

Predictive Analytics in Stock Market Forecasting: A Comparison of Decision Trees and Support Vector Machines

1. Vahid Ebrahimi^{id*}: Department of IT, University of Zanjan, Zanjan, Iran. Email: vahid.ebrahimi@zanjan.ac.ir (Corresponding Author)

Article history



Received: 08 January 2024

Revised: 19 February 2024

Accepted: 08 March 2024

Published: 09 April 2024

Abstract:

Stock market prediction, as one of the critical challenges in the financial domain, requires the application of advanced machine learning algorithms. Decision Trees and Support Vector Machines (SVM) are two popular algorithms, each with its advantages and limitations in predicting market fluctuations. The aim of this paper is to compare the performance, accuracy, and efficiency of Decision Trees and Support Vector Machines in stock market forecasting. This study follows a descriptive-analytical review method, examining past research on the use of Decision Trees and Support Vector Machines for stock market prediction. Relevant studies from reputable academic sources were analyzed based on accuracy, speed, and the ability of each algorithm to process complex data. Decision Trees, due to their simplicity and high processing speed, perform well in quick and straightforward predictions, but they may struggle with overfitting when dealing with complex and noisy data. In contrast, Support Vector Machines, utilizing kernel and optimization techniques, demonstrate higher accuracy in identifying complex patterns and nonlinear data, though they require more complex parameter tuning and longer computational time. Both algorithms can be effective tools for stock market forecasting, depending on the type of data and market conditions. Decision Trees are better suited for quick and interpretable predictions, while Support Vector Machines outperform in handling complex and noisy datasets.

Keywords: Stock market prediction, machine learning, Decision Trees, Support Vector Machines, financial data analysis.

Extended Abstract

The stock market, characterized by its volatility and complexity, remains one of the most challenging areas for accurate prediction. Traditional methods such as technical and fundamental analysis, while useful, have often been limited in capturing the intricate patterns and nonlinearities present in market behavior. With the advent of machine learning, more sophisticated techniques have emerged, providing tools that can process large volumes of data and uncover hidden patterns. Among these, Decision Trees and Support Vector Machines (SVM) have garnered significant attention for their ability to tackle the complexities of stock market forecasting. Decision Trees offer simplicity and interpretability, while SVMs provide higher

Citation: Ebrahimi, V. (2024). Predictive Analytics in Stock Market Forecasting: A Comparison of Decision Trees and Support Vector Machines. *Accounting, Finance and Computational Intelligence*, 1(1), 56-70.



Copyright: © 2024 by the authors. Published under the terms and conditions of Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

accuracy in handling nonlinear relationships. This paper aims to compare these two methods in terms of performance, accuracy, and efficiency in predicting stock market trends, drawing insights from recent research.

Decision Trees are one of the most widely used machine learning algorithms for classification and regression tasks. The core idea behind this algorithm is to split the data into subsets based on the value of input features, creating a tree-like structure of decisions. Each internal node of the tree represents a test on a feature, while each branch corresponds to the outcome of that test, and the leaf nodes represent the final classification or prediction. The algorithm recursively partitions the data until it reaches an optimal solution. Ampomah et al. (2020) demonstrated that Decision Trees can perform well in predicting stock price movement, especially when the dataset is relatively simple and well-structured [1]. However, despite their advantages in terms of interpretability and speed, Decision Trees are prone to overfitting, particularly when dealing with noisy or complex data [2]. Overfitting occurs when the model becomes too finely tuned to the training data, failing to generalize to new data.

In contrast, Support Vector Machines (SVMs) offer a more complex approach, particularly suited for classification problems involving nonlinear data. SVMs work by finding the hyperplane that best separates the data points of different classes in a multidimensional space. The algorithm seeks to maximize the margin between the hyperplane and the nearest data points, known as support vectors. When the data are not linearly separable, SVMs employ kernel functions to project the data into a higher-dimensional space, where a separating hyperplane can be more easily identified. Studies such as those by Kaščelan et al. (2014) have shown that SVMs excel in identifying complex and nonlinear patterns in stock market data. This capability makes SVMs particularly effective in markets characterized by high volatility and irregular price movements [3]. However, the complexity of SVMs comes with a trade-off in computational cost and the need for careful tuning of parameters, such as the choice of kernel function and regularization terms.

A direct comparison of these two methods highlights their respective strengths and weaknesses in different market conditions. Decision Trees are highly effective in situations where the data are structured and exhibit clear, linear relationships between variables. Their main advantage lies in the ease with which they can be interpreted, as the decision-making process follows a logical, step-by-step structure. For example, in a straightforward prediction scenario where stock prices are primarily influenced by a few key factors, Decision Trees can provide accurate predictions quickly. However, as noted by Barak et al. (2017), the simplicity of Decision Trees limits their ability to capture more complex interactions between variables, particularly in noisy or highly volatile markets [4].

On the other hand, SVMs are better equipped to handle these complexities. Their use of kernel functions allows them to model nonlinear relationships more effectively, making them more suitable for markets where price movements are influenced by a wide range of factors, including those that are less obvious or more difficult to quantify. Nti et al. (2020) found that SVMs outperform Decision Trees in predicting stock price direction in cases where the data are noisy and involve multiple interdependent variables. However, the trade-off is that SVMs require significantly more computational resources, and their predictions can be more difficult to interpret, especially for non-experts. The algorithm's reliance on mathematical optimization makes it less intuitive than Decision Trees, which can limit its practical application in environments where interpretability is crucial.

Despite their differences, both Decision Trees and SVMs can be effective tools for stock market prediction, depending on the specific context and data involved. In scenarios where simplicity, speed, and interpretability are key requirements,

Decision Trees offer a clear advantage. Their ability to generate easily understandable models makes them an attractive option for traders and analysts who need to make quick decisions based on a limited set of variables. Conversely, when accuracy and the ability to model complex, nonlinear relationships are paramount, SVMs are the preferred choice. As Chen et al. (2022) point out, the trade-off between accuracy and interpretability is a key consideration when selecting a machine learning model for financial forecasting [5].

Looking ahead, one promising area for future research is the combination of these two algorithms. Hybrid models that leverage the strengths of both Decision Trees and SVMs have the potential to provide more robust and accurate predictions while mitigating the weaknesses of each method individually. For instance, Barak et al. (2017) demonstrated that combining Decision Trees with SVMs could enhance prediction accuracy by addressing the limitations of both algorithms—specifically, the overfitting tendencies of Decision Trees and the computational complexity of SVMs. Such hybrid models could provide a more balanced approach, offering both the interpretability of Decision Trees and the accuracy of SVMs in handling nonlinear data [4].

In conclusion, both Decision Trees and Support Vector Machines offer valuable insights and tools for stock market prediction, each with its distinct advantages and limitations. Decision Trees are well-suited for simpler, more linear prediction tasks where speed and interpretability are key considerations. In contrast, SVMs excel in handling more complex, nonlinear data but require more computational resources and careful parameter tuning. As stock markets continue to grow in complexity, the need for advanced predictive models that can accurately capture market dynamics becomes increasingly important. Future research should focus on developing hybrid models that combine the strengths of both algorithms, offering a more comprehensive approach to stock market forecasting.

Authors' Contributions

Authors equally contributed to this article.

Acknowledgments

Authors thank all participants who participate in this study.

Declaration of Interest

The authors report no conflict of interest.

Funding

According to the authors, this article has no financial support.

Ethical Considerations

All procedures performed in this study were under the ethical standards.

تحلیل پیش‌بینی در پیش‌بینی بازار سهام: مقایسه درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان



تاریخچه مقاله

تاریخ دریافت: ۱۸ دی ۱۴۰۲

تاریخ بازنگری: ۳۰ بهمن ۱۴۰۲

تاریخ پذیرش: ۱۸ اسفند ۱۴۰۲

تاریخ انتشار: ۲۱ فروردین ۱۴۰۳

۲. وحید ابراهیمی*^{ID}: دانشکده آی‌تی، دانشگاه زنجان، زنجان، ایران، ایمیل: vahid.ebrahimi@znan.ac.ir (نویسنده مسئول)

چکیده

پیش‌بینی بازار سهام به‌عنوان یکی از چالش‌های مهم در حوزه مالی، نیازمند استفاده از الگوریتم‌های پیشرفته یادگیری ماشین است. دو الگوریتم محبوب در این زمینه، درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان هستند که هرکدام مزایا و معایب خاص خود را در پیش‌بینی نوسانات بازار دارند. هدف این مقاله مقایسه عملکرد، دقت و کارایی دو الگوریتم درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان در پیش‌بینی بازار سهام است. این پژوهش با روش مرور توصیفی-تحلیلی به بررسی مطالعات گذشته پیرامون استفاده از درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان در پیش‌بینی بازار سهام پرداخته است. مقالات مرتبط در منابع معتبر علمی جستجو و نتایج آنها بر اساس معیارهای دقت، سرعت، و توانایی هر الگوریتم در پردازش داده‌های پیچیده تحلیل شدند. درخت‌های تصمیم‌گیری به دلیل سادگی و سرعت بالا در پردازش داده‌ها، در پیش‌بینی‌های سریع و ساده‌تر عملکرد خوبی از خود نشان می‌دهند، اما ممکن است در مواجهه با داده‌های پیچیده و نویزی با مشکلاتی مانند بیش‌برازش روبه‌رو شوند. از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل استفاده از تکنیک‌های هسته و بهینه‌سازی، در شناسایی الگوهای پیچیده و داده‌های غیرخطی دقت بالاتری دارند، اما نیازمند تنظیمات پیچیده‌تر و زمان محاسباتی بیشتری هستند. هر دو الگوریتم بسته به نوع داده‌ها و شرایط بازار می‌توانند ابزارهای موثری برای پیش‌بینی بازار سهام باشند. درخت‌های تصمیم‌گیری برای پیش‌بینی‌های سریع و قابل فهم مناسب‌تر هستند، در حالی که ماشین‌های بردار پشتیبان در مواجهه با داده‌های پیچیده و نویزی عملکرد بهتری از خود نشان می‌دهند.

کلیدواژه‌گان: پیش‌بینی بازار سهام، یادگیری ماشین، درخت‌های تصمیم‌گیری، ماشین‌های بردار پشتیبان، تحلیل داده‌های مالی.

مقدمه

شیوه استناددهی: ابراهیمی، وحید. (۱۴۰۳). تحلیل پیش‌بینی در پیش‌بینی بازار سهام: مقایسه درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان. حسابداری، امور مالی و هوش محاسباتی، ۱(۱)، ۷۰-۵۶.



پیش‌بینی بازار سهام یکی از مهم‌ترین چالش‌های موجود در حوزه مالی است که توجه بسیاری از محققان و متخصصان را به خود جلب کرده است. دقت و صحت در پیش‌بینی قیمت‌های آتی سهام، می‌تواند به سرمایه‌گذاران کمک کند تا تصمیمات بهتری در زمینه خرید و فروش سهام بگیرند و در نتیجه بازدهی خود را افزایش دهند [6-9]. با این حال، پیش‌بینی دقیق نوسانات بازار سهام به دلیل ماهیت پویا و پیچیده آن، همواره امری دشوار بوده است. بازار سهام تحت تأثیر عوامل مختلفی همچون رویدادهای اقتصادی، سیاسی و اجتماعی قرار دارد که پیش‌بینی دقیق این تغییرات را به یک چالش تبدیل می‌کند [10].

پیش‌بینی بازار سهام اهمیت ویژه‌ای در تصمیم‌گیری‌های سرمایه‌گذاری دارد. به‌عنوان یک ابزار کاربردی، پیش‌بینی‌های دقیق می‌تواند میزان ریسک را کاهش دهد و به سرمایه‌گذاران در بهبود بازدهی و کاهش زیان‌های احتمالی کمک کند [11-13]. روش‌های سنتی پیش‌بینی مانند تحلیل تکنیکال و تحلیل بنیادی اغلب با محدودیت‌هایی مواجه‌اند و در مواردی که اطلاعات پیچیده و گسترده‌ای در دسترس است، نمی‌توانند به دقت کافی دست یابند. در این راستا، استفاده از روش‌های یادگیری ماشین به دلیل توانایی در پردازش حجم وسیعی از داده‌ها و شناسایی الگوهای پیچیده، به‌عنوان ابزاری قدرتمند در پیش‌بینی بازار سهام مورد توجه قرار گرفته است (Caö et al., 2019).

درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان دو الگوریتم محبوب در یادگیری ماشین هستند که کاربردهای گسترده‌ای در پیش‌بینی‌های مالی دارند. درخت‌های تصمیم‌گیری از ساختاری سلسله‌مراتبی برای تقسیم داده‌ها به دسته‌های مختلف استفاده می‌کنند و این تقسیم‌بندی بر اساس معیارهای مختلفی انجام می‌شود که به‌طور مستمر تصمیمات را بهبود می‌بخشد. این روش از نظر سادگی و قابلیت تفسیر، مزیت‌هایی دارد و در بسیاری از موارد به‌عنوان یک ابزار مفید برای پیش‌بینی قیمت سهام مورد استفاده قرار گرفته است [1]. از سوی دیگر، ماشین‌های بردار پشتیبان به‌عنوان یکی از روش‌های پیشرفته‌تر یادگیری ماشین، با استفاده از تکنیک‌های ریاضی پیچیده، مرزهایی را برای طبقه‌بندی داده‌ها ایجاد می‌کنند که دقت و کارایی بالایی در پیش‌بینی نتایج دارد [3]. این الگوریتم به‌خصوص در شرایطی که داده‌ها پیچیده و دارای نویز هستند، عملکرد بهتری نسبت به روش‌های سنتی از خود نشان می‌دهد.

هدف اصلی این مقاله مقایسه عملکرد دو الگوریتم درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان در پیش‌بینی بازار سهام است. با توجه به کاربردهای گسترده این دو الگوریتم در پیش‌بینی‌های مالی، بررسی مزایا و معایب هر یک از آنها می‌تواند به سرمایه‌گذاران و محققان کمک کند تا بهترین ابزار را برای پیش‌بینی‌های خود انتخاب کنند. این مقاله با استفاده از بررسی‌های کتابخانه‌ای و تحلیل توصیفی، به مقایسه دقت و کارایی این دو الگوریتم پرداخته و به بررسی اینکه کدام روش در شرایط مختلف بازار بهتر عمل می‌کند، می‌پردازد.

روش پژوهش و مواد

در این مطالعه، از روش توصیفی-تحلیلی برای بررسی و مقایسه دو روش یادگیری ماشین، یعنی درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان، در پیش‌بینی بازار سهام استفاده شده است. این روش مبتنی بر بررسی جامع مقالات و مطالعات پیشین است که در حوزه پیش‌بینی بازار سهام به‌وسیله این دو الگوریتم انجام شده‌اند. منابع علمی و داده‌های موجود در بانک‌های اطلاعاتی معتبر به‌عنوان مواد اصلی تحقیق در نظر گرفته شده‌اند. این بخش از مقاله به‌طور مفصل به معرفی و تحلیل معیارهای مقایسه، شیوه انتخاب مطالعات، و روش تحلیل داده‌ها می‌پردازد.

انتخاب مقالات و منابع مورد بررسی یکی از مراحل کلیدی این پژوهش بوده است. مقالاتی که در بازه زمانی پنج سال اخیر منتشر شده‌اند و در حوزه پیش‌بینی بازار سهام با استفاده از درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان تمرکز دارند، مورد بررسی قرار گرفتند. این مقالات از منابعی چون پایگاه داده‌های علمی معتبر مانند Google Scholar، Scopus، و IEEE Xplore جمع‌آوری شدند. معیار انتخاب مقالات شامل سطح علمی، تعداد استنادات، و تمرکز آنها بر تحلیل پیش‌بینی در بازار سهام با استفاده از الگوریتم‌های یادگیری ماشین بوده است. به‌علاوه، مقالاتی که در آنها داده‌های واقعی از بازارهای مالی معتبر مورد استفاده قرار گرفته‌اند، اولویت بالاتری در انتخاب داشتند. برای مقایسه این دو الگوریتم، از معیارهای عملکردی خاصی استفاده شده است. معیارهای کلیدی که برای سنجش دقت و کارایی الگوریتم‌ها در مقالات مختلف به کار رفته‌اند، شامل دقت پیش‌بینی، زمان محاسباتی، و پیچیدگی الگوریتم است. علاوه بر این، میزان مقاومت هر الگوریتم در برابر نویز و داده‌های ناپایدار بازار نیز بررسی شده است. مقایسه این معیارها به‌صورت کیفی انجام شده و یافته‌های مقالات مختلف با هم تطبیق داده شده‌اند تا بتوان نتیجه‌گیری دقیقی از برتری یا تفاوت‌های این دو روش به دست آورد.

در نهایت، به منظور اطمینان از روایی و پایایی نتایج به دست آمده، معیارهایی چون تعداد داده‌های مورد استفاده در هر مقاله، روش‌های اعتبارسنجی (مانند اعتبارسنجی متقابل یا Cross-Validation) و نحوه ارزیابی دقت مدل‌ها بررسی شدند. این تحلیل‌ها با هدف ارائه یک نمای کلی و جامع از عملکرد این دو الگوریتم در حوزه پیش‌بینی بازار سهام انجام شده است. داده‌های به دست آمده از مطالعات مختلف به صورت تطبیقی تحلیل شدند تا به یک نتیجه نهایی در مورد کاربردی‌ترین روش برای پیش‌بینی دقیق‌تر بازار سهام برسیم.

روش تحلیلی این مطالعه بر پایه مقایسه کیفی است، به طوری که نقاط قوت و ضعف هر یک از الگوریتم‌ها در شرایط مختلف بازار مالی به طور دقیق مورد بررسی قرار گرفت. این رویکرد به محققان و سرمایه‌گذاران کمک می‌کند تا بهترین انتخاب را برای استفاده از الگوریتم‌های یادگیری ماشین در پیش‌بینی بازار سهام داشته باشند.

پیشینه پژوهش

پیش‌بینی بازار سهام با استفاده از الگوریتم‌های یادگیری ماشین در سال‌های اخیر توجه بسیاری از محققان و تحلیلگران مالی را به خود جلب کرده است. استفاده از روش‌های نوین یادگیری ماشین، از جمله درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان، به دلیل دقت بالاتر و توانایی این الگوریتم‌ها در پردازش داده‌های پیچیده و غیرخطی، نسبت به روش‌های سنتی تحلیل تکنیکال و بنیادی، رایج شده است. در این بخش به مرور مطالعاتی پرداخته می‌شود که به استفاده از این دو الگوریتم در پیش‌بینی بازار سهام پرداخته‌اند و نتایج حاصل از آن‌ها را تحلیل می‌کنیم.

درخت‌های تصمیم‌گیری به دلیل ساختار ساده و قابل تفسیر، یکی از ابزارهای پرکاربرد در پیش‌بینی‌های مالی محسوب می‌شوند. ساختار سلسله‌مراتبی این الگوریتم به تحلیلگران این امکان را می‌دهد تا با تقسیم‌بندی داده‌ها بر اساس معیارهای مختلف، الگوهایی را برای پیش‌بینی رفتار بازار شناسایی کنند. به عنوان مثال، مطالعه‌ای که توسط Ampomah و همکاران (۲۰۲۰) انجام شد، نشان داد که استفاده از مدل‌های یادگیری مبتنی بر درخت‌های تصمیم‌گیری توانسته است دقت پیش‌بینی حرکت قیمت سهام را به طور چشمگیری افزایش دهد. در این مطالعه، از مدل‌های درختی برای پیش‌بینی جهت حرکت قیمت سهام استفاده شد و نتایج حاکی از آن بود که این الگوریتم‌ها می‌توانند در شرایطی که داده‌های زیادی در دسترس است، دقت بالایی را ارائه دهند. این ویژگی به ویژه در بازارهایی که نوسانات زیادی دارند، از اهمیت زیادی برخوردار است [1].

یکی دیگر از مطالعات مهم در این زمینه توسط Zhang و همکاران (۲۰۱۸) انجام شد. آنها به بررسی مدل انتخاب سهام با استفاده از الگوریتم درخت تصمیم‌گیری C5.0 پرداختند. نتایج این مطالعه نشان داد که این مدل با استفاده از داده‌های گذشته بازار سهام، توانسته است الگوهای قابل توجهی را در حرکت قیمت‌ها شناسایی کند. این الگوریتم به دلیل ساختار پیچیده‌اش می‌تواند حجم وسیعی از داده‌ها را به طور همزمان پردازش کند و نتایج دقیقی را برای پیش‌بینی ارائه دهد. محققان همچنین به این نکته اشاره کردند که استفاده از درخت‌های تصمیم‌گیری به خصوص در مواردی که داده‌های نویزی و غیرخطی وجود دارند، می‌تواند عملکرد بهتری نسبت به دیگر روش‌های یادگیری ماشین داشته باشد [14].

با این حال، درخت‌های تصمیم‌گیری محدودیت‌هایی نیز دارند. یکی از مشکلات عمده این الگوریتم‌ها، بیش‌برازش (overfitting) است. به این معنا که درخت‌های تصمیم‌گیری ممکن است به دلیل پیچیدگی بیش از حد، داده‌های آموزشی را به طور کامل مطابقت دهند، اما در مواجهه با داده‌های جدید دچار خطا شوند. مطالعه‌ای که توسط Gajowniczek و همکاران (۲۰۱۶) انجام شد، به بررسی این مسئله پرداخت و نشان داد که استفاده از تکنیک‌های خاصی مانند هرس کردن (pruning) می‌تواند به کاهش بیش‌برازش در مدل‌های درختی کمک کند. این تکنیک باعث می‌شود که بخش‌های غیرضروری مدل حذف شوند و الگوریتم بتواند با داده‌های جدید بهتر تطبیق پیدا کند [2].

در مقابل، ماشین‌های بردار پشتیبان به عنوان یکی از الگوریتم‌های پیشرفته‌تر یادگیری ماشین، دارای توانایی بیشتری در شناسایی الگوهای پیچیده و غیرخطی هستند. این الگوریتم با ایجاد مرزهایی برای طبقه‌بندی داده‌ها، می‌تواند دقت بالایی را در پیش‌بینی‌های مالی ارائه دهد. Kaščelan و همکاران (۲۰۱۴) در مطالعه‌ای که در مونت‌نگرو انجام دادند، به بررسی استفاده از ماشین‌های بردار پشتیبان در پیش‌بینی رفتار سرمایه‌گذاران در بازار سهام پرداختند. نتایج این مطالعه نشان داد که این الگوریتم توانسته است به طور قابل توجهی رفتار سرمایه‌گذاران را پیش‌بینی کرده و به عنوان یک ابزار موثر در تحلیل داده‌های بازار عمل کند. این مطالعه همچنین نشان داد که ماشین‌های بردار پشتیبان می‌توانند در مواردی که داده‌ها پیچیده و چندبعدی هستند، عملکرد بهتری نسبت به دیگر الگوریتم‌ها از خود نشان دهند [3].

یکی از مطالعات دیگر که به مقایسه عملکرد ماشین‌های بردار پشتیبان با دیگر الگوریتم‌های یادگیری ماشین پرداخت، توسط Nti و همکاران (۲۰۲۰) انجام شد. در این مطالعه، از مدل‌های یادگیری ماشین مبتنی بر بردار پشتیبان برای پیش‌بینی جهت حرکت بازار سهام استفاده شد و نتایج نشان داد که این الگوریتم‌ها به‌خصوص در شرایطی که داده‌ها دارای نویز هستند، می‌توانند عملکرد بهتری نسبت به الگوریتم‌های ساده‌تر مانند درخت‌های تصمیم‌گیری داشته باشند. این الگوریتم به دلیل استفاده از تکنیک‌های پیچیده ریاضی، قادر است داده‌های نویزی را با دقت بالاتری تحلیل کند و نتایج بهتری در پیش‌بینی‌های مالی ارائه دهد [15].

همچنین، Egüz و همکاران (۲۰۲۱) در تحقیقی که روی بانک‌های ترکیه انجام دادند، از ماشین‌های بردار پشتیبان برای پیش‌بینی قیمت سهام استفاده کردند. نتایج این تحقیق نشان داد که ماشین‌های بردار پشتیبان به دلیل توانایی در شناسایی الگوهای پیچیده و استفاده از تکنیک‌های بهینه‌سازی، دقت بالاتری در پیش‌بینی قیمت سهام ارائه می‌دهند. با این حال، این مطالعه به این نکته نیز اشاره کرد که استفاده از ماشین‌های بردار پشتیبان نیاز به تنظیمات پیچیده‌تری دارد و برای تحلیل دقیق‌تر داده‌ها نیاز به تنظیم پارامترهای بیشتری است [16].

در کنار این مطالعات، Ardakani و همکاران (۲۰۲۳) نیز به بررسی استفاده از الگوریتم یادگیری فدرالی برای پیش‌بینی روندهای بازار سهام پرداختند. این مطالعه نشان داد که استفاده از روش‌های نوین مانند یادگیری فدرالی می‌تواند به بهبود دقت پیش‌بینی‌ها کمک کند و به‌خصوص در مواردی که داده‌ها از منابع مختلف جمع‌آوری شده‌اند، عملکرد بهتری داشته باشد. آنها نشان دادند که الگوریتم‌های پیشرفته‌تر مانند ماشین‌های بردار پشتیبان با استفاده از یادگیری فدرالی می‌توانند نتایج بهتری نسبت به درخت‌های تصمیم‌گیری ارائه دهند [17].

یکی دیگر از مطالعات مهم در این زمینه توسط Chen و همکاران (۲۰۲۲) انجام شد که به بررسی استفاده از ماشین‌های یادگیری در پیش‌بینی بازار سهام پرداختند. آنها نشان دادند که الگوریتم‌های پیچیده‌تر مانند ماشین‌های بردار پشتیبان، به دلیل استفاده از مدل‌های ریاضی دقیق‌تر و توانایی در شناسایی الگوهای غیرخطی، می‌توانند در شرایطی که بازار نوسانات زیادی دارد، عملکرد بهتری داشته باشند. این مطالعه همچنین به این نکته اشاره کرد که استفاده از ماشین‌های بردار پشتیبان می‌تواند به کاهش خطاهای پیش‌بینی کمک کند و دقت کلی پیش‌بینی‌ها را افزایش دهد [5].

از سوی دیگر، مطالعاتی نیز به بررسی ترکیب الگوریتم‌ها پرداخته‌اند. به‌عنوان مثال، Barak و همکاران (۲۰۱۷) در مطالعه‌ای که به ترکیب چند الگوریتم مختلف برای پیش‌بینی بازار سهام پرداخته بود، نشان دادند که ترکیب الگوریتم‌ها می‌تواند دقت پیش‌بینی‌ها را افزایش دهد. آنها از ترکیب ماشین‌های بردار پشتیبان و درخت‌های تصمیم‌گیری استفاده کردند و نشان دادند که این ترکیب می‌تواند به شناسایی دقیق‌تر الگوهای پیچیده کمک کند و دقت کلی پیش‌بینی‌ها را بهبود بخشد. این مطالعه به‌طور خاص به این نتیجه رسید که استفاده از روش‌های ترکیبی می‌تواند مشکلاتی مانند بیش‌برازش در درخت‌های تصمیم‌گیری را کاهش دهد و به بهبود دقت پیش‌بینی‌ها کمک کند [4].

از نظر تحلیلی، مقایسه درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان نشان می‌دهد که هر یک از این الگوریتم‌ها دارای مزایا و معایب خاص خود هستند. درخت‌های تصمیم‌گیری به دلیل سادگی و قابلیت تفسیر، برای تحلیل‌گرانی که به دنبال مدلی ساده و قابل فهم هستند، مناسب‌تر به نظر می‌رسد. اما این الگوریتم‌ها ممکن است در مواجهه با داده‌های پیچیده و نویزی دچار مشکلاتی مانند بیش‌برازش شوند. از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل استفاده از تکنیک‌های پیچیده‌تر و توانایی در شناسایی الگوهای غیرخطی، دقت بالاتری در پیش‌بینی‌های مالی ارائه می‌دهند، اما نیاز به تنظیمات دقیق‌تری دارند و استفاده از آنها پیچیده‌تر است [18].

به‌طور کلی، مرور تحقیقات گذشته نشان می‌دهد که هر دو الگوریتم درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان می‌توانند ابزارهای موثری برای پیش‌بینی بازار سهام باشند، اما انتخاب بهترین الگوریتم بستگی به نوع داده‌ها و شرایط بازار دارد. در بازارهایی که نوسانات زیادی دارند و داده‌ها پیچیده هستند، ماشین‌های بردار پشتیبان عملکرد بهتری دارند، در حالی که در بازارهایی با داده‌های ساده‌تر، درخت‌های تصمیم‌گیری نیز می‌توانند نتایج قابل قبولی ارائه دهند.

درخت‌های تصمیم‌گیری

درخت‌های تصمیم‌گیری (Decision Trees) یکی از الگوریتم‌های مهم و پرکاربرد در یادگیری ماشین هستند که به‌ویژه در مسائل طبقه‌بندی و رگرسیون کاربرد دارند. این روش با تقسیم‌بندی داده‌ها به شاخه‌های مختلف، به تحلیل‌گران این امکان را می‌دهد تا بتوانند تصمیمات و پیش‌بینی‌های دقیقی را بر اساس داده‌های موجود اتخاذ کنند. ساختار

درخت‌های تصمیم‌گیری به گونه‌ای است که هر گره درخت نشان‌دهنده یک تصمیم یا معیار برای تقسیم داده‌ها است و هر شاخه نتیجه یک تصمیم است که داده‌ها را به دسته‌های مختلف طبقه‌بندی می‌کند. در نهایت، برگ‌های درخت نشان‌دهنده دسته‌بندی‌های نهایی هستند.

عملکرد درخت‌های تصمیم‌گیری بر اساس اصل تقسیم و غلبه است؛ به این معنا که داده‌های اولیه بر اساس معیارهایی مانند انترپوی یا معیار جینی به دسته‌های کوچک‌تر تقسیم می‌شوند. در هر گره، تصمیم‌گیری بر اساس یکی از ویژگی‌های داده انجام می‌شود و داده‌ها به شاخه‌های بعدی هدایت می‌شوند. این فرآیند تا زمانی ادامه می‌یابد که تمامی داده‌ها به یکی از دسته‌های نهایی تعلق گیرند. به‌عنوان مثال، در پیش‌بینی قیمت سهام، درخت‌های تصمیم‌گیری می‌توانند از ویژگی‌هایی مانند حجم معاملات، قیمت‌های گذشته، شاخص‌های اقتصادی و دیگر عوامل برای پیش‌بینی جهت حرکت بازار استفاده کنند [1].

یکی از مهم‌ترین مزایای درخت‌های تصمیم‌گیری، سادگی و قابلیت تفسیر بالای آن‌هاست. این روش به‌طور خاص برای تحلیل‌گرانی که به دنبال مدلی ساده و قابل درک هستند، بسیار مناسب است. درخت‌های تصمیم‌گیری به‌خوبی می‌توانند تعاملات پیچیده میان متغیرها را شناسایی کنند و نتیجه‌گیری کنند که کدام ویژگی‌ها بیشترین تأثیر را بر روی پیش‌بینی‌ها دارند. به‌علاوه، این الگوریتم نیازی به نرمال‌سازی داده‌ها ندارد و می‌تواند داده‌های خام را به‌طور مستقیم پردازش کند. این مزیت باعث می‌شود که درخت‌های تصمیم‌گیری برای تحلیل داده‌های واقعی و نویزی بسیار کارآمد باشند [2]. علاوه بر این، درخت‌های تصمیم‌گیری به‌خوبی با داده‌های گسسته و پیوسته سازگار هستند و می‌توانند در مسائل مختلف، از جمله پیش‌بینی بازار سهام، به‌طور موثر استفاده شوند.

اما در کنار مزایا، این الگوریتم معایب خود را نیز دارد. یکی از بزرگ‌ترین مشکلات درخت‌های تصمیم‌گیری، مسئله بیش‌برازش (overfitting) است. در این حالت، درخت تصمیم‌گیری ممکن است به دلیل پیچیدگی بیش از حد، داده‌های آموزشی را به‌طور کامل تطبیق دهد، اما در مواجهه با داده‌های جدید و آزمایشی دچار مشکل شود. به‌عبارت دیگر، درخت ممکن است به‌قدری دقیق به داده‌های آموزشی واکنش نشان دهد که توانایی تعمیم به داده‌های جدید را از دست بدهد. مطالعه‌ای که توسط Gajowniczek و همکاران (۲۰۱۶) انجام شد، به بررسی این مسئله پرداخت و نشان داد که استفاده از روش‌های هرس کردن (pruning) می‌تواند به کاهش بیش‌برازش در مدل‌های درختی کمک کند. هرس کردن به این مناسبت که بخش‌هایی از درخت که به نظر می‌رسد بیش از حد پیچیده هستند و تأثیر زیادی بر روی نتایج نهایی ندارند، حذف می‌شوند تا مدل ساده‌تر و قابل تعمیم‌تر شود [2].

مشکل دیگر درخت‌های تصمیم‌گیری، حساسیت آنها به تغییرات کوچک در داده‌هاست. تغییرات کوچک در داده‌های ورودی می‌تواند منجر به تغییرات بزرگ در ساختار درخت و نتیجه‌گیری‌های نهایی شود. به‌عنوان مثال، اگر داده‌های ورودی به‌صورت تصادفی دچار تغییرات جزئی شوند، ساختار درخت ممکن است به‌طور کامل تغییر کند و نتایج متفاوتی تولید کند. این مسئله می‌تواند دقت پیش‌بینی‌های درخت‌های تصمیم‌گیری را در مواجهه با داده‌های نویزی و غیرمطمئن کاهش دهد [19]. به همین دلیل، برخی از محققان توصیه می‌کنند که برای افزایش دقت و ثبات نتایج، از روش‌های ترکیبی مانند جنگل تصادفی (Random Forest) که ترکیبی از چندین درخت تصمیم‌گیری است، استفاده شود.

از نظر دقت و عملکرد، مطالعات مختلف نشان داده‌اند که درخت‌های تصمیم‌گیری در پیش‌بینی‌های مالی، به‌ویژه در پیش‌بینی حرکت قیمت سهام، می‌توانند نتایج قابل توجهی را ارائه دهند. به‌عنوان مثال، مطالعه‌ای که توسط Zhang و همکاران (۲۰۱۸) انجام شد، نشان داد که مدل‌های درخت تصمیم‌گیری ۵۰٪ توانسته‌اند الگوهای قابل توجهی را در داده‌های بازار شناسایی کنند و پیش‌بینی‌های دقیقی را ارائه دهند. این مطالعه نشان داد که درخت‌های تصمیم‌گیری می‌توانند به‌ویژه در بازارهای با نوسانات زیاد و داده‌های حجیم، عملکرد خوبی داشته باشند.

در مطالعه دیگری، Ampomah و همکاران (۲۰۲۰) به بررسی مدل‌های یادگیری ماشین مبتنی بر درخت‌های تصمیم‌گیری برای پیش‌بینی جهت حرکت قیمت سهام پرداختند. نتایج این مطالعه نشان داد که درخت‌های تصمیم‌گیری توانسته‌اند با دقت بالایی جهت حرکت بازار را پیش‌بینی کنند و در مواردی که داده‌های زیادی در دسترس بوده است، این دقت افزایش یافته است. محققان همچنین به این نکته اشاره کردند که درخت‌های تصمیم‌گیری می‌توانند به‌خوبی داده‌های گسسته و پیوسته را پردازش کنند و نیازی به نرمال‌سازی داده‌ها ندارند، که این ویژگی آنها را به یک ابزار مناسب برای پیش‌بینی‌های مالی تبدیل می‌کند [1].

اما در برخی مطالعات، محدودیت‌های درخت‌های تصمیم‌گیری نیز مورد توجه قرار گرفته است. به‌عنوان مثال، مطالعه‌ای که توسط Bousoño-Calzón و همکاران (۲۰۱۹) انجام شد، نشان داد که درخت‌های تصمیم‌گیری به دلیل ساختار سلسله‌مراتبی خود ممکن است در مواجهه با داده‌های پیچیده و نویزی دچار مشکل شوند. این مطالعه به‌ویژه به

مسئله بیش‌برازش اشاره کرد و نشان داد که درخت‌های تصمیم‌گیری ممکن است نتوانند به‌خوبی داده‌های جدید را تعمیم دهند و دقت پیش‌بینی‌های آنها در مواجهه با داده‌های ناشناخته کاهش یابد [19].

با وجود این محدودیت‌ها، درخت‌های تصمیم‌گیری همچنان به‌عنوان یکی از الگوریتم‌های محبوب و پرکاربرد در حوزه یادگیری ماشین محسوب می‌شوند. به‌ویژه در مسائلی که نیاز به تفسیر ساده و قابل درک نتایج وجود دارد، این الگوریتم می‌تواند بسیار موثر باشد. همچنین، در مسائل مالی و پیش‌بینی بازار سهام که حجم زیادی از داده‌های تاریخی و شاخص‌های اقتصادی وجود دارد، درخت‌های تصمیم‌گیری می‌توانند به شناسایی الگوهای مخفی و غیرمستقیم کمک کنند و پیش‌بینی‌های دقیقی ارائه دهند.

یکی از کاربردهای دیگر درخت‌های تصمیم‌گیری در پیش‌بینی بازار سهام، استفاده از آن‌ها در ترکیب با دیگر الگوریتم‌های یادگیری ماشین است. به‌عنوان مثال، Barak و همکاران (۲۰۱۷) نشان دادند که ترکیب درخت‌های تصمیم‌گیری با دیگر الگوریتم‌های یادگیری ماشین مانند ماشین‌های بردار پشتیبان می‌تواند دقت پیش‌بینی‌ها را افزایش دهد و به تحلیلگران کمک کند تا نتایج بهتری در پیش‌بینی بازار به دست آورند. این مطالعه نشان داد که استفاده از روش‌های ترکیبی می‌تواند به کاهش مشکلاتی مانند بیش‌برازش در درخت‌های تصمیم‌گیری کمک کند و دقت کلی پیش‌بینی‌ها را بهبود بخشد [4].

به‌طور کلی، بررسی مطالعات مختلف نشان می‌دهد که درخت‌های تصمیم‌گیری می‌توانند ابزارهای موثری برای پیش‌بینی بازار سهام باشند، اما استفاده از آن‌ها نیازمند تنظیمات دقیق و استفاده از تکنیک‌های مناسب برای جلوگیری از بیش‌برازش است. همچنین، در مواردی که داده‌های پیچیده و نویزی وجود دارند، استفاده از روش‌های ترکیبی و یا الگوریتم‌های پیچیده‌تر مانند جنگل تصادفی می‌تواند به بهبود دقت و کارایی پیش‌بینی‌ها کمک کند. به همین دلیل، درخت‌های تصمیم‌گیری همچنان به‌عنوان یکی از روش‌های اصلی در پیش‌بینی‌های مالی و بازار سهام مورد توجه محققان و تحلیلگران مالی قرار دارند.

ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان (Support Vector Machines) یکی از الگوریتم‌های پیشرفته در یادگیری ماشین هستند که به‌ویژه برای مسائل طبقه‌بندی و رگرسیون کاربرد فراوانی دارند. این الگوریتم ابتدا توسط ولادیمیر وپنیک و همکارانش توسعه داده شد و بر اساس اصول ریاضی دقیق و محکم بنا شده است. هدف اصلی ماشین‌های بردار پشتیبان این است که بهترین مرز یا «ابر صفحه» را پیدا کند که داده‌ها را به دسته‌های مختلف تقسیم کند. این مرز باید به‌گونه‌ای باشد که داده‌ها با بیشترین فاصله ممکن از آن قرار بگیرند. به‌عبارت دیگر، ماشین‌های بردار پشتیبان به دنبال یافتن ابر صفحه‌ای هستند که فاصله بین داده‌های هر دسته با آن بیشترین باشد [3].

اصول عملکرد ماشین‌های بردار پشتیبان بر پایه مفهومی به نام «فاصله‌سازی» یا «مارجین» است. این فاصله همان اندازه‌ای است که داده‌های آموزشی از مرز جداکننده دارند. الگوریتم ماشین‌های بردار پشتیبان تلاش می‌کند تا ابر صفحه‌ای را پیدا کند که این فاصله را به حداکثر برساند. این روش با استفاده از تکنیک‌های بهینه‌سازی مانند برنامه‌ریزی خطی یا درجه دوم، بهترین مرز را برای طبقه‌بندی داده‌ها تعیین می‌کند. از آنجایی که این الگوریتم بر اساس اصول ریاضی استوار است، می‌تواند در مواجهه با داده‌های پیچیده و چندبعدی، عملکرد بسیار خوبی از خود نشان دهد. یکی از مزایای کلیدی ماشین‌های بردار پشتیبان این است که حتی در شرایطی که داده‌ها به‌صورت غیرخطی قابل جدا کردن هستند، می‌تواند با استفاده از تکنیک «هسته» یا Kernel، این داده‌ها را به فضای بالاتری نگاشت کند و در آنجا مرزهای جداکننده مناسبی ایجاد کند [16].

یکی از مزایای اصلی ماشین‌های بردار پشتیبان دقت بالای آن‌ها در مسائل پیچیده و غیرخطی است. این الگوریتم می‌تواند به‌طور موثری داده‌های پیچیده و چندبعدی را طبقه‌بندی کند و الگوهایی که به‌راحتی با دیگر الگوریتم‌های ساده‌تر شناسایی نمی‌شوند، تشخیص دهد. به‌ویژه در مسائل پیش‌بینی بازار سهام که داده‌ها دارای نوسانات زیادی هستند و رفتار بازار تحت تأثیر عوامل مختلفی قرار می‌گیرد، ماشین‌های بردار پشتیبان می‌توانند عملکرد بهتری نسبت به الگوریتم‌های دیگر از خود نشان دهند [1]. مطالعه‌ای که توسط Kaščelan و همکاران (۲۰۱۴) انجام شد، نشان داد که ماشین‌های بردار پشتیبان در پیش‌بینی رفتار سرمایه‌گذاران و حرکت قیمت سهام عملکرد بسیار دقیقی داشته و توانسته‌اند الگوهای پیچیده را با دقت بالایی شناسایی کنند [3].

یکی دیگر از مزایای ماشین‌های بردار پشتیبان، انعطاف‌پذیری آن‌ها در مواجهه با داده‌های نویزی و غیرمطمئن است. این الگوریتم به دلیل استفاده از تکنیک‌های بهینه‌سازی ریاضی می‌تواند نویز موجود در داده‌ها را فیلتر کند و نتایج دقیقی‌تری ارائه دهد. به‌عنوان مثال، در مطالعه‌ای که توسط Nti و همکاران (۲۰۲۰) انجام شد، نشان داده شد که

ماشین‌های بردار پشتیبان به‌ویژه در مواجهه با داده‌های نویزی و پیچیده مانند داده‌های بازار سهام، عملکرد بهتری نسبت به دیگر الگوریتم‌ها از خود نشان داده‌اند. این مطالعه همچنین نشان داد که ماشین‌های بردار پشتیبان در شرایطی که داده‌ها دارای ابعاد بالا و پیچیدگی زیادی هستند، می‌توانند با دقت بسیار بالایی به پیش‌بینی نتایج بپردازند [15].

با این حال، ماشین‌های بردار پشتیبان نیز محدودیت‌های خاص خود را دارند. یکی از بزرگ‌ترین معایب این روش، پیچیدگی محاسباتی آن است. تنظیم پارامترهای ماشین‌های بردار پشتیبان نیاز به دقت بالایی دارد و انتخاب نادرست پارامترها می‌تواند منجر به کاهش دقت پیش‌بینی‌ها شود. به‌ویژه در مسائل مالی و پیش‌بینی بازار سهام که حجم داده‌ها بسیار بالاست، استفاده از ماشین‌های بردار پشتیبان ممکن است زمان‌بر و پیچیده باشد. به‌عنوان مثال، مطالعه‌ای که توسط Barak و همکاران (۲۰۱۷) انجام شد، نشان داد که تنظیم دقیق پارامترهای ماشین‌های بردار پشتیبان برای پیش‌بینی قیمت سهام نیازمند زمان و محاسبات پیچیده‌ای است و اگر این تنظیمات به‌درستی انجام نشود، ممکن است دقت پیش‌بینی‌ها کاهش یابد [4].

یکی دیگر از مشکلات ماشین‌های بردار پشتیبان، عدم توانایی آنها در ارائه توضیحات واضح و قابل فهم برای نتایج است. برخلاف درخت‌های تصمیم‌گیری که ساختاری ساده و قابل تفسیر دارند، ماشین‌های بردار پشتیبان به‌دلیل استفاده از تکنیک‌های ریاضی پیچیده، نتایج را به‌گونه‌ای ارائه می‌دهند که برای تحلیلگران و سرمایه‌گذاران ممکن است به‌سختی قابل تفسیر باشد. این موضوع می‌تواند در شرایطی که نیاز به تفسیر ساده و قابل فهم نتایج وجود دارد، یک محدودیت محسوب شود [5, 20].

از نظر دقت و عملکرد، مطالعات متعددی نشان داده‌اند که ماشین‌های بردار پشتیبان در پیش‌بینی‌های مالی به‌ویژه در بازارهای پیچیده و غیرخطی، عملکرد بسیار خوبی دارند. به‌عنوان مثال، مطالعه‌ای که توسط Egüz و همکاران (۲۰۲۱) بر روی بانک‌های ترکیه انجام شد، نشان داد که ماشین‌های بردار پشتیبان توانسته‌اند با دقت بالایی قیمت سهام بانک‌ها را پیش‌بینی کنند و در مواجهه با داده‌های نویزی، نتایج دقیقی ارائه دهند. این مطالعه به‌ویژه به این نکته اشاره کرد که ماشین‌های بردار پشتیبان به‌دلیل استفاده از تکنیک‌های بهینه‌سازی، می‌توانند در شرایط پیچیده و متغیر عملکرد بهتری داشته باشند و دقت پیش‌بینی‌های آنها در مقایسه با دیگر الگوریتم‌های یادگیری ماشین بالاتر است [16].

همچنین، مطالعه‌ای که توسط Ardakani و همکاران (۲۰۲۳) انجام شد، به بررسی استفاده از ماشین‌های بردار پشتیبان در پیش‌بینی روندهای بازار سهام پرداخت. نتایج این مطالعه نشان داد که ماشین‌های بردار پشتیبان به‌طور قابل توجهی توانسته‌اند نوسانات بازار را پیش‌بینی کرده و در مواجهه با داده‌های پیچیده و حجیم، عملکرد دقیقی از خود نشان دهند [17]. این مطالعه به‌ویژه به این نکته اشاره کرد که استفاده از تکنیک‌های هسته (Kernel) در ماشین‌های بردار پشتیبان می‌تواند دقت پیش‌بینی‌ها را در شرایطی که داده‌ها غیرخطی هستند، افزایش دهد.

در مطالعه دیگری که توسط Nti و همکاران (۲۰۲۰) انجام شد، عملکرد ماشین‌های بردار پشتیبان در پیش‌بینی جهت حرکت قیمت سهام بررسی شد. این مطالعه نشان داد که ماشین‌های بردار پشتیبان به‌ویژه در بازارهایی که نوسانات زیادی دارند و داده‌ها پیچیده و چندبعدی هستند، عملکرد بسیار دقیقی دارند. محققان همچنین به این نکته اشاره کردند که استفاده از ماشین‌های بردار پشتیبان می‌تواند به کاهش خطاهای پیش‌بینی کمک کند و دقت کلی پیش‌بینی‌ها را افزایش دهد [15].

یکی از مهم‌ترین نتایج این مطالعات این است که ماشین‌های بردار پشتیبان می‌توانند در مواجهه با داده‌های حجیم و پیچیده، عملکرد بسیار خوبی داشته باشند و به‌ویژه در مسائلی که نیاز به دقت بالای پیش‌بینی وجود دارد، مفید واقع شوند. با این حال، استفاده از این الگوریتم نیازمند تنظیم دقیق پارامترها و استفاده از روش‌های مناسب برای کاهش پیچیدگی محاسباتی است [3]. در مواردی که داده‌ها بسیار حجیم و پیچیده هستند، استفاده از تکنیک‌های بهینه‌سازی مانند هسته‌های غیرخطی می‌تواند به بهبود دقت پیش‌بینی‌ها کمک کند.

در نهایت، مرور مطالعات مختلف نشان می‌دهد که ماشین‌های بردار پشتیبان به‌عنوان یکی از الگوریتم‌های قدرتمند در یادگیری ماشین، می‌توانند ابزار موثری برای پیش‌بینی بازار سهام باشند. این الگوریتم‌ها به‌ویژه در شرایطی که داده‌ها پیچیده و نویزی هستند و نیاز به دقت بالای پیش‌بینی وجود دارد، عملکرد بسیار خوبی دارند. با این حال، استفاده از این الگوریتم نیازمند تنظیم دقیق و انتخاب مناسب پارامترهاست تا دقت و عملکرد آن به حداکثر برسد. در مجموع، ماشین‌های بردار پشتیبان می‌توانند به‌عنوان یکی از ابزارهای کلیدی در پیش‌بینی‌های مالی مورد استفاده قرار گیرند، به‌ویژه در شرایطی که داده‌های پیچیده و چندبعدی وجود دارد و نیاز به پیش‌بینی‌های دقیق و قابل اعتماد است.

مقایسه درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان

مقایسه درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان از منظر عملکرد، دقت، و کارایی یکی از موضوعات مهم در حوزه یادگیری ماشین و پیش‌بینی بازار سهام است. هر یک از این دو الگوریتم دارای مزایا و معایب خاص خود هستند و انتخاب بهترین الگوریتم برای کاربردهای خاص بستگی به نوع داده‌ها، پیچیدگی مسئله، و نیازهای پیش‌بینی دارد. در ادامه، به بررسی جزئیات این مقایسه و تحلیل موارد استفاده مناسب برای هر یک از این الگوریتم‌ها پرداخته می‌شود.

درخت‌های تصمیم‌گیری یکی از الگوریتم‌های ساده و در عین حال موثر در مسائل طبقه‌بندی و رگرسیون هستند. این الگوریتم‌ها به دلیل ساختار سلسله‌مراتبی و قابل تفسیر بودن، برای تحلیلگرانی که به دنبال مدلی ساده و قابل فهم هستند، بسیار مناسب می‌باشند. از نظر عملکرد، درخت‌های تصمیم‌گیری می‌توانند به‌ویژه در مسائل ساده و داده‌هایی با ساختار نسبتاً مشخص، عملکرد خوبی داشته باشند. مطالعه‌ای که توسط Ampomah و همکاران (۲۰۲۰) انجام شد، نشان داد که درخت‌های تصمیم‌گیری توانسته‌اند در پیش‌بینی جهت حرکت قیمت سهام عملکرد قابل قبولی داشته باشند و دقت پیش‌بینی‌ها در مواردی که داده‌های زیادی در دسترس بوده است، افزایش یافته است. این الگوریتم به‌خوبی می‌تواند با داده‌های گسسته و پیوسته کار کند و نیازی به نرمال‌سازی داده‌ها ندارد، که این ویژگی باعث می‌شود که به‌ویژه در مواردی که داده‌های خام مورد استفاده قرار می‌گیرند، کارآمد باشد.

از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل استفاده از تکنیک‌های ریاضی پیچیده و اصول بهینه‌سازی، در مسائل پیچیده‌تر و داده‌های چندبعدی، عملکرد بهتری دارند. این الگوریتم با استفاده از مرزهای خطی و غیرخطی به طبقه‌بندی داده‌ها می‌پردازد و از تکنیک‌های هسته (Kernel) برای شناسایی الگوهای پیچیده‌تر استفاده می‌کند. مطالعه‌ای که توسط Kaščelan و همکاران (۲۰۱۴) انجام شد، نشان داد که ماشین‌های بردار پشتیبان در پیش‌بینی رفتار سرمایه‌گذاران و حرکت قیمت سهام عملکرد بسیار دقیقی داشته و توانسته‌اند الگوهای پیچیده را با دقت بالایی شناسایی کنند [3]. همچنین، مطالعه دیگری که توسط Nti و همکاران (۲۰۲۰) انجام شد، نشان داد که این الگوریتم به‌ویژه در مواجهه با داده‌های نویزی و پیچیده، عملکرد بهتری نسبت به درخت‌های تصمیم‌گیری از خود نشان داده است [15].

از نظر دقت، ماشین‌های بردار پشتیبان به‌طور کلی در مسائل پیچیده‌تر دقت بالاتری نسبت به درخت‌های تصمیم‌گیری دارند. این الگوریتم به‌ویژه در مواردی که داده‌ها دارای نویز هستند و یا رفتار غیرخطی دارند، عملکرد بهتری از خود نشان می‌دهد. به‌عنوان مثال، مطالعه‌ای که توسط Egüz و همکاران (۲۰۲۱) بر روی بانک‌های ترکیه انجام شد، نشان داد که ماشین‌های بردار پشتیبان توانسته‌اند با دقت بالایی قیمت سهام بانک‌ها را پیش‌بینی کنند و در مواجهه با داده‌های نویزی، نتایج دقیقی ارائه دهند. از سوی دیگر، درخت‌های تصمیم‌گیری به دلیل سادگی و قابلیت تفسیر بهتر، در مسائل ساده‌تر و مواردی که داده‌ها به‌خوبی تفکیک‌پذیر هستند، عملکرد مناسبی دارند [16]. به‌عنوان مثال، در مواردی که حجم داده‌ها محدود است و الگوهای موجود در داده‌ها به‌طور واضحی قابل شناسایی هستند، درخت‌های تصمیم‌گیری می‌توانند با دقت خوبی نتایج را پیش‌بینی کنند [14].

از نظر کارایی و زمان محاسباتی، درخت‌های تصمیم‌گیری معمولاً زمان کمتری نسبت به ماشین‌های بردار پشتیبان نیاز دارند. به دلیل ساختار ساده‌تر و نیاز به تنظیمات کمتر، درخت‌های تصمیم‌گیری می‌توانند به‌سرعت مدل‌سازی شوند و نتایج پیش‌بینی را ارائه دهند. این ویژگی به‌ویژه در مواردی که نیاز به پیش‌بینی‌های سریع وجود دارد، می‌تواند مفید باشد. به‌عنوان مثال، در بازارهای مالی که نوسانات قیمت به‌سرعت رخ می‌دهد، استفاده از درخت‌های تصمیم‌گیری می‌تواند به تحلیلگران کمک کند تا به‌سرعت واکنش نشان دهند و تصمیمات خود را بهبود بخشند [4]. از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل پیچیدگی بیشتر و نیاز به تنظیم دقیق پارامترها، معمولاً زمان بیشتری برای مدل‌سازی و پیش‌بینی نیاز دارند. این مسئله به‌ویژه در شرایطی که حجم داده‌ها بسیار بالاست، می‌تواند چالش‌برانگیز باشد و زمان محاسباتی را افزایش دهد [5, 20].

در مورد نقاط قوت و ضعف هر یک از این الگوریتم‌ها، باید به این نکته اشاره کرد که درخت‌های تصمیم‌گیری به دلیل سادگی و قابلیت تفسیر بهتر، برای مسائل ساده و داده‌هایی که الگوهای واضحی دارند، مناسب‌تر هستند. این الگوریتم می‌تواند به‌سرعت داده‌ها را تحلیل کند و نتایج را به‌صورت سلسله‌مراتبی و قابل فهم ارائه دهد. از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل استفاده از تکنیک‌های پیچیده‌تر، در مواجهه با داده‌های پیچیده‌تر و غیرخطی، عملکرد بهتری دارند. این الگوریتم می‌تواند با استفاده از تکنیک‌های هسته داده‌های پیچیده را به فضای بالاتری نگاشت کند و مرزهای دقیق‌تری برای طبقه‌بندی ایجاد کند [15].

از نظر موارد استفاده مناسب، درخت‌های تصمیم‌گیری به‌ویژه در مسائل ساده‌تر و مواردی که نیاز به تفسیر آسان نتایج وجود دارد، کاربرد دارند. این الگوریتم‌ها برای تحلیلگرانی که به دنبال مدلی ساده و قابل فهم هستند و یا در مواردی که نیاز به پیش‌بینی‌های سریع وجود دارد، مناسب می‌باشند. به‌عنوان مثال، در پیش‌بینی‌های کوتاه‌مدت بازار سهام که

نیاز به واکنش سریع به تغییرات قیمت وجود دارد، درخت‌های تصمیم‌گیری می‌توانند ابزار مناسبی باشند [1]. از سوی دیگر، ماشین‌های بردار پشتیبان به‌ویژه در مواردی که داده‌ها پیچیده‌تر هستند و نیاز به دقت بالاتری وجود دارد، کاربرد بیشتری دارند. این الگوریتم‌ها می‌توانند در پیش‌بینی‌های بلندمدت و در شرایطی که داده‌ها دارای نویز و نوسانات زیادی هستند، عملکرد بهتری داشته باشند [3].

به‌طور کلی، مقایسه درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان نشان می‌دهد که هر یک از این الگوریتم‌ها در شرایط خاص خود می‌توانند ابزارهای مفیدی برای پیش‌بینی بازار سهام باشند. درخت‌های تصمیم‌گیری به‌دلیل سادگی و سرعت بالای محاسبات، برای تحلیلگرانی که به دنبال مدل‌هایی سریع و قابل فهم هستند، مناسب‌تر هستند. این الگوریتم‌ها می‌توانند در پیش‌بینی‌های کوتاه‌مدت و مسائل ساده عملکرد خوبی داشته باشند. از سوی دیگر، ماشین‌های بردار پشتیبان به‌دلیل دقت بالاتر و توانایی در شناسایی الگوهای پیچیده، برای پیش‌بینی‌های بلندمدت و داده‌های پیچیده و نویزی مناسب‌تر هستند. با این حال، استفاده از این الگوریتم‌ها نیازمند تنظیمات دقیق و زمان محاسباتی بیشتری است.

در نهایت، انتخاب بین این دو الگوریتم بستگی به نوع مسئله، داده‌های مورد استفاده، و نیازهای خاص پیش‌بینی دارد. اگر نیاز به مدلی سریع، قابل فهم و ساده وجود دارد، درخت‌های تصمیم‌گیری گزینه مناسبی هستند. اما اگر داده‌ها پیچیده و دارای نویز هستند و نیاز به دقت بالاتری وجود دارد، ماشین‌های بردار پشتیبان می‌توانند ابزار موثرتری باشند.

بحث و نتیجه‌گیری

در این مقاله، به مقایسه عملکرد دو الگوریتم مهم و پرکاربرد یادگیری ماشین، یعنی درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان، در پیش‌بینی بازار سهام پرداخته شد. نتایج بررسی‌های مختلف نشان می‌دهد که هر یک از این دو الگوریتم دارای مزایا و معایب خاص خود هستند و در شرایط خاصی عملکرد بهتری نسبت به دیگری دارند. به‌طور کلی، درخت‌های تصمیم‌گیری به‌دلیل ساختار ساده و قابل تفسیر بودن، در مسائلی که نیاز به تفسیر نتایج و سرعت در محاسبات وجود دارد، گزینه مناسبی محسوب می‌شوند. از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل توانایی در شناسایی الگوهای پیچیده و دقت بالا در پیش‌بینی‌های غیرخطی، در مواردی که داده‌ها پیچیده و نویزی هستند، عملکرد بهتری از خود نشان می‌دهند.

یکی از یافته‌های مهم این مقاله نشان می‌دهد که درخت‌های تصمیم‌گیری به‌طور خاص برای داده‌هایی که ساختار مشخص و ساده دارند و الگوهای موجود در آنها به‌وضوح قابل شناسایی هستند، عملکرد خوبی ارائه می‌دهند. به‌عنوان مثال، مطالعه‌ای که توسط Ampomah و همکاران (۲۰۲۰) انجام شد، نشان داد که درخت‌های تصمیم‌گیری در پیش‌بینی جهت حرکت قیمت سهام در مواردی که داده‌ها از نظم مشخصی برخوردار بوده‌اند، دقت بالایی داشته‌اند. این الگوریتم به دلیل سرعت بالای محاسباتی و سادگی در تفسیر نتایج، می‌تواند ابزار مفیدی برای تحلیلگرانی باشد که به دنبال پیش‌بینی‌های سریع و قابل فهم هستند.

در مقابل، ماشین‌های بردار پشتیبان به‌دلیل استفاده از تکنیک‌های بهینه‌سازی و هسته‌های غیرخطی، در مواجهه با داده‌های پیچیده و نویزی عملکرد بهتری دارند. مطالعه‌ای که توسط Kaščelan و همکاران (۲۰۱۴) انجام شد، نشان داد که ماشین‌های بردار پشتیبان توانسته‌اند با دقت بسیار بالایی رفتار سرمایه‌گذاران و نوسانات بازار را پیش‌بینی کنند. این مطالعه به‌طور خاص به این نکته اشاره کرد که ماشین‌های بردار پشتیبان با استفاده از تکنیک‌های پیچیده ریاضی می‌توانند الگوهای غیرخطی موجود در داده‌ها را شناسایی کرده و دقت پیش‌بینی‌ها را افزایش دهند [3]. همچنین، مطالعه دیگری که توسط Nti و همکاران (۲۰۲۰) انجام شد، نشان داد که این الگوریتم در مواجهه با داده‌های حجیم و نویزی، عملکرد بسیار دقیقی از خود نشان داده است [15].

یکی از تفاوت‌های کلیدی بین این دو الگوریتم در نحوه پردازش و تحلیل داده‌ها است. درخت‌های تصمیم‌گیری به‌دلیل ساختار سلسله‌مراتبی خود می‌توانند داده‌ها را به‌سرعت طبقه‌بندی کرده و نتایج را به‌صورت ساده و قابل فهم ارائه دهند. این ویژگی به‌ویژه در مواردی که نیاز به تفسیر آسان نتایج وجود دارد، بسیار مفید است. از سوی دیگر، ماشین‌های بردار پشتیبان به‌دلیل استفاده از مرزهای پیچیده برای طبقه‌بندی داده‌ها، نیاز به تنظیمات بیشتری دارند و نتایج آنها ممکن است به‌راحتی قابل تفسیر نباشد. با این حال، این الگوریتم‌ها به‌طور کلی در شرایطی که داده‌ها پیچیده و غیرخطی هستند، عملکرد بهتری از خود نشان می‌دهند [4].

یکی دیگر از یافته‌های مهم این مقاله نشان می‌دهد که هر دو الگوریتم در مواجهه با داده‌های پیچیده، می‌توانند به‌طور موثری به پیش‌بینی حرکت قیمت سهام بپردازند. با این حال، انتخاب بهترین الگوریتم به شرایط خاص مسئله بستگی دارد. اگر داده‌ها ساده و قابل تفکیک باشند، درخت‌های تصمیم‌گیری می‌توانند گزینه مناسبی باشند. اما اگر داده‌ها پیچیده و دارای نویز باشند و نیاز به دقت بالاتری وجود داشته باشد، ماشین‌های بردار پشتیبان می‌توانند انتخاب بهتری باشند [16].

با توجه به یافته‌های این مقاله، می‌توان پیشنهاداتی برای تحقیقات آینده و کاربردهای عملی در پیش‌بینی بازار سهام ارائه داد. یکی از مهم‌ترین پیشنهادات این است که برای بهبود دقت پیش‌بینی‌ها، می‌توان از ترکیب چندین الگوریتم استفاده کرد. به‌عنوان مثال، Barak و همکاران (۲۰۱۷) نشان دادند که ترکیب درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان می‌تواند به افزایش دقت پیش‌بینی‌ها کمک کند و به تحلیلگران این امکان را بدهد که از مزایای هر دو الگوریتم بهره‌مند شوند. استفاده از مدل‌های ترکیبی می‌تواند به کاهش مشکلاتی مانند بیش‌برازش در درخت‌های تصمیم‌گیری و بهبود کارایی ماشین‌های بردار پشتیبان کمک کند [4].

همچنین، یکی دیگر از پیشنهادات برای تحقیقات آینده این است که مطالعات بیشتری در زمینه بهینه‌سازی پارامترهای ماشین‌های بردار پشتیبان انجام شود. این الگوریتم به دلیل پیچیدگی بالا نیاز به تنظیم دقیق پارامترها دارد و اگر این تنظیمات به‌درستی انجام نشود، ممکن است دقت پیش‌بینی‌ها کاهش یابد. به‌عنوان مثال، مطالعه‌ای که توسط Chen و همکاران (۲۰۲۳) انجام شد، نشان داد که تنظیم دقیق پارامترهای ماشین‌های بردار پشتیبان می‌تواند به بهبود دقت پیش‌بینی‌ها کمک کند و نتایج بهتری در پیش‌بینی بازار سهام ارائه دهد. بنابراین، انجام مطالعات بیشتر در زمینه بهینه‌سازی پارامترها و توسعه تکنیک‌های جدید برای تنظیم بهتر این الگوریتم‌ها می‌تواند به بهبود عملکرد آنها در پیش‌بینی‌های مالی کمک کند [20].

از نظر کاربردهای عملی، می‌توان نتیجه گرفت که هر دو الگوریتم می‌توانند ابزارهای مفیدی برای تحلیلگران مالی و سرمایه‌گذاران در پیش‌بینی بازار سهام باشند. درخت‌های تصمیم‌گیری به دلیل سادگی و سرعت بالای محاسبات، برای پیش‌بینی‌های کوتاه‌مدت و تحلیل‌های سریع بسیار مناسب هستند. این الگوریتم‌ها می‌توانند به تحلیلگران کمک کنند تا به‌سرعت به تغییرات بازار واکنش نشان دهند و تصمیمات بهتری در زمینه خرید و فروش سهام بگیرند. از سوی دیگر، ماشین‌های بردار پشتیبان به دلیل دقت بالا و توانایی در شناسایی الگوهای پیچیده، برای پیش‌بینی‌های بلندمدت و تحلیل‌های دقیق‌تر مناسب‌تر هستند. این الگوریتم‌ها می‌توانند به تحلیلگران کمک کنند تا الگوهای مخفی و پیچیده‌ای که به راحتی با دیگر الگوریتم‌ها قابل شناسایی نیستند، شناسایی کنند و تصمیمات بهتری در زمینه سرمایه‌گذاری بگیرند.

در نهایت، با توجه به پیچیدگی‌های موجود در بازار سهام و تأثیر عوامل مختلف اقتصادی، سیاسی و اجتماعی بر روی نوسانات قیمت‌ها، استفاده از الگوریتم‌های پیشرفته یادگیری ماشین مانند درخت‌های تصمیم‌گیری و ماشین‌های بردار پشتیبان می‌تواند به تحلیلگران و سرمایه‌گذاران کمک کند تا تصمیمات بهتری در زمینه خرید و فروش سهام بگیرند و ریسک‌های مرتبط با نوسانات بازار را کاهش دهند. با این حال، انتخاب الگوریتم مناسب باید بر اساس نوع داده‌ها و شرایط خاص بازار انجام شود تا بتوان به نتایج دقیقی دست یافت.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

این پژوهش حامی مالی نداشته است.

در انجام این پژوهش تمامی موازن و اصول اخلاقی رعایت گردیده است.

References

- [1] E. K. Ampomah, Z. Qin, and G. Nyame, "Evaluation of Tree-Based Ensemble Machine Learning Models in Predicting Stock Price Direction of Movement," *Information*, vol. 11, no. 6, p. 332, 2020, doi: 10.3390/info11060332.
- [2] K. Gajowniczek, A. Orłowski, and T. Ząbkowski, "Entropy Based Trees to Support Decision Making for Customer Churn Management," *Acta Physica Polonica A*, vol. 129, no. 5, pp. 971-979, 2016, doi: 10.12693/aphyspola.129.971.
- [3] L. Kaščelan, V. Kaščelan, and M. Jovanovic, "Hybrid Support Vector Machine Rule Extraction Method for Discovering the Preferences of Stock Market Investors: Evidence From Montenegro," *Intelligent Automation & Soft Computing*, vol. 21, no. 4, pp. 503-522, 2014, doi: 10.1080/10798587.2014.971500.
- [4] S. Barak, A. Arjmand, and S. Ortobelli, "Fusion of Multiple Diverse Predictors in Stock Market," *Information Fusion*, vol. 36, pp. 90-102, 2017, doi: 10.1016/j.inffus.2016.11.006.
- [5] Q. Chen, "Stock Market Prediction Using Machine Learning," pp. 458-465, 2022, doi: 10.2991/978-94-6463-030-5_47.
- [6] P. Eachempati and P. R. Srivastava, "Prediction of the Stock Market From Linguistic Phrases," *Journal of Database Management*, vol. 34, no. 1, pp. 1-22, 2023, doi: 10.4018/jdm.322020.
- [7] K. Chauhan and N. Sharma, "Study of Linear Regression Prediction Model for American Stock Market Prediction," 2023, doi: 10.3233/atde221289.
- [8] N. Ayyıldız, "Prediction of Stock Market Index Movements With Machine Learning," 2023, doi: 10.58830/ozgur.pub354.
- [9] G. Singh, "Machine Learning Models in Stock Market Prediction," *International Journal of Innovative Technology and Exploring Engineering*, vol. 11, no. 3, pp. 18-28, 2022, doi: 10.35940/ijitee.c9733.0111322.
- [10] C.-Y. Yeh, C. W. Huang, and S.-J. Lee, "A Multiple-Kernel Support Vector Regression Approach for Stock Market Price Forecasting," *Expert Systems With Applications*, vol. 38, no. 3, pp. 2177-2186, 2011, doi: 10.1016/j.eswa.2010.08.004.
- [11] S. H. Abdulhussein, N. J. Al-Anber, and H. A. Atee, "Iraqi Stock Market Prediction Using Proposed Model of Convolution Neural Network," *Journal of Computer Science*, vol. 18, no. 5, pp. 350-358, 2022, doi: 10.3844/jcsp.2022.350.358.
- [12] S. P. S. Rathore, "Stock Market Analysis and Prediction," *International Journal of Engineering in Computer Science*, vol. 2, no. 2, pp. 34-38, 2020, doi: 10.33545/26633582.2020.v2.i2a.100.
- [13] E. Chong, C. E. Han, and F. C. Park, "Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, and Case Studies," *Expert Systems With Applications*, vol. 83, pp. 187-205, 2017, doi: 10.1016/j.eswa.2017.04.030.
- [14] Q. Zhang, J. Zhang, Z. Chen, M. Zhang, and S.-Y. Li, "A New Stock Selection Model Based on Decision Tree C5.0 Algorithm," *Journal of Investment and Management*, vol. 7, no. 4, p. 117, 2018, doi: 10.11648/j.jim.20180704.12.
- [15] I. K. Nti, A. F. Adekoya, and B. A. Weyori, "Efficient Stock-Market Prediction Using Ensemble Support Vector Machine," *Open Computer Science*, vol. 10, no. 1, pp. 153-163, 2020, doi: 10.1515/comp-2020-0199.
- [16] B. Egüz, F. E. Çorbacı, and T. Kaya, "Stock Price Prediction of Turkish Banks Using Machine Learning Methods," pp. 222-229, 2021, doi: 10.1007/978-3-030-85577-2_26.
- [17] S. P. Ardakani, N. Du, L. Cai, J.-C. Yang, Z. Bi, and L. Chen, "A Federated Learning-Enabled Predictive Analysis to Forecast Stock Market Trends," *Journal of Ambient Intelligence and Humanized Computing*, vol. 14, no. 4, pp. 4529-4535, 2023, doi: 10.1007/s12652-023-04570-4.
- [18] M. Sedighi, H. Jahangirnia, M. Gharakhani, and S. F. Fard, "A Novel Hybrid Model for Stock Price Forecasting Based on Metaheuristics and Support Vector Machine," *Data*, vol. 4, no. 2, p. 75, 2019, doi: 10.3390/data4020075.
- [19] C. Bousoño-Calzón, J. Bustarviejo-Munoz, P. A. Aceituno, and J. J. Escudero-Garzás, "On the Economic Significance of Stock Market Prediction and the No Free Lunch Theorem," *Ieee Access*, vol. 7, pp. 75177-75188, 2019, doi: 10.1109/access.2019.2921092.
- [20] Y. Chen *et al.*, "A New Stock Market Analysis Method Based on Evidential Reasoning and Hierarchical Belief Rule Base to Support Investment Decision Making," *Frontiers in Psychology*, vol. 14, 2023, doi: 10.3389/fpsyg.2023.1123578.