ACCOUNTING, FINANCE AND COMPUTATIONAL INTELLIGENCE

Prediction of the Iranian Stock Market Using Elliott Wave Oscillations and Relative Strength Index with the Aid of Machine Learning

1. Mohammad Javad Mahmoudi*: Associate Professor of Economics, Faculty Member, Ministry of Science, Research and Technology, Tehran, Iran. Email: mah94@chmail.ir (Corresponding Author)

2. Seyedeh Melika Lajevardi: M.A., Department of Applied Mathematics, Payame Noor University, Tabriz, Iran

3. Parviz Yari: M.A., Department of Applied Mathematics, Payame Noor University, Tabriz, Iran

Article history

Received: 21 January 2026

Revised: 25 May 2026

Accepted: 03 June 2026

Initial Publish: 16 June 2026

Final Publish: 23 August 2027

Abstract:

The present study aimed to predict the trend of the Iranian stock market using the Elliott Wave Oscillator and Relative Strength Index within machine learning algorithms. This quantitative study was conducted using the daily data of the Tehran Stock Exchange Total Index from April 30, 2011, to September 21, 2024. Data were collected from the Iran Financial Information Processing Center and underwent preprocessing procedures including noise removal, normalization, and labeling into buy, sell, and hold categories. Technical signals were extracted through the Elliott Wave Oscillator and Relative Strength Index (RSI). Subsequently, the processed dataset was applied to four machine learning classification algorithms, including Decision Tree, Naïve Bayes, Support Vector Machine, and K-Nearest Neighbors. Seventy percent of the data were used for training and thirty percent for testing the models. Model performance was evaluated using accuracy, precision, and recall indicators. The findings demonstrated that identifying Elliott Waves in the Tehran Stock Exchange Index is feasible and that combining the Elliott Wave Oscillator with RSI effectively detects buy, sell, and hold positions. The machine learning algorithms also showed satisfactory performance in predicting market trends. Among the examined models, the Support Vector Machine and Decision Tree algorithms outperformed the other methods and achieved prediction accuracies above 90 percent. The results further indicated that integrating technical indicators with intelligent learning methods significantly improved forecasting capability and reduced prediction errors. The findings suggest that Elliott Wave Theory combined with the Relative Strength Index and machine learning algorithms can serve as an effective framework for predicting the Iranian stock market trend. This integrated approach may assist investors and traders in identifying market turning points, managing investment risk, and making more accurate trading decisions while supporting the development of intelligent financial forecasting systems.

Keywords: Trend Prediction, Technical Analysis, Elliott Wave Theory, Relative Strength Index, Machine Learning, Iranian Stock Market

---

Citation: Mahmoudi, M. J., Lajevardi, S. M., & Yari, P. (2027). Prediction of the Iranian Stock Market Using Elliott Wave Oscillations and Relative Strength Index with the Aid of Machine Learning. *Accounting, Finance and Computational Intelligence,* 5(3), 1-23.

Copyright: © 2027 by the authors. Published under the terms and conditions of Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

Extended Abstract

Introduction

Stock market forecasting has long been considered one of the most challenging issues in financial economics due to the nonlinear, dynamic, and uncertain nature of financial markets. Investors, portfolio managers, and policymakers continuously seek reliable methods for predicting market trends in order to reduce uncertainty, manage risk, and improve investment performance. Traditional financial forecasting approaches mainly relied on fundamental analysis and technical analysis. Fundamental analysis focuses on macroeconomic variables, financial statements, and firm performance, whereas technical analysis examines historical price movements, trading volume, and behavioral patterns in the market (Murphy, 2018). With the expansion of digital financial systems and the increasing availability of large-scale financial data, machine learning approaches have emerged as powerful alternatives to traditional forecasting methods (Bustos & Pomares-Quimbaya, 2020).

Financial markets are heavily influenced by investor psychology and collective behavioral reactions. Technical analysis theories, especially Elliott Wave Theory, assume that market movements are not entirely random and that repetitive wave patterns can be identified within financial time series. Elliott Wave Theory proposes that market prices move in recurring impulsive and corrective waves shaped by collective investor sentiment (Atsalakis et al., 2011). Previous studies have shown that Elliott Wave structures can be useful for identifying market turning points and forecasting future price trends in stock and foreign exchange markets (Jarusek et al., 2022; Satari et al., 2020). Moreover, Balasubramaniam and colleagues argued that wave oscillation structures can improve prediction efficiency in dynamic data environments (Balasubramaniam et al., 2022).

Another important technical indicator widely used in financial forecasting is the Relative Strength Index (RSI). RSI is a momentum-based indicator that measures the speed and magnitude of price movements and helps identify overbought and oversold market conditions. Prior studies have demonstrated that combining RSI with other technical indicators improves forecasting accuracy and reduces false trading signals (Khairi et al., 2019). In the Tehran Stock Exchange, technical indicators and candlestick-based strategies have also been shown to generate favorable investment returns (Peymani Foroushani et al., 2021).

In recent years, machine learning algorithms have gained significant attention in stock market prediction because of their capability to detect nonlinear relationships and hidden structures within large financial datasets. Algorithms such as Support Vector Machine (SVM), Decision Tree, Naive Bayes, Random Forest, Artificial Neural Networks, and Long Short-Term Memory (LSTM) networks have been widely applied in financial forecasting studies (Basak et al., 2019; Khaidem et al., 2016; Moghar & Hamiche, 2020). Deep learning models, in particular, have shown substantial ability to model complex market dynamics and temporal dependencies (Ji et al., 2021; Yu & Yan, 2020).

Among machine learning methods, Support Vector Machine has demonstrated superior performance in handling nonlinear financial data and classification problems (Bazrkar & Hosseini, 2023; Li-Xia et al., 2011). Decision Tree algorithms are also popular due to their interpretability and transparent classification structure (Gupta et al., 2017). Similarly, Naive Bayes classifiers have been applied successfully in risk management and probabilistic classification tasks because of their computational simplicity and efficiency (Chen et al., 2021; Wickramasinghe & Kalutarage, 2021).

Recent financial forecasting studies increasingly emphasize hybrid models that integrate technical indicators with machine learning and optimization techniques. For example, evolutionary optimization methods, particle swarm optimization, and

decomposition ensemble models have significantly improved prediction accuracy in stock markets (Bose & Mali, 2019; Chauhan et al., 2023; Guo et al., 2022). Advanced deep learning architectures combined with big data analytics have also produced promising results in market forecasting (Kanchanamala et al., 2024). Furthermore, modern algorithmic trading systems and reinforcement learning-based trading frameworks have transformed contemporary financial markets and automated investment decision-making processes (Clapham et al., 2023; Kong & So, 2023).

Despite the rapid development of intelligent forecasting systems, relatively limited research has examined the simultaneous integration of Elliott Wave Oscillator, Relative Strength Index, and supervised machine learning algorithms in the Iranian stock market. Moreover, the Tehran Stock Exchange is characterized by high volatility, investor sentiment fluctuations, and economic uncertainty, which create additional forecasting challenges. Therefore, developing a hybrid forecasting model capable of integrating technical indicators with machine learning algorithms appears necessary (Ghallabi et al., 2025; Rezaeian et al., 2024). Accordingly, the present study aimed to predict the trend of the Iranian stock market using Elliott Wave Oscillator and Relative Strength Index through supervised machine learning algorithms.

Methods and Materials

The present study employed a quantitative research design based on technical analysis indicators and machine learning classification methods. Daily data of the Tehran Stock Exchange Total Index were collected from April 30, 2011, to September 21, 2024, using the official database of the Iran Financial Information Processing Center (FIPIRAN). The collected dataset represented the overall condition and movement of the Iranian stock market.

The forecasting framework consisted of several sequential stages. First, the raw data underwent preprocessing procedures, including noise removal, normalization, sorting, and labeling. The data were then transformed into machine-readable numerical formats. Elliott Wave Oscillator (EWO) and Relative Strength Index (RSI) were calculated as the primary technical indicators. The Elliott Wave Oscillator was obtained by subtracting the 35-day moving average from the 5-day moving average. Positive oscillator values indicated impulsive upward movements, whereas negative values reflected corrective downward trends.

The RSI indicator was used as a confirmation mechanism for trend direction and momentum strength. Based on the combination of EWO and RSI values, market movements were labeled into three categories: LONG (buy), SHORT (sell), and HOLD (neutral). HOLD labels were assigned to periods where the two indicators generated conflicting signals.

The machine learning stage included four supervised classification algorithms: Decision Tree, Naive Bayes, Support Vector Machine, and K-Nearest Neighbors (KNN). Input variables consisted of price changes, multiple EWO lag values, and RSI changes, while the output variable represented the market trend category. Seventy percent of the dataset was allocated for training and thirty percent for testing. Model performance was evaluated using classification accuracy, precision, and recall measures.

Findings

The findings demonstrated that Elliott Wave patterns could be successfully identified within the Tehran Stock Exchange index and that wave oscillation structures effectively reflected market momentum and corrective phases. The Elliott Wave Oscillator generated larger positive oscillations during impulsive market movements and smaller fluctuations during corrective waves.

The combined RSI-EWO strategy successfully identified buy, sell, and hold positions within the market. The labeling process produced balanced market classifications, enabling the machine learning algorithms to distinguish between bullish, bearish, and neutral market conditions. A total of 2,954 daily observations were analyzed, with the dataset distributed across LONG, SHORT, and HOLD categories.

The results further indicated that machine learning algorithms achieved high forecasting performance in predicting market trends. Among the examined models, Support Vector Machine and Decision Tree classifiers demonstrated the highest prediction accuracy. Both models achieved forecasting accuracy above 90 percent in classifying future market movements. The SVM classifier showed strong capability in modeling nonlinear market structures and separating complex decision boundaries. Similarly, the Decision Tree algorithm effectively captured rule-based relationships between technical indicators and market trends.

The Naive Bayes classifier also produced acceptable forecasting performance; however, its accuracy was lower than SVM and Decision Tree models due to the probabilistic independence assumptions embedded within the algorithm. K-Nearest Neighbors showed moderate classification performance but demonstrated sensitivity to noisy market fluctuations and high-dimensional financial data.

The statistical findings confirmed that integrating technical analysis indicators with supervised machine learning algorithms significantly enhanced forecasting performance. The hybrid RSI-EWO approach reduced false trading signals and improved classification reliability. Overall, the results demonstrated that the proposed forecasting framework could effectively identify market turning points and predict future stock market trends in the Iranian financial market.

Discussion and Conclusion

The present study demonstrated that combining Elliott Wave Oscillator, Relative Strength Index, and machine learning algorithms provides an effective framework for forecasting stock market trends in Iran. The findings support the theoretical assumptions of technical analysis, particularly the idea that financial markets exhibit repetitive behavioral structures and that investor psychology influences price movements over time. The successful identification of Elliott Wave patterns indicates that portions of the Tehran Stock Exchange behavior are predictable rather than entirely random.

The superior performance of Support Vector Machine and Decision Tree algorithms highlights the importance of nonlinear modeling approaches in financial forecasting. Financial markets contain noisy, volatile, and multidimensional data structures, making traditional linear forecasting methods insufficient in many cases. Machine learning algorithms can effectively capture hidden relationships among technical indicators and market behavior, thereby improving prediction accuracy and reducing forecasting error.

The findings also reinforce the growing importance of hybrid intelligent systems in financial analytics. Integrating technical indicators with machine learning methods enabled the proposed model to achieve higher forecasting precision and more reliable trading signal generation. The inclusion of RSI as a confirmation indicator reduced contradictory trading signals and enhanced decision-making consistency.

From a practical perspective, the proposed framework may assist investors, portfolio managers, and financial institutions in identifying market turning points, improving trading decisions, and managing investment risk more efficiently. The results also suggest that intelligent forecasting systems can contribute to the development of algorithmic trading platforms and automated investment systems within emerging financial markets such as Iran.

Overall, the present study confirmed that combining Elliott Wave Theory, Relative Strength Index, and supervised machine learning algorithms creates a powerful forecasting framework for stock market prediction. The integration of technical analysis and artificial intelligence techniques offers significant potential for improving financial forecasting accuracy and supporting intelligent decision-making in modern capital markets.

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.

حسابداری، امور مالی و هوش محاسباتی

پیش‌بینی بازار سهام ایران با استفاده از نوسانات امواج الیوت و شاخص قدرت نسبی با کمک یادگیری ماشین

۱. محمد جواد محمودی*: دانشـیار اقتصـاد، عضـو هیئت علمی وزارت علوم، تحقیقات و فناوری، تهران، ایران. ایمیل: **mah94@chmail.ir** (نویسنده مسئول)

۲. سیده ملیکا لاجوردی: کارشناسی ارشد، گروه ریاضی کاربردی، دانشگاه پیام نور، تبریز، ایران

۳. پرویز یاری: کارشناسی ارشد، گروه ریاضی کاربردی، دانشگاه پیام نور، تبریز، ایران

تاریخچه مقاله

تاریخ دریافت: ۱ بهمن ۱۴۰۴

تاریخ بازنگری: ۴ خرداد ۱۴۰۵

تاریخ پذیرش: ۱۳ خرداد ۱۴۰۵

تاریخ چاپ اولیه: ۲۶ خرداد ۱۴۰۵

تاریخ چاپ نهایی: ۱ شهریور ۱۴۰۶

چکیده

هدف پژوهش حاضر، پیش‌بینی روند بازار سهام ایران با استفاده از نوسان‌نمای موج الیوت و شاخص قدرت نسبی در چارچوب الگوریتم‌های یادگیری ماشین بود. این پژوهش با رویکرد کمی و با استفاده از داده‌های روزانه شاخص کل بورس اوراق بهادار تهران از تاریخ ۱۳۹۰/۰۴/۳۰تا ۱۴۰۳/۰۶/۳۱ انجام شد. داده‌ها از پایگاه فناوری بورس ایران جمع‌آوری و پس از پیش‌پردازش شامل حذف داده‌های پرت، نرمال‌سازی و برچسب‌گذاری، به سه گروه خرید، فروش و نگهداری تقسیم شدند. برای استخراج سیگنال‌های معاملاتی از نوسان‌نمای موج الیوت و شاخص قدرت نسبی (RSI) استفاده شد. سپس داده‌ها به چهار الگوریتم یادگیری ماشین شامل درخت تصمیم، بیز ساده، ماشین بردار پشتیبان و K-نزدیک‌ترین همسایه وارد شدند. ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای آزمون مدل‌ها مورد استفاده قرار گرفت. عملکرد مدل‌ها با شاخص‌هایی نظیر دقت، صحت و فراخوانی ارزیابی شد. نتایج نشان داد که شناسایی امواج الیوت در شاخص بورس اوراق بهادار تهران امکان‌پذیر است و ترکیب نوسان‌نمای موج الیوت با شاخص قدرت نسبی توانایی مناسبی در تشخیص موقعیت‌های خرید، فروش و نگهداری دارد. همچنین الگوریتم‌های یادگیری ماشین در پیش‌بینی روند شاخص کل عملکرد مطلوبی ارائه کردند. در میان مدل‌های مورد بررسی، ماشین بردار پشتیبان و درخت تصمیم نسبت به سایر الگوریتم‌ها عملکرد دقیق‌تری داشتند و توانستند روند بازار را با دقتی بیش از ۹۰ درصد پیش‌بینی کنند. نتایج همچنین نشان داد که استفاده همزمان از شاخص‌های تکنیکال و روش‌های هوشمند موجب بهبود توانایی پیش‌بینی و کاهش خطای مدل‌ها شده است. یافته‌های پژوهش نشان داد که نظریه امواج الیوت در کنار شاخص قدرت نسبی و الگوریتم‌های یادگیری ماشین می‌تواند ابزار مؤثری برای پیش‌بینی روند بازار سهام ایران باشد. استفاده از این رویکرد ترکیبی می‌تواند به سرمایه‌گذاران و معامله‌گران در شناسایی نقاط بازگشت بازار، مدیریت ریسک و اتخاذ تصمیمات معاملاتی دقیق‌تر کمک کند و زمینه توسعه سامانه‌های هوشمند تحلیل بازار سرمایه را فراهم سازد.

کلیدواژگان: پیش‌بینی روند، تحلیل تکنیکال، نظریه موج الیوت، شاخص قدرت نسبی، یادگیری ماشین، بازار سهام ایران

شیوه استناددهی: محمودی، محمد جواد.، لاجوردی، سیده ملیکا.، و یاری، پرویز. (۱۴۰۶). پیش‌بینی بازار سهام ایران با استفاده از نوسانات امواج الیوت و شاخص قدرت نسبی با کمک یادگیری ماشین. *حسابداری، امور مالی و هوش محاسباتی*، ۵(۳)، ۲۳-۱.

مجوز و حق نشر: © ۱۴۰۶ تمامی حقوق انتشار این مقاله متعلق به نویسنده است. انتشار این مقاله به‌صورت دسترسی آزاد مطابق با گواهی (CC BY-NC 4.0) صورت گرفته است.

مقدمه

بازارهای مالی و به‌ویژه بازار سهام، یکی از مهم‌ترین ارکان نظام اقتصادی کشورها محسوب می‌شوند و نقش تعیین‌کننده‌ای در هدایت سرمایه‌ها، تأمین مالی بنگاه‌های اقتصادی و رشد اقتصادی دارند. در این میان، پیش‌بینی روند قیمت سهام همواره یکی از مهم‌ترین دغدغه‌های سرمایه‌گذاران، معامله‌گران و پژوهشگران حوزه مالی بوده است؛ زیرا تصمیم‌گیری صحیح در خصوص خرید، فروش یا نگهداری سهام تا حد زیادی وابسته به توانایی تحلیل و پیش‌بینی رفتار آینده بازار است. پیچیدگی ذاتی بازارهای مالی، وجود عوامل متعدد اقتصادی، سیاسی، روان‌شناختی و اجتماعی، و همچنین نوسانات شدید بازار موجب شده است که پیش‌بینی روند بازار سهام به یکی از چالش‌برانگیزترین مسائل علوم مالی و داده‌کاوی تبدیل شود (Bustos & Pomares-Quimbaya, 2020; Rezaeian et al., 2024).

در دهه‌های اخیر، توسعه فناوری اطلاعات و افزایش حجم داده‌های مالی موجب تحول اساسی در روش‌های تحلیل بازار شده است. در گذشته، تحلیلگران عمدتاً از دو رویکرد تحلیل بنیادی و تحلیل تکنیکال برای بررسی روند بازار استفاده می‌کردند. تحلیل بنیادی مبتنی بر بررسی متغیرهای اقتصادی، صورت‌های مالی شرکت‌ها و شاخص‌های کلان اقتصادی است؛ در حالی که تحلیل تکنیکال بر رفتار قیمت، حجم معاملات و الگوهای تاریخی بازار تمرکز دارد (Murphy, 2018). تحلیلگران تکنیکال معتقدند که تمامی اطلاعات مرتبط با بازار در قیمت منعکس شده است و بنابراین بررسی روند قیمت و الگوهای رفتاری آن می‌تواند مبنای مناسبی برای پیش‌بینی آینده بازار باشد (Shahrabadi & Bashiri, 2010).

یکی از شناخته‌شده‌ترین ابزارهای تحلیل تکنیکال، نظریه موج الیوت است که بر مبنای رفتار روان‌شناختی جمعی سرمایه‌گذاران شکل گرفته است. این نظریه بیان می‌کند که بازارهای مالی از الگوهای موجی تکرارشونده پیروی می‌کنند که شامل امواج جنبشی و اصلاحی هستند و این امواج می‌توانند روند آینده بازار را تا حدی آشکار سازند (Atsalakis et al., 2011; Satari et al., 2020). نظریه موج الیوت علاوه بر بازار سهام، در بازار ارز، کالا و سایر بازارهای مالی نیز کاربرد گسترده‌ای یافته و پژوهش‌های مختلفی کارایی آن را در تحلیل روندهای مالی تأیید کرده‌اند (Balasubramaniam et al., 2022; Jarusek et al., 2022). از منظر نظری، این رویکرد مبتنی بر اصل تکرارپذیری رفتار انسانی در بازار است و معتقد است که تصمیمات معامله‌گران در قالب الگوهای مشخصی بروز می‌یابد که می‌توان آن‌ها را شناسایی و تحلیل کرد (Li et al., 2014).

در کنار نظریه موج الیوت، شاخص قدرت نسبی یا RSI نیز از مهم‌ترین اندیکاتورهای تکنیکال محسوب می‌شود که برای شناسایی شرایط بیش‌خرید و بیش‌فروش بازار به کار می‌رود. این شاخص سرعت و شدت تغییرات قیمت را اندازه‌گیری می‌کند و به معامله‌گران کمک می‌کند تا نقاط بازگشت احتمالی بازار را تشخیص دهند. پژوهش‌های متعددی نشان داده‌اند که استفاده هم‌زمان از اندیکاتورهای تکنیکال می‌تواند دقت پیش‌بینی بازار را بهبود بخشد و ریسک معاملات را کاهش دهد (Khairi et al., 2019; Peymani et al., 2021). به همین دلیل، ترکیب شاخص قدرت نسبی با نظریه موج الیوت می‌تواند چارچوب مناسبی برای تحلیل روند بازار و استخراج سیگنال‌های معاملاتی فراهم کند.

با وجود کاربرد گسترده ابزارهای تحلیل تکنیکال، بازارهای مالی ماهیتی غیرخطی، پویا و پیچیده دارند و همین مسئله موجب شده است که روش‌های سنتی تحلیل نتوانند همواره عملکرد دقیقی در پیش‌بینی روند بازار ارائه دهند. در سال‌های اخیر، پیشرفت چشمگیر در حوزه هوش مصنوعی و یادگیری ماشین، افق‌های جدیدی را در تحلیل داده‌های مالی گشوده است. الگوریتم‌های یادگیری ماشین قادرند حجم عظیمی از داده‌ها را پردازش کرده، روابط پنهان و الگوهای غیرخطی را شناسایی کنند و پیش‌بینی‌هایی با دقت بالا ارائه دهند (Ji et al., 2021; Yu & Yan, 2020). به همین دلیل، استفاده از یادگیری ماشین در بازارهای مالی به یکی از موضوعات مهم پژوهشی تبدیل شده است.

الگوریتم‌های مختلف یادگیری ماشین، از جمله درخت تصمیم، بیز ساده، ماشین بردار پشتیبان، شبکه‌های عصبی و روش‌های مبتنی بر یادگیری عمیق، در پژوهش‌های متعددی برای پیش‌بینی قیمت سهام مورد استفاده قرار گرفته‌اند. برای مثال، پژوهش‌های انجام‌شده نشان داده‌اند که شبکه‌های عصبی عمیق و مدل‌های مبتنی بر LSTM توانایی بالایی در مدل‌سازی سری‌های زمانی مالی دارند و می‌توانند رفتار پیچیده بازار را با دقت مطلوبی پیش‌بینی کنند (Moghar & Hamiche, 2020; Yu & Yan, 2020). همچنین پژوهش‌های مبتنی بر الگوریتم‌های جنگل تصادفی، درخت تصمیم و ماشین بردار پشتیبان نیز نشان داده‌اند که این روش‌ها می‌توانند در شناسایی روند قیمت سهام و طبقه‌بندی داده‌های مالی عملکرد مناسبی داشته باشند (Basak et al., 2019; Gupta et al., 2017; Khaidem et al., 2016).

در میان الگوریتم‌های یادگیری ماشین، ماشین بردار پشتیبان به دلیل توانایی در مدل‌سازی داده‌های غیرخطی و کارایی بالا در داده‌های با ابعاد زیاد، توجه زیادی را به خود جلب کرده است. این الگوریتم در مسائل مختلف مالی و اقتصادی مورد استفاده قرار گرفته و نتایج مطلوبی ارائه داده است (Bazrkar & Hosseini, 2023; Li-Xia et al., 2011). از سوی دیگر، الگوریتم درخت تصمیم نیز به دلیل سادگی، شفافیت و قابلیت تفسیر بالا، یکی از پرکاربردترین روش‌ها در طبقه‌بندی داده‌های مالی محسوب می‌شود (Viswanath, 2022). همچنین الگوریتم بیز ساده به دلیل سرعت پردازش و توانایی مدیریت داده‌های احتمالاتی، در حوزه تحلیل ریسک و پیش‌بینی روند بازار کاربرد گسترده‌ای یافته است (Chen et al., 2021; Wickramasinghe & Kalutarage, 2021).

پیشرفت فناوری‌های یادگیری عمیق و داده‌کاوی موجب شده است که پژوهشگران به سمت طراحی مدل‌های ترکیبی و هیبریدی برای پیش‌بینی بازار حرکت کنند. در این مدل‌ها معمولاً از ترکیب اندیکاتورهای تکنیکال، الگوریتم‌های هوشمند و روش‌های بهینه‌سازی استفاده می‌شود تا دقت پیش‌بینی افزایش یابد. برای نمونه، استفاده از الگوریتم‌های بهینه‌سازی ازدحام ذرات در کنار شبکه‌های عصبی و مدل‌های یادگیری ماشین توانسته است عملکرد مدل‌های پیش‌بینی را بهبود بخشد (Bose & Mali, 2019; Chauhan et al., 2023; Guo et al., 2022). همچنین پژوهش‌های جدیدتر نشان می‌دهند که مدل‌های مبتنی بر یادگیری تقویتی عمیق و سامانه‌های چندعاملی می‌توانند در معاملات خودکار و مدیریت ریسک بازار نقش مؤثری ایفا کنند (Kong & So, 2023; Potdar & Mahadik, 2025).

در سطح کلان، رشد معاملات الگوریتمی و معاملات فرکانس بالا نیز ساختار بازارهای مالی را متحول کرده است. امروزه بخش قابل توجهی از معاملات بازارهای جهانی توسط سامانه‌های هوشمند انجام می‌شود و این مسئله اهمیت توسعه مدل‌های پیش‌بینی دقیق را دوچندان کرده است (Clapham et al., 2023). در چنین شرایطی، توانایی تحلیل سریع داده‌ها و استخراج الگوهای پنهان از طریق یادگیری ماشین، به مزیت رقابتی مهمی برای سرمایه‌گذاران و مؤسسات مالی تبدیل شده است.

در بازار سرمایه ایران نیز طی سال‌های اخیر توجه به روش‌های هوشمند تحلیل بازار افزایش یافته است. نوسانات شدید شاخص بورس، تغییرات اقتصادی و رفتار هیجانی سرمایه‌گذاران باعث شده است که نیاز به مدل‌های پیش‌بینی دقیق بیش از گذشته احساس شود. برخی پژوهش‌ها در ایران از شبکه‌های عصبی و مدل‌های سری زمانی برای پیش‌بینی شاخص بورس تهران استفاده کرده‌اند و نتایج قابل قبولی گزارش شده است (Haghighat Monfared et al., 2012). همچنین پژوهش‌هایی در حوزه تحلیل تکنیکال بازار سرمایه ایران نشان داده‌اند که الگوهای شمعی و شاخص‌های تکنیکال می‌توانند در پیش‌بینی بازده معاملات مؤثر باشند (Peymani Foroushani et al., 2021).

با وجود پیشرفت‌های صورت‌گرفته، هنوز چالش‌های متعددی در زمینه پیش‌بینی بازار سهام ایران وجود دارد. بسیاری از پژوهش‌ها تنها بر یک روش یا یک الگوریتم متمرکز بوده‌اند و کمتر به استفاده تلفیقی از نظریه موج الیوت، شاخص قدرت نسبی و الگوریتم‌های یادگیری ماشین پرداخته شده است. علاوه بر این، بخش عمده‌ای از مطالعات گذشته بر بازارهای بین‌المللی متمرکز بوده و پژوهش‌های اندکی در زمینه کاربرد مدل‌های ترکیبی هوشمند در بازار سهام ایران انجام شده است (Ghallabi et al., 2025; Kanchanamala et al., 2024). از این رو، توسعه مدلی جامع که بتواند از مزایای تحلیل تکنیکال و توانایی یادگیری ماشین به صورت هم‌زمان بهره ببرد، از اهمیت بالایی برخوردار است.

مطالعات اخیر نشان داده‌اند که ترکیب روش‌های یادگیری ماشین با شاخص‌های تکنیکال می‌تواند دقت پیش‌بینی بازار را به‌طور معناداری افزایش دهد. برای مثال، استفاده از ضریب همبستگی پیرسون در سیستم‌های یادگیری گسترده توانسته است عملکرد پیش‌بینی قیمت سهام را بهبود دهد (Li et al., 2022). همچنین مدل‌های مبتنی بر انتخاب هوشمند سهام و بهینه‌سازی پرتفوی با استفاده از یادگیری ماشین، بازده بالاتری نسبت به روش‌های سنتی ایجاد کرده‌اند (Chaweewanchon & Chaysiri, 2022). افزون بر این، پژوهش‌های مبتنی بر تحلیل سری‌های زمانی و الگوریتم‌های تکاملی نشان داده‌اند که ترکیب روش‌های هوشمند و داده‌های تکنیکال می‌تواند در مدیریت ریسک و افزایش دقت پیش‌بینی مؤثر باشد (Kumar et al., 2022).

در مجموع، ادبیات پژوهش نشان می‌دهد که بازار سهام محیطی پیچیده و پویاست که تحلیل آن نیازمند استفاده از ابزارهای پیشرفته و مدل‌های هوشمند است. نظریه موج الیوت و شاخص قدرت نسبی از جمله ابزارهای مهم تحلیل تکنیکال محسوب می‌شوند که در صورت ترکیب با الگوریتم‌های یادگیری ماشین می‌توانند چارچوبی قدرتمند برای

پیش‌بینی روند بازار ایجاد کنند. از سوی دیگر، اهمیت روزافزون معاملات الگوریتمی، مدیریت ریسک و تصمیم‌گیری هوشمند در بازارهای مالی، ضرورت توسعه چنین مدل‌هایی را بیش از پیش آشکار ساخته است.

بنابراین، هدف پژوهش حاضر پیش‌بینی روند بازار سهام ایران با استفاده از نوسانات موج الیوت و شاخص قدرت نسبی با کمک الگوریتم‌های یادگیری ماشین است.

روش پژوهش و مواد

پژوهش حاضر به صورت کمی مورد ارزیابی قرار گرفته است. بر این اساس با استفاده از منابع کتابخانه‌ای و اینترنت، مقالات مورد مطالعه قرار گرفت و سپس داده‌های شاخص کل، به عنوان دماسنج اقتصاد و نمایانگر وضعیت کلی بازار سهام ایران از تاریخ ۱۳۹۰/۴/۳۰تا ۱۴۰۳/۶/۳۱ از سایت fipiran به آدرس اینترنتی https://www.fipiran.com/DataService/IndexIndex به طور روزانه جمع‌آوری شد و با استفاده از نوسان نمای موج الیوت و شاخص قدرت حرکت، حرکات جنبشی و اصلاحی شناسایی و به سه دسته خرید، فروش و نگهداری برچسب گذاری شدند. سپس، خروجی این مرحله به چهار الگوریتم یادگیری ماشین شامل درخت تصمیم، بیز ساده، K- نزدیکترین همسایه و ماشین بردار پشتیبان داده شد، تا برای یادگیری و پس از آن، پیش‌بینی روند روی داده‌های آزمون، آزمایش شد. فلوچارت روش پیشنهادی در شکل ۱، ارائه شده است.

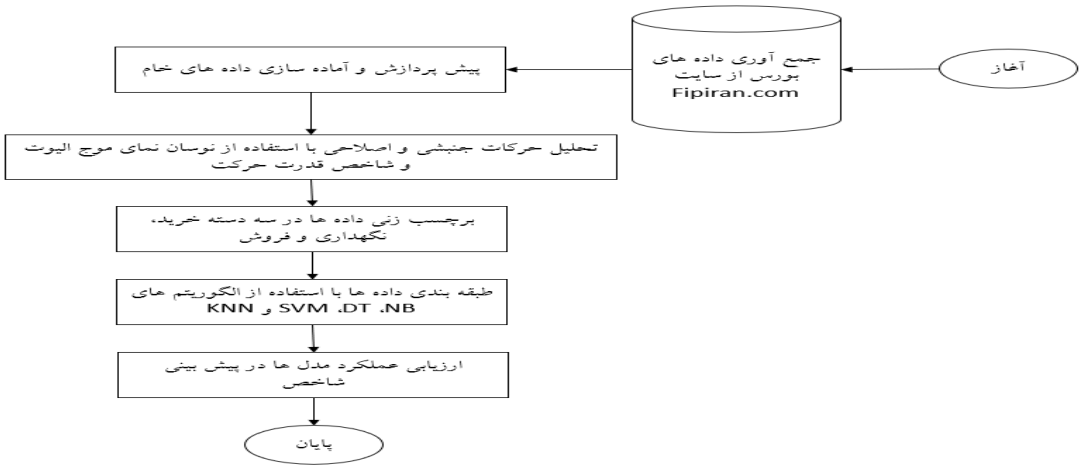

شکل ۱: فلوچارت روش پژوهش حاضر

بر اساس فلوچارت شکل ۱ ، در ابتدا پس از جمع‌آوری مجموعه داده مورد بررسی، عملیات پیش پردازش برروی داده‌ها انجام می‌شود. پیش پردازش تعیین می‌کند که منجر به چه نتایجی شود و اهمیت آن به قدری است که می‌تواند منجر به بهترین نتیجه یا ضعیف‌ترین نتیجه شود. لذا در این تحقیق کاملا پیش پردازش با توجه به مقالات و به روش اصولی انجام شده است که شامل موارد زیر می‌باشد:

۱-حذف داده‌های نویز و پرت ۲- مرتب سازی و قابل فهم و قابل خواندن داده‌ها ۳- نرمال سازی داده‌ها ۴- لیبل گذاری داده‌ها و ۵- تقسیم‌بندی داده‌ها. در این پژوهش از ۸۰ درصد داده‌ها برای امر آموزش طبقه‌بندی‌ها استفاده می‌شود و با استفاده از ۲۰ درصد باقیمانده، مدل مورد آزمایش قرار می‌گیرد. این تقسیم‌بندی‌ها کاملاً تصادفی می‌باشد تا از همه داده‌ها در هر دو کار بهره برده شود. تابع Randperm نرم‌افزار متلب به‌صورت اتوماتیک می‌تواند، ایندکس تصادفی ایجاد کند و داده‌های مربوط به ایندکس‌های ایجاد شده در ماتریس‌های متناظرشان قرار می‌گیرند. در ادامه روش‌های تجزیه تحلیل موجود در این حوزه را به تفصیل معرفی نموده‌ایم.

شاخص قدرت نسبی (RSI)[1]: در این پژوهش، در گام نخست شاخص قدرت نسبی حرکت (RSI) بازار سهام مورد بررسی قرار گرفته است. شاخص قدرت نسبی (RSI) یک نوسانگر مومنتوم است که سرعت و تغییر حرکت قیمت‌ها را اندازه‌گیری می‌کند. این شاخص توسط جی. ولس وایلدر توسعه یافته و به طور معمول برای شناسایی شرایط بیش‌خرید

[1]. Relative Strength Index (RSI)

یا بیش‌فروش در بازار استفاده می‌شود. مقادیر RSI بین ۰ تا ۱۰۰ متغیر است، به‌طوری که خوانش بالای ۷۰ نشان‌دهنده این است که احتمالاً یک سهام بیش‌خرید شده و خوانش زیر ۳۰ نشان‌دهنده این است که احتمالاً بیش‌فروش شده است. فرمول RSI شامل محاسبه میانگین سودها و ضررها در یک دوره مشخص، معمولاً ۱۴ روزه است تا یک نمودار خطی نرم و نوسانی بین این دو انتهای محدوده ایجاد کند. سرمایه‌گذاران از RSI برای اتخاذ تصمیمات معاملاتی آگاهانه‌تر با تفسیر این سطوح و شناسایی نقاط برگشت احتمالی استفاده می‌کنند. معادله ۱، برگرفته از مقاله تسای[1] و همکاران (۱۹۹۸) بیانگر رابطه RSI است:

$$RSI_t = 100 - ((\frac{100}{1 + (\sum_{t=0}^{N-1} Up_{t-1})/\, n})/(\frac{\sum_{t=0}^{N-1} Dn_{t-1}}{n})) \quad (۱)$$

که در این رابطه، Up_{t-1} میزان افزایش خروجی روش نسبت به روز قبل و Dn_{t-1} میزان کاهش خروجی روش نسبت به روز قبل است. در این پژوهش از تغییرات روزانه RSI نسبت به روز قبل استفاده کرده‌ایم.

نوسان نمای موج الیوت: نوسان نظریه موج‌های الیوت به الگوها و چرخه‌های خاصی اشاره دارد که قیمت‌های بازار را طبق این نظریه دنبال می‌کنند. اصل موج‌های الیوت دو نوع موج را شناسایی می‌کند: موج‌های موتیو و موج‌های اصلاحی. موج‌های موتیو در جهت روند کلی حرکت می‌کنند و شامل پنج موج کوچک‌تر هستند، درحالیکه موج‌های اصلاحی در جهت مخالف روند حرکت می‌کنند و شامل سه موج کوچک‌تر هستند.

نوسان نمای موج الیوت با تفریق میانگین متحرک ۳۵ روزه از میانگین متحرک پنج روزه به دست می‌آید. این اندیکاتور در موج سوم مقادیر بالاتری خواهد داشت و در امواج اول و پنجم مقادیر کم، اما مثبت دارد. اگر میانگین متحرک کوتاه مدت پنج روزه میانگین متحرک بلندمدت ۳۵ روزه را به سمت بالا قطع کند، امواج جنبشی صعودی الیوت تشکیل شده و سیگنال خرید است.

با توجه به پژوهش آستالاکیس[2] و همکاران (۲۰۱۱) می‌توان قوانین مختلف توابع خطی برای انواع سناریوهای غیر خطی، مانند عبارت زیر ایجاد کرد:

اگر مقدار $(EWO(5/35)_t$ مثبت و زیاد است و $(EWO(5/35)_{t-1}$ مثبت و زیاد است؛ ولی $(EWO(5/35)_{t-2}$ منفی و پایین است، پس پیش‌بینی کن خرید و برعکس.

اگر مقدار $(EWO(5/35)_t$ منفی و پایین است و $(EWO(5/35)_{t-1}$ منفی و پایین است؛ ولی $(EWO(5/35)_{t-2}$ مثبت است، پس پیش‌بینی کن فروش.

در این پژوهش از این قانون برای برچسب گذاری خرید، فروش و نگهداری بر اساس نوسان نمـــای مـوج الیوت استفاده شده است.

الگوریتم شبکه بیزین، یک طبقه‌بندی احتمالاتی است که بر اساس قضیه بیز با فرضیات قوی استقلال بین ویژگی‌ها عمل می‌کند. با وجود سادگی، این الگوریتم در کاربردهای مختلف دنیای واقعی مانند تشخیص اسپم، تحلیل احساسات و تشخیص پزشکی بسیار مؤثر بوده است. این الگوریتم احتمال هر کلاس را با توجه به ویژگی‌های ورودی محاسبه کرده و کلاسی را که بالاترین احتمال را دارد، انتخاب می‌کند.

الگوریتم نزدیک‌ترین همسایگان (KNN)[3] یک روش غیرپارامتری ساده، اما قدرتمند است که برای وظایف طبقه‌بندی و رگرسیون استفاده می‌شود. این الگوریتم با شناسایی 'k'نمونه آموزشی نزدیک در فضای ویژگی به یک نمونه تست داده شده و پیش‌بینی‌ها را بر اساس کلاس اکثریت (برای طبقه‌بندی) یا میانگین (برای رگرسیون) این همسایگان انجام می‌دهد.

درخت تصمیم یکی از الگوریتم‌های مهم در حوزه یادگیری ماشین است. تکنیک‌های درخت تصمیم به‌طور گسترده برای مسائل طبقه‌بندی استفاده می‌شوند، زیرا این مدل‌ها توضیح پذیر و شفاف هستند. درخت تصمیم درختی است که در آن هر گره میانی، انتخابی را بین تعدادی از گزینه‌ها نشان می‌دهد و هر گره برگ، نشان دهنده یک کلاس یا طبقه‌بندی است. الگوریتم‌های ID۳، CART و C۴.۵ اساساً رایج‌ترین الگوریتم‌های درخت تصمیم هستند که از معیارهای تقسیم متفاوتی برای تقسیم گره در هر سطح، برای تشکیل یک گره استفاده می‌کنند.

---

[1]. Tsaih
[2]. Atsalakis
[3]. K-Nearest Neighbors

درخت‌های تصمیم مورد استفاده در داده‌کاوی عمدتاً دو نوع هستند:

۱. درخت طبقه‌بندی که در آن تجزیه و تحلیل زمانی انجام می‌پذیرد که نتیجه پیش‌بینی شده حاصل کلاسی است که داده‌ها به آن تعلق دارند.

۲. درخت رگرسیون که در آن تجزیه و تحلیل زمانی انجام می‌پذیرد که می‌توان نتیجه پیش‌بینی شده را یک عدد واقعی در نظر گرفت. به عنوان مثال جمعیت یک ایالت.

هر دو درخت طبقه‌بندی و رگرسیون، شباهت‌ها و همچنین تفاوت‌هایی دارند، مانند: روشی که برای تعیین محل تقسیم گره استفاده می‌شود. شکل ۲ ، نمونه یک درخت تصمیم همراه با اجزای آن و چگونگی ایجاد شاخه و تصمیم‌گیری را نشان می‌دهد.

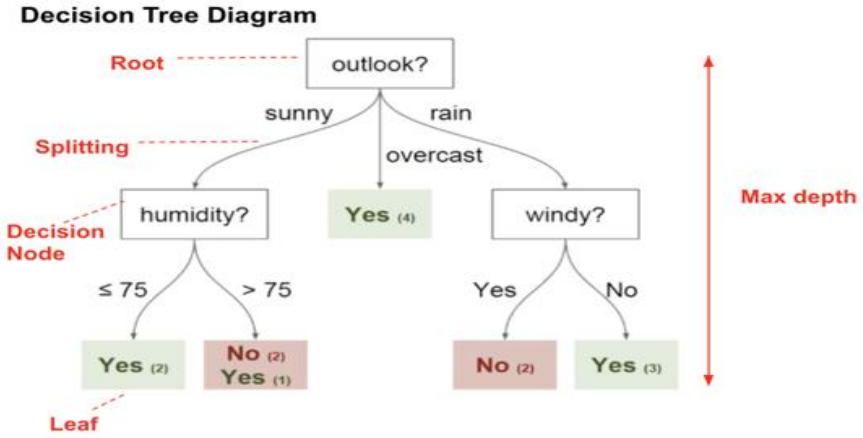

شکل ۲: درخت تصمیم همراه با اجزای آن شامل گره ریشه، گره تصمیم، شاخه، گره‌های برگ و عمق درخت

ماشین‌بردار پشتیبان [1](SVM) یک مجموعه از روش‌های یادگیری نظارت‌شده برای کلاس‌بندی، رگرسیون و شناسایی ناهمگون‌ها است که برای اولین بار توسط ولادیمیر واپنک و همکارانش توسعه یافت. ماشین‌بردار پشتیبان به خصوص برای کارآیی درمجموعه داده‌های با ابعاد بالا و توانایی آنها برای مدل‌سازی مرزهای تصمیم‌گیری پیچیده و غیرخطی با استفاده از تابع‌های کریل است. ماشین‌بردار پشتیبان در زمینه‌های مختلفی از جمله طبقه‌بندی متن، شناسایی تصویر، بیوانفورماتیک و مدل‌سازی مالی استفاده می‌شود.

به منظور درک بهتر مطلب، در شکل(۳) تصویری از یک مجموعه داده متعلق به دو کلاس نشان داده شده که روش ماشین‌بردار پشتیبان بهترین ابرسطح را برای جداسازی آنها انتخاب می‌کند.

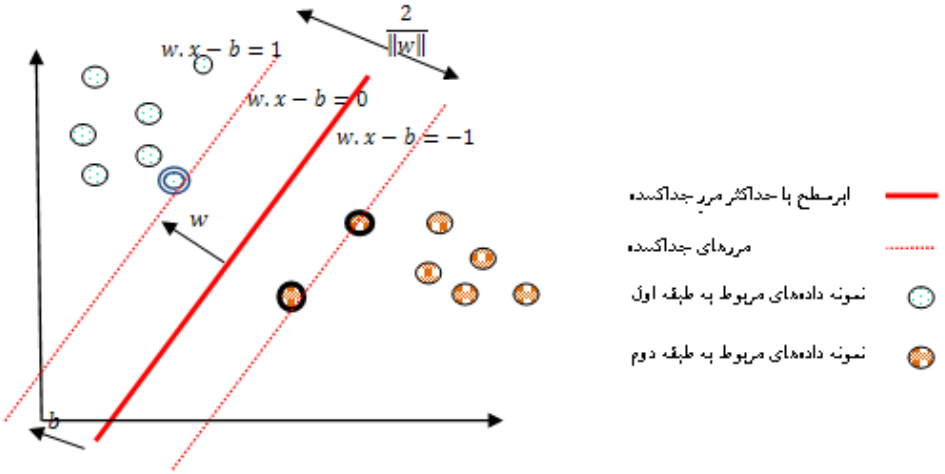

شکل ۳: ابرسطح با حداکثر مرزِ جداکننده به همراه مرزهای جداکننده برای طبقه‌بندی نمونه داده‌های مربوط به دو طبقه متفاوت.

[1]. Support Vector Machine

ماشین‌بردار استفاده شده در این مقاله به صورت باینری بوده و از کرنل خطی در آن استفاده شده است.

در یک مساله تصمیم‌گیری، نمونه‌های دسته‌بندی به صورت مثبت یا منفی برچسب می‌خورد. در این راستا، به منظور ارزیابی عملکرد الگوریتم پیشنهادی و بررسی میزان دقت آن، از معیارهای ارزیابی استفاده می‌کنیم که در زیر معرفی شده‌اند:

TP: تعداد ویژگی‌های صحیحی که درست تشخیص داده شده‌اند.

TN : تعداد ویژگی‌های اشتباهی که درست تشخیص داده شده‌اند.

FP: تعداد ویژگی‌های صحیحی که به اشتباه غلط تشخیص داده شده‌اند.

FN: تعداد ویژگی‌های اشتباهی که به اشتباه درست تشخیص داده شده‌اند.

صحت[1]: نسبت تعداد نمونه‌های درست طبقه‌بندی شده به تمام نمونه‌ها.

دقت[2]: نسبت نمونه‌های مثبت درست طبقه‌بندی‌شده به کل نمونه‌های مثبت موجود.

فراخوانی[3]: نسبت نمونه‌های مثبت درست طبقه‌بندی شده به کل نمونه‌هایی که مثبت تشخیص داده شده‌اند.

یافته‌ها

با توجه به روش پیشنهادی شده در بخش قبل مبنی بر بکارگیری رویکرد تلفیقی موج الویت، شاخص قدرت نسبی و روش‌های یادگیری ماشین، به پیش‌بینی روند بورس سهام ایران می‌پردازیم. بر این اساس در گام نخست مجموعه داده مورد استفاده بیان شده و سپس با اعمال مراحل پیش پردازش، به اعمال روش‌های پیشنهادی پرداخته خواهد شد.

داده‌ها با استفاده از TSCE Client 2.0 که شرکت مدیریت فناوری بورس ایران معرفی کرده است، جمع آوری شده‌اند و محاسبات با استفاده از نرم افزار اکسل انجام شده است. داده‌های مربوط به شاخص کل بورس اوراق بهادار تهران (شاخص هم وزن) از تاریخ ۱۳۹۰/۴/۱ تا ۱۴۰۳/۶/۳۱ بصورت روزانه جمع‌آوری شده‌اند. با توجه به اینکه الگوی موج الیوت در رابطه با همه بازارهای مالی و صنایع و سهام مختلف وجود دارد، به خصوص آنهایی که بیشتر در مشارکت عمومی قرار می‌گیرند، مبتنی بر روانشناسی توده است، از این رو، این پژوهش روی شاخص کل قیمت در بورس اوراق بهادار ایران به عنوان دماسنج اقتصاد و نمایانگر وضعیت کلی بازار سهام ایران انجام شده است. در جدول ۱، بخشی از مقادیر مربوط به شاخص کل ارائه شده است.

جدول ۱: بخشی از پایگاه داده

تاریخ	شاخص	مقدار
۱۳۹۰/۴/۱	شاخص کل (هم وزن)	۹۳۶۴.۱
۱۳۹۰/۴/۵	شاخص کل (هم وزن)	۹۷۳۴.۶
۱۳۹۰/۴/۱۰	شاخص کل (هم وزن)	۹۷۱۴.۴
۱۳۹۰/۴/۱۵	شاخص کل (هم وزن)	۹۲۲۳.۰
۱۳۹۰/۴/۲۰	شاخص کل (هم وزن)	۹۸۶۲.۵
۱۳۹۰/۴/۲۱	شاخص کل (هم وزن)	۹۴۸۷.۴
۱۳۹۰/۴/۲۳	شاخص کل (هم وزن)	۹۳۷۴.۹

بر این اساس، در گام نخست، باکس‌های الیوت که نوسانات قیمت را جدا می‌کنند، تعریف و تحلیل خواهند شد. تئوری موج الیوت روند را به عنوان یک دنباله پنج موجی که شامل سه مرحله انگیزشی و دو مرحله اصلاحی است، تعریف می‌کند. هدف اصلی شناسایی الگوهای تکراری و تشخیص اوج و فرودهای بازار است. نقاط اوج بازار برای ثبت سفارش

[1]. Accuracy
[2]. Precision
[3]. Recal

فروش و نقاط فرود بازار برای ثبت سفارش خرید بهینه هستند. در این مرحله برای تحلیل روند از اندیکاتورهای تکنیکی مانند نوسان‌نمای موج الیوت و شاخص قدرت نسبی حرکت استفاده شده است که در ادامه توضیح داده خواهند شد.

نوسان‌نمای موج الیوت با تفریق میانگین متحرک ۳۵ روزه از میانگین متحرک پنج روزه به دست خواهد آمد. این اندیکاتور در موج سوم مقادیر بالاتری خواهد داشت و در امواج اول و پنجم مقادیر کم اما مثبتی نشان خواهد داد. به عبارت دیگر، در صورتی که میانگین متحرک کوتاه‌مدت (پنج روزه) میانگین متحرک بلندمدت (۳۵ روزه) را به سمت بالا قطع کند، امواج جنبشی صعودی الیوت تشکیل خواهد شد و سیگنال خرید صادر می‌شود و برعکس، مقادیر منفی اصلاحات بزرگتری را به همراه خواهند داشت.

در شکل ۴، حرکت قیمت یک سهم نشان داده شده است. از طرفی در شکل ۵ ، میانگین متحرک پنج روزه و ۳۵ روزه نمایش داده شده است. همچنین در شکل ۶ تفاوت میانگین‌های متحرک یا همان نوسان‌نمای موج الیوت (EWO) را نشان می‌دهد. در واقع، اگر یک میانگین متحرک کوتاه‌مدت با یک میانگین متحرک بلندمدت به کار گرفته شود، تفاوت بین این دو، افزایش در قیمت را نشان می‌دهد. میانگین متحرک کوتاه‌مدت نشان‌دهنده تغییرات قیمت فعلی است، درحالیکه میانگین متحرک بلندمدت، نشان‌دهنده تغییرات کلی قیمت است.

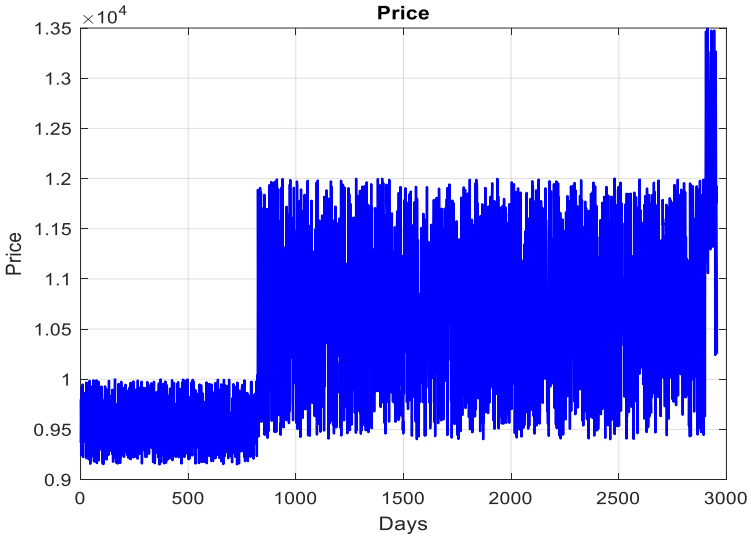

شکل ۴: تغییرات قیمت یک سهم

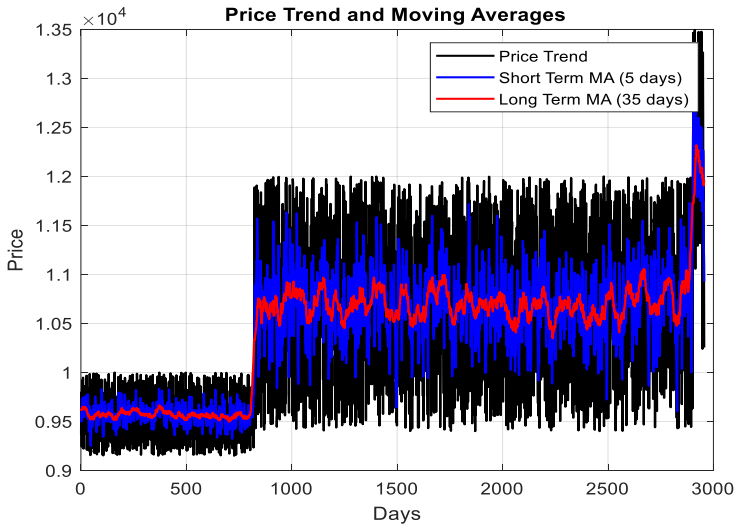

شکل ۵: روند قیمت‌ها و میانگین متحرک پنج روزه و ۳۵ روزه

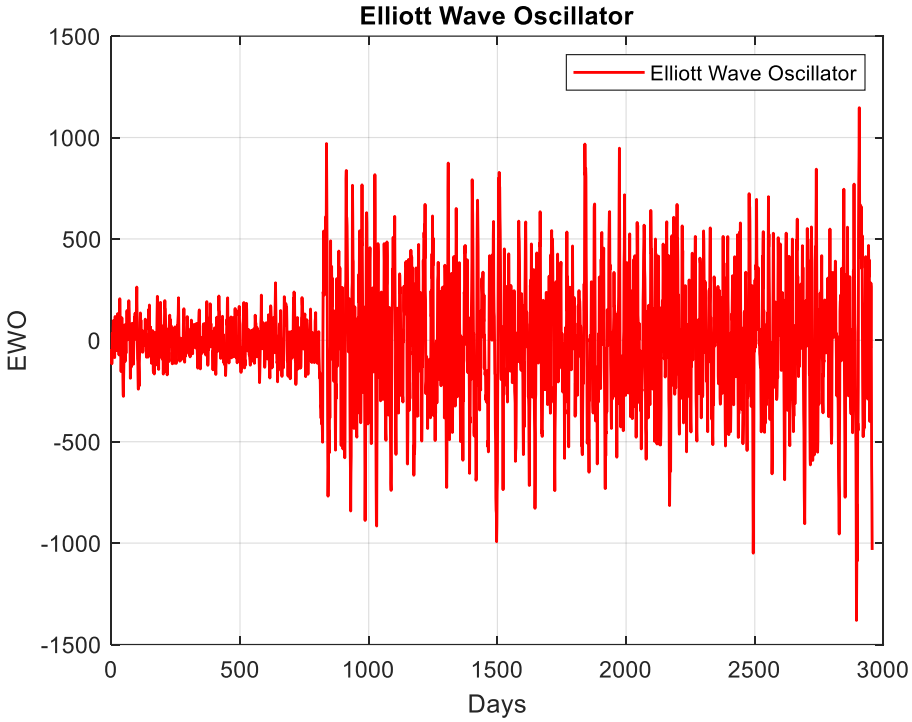

شکل ۶: نوسان‌نمای موج الیوت (EWO)

زمانی که قیمت موج سه را تشکیل می‌دهد، قیمت جاری سریع‌تر حرکت می‌کند و تفاوت بین میانگین متحرک کوتاه‌مدت و بلندمدت زیاد می‌شود و یک نوسان‌نمای بزرگ ایجاد می‌شود. در موج پنج، قیمت جاری با سرعت قبلی حرکت می‌کند، بنابراین تفاوت بین میانگین متحرک کوتاه‌مدت و بلندمدت کمتر است. این وضعیت، نوسان‌نمای کوچکی را ایجاد می‌کند.

در این پژوهش، برای برچسب‌گذاری خرید، فروش و نگهداری بر اساس نوسان‌نمای موج الیوت استفاده شده است. همچنین از اندیکاتور دیگری که توسط شرکت مدیریت فناوری بورس ایران تأیید شده است، برای تأیید و تشخیص قدرت نسبی (RSI) روند قیمت بهره گرفته شده که در ادامه توضیح داده شده است.

در مرحله بعد، برچسب گذاری به کمک روش تشخیص قدرت نسبی(RSI) انجام خواهد شد. برچسب‌ها باید معرف باکس‌های نوسان (روزها) طی روند باشند. اگر یک باکس شرایط موج جنبشی الیوت را برآورده کند و روند به سمت بالا و صعودی باشد و تغییرات RSI نیز مثبت باشد، آن باکس به عنوان خرید (LONG) برچسب گذاری خواهد شد. اگر یک باکس شرایط موج جنبشی الیوت را برآورده کند و روند به سمت پایین و نزولی باشد و تغییرات RSI نیز منفی باشد، آن باکس به عنوان فروش (SHORT) برچسب گذاری خواهد شد. سپس، به دلیل اینکه نوسان‌نمای موج الیوت دقیق اما تأخیری است، از شاخص قدرت نسبی حرکت استفاده شده است که در مقایسه با نوسان‌نمای موج الیوت، یک اندیکاتور پیشگام‌تر است و سیگنال خرید یا فروش را زودتر نشان می‌دهد. به این ترتیب، روزهایی که دو اندیکاتور با هم اختلاف نظر دارند، سیگنال نگهداری (HOLD) در نظر گرفته خواهد شد. یعنی تا زمانی که وضعیت قطعی خرید یا فروش توسط نوسان‌نمای موج الیوت و شاخص قدرت نسبی حرکت مشخص شود، محدوده متناقض بین سیگنال خرید یا فروش این دو اندیکاتور به عنوان منطقه نگهداری و خودداری از معامله برچسب‌گذاری می‌شود. این در تئوری موج الیوت همان زیر موج‌های اصلاحی است. نتیجه اعمال رویکرد RSI در شکل ۷، ارائه شده است.

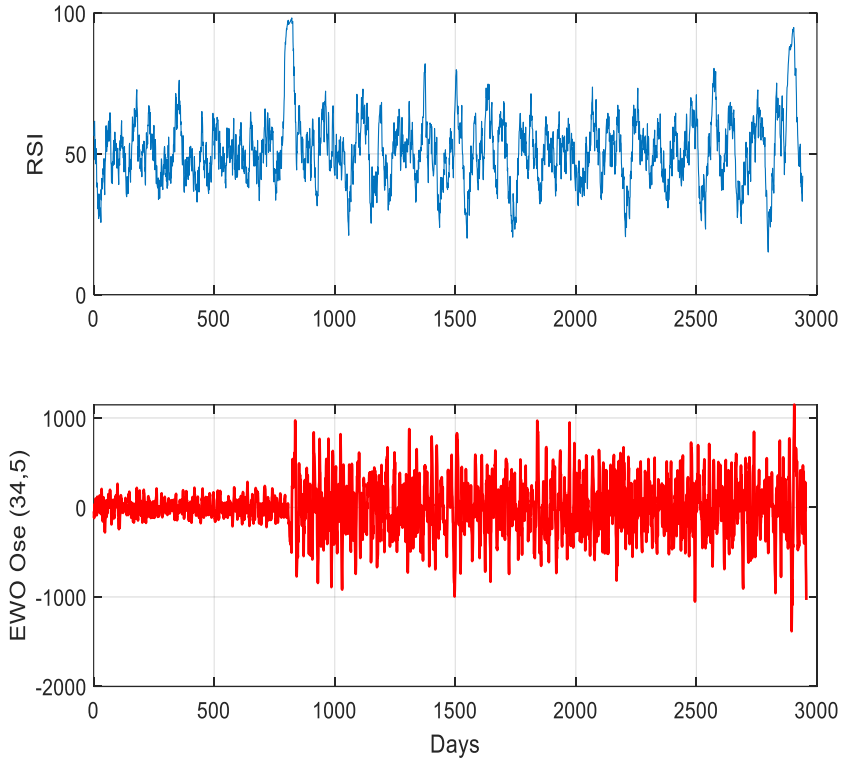

شکل ۷: استراتژی ترکیبی تکنیکال استفاده شده در شاخص کل

در جدول ۲، پارامترهای مورد استفاده برای بخش یادگیری ماشین ارائه شده است. با توجه به اینکه هدف پژوهش، تخمین روند کلی سهام می‌باشد، پارامتر Y که بیان کننده سه برچسب HOLD، SHORT و LONG می‌باشد، به عنوان پارامتر خروجی و پارامترهای ΔCLOSE، EWO1، EWO2، EWO3 و ΔRSI که در بالا توضیح داده شده‌اند، به عنوان پارامترهای ورودی هر سه مدل یادگیری ماشین برای طبقه‌بندی و در نهایت تخمین درنظر گرفته می‌شوند.

جدول ۲: بخشی از مجموعه داده بخش یادگیری ماشین

ΔCLOSE	EWO۱	EWO۲	EWO۳	ΔRSI	Y
۶۵۲.۶۸۱	۰	۰	۰	۵۶.۴۰۷۹	۳
۱۰۰۰.۱۴۵	۰	۰	۰	۵۸.۷۵۲۴۱	۱
۶۷۰.۰۵۸	۰	۰	۰	۶۱.۱۷۰۱	۳
۸۷۱.۱۳۵	۴۸.۹۳۴۶۳	۰	۰	۶۱.۵۶۳۸۷	۳
۷۴۱.۰۱۵	۸.۷۸۷۵۲۴	۴۸.۹۳۴۶۳	۰	۵۳.۸۴۹۱۶	۱
۹۲۳.۱۸۹	۶.۰۹۳۳۵۷	۸.۷۸۷۵۲۴	۴۸.۹۳۴۶۳	۴۷.۹۰۵۲۳	۱
۷۲۴.۰۷۱	۸۷.۳۴۶۴	۶.۰۹۳۳۵۷	۸.۷۸۷۵۲۴	۵۴.۹۸۵۲۸	۲
۱۱۲۱.۰۳۸	۹۶.۰۸۶۳۶	۸۷.۳۴۶۴	۶.۰۹۳۳۵۷	۴۸.۵۱۷۱۳	۳
۶۳۴.۳۰۸	۱۷.۲۱۴۴۹	۹۶.۰۸۶۳۶	۸۷.۳۴۶۴	۴۶.۴۶۳۱	۳
۷۰۰.۵۱۶	−۱۸.۰۴۴۲	۱۷.۲۱۴۴۹	۹۶.۰۸۶۳۶	۵۱.۹۰۶۶۸	۱
۹۴۰.۳۹۴	−۷.۰۳۵۵	−۱۸.۰۴۴۲	۱۷.۲۱۴۴۹	۵۱.۶۲۳۸۲	۱
۷۵۹.۹۹۵	−۱.۰۳۳	−۷.۰۳۵۵	−۱۸.۰۴۴۲	۴۶.۲۷۳۸۳	۱
۶۷۴.۴۴۰	−۶۷.۹۶۸۳	−۱.۰۳۳	−۷.۰۳۵۵	۳۸.۲۲۴۲۸	۲
۷۰۳.۱۵۱	−۱.۰۵۱۶۶	−۶۷.۹۶۸۳	−۱.۰۳۳	۳۹.۶۷۴۱۴	۲
۱۱۲۲.۷۷۸	۱۱۲.۷۴۶۸	−۱.۰۵۱۶۶	−۶۷.۹۶۸۳	۳۹.۲۹۸۴۲	۱

در ادامه عملیات پیش پردازش برروی داده‌ها انجام می‌شود. پس از مرتب سازی و برچسب گذاری داده‌ها، مهمترین گام، نرمالسازی داده‌هاست. در جدول ۳، مقادیر نرمال مجموعه داده که در بازه [0,1] قرار گرفته‌اند، مشاهده می‌شود. به عبارتی مقادیر این جدول، همان مقادیر جدول ۲، می‌باشند که در بازه صفر و ۱ قرار گرفته‌اند.

جدول ۳: بخشی از مجموعه داده بخش یادگیری ماشین

ΔCLOSE	EWO۱	EWO۲	EWO۳	ΔRSI	Y
۰.۶۰۵۲	۰.۰۵۷۱	۰.۰۵۷۱	۰.۰۵۷۱	۰.۱۰۴۵	۳
۰.۸۹۷۰	۰.۰۵۷۱	۰.۰۵۷۱	۰.۰۵۷۱	۰.۱۰۶۴	۱
۰.۶۱۹۸	۰.۰۵۷۱	۰.۰۵۷۱	۰.۰۵۷۱	۰.۱۰۸۵	۳
۰.۷۸۸۷	۰.۰۹۸۲	۰.۰۵۷۱	۰.۰۵۷۱	۰.۱۰۸۸	۳
۰.۶۷۹۴	۰.۰۶۴۵	۰.۰۹۸۲	۰.۰۵۷۱	۰.۱۰۲۳	۱
۰.۸۳۲۴	۰.۰۶۲۲	۰.۰۶۴۵	۰.۰۹۸۲	۰.۰۹۷۳	۱
۰.۶۶۵۲	۰.۱۳۰۴	۰.۰۶۲۲	۰.۰۶۴۵	۰.۱۰۳۳	۲
۰.۹۹۸۵	۰.۱۳۷۸	۰.۱۳۰۴	۰.۰۶۲۲	۰.۰۹۷۸	۳
۰.۵۸۹۸	۰.۰۷۱۵	۰.۱۳۷۸	۰.۱۳۰۴	۰.۰۹۶۱	۳
۰.۶۴۵۴	۰.۰۴۱۹	۰.۰۷۱۵	۰.۱۳۷۸	۰.۱۰۰۷	۱
۰.۸۴۶۸	۰.۰۵۱۲	۰.۰۴۱۹	۰.۰۷۱۵	۰.۱۰۰۴	۱
۰.۶۹۵۳	۰.۰۵۶۲	۰.۰۵۱۲	۰.۰۴۱۹	۰.۰۹۵۹	۱
۰.۶۲۳۵	۰.۰۰۰۰	۰.۰۵۶۲	۰.۰۵۱۲	۰.۰۸۹۲	۲
۰.۶۴۷۶	۰.۰۵۶۲	۰.۰۰۰۰	۰.۰۵۶۲	۰.۰۹۰۴	۲
۱.۰۰۰۰	۰.۱۵۱۸	۰.۰۵۶۲	۰.۰۰۰۰	۰.۰۹۰۱	۱

در ادامه ابتدا یافته‌های متغیرهای پژوهش ارائه می‌شود، سپس هر یک از الگوریتم‌های یادگیری ماشین به منظور پیش‌بینی شاخص کل بورس اوراق بهادار ایران ارائه و ارزیابی خواهند شد. در این پژوهش، ۲۹۵۴ روز از بازه ۱۳۹۰/۴/۱ تا ۱۴۰۳/۶/۳۱ بصورت روزانه بررسی شده است. در جدول۴، تعداد نمونه‌های برچسب گذاری شده HOLD، LONG و SHORT ارائه شده است. همچنین لازم به ذکر است که برای طبقه‌بندی داده‌ها، ۷۰ درصد وارد مرحله آموزش و ۳۰ درصد وارد مرحله آزمایش شده‌اند. همانطور که مشاهده می‌شود، برچسب HOLD که در کل مجموعه داده دارای ۹۷۶ نمونه است، در مرحله آموزش دارای ۶۹۴ نمونه (به ازای ۷۰ درصد داده‌ها) و در مرحله آزمایش دارای ۲۸۲ نمونه (به ازای ۳۰ درصد داده‌ها) می‌باشد. برچسب‌های LONG و SHORT نیز به همین روال مقدار دهی شده‌اند.

جدول ۴: برچسب های مجموعه داده

	HOLD	LONG	SHORT
تعداد کل	۹۷۶	۹۸۰	۹۹۸
تعداد در مرحله آموزش	۶۹۴	۶۷۸	۶۹۶
تعداد در مرحله آزمایش	۲۸۲	۳۰۲	۳۰۲

در جدول ۵، نیز آمار توصیفی متغیرهای پژوهش ارائه شده است.

جدول ۵: آمار توصیفی متغیرهای تکنیکالی ورودی به مدل در شاخص کل

	تعداد	میانگین	انحراف معیار	کمترین	بیشترین	واریانس
Δ_{CLOSE}	۲۹۵۴	۸۷۵.۴۸۵۱	۱۵۶.۳۱۶۲	۶۰۰.۰۵۷۱	۱۱۴۶.۸	۲۴۴۳۵
EWO_t	۲۹۵۴	۱۲.۵۸۳۷	۲۸۸.۵۳۵۷	-۹۹۵.۵۱۵۳	۱۶۴۳.۱	۸۳۲۵۳
EWO_{t-1}	۲۹۵۴	۱۲.۸۳۶۲	۲۸۸.۱۹۷۹	-۹۹۵.۵۱۵۳	۱۶۴۳.۱	۸۳۰۵۸
EWO_{t-2}	۲۹۵۴	۱۲.۹۳۹۰	۲۸۸.۱۳۹۲	-۹۹۵.۵۱۵۳	۱۶۴۳.۱	۸۳۰۲۴
Δ_{RSI}	۲۹۵۴	۵۱.۱۶۲۵	۱۲.۱۵۰۷	۱۵.۱۳۵۷	۹۸.۲۷۶۳	۱۴۷۶۳۹۰

جدول ۵، داده‌های آماری پنج متغیر ورودی را در ۲۹۵۴ مشاهده نشان می‌دهد. برای متغیر ΔCLOSE، میانگین آن ۸۷۵.۴۸۵۱ است، با انحراف معیار ۱۵۶.۳۱۶۲، و دامنه آن بین حداقل ۶۰۰.۰۵۷۱ و حداکثر ۱۱۴۶.۸ قرار دارد که واریانس آن ۲۴۴۳۵ می‌باشد. متغیرهای EWO_t EWO_{t-1} و EWO_{t-2} الگوهای مشابهی را نشان می‌دهند، به‌طوری‌که میانگین‌های آنها به ترتیب ۱۲.۵۸۳۷، ۱۲.۸۳۶۲ و ۱۲.۹۳۹۰ است و هرکدام انحراف معیار حدود ۲۸۸ دارند[1]. دامنه این متغیرها از ۹۹۵.۵۱۵۳- تا ۱۶۴۳.۱ متغیر است و واریانس‌های آنها به ترتیب ۸۳۲۵۳، ۸۳۰۵۸ و ۸۳۰۲۴ می‌باشد. متغیر Δ_{RSI} میانگین ۵۱.۱۶۲۵ و انحراف معیار ۱۲.۱۵۰۷ دارد، با مقادیری که از ۱۵.۱۳۵۷ تا ۹۸.۲۷۶۳ متغیر است و واریانس آن ۱۴۷.۶۳۹۰ است. این آمار نمای کلی از توزیع و تغییرپذیری داده‌ها برای هر متغیر را ارائه می‌دهند. از این رو در ادامه به ارزیابی عملکرد تکنیک‌های طبقه‌بندی بیزین ساده، درخت تصمیم، KNN و SVM در راستای پیش‌بینی روند بازار سهام ایران می‌پردازیم.

با تنظیم پارامترهای اولیه این مدل، در جدول ۶، نتایج اعمال مدل بیزین در پیش‌بینی شاخص کل سهام ارائه شده است.

جدول ۶: نتایج مدل بیزین ساده در پیش‌بینی شاخص کل سهام

	Precision	Recall	Accuracy
Hold	۰.۷۱۶۳	۰.۷۵۱۱	۰.۷۳۳۰
Long	۰.۷۳۳۳	۰.۹۸۱۱	
Short	۰.۷۵۱۶	۰.۷۱۷۹	

جدول ۶، نشاندهنده عملکرد مدل بیز ساده در پیش‌بینی شاخص سهام در سه برچسب مختلف یعنی Hold، Long و Short است. برای برچسب "Hold"، مقدار دقت ۰.۷۱۶۳، بازخوانی ۰.۷۵۱۱ است. در برچسب "Long"، دقت ۰.۷۳۳۳ و بازخوانی ۰.۹۸۱۱ است، برای برچسب "Short" نیز دقت ۰.۷۵۱۶ و بازخوانی ۰.۷۱۷۹ است. لازم به ذکر است که دقت کلی این مدل برابر با ۰.۷۳۳۰ می‌باشد.

این مدل نیز با توجه به ساختار درختی که دارد، شاخص کل سهام را پیش‌بینی کرده است. در شکل ۸ ، ساختار درختی درخت تصمیم پیشنهادی ارائه شده است.

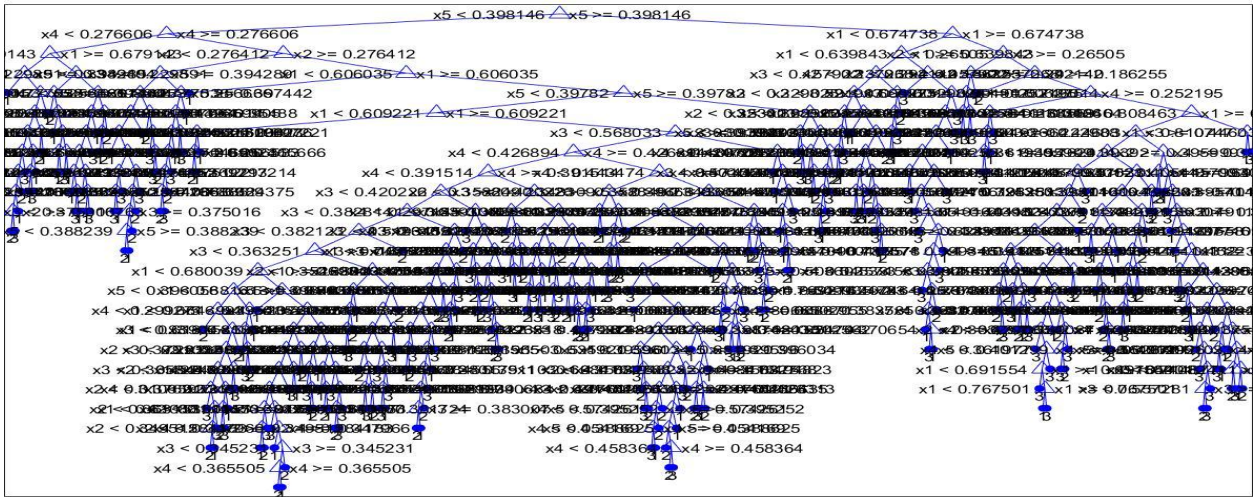

شکل ۸: ساختار درختی درخت تصمیم

جدول۷، نتایج مدل درخت تصمیم در پیش‌بینی شاخص کل سهام را نشان می‌دهد.

[1]. با توجه به ماهیت محاسبه نوسان نمای میانگین متحرک، داده‌ها در یک سری از بازه‌ها مقادیر منفی بسیار بزرگی رو گرفته که آن هم بخاطر نوساناتی هست که در بازه‌های مختلف ناگزیر به بازار وارد شده و باعث می‌شود، انحراف معیار به سمت بالا و میانگین به سمت شدیداً پایین کشیده بشود. انحراف معیار هم به خاطر حساسیت زیاد به مجذور فاصله، واکنش نشان می‌دهد و وقتی یک عدد منفی باشه واریانس به شدت بزرگ و در نتیجه انحراف معیار خیلی بزرگ می‌شود، حتی اگر چندین داده هم به میانگین نزدیک باشند. این اتفاق در بازارهایی با نوسانات زیاد مثل بازار سهام ایران طبیعی است.

جدول ۷: نتایج مدل درخت تصمیم در پیش‌بینی شاخص کل سهام

	Precision	Recall	Accuracy
Hold	۰.۹۹۴۶	۰.۸۴۶۲	۰.۹۳۰۷
Long	۰.۸۶۱۷	۰.۹۹۷۷	
Short	۰.۹۷۷۸	۰.۹۹۷۸	

برای برچسب"Hold" ، دقت0.9946 و بازخوانی 0.8462 بدست آمده است. در دسته"Long" ، دقت ۰.۸۶۱۷ و بازخوانی ۰.۹۹۷۷ است، و در نهایت برای برچسب "Short"، دقت ۰.۹۷۷۸ و بازخوانی ۰.۹۹۷۸ است. دقت کلی این روش ۰.۹۳۰۷ می‌باشد.

با تنظیم پارامترهای اولیه این مدل، در جدول ۸، نتایج اعمال ماشین‌بردار پشتیبان (SVM) در پیش‌بینی شاخص کل سهام ارائه شده است.

جدول ۸: نتایج مدل SVM در پیش‌بینی شاخص کل سهام

	Precision	Recall	Accuracy
Hold	۰.۹۹۶۳	۰.۹۷۸۷	۰.۹۹
Long	۰.۹۹۷۵	۰.۹۹۷۵	
Short	۰.۹۹۵۰	۰.۹۹۱۲	

در جدول ۸ نتایج مدل SVM همچون دو روش قبلی در پیش‌بینی شاخص کل سهام ارائه شده است. مشاهده می‌شود که دقت کلی این روش برابر با ۰.۹۹ می‌باشد. در بین سه برچسب خروجی نیز، دسته Long دارای بالاترین دقت (۰.۹۹۷۵) و Short پایین‌ترین دقت (۰.۹۹۵۰) می‌باشد.

با تنظیم پارامترهای اولیه این مدل، در جدول ۹، نتایج اعمال مدل KNN در پیش‌بینی شاخص کل سهام ارائه شده است.

جدول ۹: نتایج مدل KNN در پیش‌بینی شاخص کل سهام

	Precision	Recall	Accuracy
Hold	۰.۸۲۶۳	۰.۸۵۰۰	۰.۸۴۴۲
Long	۰.۸۵۶۴	۰.۷۲۴۵	
Short	۰.۸۷۰۸	۰.۸۱۸۵	

نتایج جدول ۹، نیز نشاندهنده دقت ۰.۸۴۴۲ روش KNN در پیش‌بینی شاخص کل سهام می‌باشد.

همچنین به منظور مقایسه این مدل‌های یادگیری ماشین، شاخص دقت (Accuracy) در جدول ۱۰، مقایسه شده است.

جدول ۱۰: مقایسه دقت الگوریتم‌های یادگیری ماشین

الگوریتم	دقت (Accuracy)
درخت تصمیم	۰.۹۳۰۷
بیزین ساده	۰.۷۳۳۰
ماشین‌بردار پشتیبان	۰.۹۹
K–نزدیکترین همسایه	۰.۸۴۴۲

جدول ۱۰، مقایسه دقت الگوریتم‌های یادگیری ماشین را نشان می‌دهد. در این جدول، دقت (Accuracy) مدل‌ها در پیش‌بینی شاخص کل سهام آورده شده است. الگوریتم ماشین‌بردار پشتیبان با دقت ۰.۹۹، بالاترین دقت را دارد. پس از آن، درخت تصمیم با دقت ۰.۹۳۰۷ قرار دارد که عملکرد بسیار خوبی را نشان می‌دهد. الگوریتم K– نزدیکترین

همسایه با دقت ۰.۸۴۴۲ و بیزین ساده با دقت ۰.۷۳۳۰، به ترتیب پایین‌ترین دقت‌ها را در مقایسه با سایر الگوریتم‌ها دارند. این مقایسه نشان می‌دهد که مدل ماشین‌بردار پشتیبان و درخت تصمیم عملکرد بهتری در پیش‌بینی نسبت به سایر الگوریتم‌ها دارند.

بحث و نتیجه‌گیری

پژوهش حاضر با هدف پیش‌بینی روند بازار سهام ایران با استفاده از نوسانات موج الیوت و شاخص قدرت نسبی در چارچوب الگوریتم‌های یادگیری ماشین انجام شد. نتایج پژوهش نشان داد که ترکیب ابزارهای تحلیل تکنیکال با الگوریتم‌های هوشمند یادگیری ماشین می‌تواند عملکرد مطلوبی در پیش‌بینی روند شاخص کل بورس اوراق بهادار تهران ارائه دهد. یافته‌ها نشان دادند که نظریه موج الیوت قابلیت مناسبی در شناسایی روندهای جنبشی و اصلاحی بازار دارد و در صورت ترکیب با شاخص قدرت نسبی، امکان استخراج سیگنال‌های خرید، فروش و نگهداری با دقت بالا فراهم می‌شود. همچنین نتایج بیانگر آن بود که الگوریتم‌های ماشین بردار پشتیبان و درخت تصمیم نسبت به سایر الگوریتم‌های مورد بررسی، عملکرد دقیق‌تری در پیش‌بینی روند بازار ارائه کرده‌اند و توانسته‌اند دقتی بیش از ۹۰ درصد را ثبت کنند.

یافته‌های پژوهش حاضر از منظر نظری نشان می‌دهد که رفتار بازار سهام ایران از الگوهای ساختاری و رفتاری مشخصی تبعیت می‌کند و برخلاف فرضیه بازار کاملاً کارا، بخشی از نوسانات بازار قابل پیش‌بینی است. این نتیجه با دیدگاه تحلیل تکنیکال که معتقد است تاریخ در بازارهای مالی تکرار می‌شود و تمامی اطلاعات در قیمت منعکس شده‌اند، هم‌راستا است (Murphy, 2018). نظریه موج الیوت نیز بر همین اصل استوار است که رفتار جمعی سرمایه‌گذاران در قالب امواج تکرارشونده ظاهر می‌شود و از طریق شناسایی این امواج می‌توان روند آینده بازار را تخمین زد (Atsalakis et al., 2011; Satari et al., 2020). نتایج پژوهش حاضر نیز نشان داد که نوسان‌نمای موج الیوت توانایی قابل قبولی در شناسایی نقاط بازگشت بازار و تفکیک امواج جنبشی و اصلاحی دارد.

نتایج مربوط به کارایی نظریه موج الیوت با یافته‌های پژوهش‌های پیشین نیز همسو است. پژوهش Jarusek و همکاران نشان داد که الگوهای موج الیوت در پیش‌بینی نرخ ارز عملکرد مؤثری دارند و استفاده از شبکه‌های عصبی در کنار این نظریه می‌تواند دقت پیش‌بینی را بهبود بخشد (Jarusek et al., 2022). همچنین پژوهش Satari و همکاران درباره پیش‌بینی قیمت مس با استفاده از شمارش امواج الیوت نشان داد که این نظریه در شناسایی روندهای قیمتی و نقاط برگشت بازار عملکرد مناسبی دارد (Satari et al., 2020). علاوه بر این، Balasubramaniam و همکاران نیز تأکید کردند که نظریه موج الیوت می‌تواند در تحلیل الگوهای نوسانی و تشخیص قدرت روند بازار مورد استفاده قرار گیرد (Balasubramaniam et al., 2022).

یافته‌های پژوهش حاضر همچنین نشان داد که شاخص قدرت نسبی (RSI) در کنار نوسان‌نمای موج الیوت توانسته است نقش مهمی در تأیید سیگنال‌های معاملاتی ایفا کند. در واقع، استفاده هم‌زمان از دو اندیکاتور موجب کاهش سیگنال‌های اشتباه و افزایش دقت تصمیم‌گیری شده است. این نتیجه با یافته‌های Khairi و همکاران هم‌راستا است که نشان دادند ترکیب شاخص‌های تکنیکال مختلف، دقت پیش‌بینی قیمت سهام را افزایش می‌دهد (Khairi et al., 2019). همچنین نتایج پژوهش Peymani Foroushani و همکاران نشان داد که الگوهای تکنیکال و شاخص‌های مبتنی بر رفتار قیمت می‌توانند بازده معاملات را در بورس تهران بهبود بخشند (Peymani Foroushani et al., 2021).

یکی دیگر از یافته‌های مهم پژوهش حاضر، عملکرد مطلوب الگوریتم‌های یادگیری ماشین در پیش‌بینی روند بازار بود. در میان الگوریتم‌های مورد استفاده، ماشین بردار پشتیبان و درخت تصمیم بهترین عملکرد را ارائه کردند. کارایی بالای ماشین بردار پشتیبان را می‌توان ناشی از توانایی این الگوریتم در مدل‌سازی روابط غیرخطی و تفکیک داده‌های پیچیده مالی دانست. بازار سهام ماهیتی پویا، غیرخطی و همراه با نویز دارد و الگوریتم SVM به دلیل استفاده از ابرصفحه‌های بهینه و توابع کرنل، توانایی بالایی در مدیریت چنین داده‌هایی دارد (Bazrkar & Hosseini, 2023; Li-Xia et al., 2011). نتایج پژوهش حاضر در این زمینه با یافته‌های Bazrkar و Hosseini همسو است که گزارش کردند مدل SVM ترکیب‌شده با الگوریتم بهینه‌سازی ازدحام ذرات توانسته است دقت پیش‌بینی بالای ۹۰ درصد را در پیش‌بینی قیمت سهام ارائه دهد (Bazrkar & Hosseini, 2023).

همچنین یافته‌های پژوهش حاضر درباره کارایی درخت تصمیم با نتایج مطالعات قبلی هم‌راستا است. الگوریتم درخت تصمیم به دلیل ساختار سلسله‌مراتبی، قابلیت تفسیر بالا و توانایی شناسایی الگوهای تصمیم‌گیری در داده‌های مالی، یکی از روش‌های پرکاربرد در داده‌کاوی مالی محسوب می‌شود (Gupta et al., 2017). پژوهش Basak و همکاران

نیز نشان داد که روش‌های مبتنی بر درخت تصمیم می‌توانند جهت حرکت قیمت سهام را با دقت مناسبی پیش‌بینی کنند (Basak et al., 2019). همچنین Viswanath بیان کرد که ساختار تصمیم‌گیری درختی می‌تواند در مسائل پیش‌بینی مبتنی بر داده‌های پیچیده، عملکرد پایداری ارائه دهد (Viswanath, 2022).

در خصوص الگوریتم بیز ساده، نتایج پژوهش حاضر نشان داد که اگرچه این الگوریتم عملکرد قابل قبولی دارد، اما دقت آن نسبت به SVM و درخت تصمیم پایین‌تر است. این مسئله را می‌توان ناشی از فرض استقلال ویژگی‌ها در الگوریتم بیز ساده دانست؛ در حالی که در داده‌های مالی، متغیرها اغلب دارای همبستگی و وابستگی متقابل هستند. با این حال، سرعت بالا و سادگی این الگوریتم باعث شده است که همچنان در مسائل طبقه‌بندی مالی مورد توجه باشد (Chen et al., 2021; Wickramasinghe & Kalutarage, 2021).

نتایج پژوهش حاضر همچنین نشان داد که استفاده از مدل‌های ترکیبی مبتنی بر تحلیل تکنیکال و یادگیری ماشین می‌تواند دقت پیش‌بینی را نسبت به روش‌های سنتی افزایش دهد. این یافته با روند جدید پژوهش‌های مالی که بر توسعه مدل‌های هیبریدی تأکید دارند، همسو است. برای مثال، Guo و همکاران نشان دادند که ترکیب روش‌های خوشه‌بندی، تجزیه سیگنال و الگوریتم‌های بهینه‌سازی موجب افزایش دقت پیش‌بینی بازار می‌شود (Guo et al., 2022). همچنین پژوهش Bose و Mali بیان کرد که ترکیب شبکه‌های عصبی با روش‌های بهینه‌سازی مانند ازدحام ذرات می‌تواند عملکرد پیش‌بینی سری‌های زمانی مالی را بهبود بخشد (Bose & Mali, 2019).

در سال‌های اخیر، مدل‌های مبتنی بر یادگیری عمیق نیز در پیش‌بینی بازار سهام کاربرد گسترده‌ای یافته‌اند. نتایج پژوهش حاضر در زمینه کارایی مدل‌های هوشمند با یافته‌های Yu و Yan همسو است که گزارش کردند شبکه‌های عصبی عمیق قادرند روابط پیچیده و غیرخطی بازار سهام را با دقت بالایی مدل‌سازی کنند (Yu & Yan, 2020). همچنین پژوهش Moghar و Hamiche نشان داد که شبکه‌های LSTM در پیش‌بینی قیمت سهام عملکرد مطلوبی دارند و می‌توانند وابستگی‌های زمانی بلندمدت را شناسایی کنند (Moghar & Hamiche, 2020). علاوه بر این، Ji و همکاران نیز بیان کردند که استفاده از یادگیری عمیق و داده‌های شبکه‌های اجتماعی می‌تواند دقت پیش‌بینی قیمت سهام را افزایش دهد (Ji et al., 2021).

نتایج پژوهش حاضر همچنین با مطالعات جدید مبتنی بر تحلیل کلان داده و یادگیری عمیق همسو است. Kanchanamala و همکاران نشان دادند که ترکیب معماری‌های مبتنی بر داده‌های بزرگ و مدل‌های عمیق بهینه‌سازی‌شده، توانایی بالایی در پیش‌بینی بازار سهام دارد (Kanchanamala et al., 2024). همچنین Ghallabi و همکاران در پژوهش خود بیان کردند که الگوریتم‌های پیشرفته یادگیری ماشین می‌توانند در پیش‌بینی بازارهای مالی و انرژی پاک عملکرد قابل توجهی داشته باشند (Ghallabi et al., 2025). این یافته‌ها نشان می‌دهد که حرکت به سمت سامانه‌های هوشمند تحلیل بازار، روند غالب پژوهش‌های مالی معاصر است.

از منظر کاربردی، نتایج پژوهش حاضر نشان می‌دهد که استفاده از رویکرد ترکیبی موج الیوت، RSI و یادگیری ماشین می‌تواند ابزار مناسبی برای سرمایه‌گذاران، تحلیلگران و مدیران مالی باشد. این مدل می‌تواند در شناسایی نقاط ورود و خروج بازار، مدیریت ریسک و بهینه‌سازی تصمیمات سرمایه‌گذاری مورد استفاده قرار گیرد. همچنین با توجه به گسترش معاملات الگوریتمی و معاملات خودکار در بازارهای مالی، توسعه چنین مدل‌هایی می‌تواند زمینه طراحی سامانه‌های هوشمند معاملاتی را فراهم سازد (Clapham et al., 2023; Kong & So, 2023).

علاوه بر این، یافته‌های پژوهش حاضر نشان می‌دهد که بازار سهام ایران ظرفیت مناسبی برای استفاده از فناوری‌های هوش مصنوعی و داده‌کاوی دارد. با توجه به نوسانات شدید بازار و رفتار هیجانی سرمایه‌گذاران، بهره‌گیری از مدل‌های هوشمند می‌تواند به کاهش ریسک و افزایش کارایی تصمیم‌گیری کمک کند. این مسئله با یافته‌های Rezaeian و همکاران نیز همسو است که بر ضرورت توسعه مدل‌های جامع پیش‌بینی بازار سرمایه تأکید کرده‌اند (Rezaeian et al., 2024). همچنین Chaweewanchon و Chaysiri بیان کردند که استفاده از یادگیری ماشین در انتخاب سهام و بهینه‌سازی پرتفوی می‌تواند عملکرد سرمایه‌گذاری را بهبود بخشد (Chaweewanchon & Chaysiri, 2022).

در مجموع، نتایج پژوهش حاضر نشان داد که ترکیب نظریه موج الیوت، شاخص قدرت نسبی و الگوریتم‌های یادگیری ماشین می‌تواند چارچوب مؤثری برای پیش‌بینی روند بازار سهام ایران فراهم سازد. یافته‌ها بیانگر آن بود که الگوریتم‌های هوشمند در صورت استفاده از داده‌های تکنیکال مناسب، توانایی بالایی در شناسایی الگوهای رفتاری بازار دارند و می‌توانند در تصمیم‌گیری‌های مالی و سرمایه‌گذاری مورد استفاده قرار گیرند.

از جمله محدودیت‌های پژوهش حاضر می‌توان به استفاده از داده‌های شاخص کل بورس به‌جای داده‌های شرکت‌های منفرد اشاره کرد که ممکن است بخشی از رفتار اختصاصی صنایع و شرکت‌ها را پوشش نداده باشد. همچنین در این پژوهش تنها از چند الگوریتم یادگیری ماشین استفاده شد و سایر مدل‌های پیشرفته یادگیری عمیق مورد بررسی قرار نگرفتند. محدودیت دیگر مربوط به تأثیر عوامل سیاسی، اقتصادی و روانی بر بازار سرمایه ایران است که اندازه‌گیری دقیق آن‌ها دشوار بوده و ممکن است بر نتایج مدل اثرگذار باشد.

پیشنهاد می‌شود در پژوهش‌های آینده از مدل‌های پیشرفته‌تر یادگیری عمیق مانند Transformer و شبکه‌های عصبی ترکیبی استفاده شود و داده‌های مربوط به احساسات بازار، اخبار اقتصادی و شبکه‌های اجتماعی نیز در مدل‌های پیش‌بینی وارد شوند. همچنین بررسی عملکرد مدل‌های پیشنهادی در صنایع مختلف بورس و مقایسه آن‌ها با بازارهای بین‌المللی می‌تواند به توسعه ادبیات پژوهش در این حوزه کمک کند.

از نظر کاربردی، پیشنهاد می‌شود سرمایه‌گذاران و تحلیلگران بازار سرمایه از مدل‌های ترکیبی مبتنی بر تحلیل تکنیکال و یادگیری ماشین برای تصمیم‌گیری‌های معاملاتی استفاده کنند. همچنین سازمان بورس و شرکت‌های کارگزاری می‌توانند با توسعه سامانه‌های هوشمند تحلیل بازار، زمینه استفاده گسترده‌تر از فناوری‌های هوش مصنوعی را در بازار سرمایه ایران فراهم سازند.

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 منافعی وجود ندارد.

حمایت مالی

این پژوهش حامی مالی نداشته است.

موازین اخلاقی

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

References

Atsalakis, G. S., Dimitrakakis, E. M., & Zopounidis, C. D. (2011). Elliott Wave Theory and Neuro-Fuzzy Systems, in Stock Market Prediction: The WASP System. *Expert Systems with Applications*, *38*(8), 9196-9206. https://doi.org/10.1016/j.eswa.2011.01.06

Balasubramaniam, P. M., Arivoli, S., & Prabhakaran, N. (2022). Performance of Signal Strength Prediction in Data Transmission Using Elliott Wave Theory. https://doi.org/10.34256/ijcci2017

Basak, S., Kar, S., Saha, S., Khaidem, L., & Dey, S. R. (2019). Predicting the Direction of Stock Market Prices Using Tree-Based Classifiers. *The North American Journal of Economics and Finance*, *47*, 552-567. https://doi.org/10.1016/j.najef.2018.06.013

Bazrkar, M. J., & Hosseini, S. (2023). Predict Stock Prices Using Supervised Learning Algorithms and Particle Swarm Optimization Algorithm. *Computational Economics*, *62*(1), 165-186. https://doi.org/10.1007/s10614-022-10273-3

Bose, M., & Mali, K. (2019). Fuzzy Time Series Forecasting Model Using Particle Swarm Optimization and Neural Network. In *Soft Computing for Problem Solving* (pp. 413-423). Springer. https://doi.org/10.1007/978-981-13-1592-3_32

Bustos, O., & Pomares-Quimbaya, A. (2020). Stock Market Movement Forecast: A Systematic Review. *Expert Systems with Applications*, *156*, 113464. https://doi.org/10.1016/j.eswa.2020.113464

Chauhan, A., Shivaprakash, S. J., Sabireen, H., Md, A. Q., & Venkataraman, N. (2023). Stock Price Forecasting Using PSO Hyper Tuned Neural Nets and Ensemble. *Applied Soft Computing*, *147*, 110835. https://doi.org/10.1016/j.asoc.2023.110835

Chaweewanchon, A., & Chaysiri, R. (2022). Markowitz Mean-Variance Portfolio Optimization with Predictive Stock Selection Using Machine Learning. *International Journal of Financial Studies*, *10*(3), 64. https://doi.org/10.3390/ijfs10030064

Chen, H., Hu, S., Hua, R., & Zhao, X. (2021). Improved Naive Bayes Classification Algorithm for Traffic Risk Management. *EURASIP Journal on Advances in Signal Processing*, *2021*(1), 30. https://doi.org/10.21203/rs.3.rs-355037/v1

Clapham, B., Haferkorn, M., & Zimmermann, K. (2023). The Impact of High-Frequency Trading on Modern Securities Markets: An Analysis Based on a Technical Interruption. *Business & Information Systems Engineering*, *65*(1), 7-24. https://doi.org/10.1007/s12599-022-00768-6

Ghallabi, F., Souissi, B., Du, A. M., & Ali, S. (2025). ESG stock markets and clean energy prices prediction: Insights from advanced machine learning. *International Review of Financial Analysis*, *97*(1), 103889. https://doi.org/10.1016/j.irfa.2024.103889

Guo, Y., Guo, J., Sun, B., Bai, J., & Chen, Y. (2022). A New Decomposition Ensemble Model for Stock Price Forecasting Based on System Clustering and Particle Swarm Optimization. *Applied Soft Computing*, *130*, 109726. https://doi.org/10.1016/j.asoc.2022.109726

Gupta, B., Rawat, A., Jain, A., Arora, A., & Dhami, N. (2017). Analysis of Various Decision Tree Algorithms for Classification in Data Mining. *International Journal of Computer Applications*, *163*(8), 15-19. https://doi.org/10.5120/ijca2017913660

Haghighat Monfared, J., Ahmadalinejad, M., & Motaghalchi, S. (2012). Comparison of Neural Network Models with Box-Jenkins Time Series Model in Forecasting the Tehran Stock Exchange Overall Price Index.

Jarusek, R., Volna, E., & Kotyrba, M. (2022). FOREX Rate Prediction Improved by Elliott Wave's Patterns Based on Neural Networks. *Neural Networks*, *145*, 342-355. https://doi.org/10.1016/j.neunet.2021.10.024

Ji, X., Wang, J., & Yan, Z. (2021). A Stock Price Prediction Method Based on Deep Learning Technology. *International Journal of Crowd Science*, *5*(1), 55-72. https://doi.org/10.1108/IJCS-05-2020-0012

Kanchanamala, P., Karnati, R., & Bhaskar Reddy, P. V. (2024). Hybrid Optimization Enabled Deep Learning and Spark Architecture Using Big Data Analytics for Stock Market Forecasting. *Concurrency and Computation: Practice and Experience*, *35*(8), e7618. https://doi.org/10.1002/cpe.7618

Khaidem, L., Saha, S., & Dey, S. R. (2016). *Predicting the Direction of Stock Market Prices Using Random Forest*. https://doi.org/10.48550/arXiv.1605.00003

Khairi, T. W., Zaki, R. M., & Mahmood, W. A. (2019). Stock Price Prediction Using Technical, Fundamental and News-Based Approach. 2019 2nd Scientific Conference of Computer Sciences (SCCS), https://doi.org/10.1109/SCCS.2019.8852599

Kong, M., & So, J. (2023). Empirical Analysis of Automated Stock Trading Using Deep Reinforcement Learning. *Applied Sciences*, *13*(1), 633. https://doi.org/10.3390/app13010633

Kumar, R., Kumar, P., & Kumar, Y. (2022). Multi-Step Time Series Analysis and Forecasting Strategy Using ARIMA and Evolutionary Algorithms. *International Journal of Information Technology*, *14*(1), 359-373. https://doi.org/10.1007/s41870-021-00741-8

Li-Xia, L., Yi-Qi, Z., & Liu, X. Y. (2011). Tax Forecasting Theory and Model Based on SVM Optimized by PSO. *Expert Systems with Applications*, *38*(1), 116-120. https://doi.org/10.1016/j.eswa.2010.06.022

Li, G., Zhang, A., Zhang, Q., Wu, D., & Zhan, C. (2022). Pearson Correlation Coefficient-Based Performance Enhancement of Broad Learning System for Stock Price Prediction. *IEEE Transactions on Circuits and Systems II: Express Briefs*, *69*(5), 2413-2417. https://doi.org/10.1109/TCSII.2022.3160266

Li, H., Yang, Z., & Li, T. (2014). *Algorithmic Trading Strategy Based on Massive Data Mining*. cs229.stanford.edu

Moghar, A., & Hamiche, M. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science*, *170*, 1168-1173. https://doi.org/10.1016/j.procs.2020.03.049

Murphy. (2018). *Technical Analysis in the Capital Market*. Chalesh.

Peymani Foroushani, M., Arza, Salehi, & Salehi, A. (2021). Transaction Returns Based on Candlestick Charts in the Tehran Stock Exchange. *Financial Research*, *22*(1), 69-89. https://doi.org/10.22059/frj.2019.287302.1006912

Potdar, A., & Mahadik, S. D. (2025). A Multi-Agent Approach to Stock Market Prediction and Risk Management. *The Voice of Creative Research*, *7*(2), 203-211. https://doi.org/10.53032/tvcr/2025.v7n2.27

Rezaeian, S., Taleghani, M., & Sharj Sharifi, A. (2024). Developing a Comprehensive Model for Stock Price Prediction in the Stock Exchange Market Using Interpretive Structural Modeling. *Asset Management and Financing*, *12*(2), 39-58. https://doi.org/10.22108/amf.2024.138983.1821

Satari, R., Akbari Dehkharghani, A., & Ahangari, K. (2020). Copper Price Prediction Using Wave Count with Contribution of Elliott Waves. *Journal of Mining and Environment*, *11*(3), 825-835. https://doi.org/10.22044/jme.2020.9240.1822

Shahrabadi, A., & Bashiri, N. (2010). *Investment Management in the Stock Exchange*. Securities and Exchange Organization.

Viswanath, N. (2022). Decision Tree Based Radio Link Failure Prediction for 5G Communication Reliability. https://doi.org/10.52953/LZLJ8762

Wickramasinghe, I., & Kalutarage, H. (2021). Naive Bayes: Applications, Variations and Vulnerabilities: A Review of Literature with Code Snippets for Implementation. *Soft Computing*, *25*(3), 2277-2293.

Yu, P., & Yan, X. (2020). Stock Price Prediction Based on Deep Neural Networks. *Neural Computing and Applications*, *32*, 1609-1628. https://doi.org/10.1007/s00521-019-04212-x