳۹۹) با استفاده از الگوریتم کلونی زنبورعسل مصنوعی (ABC) و مقایسه آن با مدل‌های خطی مرسوم، تلاش کردند اختلاف قیمت پیشنهادی خرید و فروش سهام شرکت‌های سرمایه‌گذاری را کاهش دهند. نتایج نشان داد مدل غیرخطی مبتنی بر ABCعملکرد دقیق‌تری نسبت به روش‌های خطی مبتنی بر داده‌های پانل دارد. رنجبر ناوی و همکاران (۱۴۰۰) نیز با رویکرد داده‌های تابلویی به بررسی اولویت عوامل اثرگذار بر معیارهای نوسان و ریسک سقوط قیمت سهام در بورس تهران پرداختند. یافته‌های آنان نشان داد که عواملی همچون سررسید بدهی، محافظه‌کاری، ارتباطات سیاسی، محدودیت‌های مالی، نقدشوندگی، راهبرد تجاری، مالکیت نهادی، بیش‌ارزش‌گذاری و عدم شفافیت اطلاعاتی بر ریسک سقوط قیمت مؤثرند. در پژوهشی دیگر صالحی (۱۴۰۰) ه نقش حاکمیت شرکتی در نقدشوندگی بازار سهام پرداخت و نشان داد که قدرت بالاتر حاکمیت شرکتی با بهبود نقدشوندگی بر اساس معیارهایی مانند شاخص آمیهود، حجم معاملات و شکاف قیمتی ارتباط مثبت دارد. رضایی و همکاران (۱۴۰۱) نیز با بهره‌گیری از الگوریتم ژنتیک و روش حداقل افزونگی ـ حداکثر ارتباط[3] متغیرهای مؤثر بر نقدشوندگی را شناسایی کردند. نتایج نشان داد عواملی همچون ارزش بازار، شدت رقابت محصول، رشد تولید ناخالص داخلی، بازده حقوق صاحبان سهام، نرخ تورم، مالکیت خانوادگی و نوع بازار نقش تعیین‌کننده دارند. در ادامه قاسمیه و همکاران (۱۴۰۲) به پیش‌بینی نقدشوندگی در بورس تهران با بهره‌گیری از روش‌های یادگیری ماشین پرداختند. در این تحقیق شاخص‌هایی نظیر حجم و ارزش معاملات، نسبت گردش، آمیهود و اختلاف قیمت‌های پیشنهادی خرید و فروش برای اندازه‌گیری نقدشوندگی به کار گرفته شد. سپس سه مدل شامل پرسپترون چند لایه[4]، الگوی ترکیبی یادگیری عمیق[5] و الگوی کلاسیک رگرسیون خطی[6] آزمون شدند. نتایج نشان داد که مدل ترکیبی یادگیری عمیق از دقت بالاتری برخوردار است و آزمون‌های آماری نیز اختلاف میان این مدل و دو روش دیگر را در سطح اطمینان ۹۵ درصد تأیید کردند. یافته‌ها نشان می‌دهد که الگوی ترکیبی پیشنهادی عملکرد بهتری نسبت به دو مدل دیگر ارائه می‌دهد. در همین راستا، نظامی و همکاران (۱۴۰۴) به بررسی الگوهای پیش‌بینی ورشکستگی با تمرکز بر

[1] Chong
[2] Makridakis
[3] mRMR
[4] MLP
[5] MDL
[6] LR

روش‌های نوین مانند شبکه‌های عصبی و ماشین بردار پشتیبان پرداختند. نتایج پژوهش آنها حاکی از آن است که به‌کارگیری ساختارهای نوآورانه نظیر سیستم‌های هوشمند ترکیبی مبتنی بر داده‌کاوی، توان بالایی در شناسایی وضعیت ورشکستگی شرکت‌ها در سطح ملی دارد.

بنابراین با توجه به اهمیت نقدشوندگی سهام و به منظور افزایش توانایی پیش‌بینی نقدشوندگی توسط سرمایه‌گذاران در بازار سهام لازم است اقدامات احتیاطی که می‌تواند به آنهاکمک کند، اتخاذ شود (دپرن و کارتال[1]، ۲۰۲۱). تشخیص اقدامات احتیاطی لازم، از طریق شناسایی عوامل تعیین‌کننده نقدشوندگی سهام و پیش‌بینی آنها میسر خواهد شد. در بررسی ادبیات موضوع و پیشینه مطالعه‌های انجام‌شده با موضوع نقدشوندگی سهام، خلاها و تناقض‌هایی مشاهده می‌شود که ضرورت انجام‌دادن مطالعه حاضر را تبیین می‌کند. از جمله:

- نبود چارچوب تحلیلی یکپارچه و جامع برای تحلیل هم‌زمان متغیرهای اثرگذار. اکثر پژوهش‌های پیشین تنها به تأثیر چند متغیر خاص بر نقدشوندگی یا نوسانات قیمتی پرداخته‌اند (مثلاً: قدرت حاکمیت شرکتی، بدهی، مالکیت دولتی یا خصوصی، ارتباطات سیاسی و ...) اما این متغیرها به‌صورت جامع، هم‌زمان و در قالب یک الگو ترکیبی و دقیق مورد ارزیابی قرار نگرفته‌اند.
- عدم استفاده از الگوهای یادگیری عمیق یا مدرن در تحلیل نوسانات مشروط نقدشوندگی. برخی مطالعات (مانند نادری و اسماعیل‌زاده، رنجبر ناوی و ...) از الگوهای سنتی یا هوش مصنوعی اولیه (مثل ABC) برای بررسی اثرات استفاده کرده‌اند. با این حال، پویایی و ساختار شرطی نوسانات نقدشوندگی با رویکردهای پیشرفته‌تر یادگیری ماشین کمتر الگوسازی شده است.
- نبود مقایسه جامع دقت پیش‌بینی الگوهای مختلف هوش مصنوعی با الگوهای آماری سنتی در پیش‌بینی نقدشوندگی. اگرچه برخی پژوهش‌ها (مانند قاسمیه و همکاران، ۱۴۰۲) از الگوهای یادگیری استفاده کرده‌اند، اما مقایسه سیستماتیک و آماری دقیق بین الگوهای ترکیبی و کلاسیک در اکثر مطالعات انجام نشده یا محدود به یک یا دو الگو بوده است.

لذا به دلیل پیچیدگی فزاینده بازارهای مالی، نقش حیاتی نقدشوندگی در مدیریت ریسک، شواهد تجربی متناقض و ضعف در تعمیم نتایج، تحول در روش‌های داده‌کاوی و یادگیری ماشین و نیاز به تصمیم‌سازی بهتر برای سیاست‌گذاران و ناظران بازار انجام تحقیقات بیشتر در زمینه نقدشوندگی بازار سهام، نوسانات مشروط و استفاده از الگوهای نوین پیش‌بینی ضروری است و به منظور بررسی مجدد موارد و پرکردن خلاها تاحدممکن، نیاز به بررسی گسترده و تلفیق نتایج پژوهش‌های پیشین در موضوع نقدشوندگی سهام احساس می‌شود که برای رفع آن استفاده از روشی نظام‌مند برای بررسی ادبیات موضوع و پیشینه مناسب به نظر می‌رسد. بنابراین در این مطالعه، ابتدا کلیه عوامل تعیین‌کننده نقدشوندگی سهام تعیین شده و پس از انتخاب مناسب‌ترین الگو پیش‌بینی، به پیش‌بینی نقدشوندگی سهام پرداخته شده است.

این مطالعه در دو مرحله انجام شده است که در پاسخ به سؤالات پژوهش انجام شد. سؤالات عبارتند از:

۱. عوامل تعیین‌کننده نقدشوندگی سهام در بازار سرمایه کدامند؟

۲. چگونه با استفاده از این عوامل می‌توان نقدشوندگی سهام را پیش‌بینی کرد؟

۳. آیا الگوی جنگل‌های تصادفی ابزار مناسبی جهت پیش‌بینی نقدشوندگی سهام در بازار سرمایه است؟

[1] Depren & Kartal

۴. آیا پیش‌بینی نقدشوندگی سهام بر اساس الگوی جنگل‌های تصادفی نسبت به الگوهای پیش‌بینی نقدشوندگی سنتی از دقت بالاتری برخوردار است؟

۳- روش انجام پژوهش

در این مقاله با استفاده از یک رویکرد دو مرحله‌ای و با استفاده از الگوریتم هوش مصنوعی به پیش‌بینی نقدشوندگی سهام پرداخته شده است. این دو مرحله عبارتند از:

۱. مرور مقالات برای شناسایی معیارهای نقدشوندگی سهام از طریق تحلیل محتوا.

۲. استفاده از الگوریتم رگرسیون جنگل تصادفی جهت پیش‌بینی نقدشوندگی سهام.

۳-۱- روش گردآوری داده‌ها

این پژوهش بر حسب هدف که همان طراحی و تبیین الگوی پیش‌بینی نقدشوندگی سهام در بازار سرمایه است، کاربردی است که در دو بخش انجام شده است. بخشی از این پژوهش که مربوط به تاریخچه و سوابق و تدوین عوامل تعیین‌کننده نقدشوندگی سهام است، به صورت مطالعات کتابخانه‌ای انجام و به همین جهت از متون، مقالات، نشریات و سایت‌های مختلف برای جمع‌آوری اطلاعات استفاده شده است. با انجام مطالعات کتابخانه‌ای، پژوهش‌هایی که تأثیر عوامل خاصی را بر نقدشوندگی سهام بررسی و نقدشوندگی به عنوان متغیر وابسته در این پژوهش‌ها معرفی شده، استخراج شدند. نتایج نشان می‌دهد تأثیر بیش از ۷۰ عامل بر نقدشوندگی سهام، در مطالعات مختلف جهانی، بررسی شده است(برای مثال کوبنداگ و ایکنچی[1]، ۲۰۲۲). سپس براساس نظرسنجی از طریق مصاحبه با ده نفر از نخبگان که شامل اساتید دانشگاه در رشته حسابداری، مهندسی مالی و مدیریت مالی و خبرگان حوزه بازار سهام بودند و به روش گلوله برفی انتخاب شدند و عوامل بدست آمده ازطریق مطالعات کتابخانه‌ای بر اساس پرسشنامه‌ای که در ادامه ارائه شده، در اختیار خبرگان قرار گرفته و عوامل با توجه به نظرات خبرگان غربالگری شده و برخی از این عوامل، از جمله بازخرید سهام که سابقه اندکی در بازار سرمایه ایران داشته و در بازه زمانی منتخب قابلیت بررسی نداشته حذف شدند. با حذف این عوامل از فهرست متغیرهای مؤثر بر نقدشوندگی تعداد متغیرهای باقیمانده به ۵۳ متغیرکاهش یافت. تعداد دیگری از عوامل هم به دلیل مشابهت، ادغام و در نهایت ۴۷ عامل مهم به عنوان عوامل مؤثر بر نقدشوندگی سهام انتخاب شد و در بخش دوم برای پیش‌بینی نقدشوندگی سهام از روش‌های یادگیری ماشین استفاده شده است.

جدول ۱. پرسشنامه ارائه شده به خبرگان جهت غربالگری شاخص‌های نقدشوندگی سهام

معیار / شاخص	درجه اهمیت	میزان سابقه در بازار سهام ایران	قابلیت پیاده‌سازی	سهولت پیاده‌سازی

داده‌های مالی مورد نیاز برای طراحی الگو پیش‌بینی، از نرم افزارهای ره آورد نوین، تدبیر پرداز و سایت رسمی بورس اوراق بهادار تهران استخراج گردیده است.

۳-۲- قلمرو پژوهش

پژوهش حاضر از لحاظ مکانی در بورس اوراق بهادار تهران، از لحاظ زمانی، طی سال‌های ۱۴۰۱-۱۳۹۷ صورت پذیرفته است و از لحاظ موضوعی نیز در حوزه سرمایه‌گذاری و مدیریت مالی قرار دارد.

[1] Cobandag & Ekinci

۳-۳- جامعه و نمونه آماری

جامعه آماری پژوهش شامل تمام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است (۶۶۶) شرکت که بر اساس یک سری قیود محدود کننده که در جدول (۱) بیان شده، تعداد ۱۷۱ شرکت به عنوان نمونه انتخاب شدند.

جدول ۱. نحوه انتخاب نمونه آماری

تعاریف شرایط برای انتخاب نمونه آماری	جمع	جمع
تعداد کل شرکت‌های پذیرفته شده در بورس تا پایان سال ۱۴۰۱		۶۶۶
تعداد شرکت‌هایی که در دامنه زمانی ۱۳۹۷ تا ۱۴۰۱ فعال نبودند	۷۳	
تعداد شرکت‌هایی که بعد از سال ۱۳۹۷ در بورس پذیرفته شده‌اند	۶۱	
تعداد شرکت‌هایی که جزء هلدینگ، سرمایه‌گذاری‌ها ، واسطه‌گری‌های مالی، بانک، بیمه و لیزینگ‌ها (به علت متفاوت بودن روش‌های حسابداری)	۱۴۸	
تعداد شرکت‌هایی که در دامنه زمانی پژوهش تغییر سال مالی داده و یا سال مالی آنها منتهی به اسفند نبوده (برای یکسان بودن دوره مالی)	۴۸	
تعداد شرکت‌هایی که سهام آنها در دامنه زمانی پژوهش توقف فعالیت داشته‌اند:	۸۶	
تعداد شرکت‌هایی که اطلاعات آنها در دامنه زمانی پژوهش در دسترس نیست:	۷۹	
جمع		۴۹۵
تعداد شرکت‌های غربالگری شده		۱۷۱

۴- روش تجزیه و تحلیل

در این پژوهش، به‌منظور تجزیه‌وتحلیل داده‌های گردآوری‌شده، اطلاعات مربوط به شرکت‌های نمونه از پایگاه اطلاعاتی ره‌آورد نوین ۳ استخراج گردید. جهت سازماندهی و آماده‌سازی اولیه داده‌ها، از نرم‌افزار Excel برای تشکیل پایگاه داده استفاده و سپس فرآیند تحلیل با استفاده از زبان برنامه‌نویسی Python در محیط Visual Studio Code انجام شد.

برای ارزیابی الگو پیشنهادی، از الگوریتم یادگیری ماشین جنگل تصادفی (Random Forest Regressor) استفاده گردید. مراحل اجرا و تنظیمات الگو به شرح زیر است:

- تقسیم داده‌ها به آموزش و آزمون: داده‌ها با استفاده از تابع train_test_split از کتابخانه sklearn به دو بخش آموزش (۸۰٪) و آزمون (۲۰٪) تقسیم شدند.
- تنظیمات الگوریتم: در گام نخست، الگو با ۱۰۰ درخت تصمیم‌گیری (n_estimators=100) پیاده‌سازی شد. پارامتر max_depth برابر مقدار پیش‌فرض None قرار گرفت تا درخت‌ها تا عمق لازم رشد کنند. معیار تقسیم شاخه‌ها بر اساس کاهش خطای میانگین مربعات انجام گرفت.
- اعتبارسنجی متقابل: برای جلوگیری از بیش‌برازش و افزایش اعتماد به الگو، اعتبارسنجی با روش K-Fold Cross-validation و با ۵ بخش انجام شد. میانگین امتیاز حاصل از اعتبارسنجی به عنوان شاخص ارزیابی عمومی الگو ثبت شد.
- مقیاس‌بندی داده‌ها: پیش از آموزش الگو، ویژگی‌های عددی با استفاده از StandardScaler استانداردسازی شدند تا الگو نسبت به تفاوت مقیاس بین متغیرها حساس نباشد.
- اصلاح عدم تعادل داده‌ها: با بررسی توزیع متغیر هدف (نقدشوندگی)، در صورت مشاهده عدم تعادل، تکنیک oversampling با استفاده از روش SMOTE اعمال شد تا نمونه‌های اقلیت تقویت شوند.

• تحلیل حساسیت پارامترها: به منظور یافتن بهترین تنظیمات، از GridSearchCV جهت بررسی ترکیب‌های مختلف n_estimators و max_depth استفاده شد. نتایج این تحلیل در انتخاب تنظیمات نهایی الگو مؤثر بودند.

تمامی مراحل فوق به گونه‌ای طراحی و اجرا شدند که دقت الگو، تفسیرپذیری نتایج و قابلیت تعمیم در شرایط مختلف بازار سرمایه ایران حفظ گردد.

۴-۱- الگوریتم رگرسیون جنگل تصادفی

برخی از الگوریتم‌های هوش مصنوعی شامل تعداد زیادی از الگوریتم‌های تصمیم‌گیری هستند که به آنها یادگیرنده‌های پایه گفته می‌شود و در زمره روش‌های یادگیری گروهی قرار دارند. یادگیرنده‌های پایه معمولاً شامل الگوریتم‌های یادگیری پایه مثل درخت تصمیم هستند. جنگل‌های تصادفی الگوریتم‌های جدیدی از حوزه هوش مصنوعی هستند که بر مبنای حجم انبوهی از درخت‌های تصمیم کلاس‌بندی و رگرسیونی قرار دارند.

تاکنون در پژوهش‌های بسیار زیادی از الگوریتم جنگل تصادفی استفاده شده است. تجربه‌های علمی و عملی ثابت کرده است که روش‌های یادگیری گروهی به دلیل توانایی در تقویت یادگیرنده‌های ضعیف، کارایی بسیار زیادی دارند (هاگان[1]، ۲۰۱۴). در الگوریتم جنگل تصادفی برای ایجاد هریک از درختان، به عنوان یادگیرنده پایه، دسته‌ای متفاوت از مجموعه کل داده‌ها با درنظرگرفتن احتمال انتخاب دوباره برخی از داده‌ها در نظر گرفته می‌شود. اندازه هر دسته نمونه انتخاب‌شده برابر با اندازه مجموعه کل داده‌هاست. ازآنجایی‌که ترکیب چند الگوریتم یادگیری ماشین دقیق‌تر از یک الگوریتم است، در الگوریتم جنگل تصادفی، این امر سبب می‌شود گره‌ها قدرت مجموعه‌های منحصربه‌فرد و منفرد در هر طبقه را بیشتر کنند.

مراحل پیاده‌سازی الگوریتم جنگل تصادفی به شرح ذیل است:

۱. اگر اندازه نمونه‌های موجود در مجموعه کل داده‌ها برابر با N باشد، به اندازه تعداد درخت‌های مدنظر به صورت تصادفی و با درنظرگرفتن مجوز انتخاب بیش از یک‌بار یک نمونه منحصر به فرد از داخل مجموعه کل داده‌ها، مجموعه‌های به اندازه N تشکیل داده می‌شود

۲. به ازای هرکدام از مجموعه‌هایی که در گام اول انتخاب شدند، یک درخت تصمیم منحصربه فرد ایجاد خواهد شد.

۳. به ازای تک‌تک درخت‌های موجود نتایج، ثبت‌شده و برای تصمیم نهایی، رأی‌گیری انجام می‌شود.

۴-۲- مراحل اجرای الگوریتم

۱) بررسی تعادل داده‌ها:

توزیع متغیر هدف (نقدشوندگی سهام) مورد بررسی قرار گرفته و با استفاده از نمودار هیستوگرام تحلیل شده است. در صورت وجود عدم تعادل، روش SMOTE برای افزایش نمونه‌های اقلیت در آموزش اعمال شده است.

۲) اعتبارسنجی متقابل:

علاوه بر تقسیم داده‌ها با train_test_split، برای اعتبارسنجی الگو از روش K-Fold Cross-validation استفاده شده است. این روش کمک کرده تا دقت الگو بالا رود و از بیش‌برازش جلوگیری شود.

[1] Hagan

۳) معیارهای ارزیابی:

در نسخه جدید، ارزیابی الگو شامل معیارهای MAE، RMSE و R^2 نیز شده است تا تحلیل جامع‌تری از عملکرد الگو ارائه گردد.

۴) تنظیمات الگو جنگل تصادفی:

پارامترهای الگو مانند n_estimators و max_depth مورد بررسی قرار گرفته‌اند. تحلیل حساسیت با استفاده از GridSearchCV انجام شده و بهترین تنظیمات برای افزایش دقت الگو انتخاب شده است. توضیحات کامل این بخش در قسمت پیاده‌سازی الگوریتم آورده شده‌اند.

کتابخانه‌های مورد استفاده

```
import pandas as pd
from sklearn.model_selection import train_test_split, cross_val_score, GridSearchCV
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import SMOTE
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
```

بارگذاری داده‌ها

```
data = pd.read_excel('C:\\Users\\Morteza\\Desktop\\Random Forest Regressor.xlsx')
```

بررسی توزیع متغیر هدف

```
sns.histplot(data['Liq'], kde=True)
plt.title('Distribution of Liquidity')
plt.show
```

تقسیم ویژگی‌ها و هدف

```
X = data[['Roa', 'Risk', 'Rmc', 'Return', 'Beta', 'Roe', 'Lev']]
y = data['Liq']
```

تقسیم داده‌ها

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

بررسی و اصلاح عدم تعادل با SMOTE

```
smote = SMOTE(random_state=42)
X_train, y_train = smote.fit_resample(X_train, y_train)
```

مقیاس‌بندی داده‌ها

```
scaler = StandardScaler
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)
```

تعریف الگو با تنظیمات اولیه

```
model = RandomForestRegressor(n_estimators=100, random_state=42)
```

اعتبارسنجی متقابل

```
cv_scores = cross_val_score(model, X_train, y_train, cv=5, scoring='neg_mean_squared_error')
print(f'Average Cross-Validation MSE: {-cv_scores.mean()}')
```

آموزش الگو

```
model.fit(X_train, y_train)
```

پیش‌بینی و ارزیابی الگو

```
y_pred = model.predict(X_test)
mse = mean_squared_error(y_test, y_pred)
mae = mean_absolute_error(y_test, y_pred)
rmse = np.sqrt(mse)
r2 = r2_score(y_test, y_pred)
print(f'MSE: {mse}, MAE: {mae}, RMSE: {rmse}, R²: {r2}')
```

بررسی اهمیت ویژگی‌ها

```
importances = model.feature_importances_
features = X.columns
importance_df = pd.DataFrame({'Feature': features, 'Importance':
importances}).sort_values(by='Importance', ascending=False)
print(importance_df)
```

تحلیل پارامترهای الگو با GridSearchCV

```
param_grid} =
' n_estimators,[۱۵۰ ,۱۰۰ ,۵۰]:'
' max_depth': [None, 10, 20]
grid_search = GridSearchCV(RandomForestRegressor(random_state=42), param_grid, cv=5,
scoring='neg_mean_squared_error')
grid_search.fit(X_train, y_train)
print(f'Best Parameters: {grid_search.best_params_}')
```

در این پژوهش، برای پیش‌بینی نقدشوندگی سهام از الگوریتم رگرسیون جنگل تصادفی (Random Forest Regressor) استفاده شده است. مراحل اجرای الگوریتم شامل موارد زیر است:

• پیش‌پردازش داده‌ها: داده‌ها از فایل اکسل بارگذاری شده و ویژگی‌های مستقل شامل: Roa، Risk، Rmc، Return، Beta، Roe و Lev انتخاب گردیدند. متغیر وابسته Liq بود.

• بررسی تعادل داده‌ها: توزیع متغیر هدف با استفاده از نمودار هیستوگرام تحلیل شد. در صورت مشاهده عدم تعادل، از روش SMOTE برای اصلاح داده‌ها استفاده گردید.

• مقیاس‌بندی داده‌ها: ویژگی‌ها با استفاده از StandardScaler نرمال‌سازی شدند.

• اعتبارسنجی الگو: علاوه بر تقسیم اولیه با تابع train_test_split، از روش K-Fold Cross-validation جهت جلوگیری از بیش‌برازش و افزایش دقت الگو بهره گرفته شد.

• آموزش الگو و پیش‌بینی: الگو با تعداد ۱۰۰ درخت (n_estimators=100) آموزش داده شد. همچنین ارزیابی عملکرد با استفاده از معیارهای MSE، MAE، RMSE و R^2 انجام شد تا تحلیل جامع‌تری صورت گیرد.

• تحلیل حساسیت الگو: با بهره‌گیری از GridSearchCV تنظیمات بهینه برای تعداد و عمق درخت‌ها n_estimators و max_depth مشخص گردید.

• اهمیت ویژگی‌ها: با بررسی مقادیر feature_importance، میزان تأثیر هر ویژگی در عملکرد الگو تعیین شد.

۱. بررسی تعادل داده‌ها: توزیع متغیر نقدشوندگی با استفاده از نمودار هیستوگرام بررسی شد. در صورت مشاهده عدم تعادل، از روش SMOTE جهت افزایش نمونه‌های اقلیت استفاده گردید.

۲. اعتبارسنجی متقابل: در کنار تقسیم اولیه داده‌ها، از اعتبارسنجی K-Fold Cross-validation بهره گرفته شد تا از بیش‌برازش جلوگیری شده و دقت پیش‌بینی افزایش یابد.

۳. ارزیابی جامع عملکرد الگو: علاوه بر MSE، معیارهای MAE، RMSE و R^2 نیز در تحلیل عملکرد الگو وارد شدند تا دید دقیق‌تری از توان الگو ارائه گردد.

۴. تحلیل تنظیمات الگو جنگل تصادفی: تنظیمات الگو از جمله تعداد و عمق درخت‌ها با استفاده از GridSearchCV بهینه‌سازی شدند. نتایج این تحلیل در بخش الگوسازی مقاله گنجانده شده است.

با توجه به اهمیت نقدشوندگی در تصمیم‌گیری‌های سرمایه‌گذاران و سیاست‌گذاران مالی، هدف این پژوهش بررسی عوامل مؤثر بر نقدشوندگی سهام با بهره‌گیری از الگوریتم‌های یادگیری ماشین است. استفاده از جنگل تصادفی به دلیل انعطاف‌پذیری بالا و قابلیت درک اهمیت ویژگی‌ها، روش مناسبی برای الگوسازی رفتار بازار تلقی می‌گردد.

نتایج حاصل از الگو رگرسیون جنگل تصادفی نشان داد که الگوریتم با تنظیمات بهینه قادر است نقدشوندگی سهام را با دقت بالا پیش‌بینی کند. استفاده از معیارهای مختلف ارزیابی عملکرد، اعتبارسنجی متقابل و تحلیل ویژگی‌ها موجب افزایش قابلیت اعتماد نتایج شده است. پیشنهاد می‌شود در مطالعات آتی، مجموعه داده‌های متنوع‌تری با توزیع‌های مختلف نیز بررسی شوند.

۴-۳- متغیرهای تحقیق

با توجه به اهداف پژوهش و همچنین پژوهش‌های سعیدی و دادار(۱۳۸۸)، ستایش و جمالیان(۱۳۸۸)، یحیی‌زاده‌فر و خرمدین(۱۳۸۷)، عسکری و همکاران(۱۳۹۴)، مهرانی و رساییان (۱۳۸۸)، رحمانی و حاجی مرادخانی(۱۳۹۶) و ... که به بررسی و تحلیل نقدشوندگی سهام پرداخته‌اند، متغیرهای پژوهش به شرح جدول (۲) انتخاب شدند:

جدول۲ . متغیرهای پژوهش و نحوه محاسبه آنها

متغیر	نحوه محاسبه
۱.اختلاف قیمت پیشنهادی خرید و فروش	اختلاف قیمت پیشنهادی خرید و فروش PBA $AP_{i,t}$ بهترین قیمت پیشنهادی فروش سهام i در دوره t تا $BP_{i,t}$ بهترین قیمت پیشنهادی خرید سهام i در دوره t تا و تعداد روزهای معامله سهام D در ماه i $PBA_{i,z} = \frac{1}{D_{i,t}} \sum_{d=1}^{D_{i,t}} (AP_{i,t} - BP_{i,t}) \,/\, (0.5\, AP_{i,t} + 0.5\, BP_{i,t})$
۲. گردش سهام	$(TO)\ \ LI = \frac{\text{تعداد سهام معامله شده شرکت}}{\text{کل سهام منتشر شده شرکت}}$
۳. معیار حجم معاملات	p_i= قیمت سهام در معامله i ام، q_i= تعداد سهام معامله شده در معامله i ام، N_t= تعداد معاملات در بازه زمانی سالانه $TU = \sum_{i-1}^{N_t} p_i \times q_i$

متغیر	نحوه محاسبه
۴. معیار گردش معاملات	$Volume_{i,d}$ تعداد سهام i که در روز d در بازار معامله می‌شود. Share out Standing تعداد سهامی که توسط شرکت منتشر شده و در بازار به فروش رسیده است و در ترازنامه شرکت با عنوان سهام سرمایه نمایش داده می‌شود. $Days_t$ تعداد روزهایی که در ماه t امکان معامله سهام i وجود دارد. $$Tornover = \frac{1}{Days_t}\sum_{d=1}^{Days_t}\frac{Volume_{i,d}}{Share\ out\ Standing_{i,d}}$$
۵. درصد روزهایی انجام معامله (PDT):	$$\frac{\text{تعداد روز روزهایی که سهم مورد نظر حداقل یک بار معامله شده است}}{\text{تعداد کل روز که‌هایی بورس فعالیت معاملاتی دارد}}$$
۶. تعداد دفعات معاملات	تعداد معاملات یک سهم در بازه سالانه است. {تعداد دفعاتی که در یک روز معاملات (خرید و فروش) انجام شده است}
۷. گردش سهام شناور	$$FLTO = \frac{\text{تعداد سهام معامله شده}}{\text{تعداد سهام شناور}}$$
۸. ارزش معاملات	حجم معاملات × قیمت معامله سهم
۹. درصد سهام شناور آزاد	درصدی از کل سرمایه شرکت است که جهت معامله در بازار سهام در دسترس باشد یا قسمتی از سهام یک شرکت است که بدون هیچ گونه محدودیتی قابل معامله باشد (توسط بورس محاسبه و به صورت گزارشات فصلی ارائه می‌شود).
۱۰. زمان انتظار معامله	$$WAIT = \frac{240}{\text{تعداد دفعات معاملات}}$$ به دلیل محاسبه این معیار به صورت سالانه عدد ۲۴۰ به عنوان تعداد روزهای قابل معامله در سال استفاده شده است.
۱۱. نسبت جریان	$$\frac{\text{ارزش معاملات}}{\text{زمان انتظار معاملات}}$$
۱۲. نسبت عدم نقد شوندگی آمیهود (اثر قیمتی)	$TVOL_{it}$= حجم معاملات در روز، P_{it}= قیمت سهام در پایان روز، P_{it-1}= قیمت سهام در ابتدای روز، K= تعداد روزهای معاملات در طول سال $$AMIHUD = \frac{\left\vert \text{بازده} \right\vert}{\text{حجم معاملات}} = \frac{1}{K}\sum_{t=1}^{K}\frac{\frac{\vert P_{it}-P_{it-1}\vert}{P_{it-1}}}{TVOL_{it}}$$
۱۳. نسبت نقد شوندگی آمیوست	$$AMIVEST = \frac{\text{ارزش معاملات}}{\left\vert \text{بازده} \right\vert} = \frac{1}{K}\sum_{t=1}^{K}\frac{TVOL_{it}\times P_{it}}{\frac{\vert P_{it}-P_{it-1}\vert}{P_{IT-1}}}$$
۱۴. رتبه نقد شوندگی	$$\text{رتبه نقد شوندگی} = \frac{1}{\frac{1}{\text{متوسط ارزش روز}}+\frac{1}{\text{حجم معاملات}}+\frac{1}{\text{تعداد سهام معامله شده}}+\frac{1}{\text{تعداد روزهای معاملاتی}}+\frac{1}{\text{تعداد دفعات معاملات}}+\frac{1}{\text{تعداد خریداران}}}$$
۱۵. عمق ریالی (معیار اطلاعاتی)	P_A= قیمت پیشنهادی فروش(پایین‌ترین قیمت) Q_A= مقدار پیشنهادی فروش (بهترین مقدار) P_B= قیمت پیشنهادی خرید (بالاترین قیمت) Q_B= مقدار پیشنهادی خرید (بالاترین مقدار) $$DM = P_A \times Q_A + P_B \times Q_B$$ $$RD = \frac{P_A \times Q_A + Q_B \times P_B}{2}$$

متغیر	نحوه محاسبه
۱۶. شکاف مطلق قیمت‌های پیشنهادی خرید و فروش	P_A= قیمت پیشنهادی فروش P_B= قیمت پیشنهادی خرید $ABS = P_A - P_B$
۱۷. نسبت نقد شوندگی برونر	$\|r_t\|$= قدر مطلق تغییرات قیمت در بازه زمانی سالانه N_t= تعداد معاملات در بازه زمانی سالانه $LR_3 = \sum_{i=1}^{N} \|r_t\| \times \frac{1}{N_t}$
۱۸. معیار بازده صفر	$Zero\ Return$= تعداد روزهایی با بازده صفر برای سهام شرکت i در ماه t Tradig day= تعداد روزهای معاملاتی شرکت i در ماه t است. $ZERO_{i,t} = ZERO\ Return_{i,t} / Tradig\ day_{i,t}$
۱۹. تعداد روزهای معامله	تعداد روزهایی که در یک بازه زمانی مشخص در آن مبادله سهم رخ داده است.
۲۰. حجم نسبی	حجم معاملات سهام هر شرکت / میانگین حجم معاملات شرکت بازارهای اوراق بهادار
۲۱. اندازه معاملات	$TS = \frac{\text{حجم معاملات روزانه (تعداد سهم)}}{\text{دفعات معامله روزانه}}$
۲۲. سرعت گردش سهام	$TV = \frac{\text{کل ارزش سهام معامله شده در هر روز}}{\text{کل ارزش روزانه بازار سهام}}$
۲۳. ارزش بازار شرکت	کل سهام منتشر شده شرکت × قیمت معامله در آن مقطع
۲۴. نرخ گردش	V= حجم معاملات، N= تعداد سهام شرکت $Liquidity = \frac{V}{N}$
۲۵. حجم نسبی معاملات (RTV)	$RTV = \frac{\text{حجم معاملات هر سهم شرکت}}{\text{میانگین حجم معاملات شرکت موردهای بررسی}}$
۲۶. معیار نسبت جاری	نسبت جاری $= \frac{\text{دارایی جاری‌های}}{\text{بدهی جاری‌های}}$
۲۷. نسبت گردش سهام (فرکانس معامله)	$V_{i,d}$= حجم معاملات سهم i در روز معاملاتی d ام SO_i= تعداد سهام شناور، $TR_{i,m}$= نسبت گردش سهام i در ماه m است. $Day_{i,m}$= تهداد روزهای معاملاتی سهم i در ماه m $TR_{i,m} = \frac{1}{Day_{i,m}} \sum_{d=1}^{Day_{i,m}} \frac{V_{i,d}}{SO_i}$
۲۸. شکاف قیمت مؤثر (ES)	$ES = 2 \times \|Price - M\| / M$ M= قیمت متوسط Price= آخرین قیمت معامله روز
۲۹. عمق بازار (MD)	$Dlog_t = Ln(q_t^A) + Ln(q_t^B)$ q_t^B و q_t^A به ترتیب حجم تقاضای خرید و فروش سهام مربوط به بهترین پیشنهادی قیمتی هستند.
۳۰. نسبت گردش حجم معاملات (TOR)	$TOR = \frac{TV}{S}$ TV= حجم معاملات، S= تعداد سهام منتشر

متغیر	نحوه محاسبه
۳۱. تعدیل تعداد روزهای بدون معامله براساس گردش (LM)	$NOZV_{i,t}$= تعداد روزهای بدون معامله سهام i در ماه t $\text{turnover}_{i,t}$= نرخ گردش سهام در ماه NOTD_t= تعداد کل روزهای معامله در بازار در ماه t $LM_{i,t} = \left[NOZV_{i,t} + \frac{1/(turnover_{i,t})}{480000}\right] \times \frac{21}{NOTD_t}$
۳۲. معیار محاسبه نسبت بازده‌های مفقودی روزانه	n= تفاوت زمانی (به روز) بین آخرین تاریخ معاملاتی بورس در یک ماه و آخرین تاریخ معامله سهام مورد نظر در ماه مربوط است. $BEEDLES = (100 - [100 / (n + 1)] / 100$
۳۳. میانگین ارزشی هر بار مبادله	$\frac{\text{حجم ریالی معاملات}}{\text{تعداد دفعات معاملات}}$
۳۴. میانگین تعدادی هربار مبادله	$\frac{\text{حجم تعدادی معاملات}}{\text{تعداد دفعات معاملات}}$
۳۵. تعداد خریداران	تعداد افرادی که در یک روز اقدام به خرید یا فروش سهام نموده‌اند.
۳۶. میانگین تعداد مبادلات توسط افراد	$\frac{\text{تعداد دفعات معامله}}{\text{تعداد افراد}}$
۳۷. کوواریانس تغییرات قیمت	محاسبه کوواریانس تغییرات قیمت در بازه مورد نظر
۳۸. واریانس بازده	بازده کل را بر اساس رابطه زیر محاسبه نموده و سپس واریانس این نسبت محاسبه می‌شود. $R_e = \frac{(\text{تفاوت قیمت سهام در اول و آخر دوره}) + \text{مزایای سهام جایزه} + \text{مزایای حق تقدم} + \text{سود نقدی}}{\text{اولین قیمت سهم در ابتدای سال مالی}}$
۳۹. تغییر پذیری بازده سهام	لگاریتم طبیعی انحراف معیار بازده‌های ورقه سهام
۴۰. حق الزحمه حسابرسی	لگاریتم طبیعی مجموع حق‌الزحمه پرداخت شده به حسابرس مستقل بابت خدمات حسابرسی مالی و مالیاتی
۴۱. تعداد روزهای معاملاتی	تعداد روزهایی که در بازه زمانی یک ماهه در آن معامله‌ای انجام شده است.
۴۲. تعداد سهام معامله شده	کل سهامی که در بازه زمانی یک روزه در بورس اوراق بهادار معامله شده است.
۴۳. سرمایه ارتباطی	به کمک شاخص سهم بازار اندازه‌گیری می‌شود که از طریق فروش خالص سالانه شرکت بر کل فروش در همان صنعت به دست می‌آید.
۴۴. قیمت سهام	لگاریتم طبیعی قیمت سهام شرکت در پایان سال
۴۵. نرخ بازگشت سرمایه	$\text{ROI} = \frac{\text{سود خالص}}{\text{هزینه سود گذاری}} \times 100$
۴۶. ریسک پرتفوی	$\sigma_p^2 = \sum_{i=1}^{n}\sum_{j=1}^{n} W_i W_j \sigma_i \sigma_j \rho_{ij}$ σ_p^2. واریانس پرتفوی. W_i و W_j : وزن‌های دارایی‌های (i) و (j) در پرتفوی هستند. σ_i و σ_j. انحراف معیار دارایی‌های (i) و (j) هستند. ρ_{ij}. ضریب همبستگی بین بازده دارایی‌های (i) و (j) است.

متغیر	نحوه محاسبه
۴۷. مدیریت و استراتژی پوشش ریسک*	$d^{s}(t,s)=$ توابعی با مقادیر مثبت هستند. برای سادگی محاسبات، ثابت مثبت $d^{b,s}(t,s)$ که $d^{s}(t,s)=d$ به‌کار گرفته شده است. $y_{n\delta}=\begin{cases} Y^{b}(n\delta,S_{n\delta}) & \text{if} \quad y_{(n-1)\delta}<Y^{b}(n\delta,S_{n\delta}) \\ y_{(n-1)\delta} & \text{if} \quad Y^{b}(n\delta,S_{n\delta})\le y_{(n-1)\delta}<Y^{s}(n\delta,S_{n\delta}) \\ Y^{b}(n\delta,S_{n\delta}) & \text{if} \quad y_{(n-1)\delta}>Y^{b}(n\delta,S_{n\delta}) \end{cases}$ در این روش می‌توان از کران‌های خرید و فروش زیر استفاده کرد. $Y^{b}(t,s)\approx\max\{\Delta^{bs}(t,s)-d^{b}(t,s),0\}$ $Y^{s}(t,s)\approx\max\{\Delta^{bs}(t,s)-d^{s}(t,s),1\}$

*فرض کنید سبدی از M اختیار با دارایی پایه یکسانی ایجاد شده است و با $m=1,2,\dots,M$ اندیس گذاری شده است. زمان شروع و سررسید m امین اختیار با t_m و T_m نشان داده شده می‌شوند. عملکرد استراتژی پوشش ریسک را

$$\hat{\eta}=(\frac{1}{M}\sum_{m=1}^{M}\overline{err}_{m}^{2})^{1/2}$$
$$\overline{err}m^{2}=e^{-r(T_m-t_m)}err(t_m,T_m;\delta)$$

در نظر گرفته و آن را خطای پیش بینی تحقیق می‌نامیم. دوره‌های متوالی پوشش ریسک را با شاخص $k=0,1,2,\dots$ اندیس‌گذاری می‌کنیم. سبد اختیارها در k امین دوره شامل M_k اختیار است که اولین و آخرین معامله بر m امین اختیار در دوره k ام، به ترتیب $t_{k,m}$ و $T_{k,m}$ است. در نتیجه خطای تحقق یافته برای k امین به صورت زیر خواهد بود:

$$\hat{\eta}_{k}=\left((\frac{1}{M}\sum_{m=1}^{M}\overline{err}_{k,m}^{2})\right)^{1/2}$$
$$\overline{err}m^{2}=e^{-r(T_m-t_m)}err(t_m,T_m;\delta)$$

۵- یافته‌های پژوهش

این مطالعه با هدف «ارائه الگو بهینه پیش‌بینی نقدشوندگی سهام» در دو مرحله انجام شد. در ابتدا، داده‌های متغیرهای مربوطه(عوامل مؤثر در نقدشوندگی سهام) در بازه زمانی ۵ ساله از سال ۱۳۹۷ تا ۱۴۰۱ استخراج شدند. پس از استخراج داده‌های متغیرها از منابع اطلاعاتی معتبر، از الگوریتم‌های یادگیری ماشینی برای پیش‌بینی نقدشوندگی سهام استفاده شد. ۹۰ درصد داده‌ها به عنوان داده یادگیری و ۱۰ درصد به عنوان داده تست استفاده شد. نتایج به دست آمده از الگو جنگل‌های تصادفی حاکی از دقت و کارایی بالای این الگو در پیش‌بینی نقدشوندگی سهام است.

یافته‌های کلیدی نشان می‌دهند که ویژگی‌های Beta (میزان تغییرات قیمت سهام نسبت به تغییرات بازار) و Rmc (معیار ریسک مالی که نشان‌دهنده میزان تغییرات و نوسانات در بازدهی سهام است) بیشترین تأثیر را بر نقدشوندگی سهام دارند و الگو جنگل‌های تصادفی این دو ویژگی را به عنوان مؤثرترین عوامل در تعیین میزان نقدشوندگی شناسایی کرده است. همچنین خطای مربعی میانگین الگو و مقدار پایین MSE نشان‌دهنده دقت بالای پیش‌بینی‌های انجام شده توسط الگو است. این یافته‌ها نقش مهمی در ارائه الگویی دقیق‌تر برای پیش‌بینی نقدشوندگی سهام ایفا می‌کنند و می‌توانند به سرمایه‌گذاران و تحلیل‌گران مالی در اتخاذ تصمیمات بهتر کمک کنند. الگو ارائه شده می‌تواند به عنوان یک ابزار قدرتمند در تحلیل‌های مالی و سرمایه‌گذاری مورد استفاده قرار گیرد. در جدول ۳ اهمیت نسبی ویژگی‌های مختلف در الگو نمایش داده شده است. این جدول نشان می‌دهد که کدام ویژگی‌ها بیشترین تأثیر را در پیش‌بینی نقدشوندگی دارند.

جدول ۳. اهمیت نسبی ویژگی‌ها در الگو جنگل‌های تصادفی

متغیرهای پژوهش	میزان تأثیر در الگو
Beta	۱۷/۱۰٪
Rmc	۱۶/۷۹٪
Roe	۱۶/۴۲٪
Return	۱۵/۶۷٪
Risk	۱۱/۹۹٪
Lev	۱۱/۶۲٪
Roa	۱۰/۴۲٪

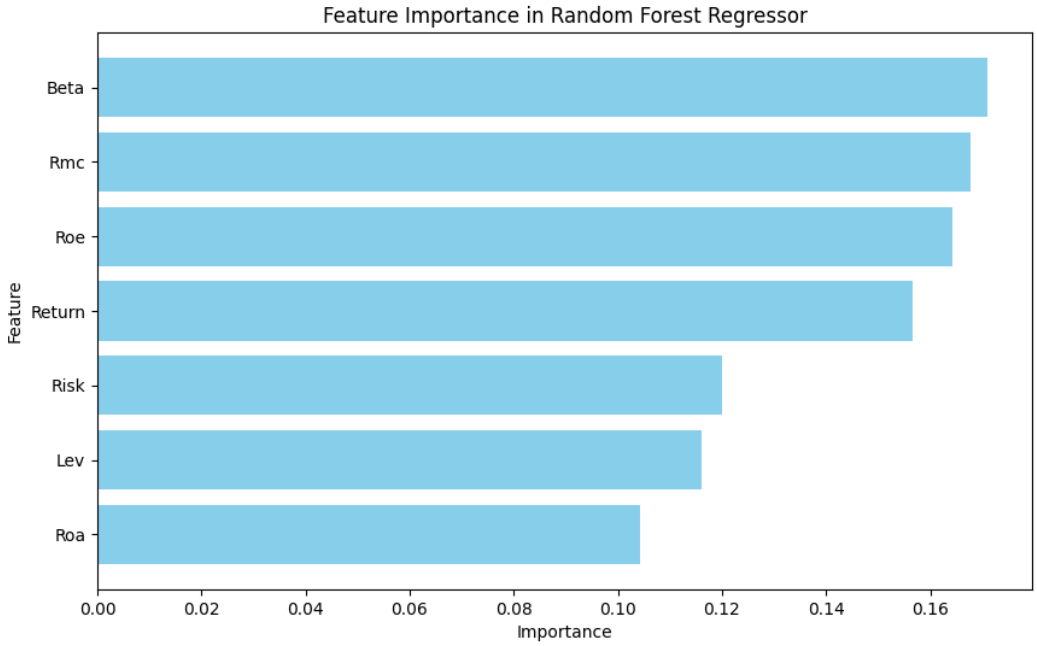

نمودار۱. نمودار اهمیت ویژگی‌ها در الگو رگرسیون جنگل تصادفی

در این نمودار محور افقی اهمیت ویژگی‌ها را از ۰/۰۰ تا ۰/۲۰ نمایش می‌دهد و محور عمودی ویژگی‌های مختلف را شامل می‌شود. ویژگی‌ها به ترتیب اهمیت عبارتند از:

Beta: با اهمیت ۰/۱۷۱، نشان‌دهنده تأثیر بالا بر نقدشوندگی سهام است. Beta نمایانگر حساسیت سهام به تغییرات بازار کلی است.

Rmc: با اهمیت ۰/۱۶۷، تأثیر قابل توجهی بر نقدشوندگی دارد و نشان‌دهنده معیارهای ریسک مالی است.

Roe: با اهمیت ۰/۱۶۴، نشان‌دهنده بازدهی سهام بر اساس حقوق صاحبان سهام است.

Return: با اهمیت ۰/۱۵۷، نشان‌دهنده بازدهی سهام در یک دوره زمانی است.

Risk: با اهمیت ۰/۱۲۰، نمایانگر میزان ریسک مرتبط با سهام است.

Lev: با اهمیت ۰/۱۱۶، نشان‌دهنده نسبت بدهی به دارایی‌های شرکت است.

Roa: با اهمیت ۰/۱۰۴، نشان‌دهنده بازده دارایی‌ها است.

این نمودار برای تحلیل و تفسیر اهمیت ویژگی‌های مختلف در الگو رگرسیون جنگل تصادفی مفید است.

۵-۱- تحلیل خطای مربعی میانگین

الگو آموزش داده شده با استفاده از الگوریتم جنگل‌های تصادفی دقت بالایی در پیش‌بینی نقدشوندگی سهام نشان داده است. یکی از معیارهای اصلی ارزیابی دقت الگو، خطای مربعی میانگین است.

خطای مربعی میانگین، میانگین مربعات اختلافات بین مقادیر پیش‌بینی شده و مقادیر واقعی را محاسبه می‌کند. به عبارت دیگر MSE میانگین مربعات خطاهای پیش‌بینی را اندازه‌گیری می‌کند و به عنوان یک معیار اصلی برای ارزیابی دقت الگوهای یادگیری ماشین مورد استفاده قرار می‌گیرد. مقدار MSE محاسبه شده برای الگو جنگل‌های تصادفی به‌طور قابل‌توجهی پایین است. این مقدار نشان‌دهنده اختلاف بسیار کم بین مقادیر پیش‌بینی شده و مقادیر واقعی نقدشوندگی سهام است، که بیانگر دقت بالای الگو در پیش‌بینی نقدشوندگی است. مقدار MSE پایین به این معناست که الگو به خوبی توانسته است روابط میان ویژگی‌های مختلف سهام و نقدشوندگی آنها را شناسایی و پیش‌بینی کند. این یافته‌ها نشان می‌دهند که الگو جنگل‌های تصادفی قادر است با دقت بالایی نقدشوندگی سهام را پیش‌بینی کند و به عنوان یک ابزار قدرتمند در تحلیل‌های مالی و سرمایه‌گذاری به کار گرفته شود.

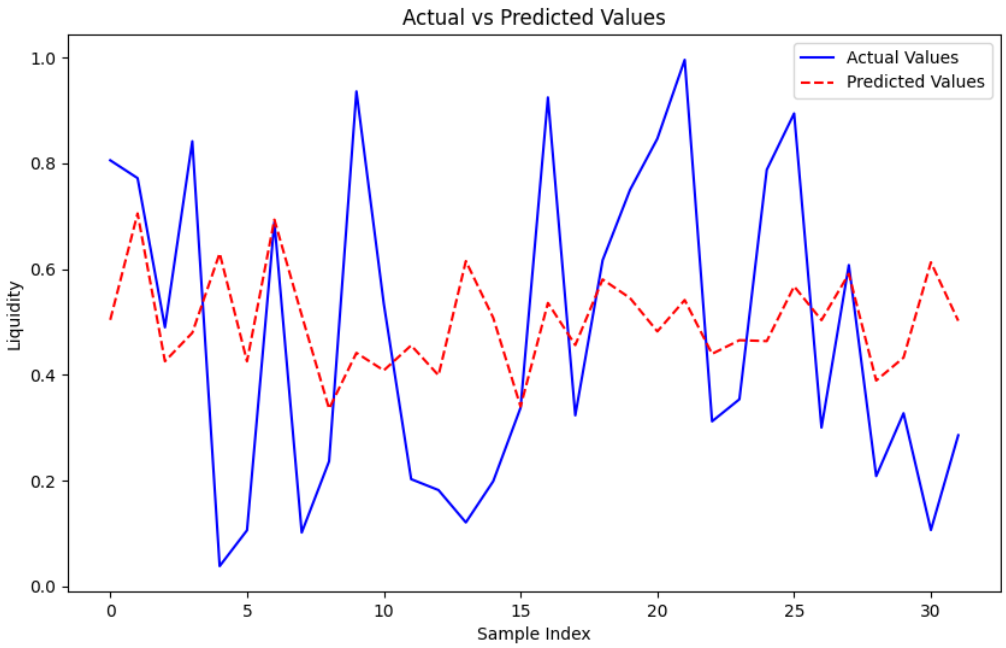

نمودار ۲. نمودار مقایسه مقادیر واقعی و پیش‌بینی شده نقدشوندگی

نمودار (۲) مقایسه‌ای بین مقادیر واقعی و مقادیر پیش‌بینی شده نقدشوندگی سهام را نشان می‌دهد. محور افقی نشان‌دهنده شاخص نمونه‌ها (Sample Index) است و محور عمودی نقدشوندگی را با دامنه‌ای از ۰/۰ تا ۱/۰ نمایش می‌دهد. مقادیر واقعی (خط آبی): نشان‌دهنده تغییرات واقعی نقدشوندگی در داده‌ها است.

مقادیر پیش‌بینی شده (خط قرمز نقطه‌چین): نشان‌دهنده تغییرات نقدشوندگی که توسط الگو پیش‌بینی‌شده است. مقایسه این دو خط نشان می‌دهد که الگو توانسته است با دقت معقولی نقدشوندگی را پیش‌بینی کند. اختلاف بین این دو خط بیانگر میزان خطای مربعی میانگین (MSE) است که در اینجا مقدار آن ۰/۰۸۶۰۳۷۶۶۲۷۲۳۷۷۰۷۸ است.

این نمودار به خوبی نشان می‌دهد که الگو پیش‌بینی توانسته است به خوبی روند تغییرات نقدشوندگی را دنبال کند، هرچند که اختلافات جزئی وجود دارد. این نمودار مقادیر واقعی و پیش‌بینی شده نقدشوندگی سهام را مقایسه می‌کند. خط آبی نشان‌دهنده مقادیر واقعی و خط قرمز نقطه‌چین نشان‌دهنده مقادیر پیش‌بینی‌شده است. نزدیکی این دو خط نشان‌دهنده دقت الگو است.

نمودار شماره (۳) نشان‌دهنده خطای مطلق میانگین (MAE) برای هر نمونه است. محور افقی نشان‌دهنده شاخص نمونه‌ها (Sample Index) و محور عمودی نشان‌دهنده خطای مطلق است. مقدار MAE که در نمودار نشان داده شده، ۰/۲۴۴۲۸۰۴۲۹۸۵۳۸۹۵۵۳ است. هر نوار در این نمودار مقدار خطای مطلق مربوط به هر نمونه را نمایش می‌دهد. این نمودار به خواننده کمک می‌کند تا میزان خطای مطلق میانگین را برای هر نمونه به صورت بصری مشاهده نموده و عملکرد الگو پژوهش راارزیابی کند.

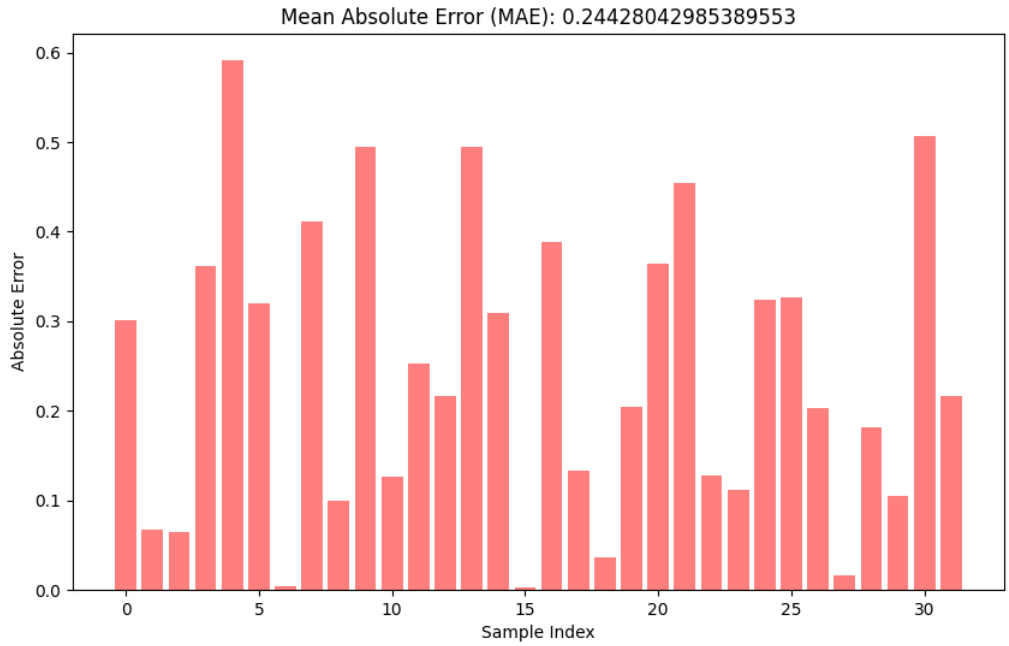

نمودار ۳. نمودار خطای مطلق میانگین (MAE)

۵-۲- تحلیل نتایج و نمودارها

Mean Squared Error (MSE): ۰/۰۸۶

Mean Absolute Error (MAE):۰/۲۴۴

خطای مربعی میانگین (MSE) یکی از معیارهای مهم برای ارزیابی دقت الگو و نشان‌دهنده میانگین مربع اختلافات بین مقادیر پیش‌بینی شده و مقادیر واقعی است. مقدار ۰/۰۸۶ نشان‌دهنده این است که اختلاف بین مقادیر پیش‌بینی شده و واقعی کم است و الگو به خوبی عمل کرده است. هرچه مقدار MSE کمتر باشد، دقت الگو بیشتر است.

خطای مطلق میانگین (MAE) نیز یکی دیگر از معیارهای ارزیابی دقت الگو و نشان‌دهنده میانگین مطلق اختلافات بین مقادیر پیش‌بینی شده و مقادیر واقعی است. مقدار ۰/۲۴۴ نشان‌دهنده میانگین اختلافات نسبی کم بین مقادیر واقعی و پیش‌بینی شده است. مقدار کم MAE نشان‌دهنده عملکرد دقیق الگو است.

۶- نتیجه‌گیری و پیشنهادها

یکی از ریسک‌های سرمایه‌گذاری در اوراق بهادار نقدشوندگی آنهاست. نقدشوندگی مفهومی تک‌بعدی نبوده و ادبیات موجود طیف گسترده‌ای از معیارهای اندازه‌گیری برای نقدشوندگی ارائه می‌دهد و توافق کمی در مورد بهترین معیار وجود داشته و بین بسیاری از این معیارها همبستگی کمی وجود دارد. پژوهش حاضر، با شناسایی عوامل مؤثر بر نقدشوندگی سهام، که در بازار سهام ایران اعتبار و قابلیت ردیابی دارند، با استفاده از یادگیری ماشینی، الگویی نوین، متناسب و عملیاتی برای ارزیابی نقدشوندگی بازار اوراق بهادار تهران ارائه نموده است. مطالعات انجام یافته نشان می‌دهد که تأثیر بیش از ۷۰ عامل مختلف در نقدشوندگی سهام کشورهای مختلف جهان، بررسی شده است. از این میان تأثیر ۴۷ عامل که قابلیت تعریف در بازار اوراق بهادار تهران را دارند، در استخراج الگو مورد استفاده واقع شدند. در این پژوهش، با بهره‌گیری از الگوریتم رگرسیون جنگل تصادفی، الگویی برای پیش‌بینی نقدشوندگی سهام شرکت‌های پذیرفته‌شده در بازار اوراق بهادار تهران طراحی شد. مجموعه داده‌های مورد استفاده شامل ۴۷ عامل قابل‌ردیابی در بازار ایران بود که از میان بیش از ۷۰ عامل شناخته‌شده جهانی انتخاب شدند. نتایج پژوهش حاضر نشان می‌دهد که:

- الگو جنگل تصادفی توانست با دقت قابل‌توجهی نقدشوندگی را پیش‌بینی کند. میزان میانگین خطای مربعی (MSE)، میانگین قدر مطلق خطا (MAE)، ریشه میانگین مربعات (RMSE) و ضریب تعیین (R^2) همگی نشان‌دهنده عملکرد مطلوب الگو بودند.
- بررسی اهمیت ویژگی‌ها نشان داد که برخی متغیرها مانند بازده حقوق صاحبان سهام و نسبت بدهی تأثیر چشم‌گیری بر نقدشوندگی دارند.
- اعتبارسنجی متقابل با روش K-Fold از بیش‌برازش الگو جلوگیری کرده و میزان پایداری نتایج را افزایش داده است.

لازم به ذکر است، ادعای دقت ۹۹.۹۱۴٪ بر اساس ضریب تعیین R^2 از خروجی الگو در مجموعه آزمایش به‌دست آمده است، اما برای حفظ واقع‌گرایی تحلیل، پیشنهاد می‌شود که این مقدار به‌عنوان شاخص نسبی و در کنار سایر معیارهای ارزیابی تفسیر شود.

اگرچه الگو جنگل تصادفی عملکرد قدرتمندی از خود نشان داده، اما محدودیت‌هایی نیز دارد:

- امکان بیش‌برازش در صورت حجم کم داده یا ویژگی‌های پرت
- حساسیت به انتخاب پارامترهای الگو مانند تعداد و عمق درخت‌ها
- محدودیت زمانی در آموزش الگو با تعداد داده‌های بالا و پارامترهای پیچیده

برای بهبود آینده الگو، می‌توان از روش‌های ترکیبی مانند الگوهای Ensemble چندگانه یا تحلیل تطبیقی با الگوریتم‌های دیگر (مثل XGBoost یا شبکه‌های عصبی عمیق) بهره برد.

پژوهش حاضر می‌تواند در حوزه‌های زیر مورد استفاده قرار گیرد:

برای سرمایه‌گذاران: با استفاده از خروجی الگو، امکان مقایسه و انتخاب سهام با نقدشوندگی بالاتر فراهم می‌شود، که به کاهش هزینه‌های معاملاتی کمک می‌کند.

برای مدیران مالی شرکت‌ها: با تحلیل ویژگی‌های تأثیرگذار بر نقدشوندگی، می‌توان سیاست‌هایی برای بهبود نقدشوندگی سهام اتخاذ کرد، از جمله مدیریت ساختار سرمایه و بازدهی عملیاتی.

برای تحلیل‌گران بازار: الگو طراحی‌شده قابلیت ادغام با ابزارهای تحلیل تکنیکال و بنیادی را داشته و می‌تواند به‌عنوان بخشی از فرآیند ارزیابی ریسک سبد سهام استفاده شود.

برای سیاست‌گذاران مالی: با توسعه الگو در سطح کلان، امکان ارائه تحلیل‌هایی از روند نقدشوندگی بازار در پاسخ به تغییرات اقتصادی (مانند نرخ ارز و تورم) فراهم خواهد شد. همچنین انتشار منظم اطلاعات مالی شرکت‌ها مانند صورت‌های مالی حسابرسی‌شده، زمینه را برای بهبود کیفیت داده‌ها و دقت الگو فراهم می‌سازد.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت و این موضوع مورد تأیید همه آنهاست.

مشارکت نویسندگان

این مقاله برگرفته از رساله **عبدالرضا قاسمپور** در رشته **حسابداری** به راهنمایی **دکتر احمد خدامی‌پور** در **دانشگاه آزاد اسلامی واحد کرمان** است.

نویسنده اول: تهیه و آماده‌سازی نمونه‌ها، انجام آزمایش و گردآوری داده‌ها، انجام محاسبات، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج، تهیه پیشنویس مقاله.

نویسنده دوم: استاد راهنمای رساله ، طراحی پژوهش، نظارت بر مراحل انجام پژوهش، بررسی و کنترل نتایج، اصلاح، بازبینی و نهایی‌سازی مقاله.

نویسنده سوم: استاد مشاور رساله، مشارکت در طراحی پژوهش، نظارت بر پژوهش، مطالعه و بازبینی مقاله.

نویسنده چهارم: استاد مشاور رساله ، مشارکت در طراحی پژوهش، نظارت بر پژوهش، مطالعه و بازبینی مقاله.

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

حامی مالی

نویسندگان هیچگونه حمایت مالی برای تحقیق، تألیف و انتشار این مقاله دریافت نکرده‌اند.

تقدیر و تشکر

از تمامی افراد و مؤسساتی که در انجام این تحقیق مؤلفین را مساعدت نمودند، قدردانی می‌شود. همچنین از معاونت محترم پژوهشی دانشگاه‌های شهید باهنر کرمان و آزاد اسلامی واحد کرمان تقدیر به عمل می‌آید.

منابع

احمدوند، میثم؛ تقوی فرد، محمدتقی؛ غائبی مهماندوست علیا، شایان و روحی، محمد (۱۴۰۳). نکول شرکتی و قیمت‌گذاری دارایی‌ها در بازار سهام. *مجله دانش حسابداری*، ۱۵(۱)، ۴۷-۸۲. DOI: 10.22103/jak.2023.21254.3868.

بادآور نهندی، یونس و ملکی نژاد، آمنه (۱۳۸۹). بررسی نقدشوندگی سهام در زمان انتشار گزارشهای مالی در بورس اوراق بهادار تهران. *مجله دانش حسابداری*، ۱(۳)، ۹۹-۱۱۵. DOI: 10.22103/jak.2010.42.

شفیعی، پریسا؛ میرعسکری جیلدانی، سید رضا و رضائی پیته نوئی، یاسر (۱۴۰۴). افشای اطلاعات زیست‌محیطی، اجتماعی و حاکمیتی و نقدشوندگی سهام. *مجله دانش حسابداری*، مقالات آماده انتشار. DOI: 10.22103/jak.2025.24844.4152.

هوشیار، محمدرضا؛ دارابی، رویا و فلاح، میرفیض (۱۴۰۲). ارائه الگوی اثر درجه شباهت گروهی و کیفیت اطلاعات حسابداری و کیفیت گزارشگری مالی بر ارزش‌گذاری عرضه عمومی اولیه سهام با استفاده از الگوریتم شبکه‌های عصبی مصنوعی. *مجله دانش حسابداری*، ۱۴(۴)، ۵۳-۸۰. DOI: 10.22103/jak.2023.20377.3790.

اسعدی، عبدالرضا و شادمهر، مریم (۱۳۹۴). اثر انتشار به موقع اطلاعات بر نقدشوندگی سهام در بورس اوراق بهادار تهران. *بورس اوراق بهادار*، ۸(۳۱)، ۵-۲۵. https://journal.seo.ir/article_11059.html.

ایزدی‌نیا، ناصر و رسائیان، امیر (۱۳۸۹). پراکندگی مالکیت و نقدشوندگی سهام. *بررسی‌های حسابداری و حسابرسی*، ۱۷(۲)، ۳-۲۲. https://acctgrev.ut.ac.ir/article_21205.html.

تقوی، مهدی و بیابانی، شاعر (۱۳۸۲). اثرات تغییر نرخ ارز بازار آزاد و جریان نقد آتی بر ارزش سهام شرکت‌های سهامی عام پذیرفته شده در بورس اوراق بهادار تهران. *پژوهشنامه اقتصادی*، ۳(۱۰)، ۱۳-۳۸. https://joer.atu.ac.ir/article_3094.html.

خلیفه سلطانی، سید احمد و بهرامی، ماندانا (۱۳۹۱). رابطه تغییرات ساختار سرمایه و تغییرات نقدشوندگی سهام. *پژوهش‌های تجربی حسابداری*، ۲(۲)، ۳۵-۵۳. https://doi.org/10.22051/jera.2013.545.

رضاپور، نرگس؛ حسینی، سید علی و رحمانی، علی (۱۳۸۹). رابطه مالکیت نهادی و نقد شوندگی سهام در ایران. *بررسی‌های حسابداری و حسابرسی*، ۱۷(۳)، ۲۹-۵۴. https://acctgrev.ut.ac.ir/article_21684.html.

رضایی، محمود؛ پناهیان، حسین؛ معدنچی زاج، مهدی و قدرتی، حسن (۱۴۰۱). تبیین عوامل مؤثر بر نقد شوندگی سهام با استفاده از الگوریتم ژنتیک و روش حداقل افزونگی و حداکثر ارتباط (MRMR). *نشریه مهندسی مالی و مدیریت اوراق بهادار*، ۱۳(۵۳)، ۵۴-۷۱. https://journals.iau.ir/article_693732.html.

رنجبر ناوی، رستم؛ حمیدیان، محسن و باغانی، علی (۱۴۰۰). تدوین الگو و تعیین اولویت‌های مؤثر بر معیارهای نوسان پایین به بالا و دوره سقوط قیمت سهام در بورس اوراق بهادار تهران با رویکرد پانل دیتا. *فصلنامه دانش سرمایه گذاری*، ۱۰(۳۸)، ۱۰۵-۱۳۴. http://www.jik-ifea.ir/article_17522.html.

صالحی، الله کرم (۱۴۰۰). تأثیر قدرت حاکمیت شرکتی بر نقدشوندگی بازار سهام: با تاکید بر معیارهای آمیهود، حجم معامله و شکاف قیمتی. *فصلنامه دانش سرمایه گذاری*، ۱۰(۳۷)، ۳۷-۵۵. https://sanad.iau.ir/Journal/jik/Article/841707.

صلواتی، شاپور و رسائیان، امیر (۱۳۸۶). بررسی رابطه بین ساختار سرمایه و نقدشوندگی سهام در ایران. *دوفصلنامه علمی مطالعات و سیاست‌های اقتصادی*، ۱۲(۶۳)، ۱۴۳-۱۶۳. https://economic.mofidu.ac.ir/article_47126.html.

قاسمیه، رحیم؛ سینایی، حسنعلی و صحرایی، صدیقه (۱۴۰۲). پیش بینی نقدشوندگی در بورس اوراق بهادار تهران با استفاده از الگوهای یادگیری. *نشریه پژوهش‌های راهبردی بودجه و مالیه*، ۴(۳)، ۱۱-۲۹. https://dor.isc.ac/dor/20.1001.1.27171809.1402.4.3.1.5.

نادری، ابراهیم و اسماعیل‌زاده مقری، علی (۱۳۹۹). برآورد اختلاف قیمت پیشنهادی خریدوفروش سهام با استفاده از الگوریتم کلونی زنبورعسل مصنوعی (ABC). *نشریه پژوهش‌های حسابداری مالی و حسابرسی*، ۱۲(۴۸)، ۱۲۱-۱۴۸. https://journals.iau.ir/article_680058.html.

نظامی، نصرت؛ محمدی نوده، فاضل و خردیار، سینا (۱۴۰۴). مدل یابی پیش بینی ورشکستگی با تأکید بر روش‌های نوین اندازه گیری شبکه‌های عصبی و ماشین بردار پشتیبان. *دانش حسابداری و حسابرسی مدیریت*، ۱۴(۵۵)، ۲۶۵-۲۷۸. https://www.jmaak.ir/article_23640.html.

References

Ahmadvand, M., Taghavifard, M.T., Ghaebi Mehmandoust Olya, S., & Rouhi, M. (2024). Corporate default and asset pricing in stock market. *Journal of Accounting Knowledge*, 15(1), 47-82. DOI: 10.22103/jak.2023.21254.3868 [In Persian].

Aliyu, S.U.R. (2012). Does inflation have an impact on stock returns and volatility? Evidence from Nigeria and Ghana. Applied financial economics, 22(6), 427-435. http://dx.doi.org/10.1080/09603107.2011.617691.

Amihud, Y. (2002). Illiquidity and stock returns: cross-section and time-series effects. *Journal of Financial Markets*, 5(1), 31-56. https://www.sciencedirect.com/science/article/pii/S1386418101000246.

Amihud, Y. and Mendelson, H. (1986). Asset pricing and bid ask spread. *Journal of Financial Economics*, 17, 223-249. https://doi.org/10.1016/0304-405X(86)90065-6.

Amihud, Y., & Noh, J. (2021). Illiquidity and stock returns II: Cross-section and time-series effects. *The Review of Financial Studies*, 34(4), 2101-2123. https://academic.oup.com/rfs/article-abstract/34/4/2101/5869447.

Andersen, T.G. (1996). Return volatility and trading volume: An information flow interpretation of stochastic volatility. *The Journal of Finance*, 51(1), 169-204. https://doi.org/10.1111/j.1540-6261.1996.tb05206.x.

Anifowose, M. (2012). Information asymmetric effect on the stock return volatility in Nigerian capital market. *Accounting Frontier*, 14(2), 47-64. https://dx.doi.org/10.2139/ssrn.2752915.

Asa'di, A., Shadmehr, M. (2015). The effect of timely information disclosure on stock liquidity in Tehran Stock Exchange. *Stock Exchange*, 8(31), 5-25. https://journal.seo.ir/article_11059.html [In Persian].

Badavar Nahandi, Y., & Maleki Nejad, A. (2010). Survey the stock liquidity at the time of issuing financial reports. *Journal of Accounting Knowledge*, 1(3), 99-115. DOI: 10.22103/jak.2010.42 [In Persian].

Barberis, N., & Thaler, R. (2003). A survey of behavioral finance. *Handbook of the Economics of Finance*, 1, 1053-1128. https://www.sciencedirect.com/science/article/pii/S1574010203010276.

Bhatia, S., Peri, S., Friedman, S., & Malen, M. (2024). High-frequency trading liquidity analysis| application of machine learning classification. arXiv preprint arXiv:2408.10016. https://arxiv.org/abs/2408.10016

Boubaker, S., Gounopoulos, D., Kallias, A., & Kallias, K. (2017). Management earnings forecasts and IPO performance: evidence of a regime change. *Review of Quantitative Finance and Accounting*, 48, 1083-1121. https://link.springer.com/article/10.1007/s11156-016-0579-8.

Cartea, Á., Jaimungal, S., & Sánchez-Betancourt, L. (2021). Latency and liquidity risk. International Journal of Theoretical and Applied Finance, 24(06n07), 2150035. [World Scientific].

Chang, Y.H., & Huang, C.W. (2024). Utilizing genetic algorithms in conjunction with ANN-based stock valuation models to enhance the optimization of stock investment decisions. *AI*, 5(3), 1011-1029. https://doi.org/10.3390/ai5030050.

Chong, E., Han, C., & Park, F.C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187-205. https://doi.org/10.1016/j.eswa.2017.04.030.

Chordia, T., Roll, R., & Subrahmanyam, A. (2001). Market liquidity and trading activity. *The Journal of Finance*, 56(2), 501-530. https://onlinelibrary.wiley.com/doi/abs/10.1111/0022-1082.00335.

Cobandag Guloglu, Z., & Ekinci, C. (2022). Liquidity measurement: A comparative review of the literature with a focus on high frequency. *Journal of Economic Surveys*, 36(1), 41-74. [Wiley Online Library].

Datar, V.T., Naik, N.Y., & Radcliffe, R. (1998). Liquidity and stock returns: An alternative test. *Journal of Financial Markets*, 1(2), 203-219. https://doi.org/10.1016/S1386-4181(97)00004-9.

Depren, Ö., Kartal, M.T., & Kılıç Depren, S. (2021). Recent innovation in benchmark rates (BMR): Evidence from influential factors on Turkish Lira overnight reference interest Rate with machine learning algorithms. *Financial Innovation*, 7(1), 44. https://doi.org/10.1186/s40854-021-00245-1.

Dey, M. (2005). Liquidity, turnover, and return in global stock markets. *Emerging Markets Review*, 6(1), 45-67. https://doi.org/10.1016/j.ememar.2004.09.003.

Fama, E.F. (1970). Efficient capital markets. *Journal of Finance*, 25(2), 383-417. [De Gruyter].

Frieder, L., & Martell, R. (2006). On capital structure and the liquidity of a firm's stock. Available at SSRN 880421. http://dx.doi.org/10.2139/ssrn.880421.

Ghasemiyeh, R., Sinaei, H., & Sahraei, S. (2023). Liquidity prediction in Tehran stock exchange using learning models. *Budget and Finance Strategic Research*, 4(3), 11-29. https://fbarj.ihu.ac.ir/article_208569.html [In Persian].

Goyenko, R.Y., Holden, C.W., & Trzcinka, C.A. (2009). Do liquidity measures measure liquidity? *Journal of Financial Economics*, 92(2), 153-181. https://doi.org/10.1016/j.jfineco.2008.06.002.

Grossman, S.J., & Stiglitz, J.E. (1980). On the impossibility of informationally efficient markets. *The American Economic Review*, 70(3), 393-408. https://www.jstor.org/stable/1805228.

Hooshyar, M., Darabi, R., & Fallah, M. (2023). Presenting the model of the effect of the degree of group similarity on the quality of accounting information and the quality of financial reporting on the valuation of the initial public offering of shares using the algorithm of artificial neural networks. *Journal of Accounting Knowledge*, 14(4), 53-80. DOI: 10.22103/jak.2023.20377.3790 [In Persian].

Hu, S. Y. (1997). Trading turnover and expected stock returns: The trading frequency hypothesis and evidence from the Tokyo Stock Exchange. Available at SSRN 15133. https://dx.doi.org/10.2139/ssrn.15133.

Izadinia, N., & Rasaiian, A. (2010). Ownership dispersion and stock liquidity. *Accounting and Auditing Review*, 17(2), 3-22. https://acctgrev.ut.ac.ir/article_21205.html [In Persian].

Jeribi, F., Martin, R.J., Mittal, R., Jari, H., Alhazmi, A.H., Malik, V., ... & Singh, S.V. (2024). A deep learning based expert framework for portfolio prediction and forecasting. *IEEE Access*, https://ieeexplore.ieee.org/abstract/document/10613392.

Khalifeh Soltani, S.A., & Bahrami, M. (2012). The relationship between changes in capital structure and changes in equity liquidity. *Empirical Research in Accounting*, *2*(2), 35-53. DOI: 10.22051/jera.2013.545 [In Persian].

Khang, P.Q., Kaczmarczyk, K., Tutak, P., Golec, P., Kuziak, K., Depczyński, R., ... & Rot, A. (2021). Machine learning for liquidity prediction on Vietnamese stock market. *Procedia Computer Science*, 192, 3590-3597. https://www.sciencedirect.com/science/article/pii/S1877050921018718.

Lang, M., & Maffett, M. (2011). Transparency and liquidity uncertainty in crisis periods. *Journal of Accounting and Economics*, 52(2-3), 101-125. https://doi.org/10.1016/j.jacceco.2011.07.001.

Liu, W., & Suzuki, Y. (2024). Stock liquidity, financial constraints, and innovation in Chinese SMEs. *Financial Innovation*, 10(1), 91. https://doi.org/10.1186/s40854-023-00597-w.

Lo, A.W. (2004). The adaptive markets hypothesis: Market efficiency from an evolutionary perspective. *Journal of Portfolio Management, Forthcoming*, 2004, 1-31. [PDF].

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS One*, 13(3), e0194889. https://doi.org/10.1371/pone.0194889.

Malagrino, L.S., Roman, N.T., & Monteiro, A.M. (2018). Forecasting stock market index daily direction: A Bayesian Network approach. *Expert Systems with Applications*, 105, 11-22. https://doi.org/10.1016/03.039.

Marshall, B.R., & Young, M. (2003). Liquidity and stock returns in pure order-driven markets: evidence from the Australian stock market. *International Review of Financial Analysis*, 12(2), 173-188. http://dx.doi.org/10.1016/S1057-5219(03)00006-1.

Mohebbi, S., Fadaeinejad, M.E., & Hamidizadeh, M.R. (2021). The proposed algorithm to select appropriate features for predicting Tehran Stock Exchange index. *Financial Management Perspective*, 11(34), 35-67. https://doi.org/10.52547/jfmp.11.34.35.

Naderi, E., & Esmaeilzadeh Moqri, A. (2019). Estimating the difference between the bid and ask price of stocks using the Artificial Bee Colony (ABC) algorithm. *Journal of Financial Accounting and Auditing Research*, 12(48), 121-148. https://journals.iau.ir/article_680058.html [In Persian].

Nezami, N., Mohammadi Node, F., & Kheradyar, S. (2025). Predictive modeling of bankruptcy with an emphasis on modern measurement methods such as Neural Networks and support vector machines. *Journal of Management Accounting and Auditing Knowledge*, 14(55), 265-278. https://www.jmaak.ir/article_23640.html [In Persian].

Norvaišienė, R., & Stankevičienė, J. (2014). Impact of companies' internal factors on stock liquidity in Baltic markets. *Procedia-Social and Behavioral Sciences*, 156, 543-547. https://doi.org/10.1016/11.237.

Oussar, Y., & Dreyfus, G. (2000). Initialization by selection for wavelet network training. *Neurocomputing*, 34(1-4), 131-143. https://hal.science/hal-00922196v1.

Peters, E. E. (1994). Fractal market analysis: Applying chaos theory to investment and economics. John Wiley & Sons. [Google Books].

Rahmani, A., Hosseini, S.A., & Rezapour, N. (2010). Institutional ownership and stock liquidity: Evidence from Iran. *Accounting and Auditing Review*, 17(3), 29-54. https://acctgrev.ut.ac.ir/article_21684.html [In Persian].

Ranjbar Navi, R., Hamidian, M., & Baghani, A. (2021). Modeling and identifying hierarchy of the effective measures of DUVOL criteria and the period of falling stock prices in Tehran Stock Exchange with panel data approach. *Journal of Investment Knowledge*, 10(38), 105-134. http://www.jik-ifea.ir/article_17522.html [In Persian].

Rezaei, M., Panahian, H., Madanchizaj, M., & Ghodrati, H. (2013). Explaining the factors affecting stock liquidity using genetic algorithm and minimum redundancy and maximum relevance (MRMR) method. *Journal of Financial Engineering and Securities Management*, 13(53), 54-71. https://journals.iau.ir/article_693732.html [In Persian].

Salavati, S., & Rasaiian, A. (2007). A survey on the relationship between capital structure and stock liquidity in Iran. *The Journal of Economic Studies and Policies*, 12(63), 143-163. https://economic.mofidu.ac.ir/47126.html [In Persian].

Salehi, A.K. (2021). The effect of corporate governance strength on stock market liquidity: with emphasis on Amihood criteria, trading volume and price gap. *Quarterly Journal of Investment Knowledge*, 10(37), 37-55. https://sanad.iau.ir/Journal/jik/Article/841707 [In Persian].

Salim Hadad, F.(2012). Stock liquidity and capital structure: An empirical study on Amman stock exchange. *European Journal of Economics, Finance and Administrative Sciences*, ISSN 1450-2275 Issue 47. http://dx.doi.org/10.13140/RG.2.1.1699.6240.

Sethy, T.K., & Tripathy, N. (2024). A new method for estimating liquidity and stock returns in Indian stock market. *China Accounting and Finance Review*. https://doi.org/10.1108/CAFR-05-2023-0052.

Shafiei, P., Miraskari Jildani, S.R., & Rezaei Pitenoei, Y. (2025). Disclosure of environmental, social and governance information and stock liquidity. *Journal of Accounting Knowledge*, Articles in Press. DOI: 10.22103/jak.2025.24844.4152 [In Persian].

Shiller, R.J. (2003). From efficient markets theory to behavioral finance. Journal of economic perspectives, 17(1), 83-104. https://www.aeaweb.org/articles?id=10.1257%2F0895330033211649 67&source=post_page.

Shleifer, A., & Vishny, R. W. (1992). Liquidation values and debt capacity: A market equilibrium approach. The *Journal of Finance*, 47(4), 1343-1366. https://doi.org/10.1111/j.1540-6261.1992.tb04661.x.

Subramaniam, R. K., Samuel, S. D., & Mahenthiran, S. (2016). Liquidity implications of corporate social responsibility disclosures: Malaysian evidence. *Journal of International Accounting Research*, 15(1), 133-153. https://doi.org/10.2308/jiar-51204.

Taghavi, M., & Biabani, Sh. (2003). The effects of changes in the free market exchange rate and future cash flow on the stock value of public joint stock companies listed on the Tehran Stock Exchange. *Journal of Economic Research*, 3(10), 13-38. https://joer.atu.ac.ir/article_3094.html [In Persian].

Tsai, K.H., & Wang, J.C. (2009). External technology sourcing and innovation performance in LMT sectors: An analysis based on the Taiwanese Technological Innovation Survey. *Research Policy*, 38(3), 518-526. http://dx.doi.org/10.1016/j.respol.2008.10.007.

Zhu, J. (2009). Pricing volatility of stock returns with volatile and persistent components. *Financial Markets and Portfolio Management*, 23, 243-269. https://doi.org/10.1007/s11408-009-0107-0.