



Financial Management Perspective

Journal homepage: <https://jfmp.sbu.ac.ir/>



Original Article

Optimizing the trade-off Between Accuracy and Speed in Stock Price Forecasting: An Online Adaptive Ensemble learning Framework Based on Differential Evolution

Saeed Alamchi Meybodi *

Ali Delavarkhalafi **

Maryam Khalili Araghi ***

Mehdi Yazdian Dehkordi ****

Abstract

Introduction: The primary objective of this research is to resolve the fundamental and critical trade-off between prediction accuracy and computational efficiency in stock price forecasting models. Despite the ability of advanced deep learning models, such as LSTM and Transformer, to achieve high accuracy, their heavy processing costs and high latency present serious challenges for their practical deployment in online, time-sensitive financial ecosystems. This issue highlights a significant research gap: the absence of an integrated framework capable of systematically and intelligently optimizing these two conflicting objectives simultaneously. In response to this need, this study introduces a hybrid, adaptive, and self-optimizing framework named DE-Optimized AT-M(OS-ELM), specifically designed to find an optimal balance between these two metrics. The ultimate goal is to provide a practical and realistic solution that maintains competitive statistical accuracy while adapting to streaming data with extremely high speed, paving the way for the operationalization of artificial intelligence in real-time algorithmic trading systems.

Method: The methodology of this research is based on a multi-layered and intelligent architecture. The proposed framework, DE-Optimized AT-M(OS-ELM), integrates three key components: (1) Base Learner (OS-ELM): The Online Sequential Extreme Learning Machine is utilized for fast learning and instantaneous adaptation to new data without requiring complete retraining. (2) Adaptive Ensemble Structure (AT-M): To enhance stability and manage noise and "concept drift," multiple OS-ELM models are placed in an ensemble structure. The weight of each model is dynamically adjusted based on its recent

Received; 26 July 2025

Accepted; 16 November 2025

* Department of Financial management, SR.C., Islamic Azad University, Tehran, Iran. saeed.alamchimeybodi@iau.ac.ir

** Full Professor of Applied Mathematics, Department of Applied Mathematics, Faculty of Mathematical Sciences, Yazd University, Yazd, Iran. (Corresponding Author) delavarkh@yazd.ac.ir

*** Department of Financial management, SR.C., Islamic Azad University, Tehran, Iran. m.khaliliaraghi@iau.ac.ir

**** Associate Professor of Computer Engineering, Artificial Intelligence and Robotics Group, Faculty of Computer Engineering, Yazd University, Yazd, Iran. yazdian@yazd.ac.ir

performance within a sliding time window, using an "Adaptive Trust-weighted" mechanism. (3) Optimization Engine (DE): The Differential Evolution algorithm is employed for the automatic and intelligent optimization of the model's key hyperparameters. The core innovation of this research is the design of a dual-objective function for the DE algorithm, which simultaneously minimizes prediction error (RMSE) and computational cost (training time). For a comprehensive performance evaluation, a 14-year historical dataset (2010-2023) of five key assets from the US stock market was used. The proposed model was benchmarked against a diverse set of models, including ARIMA, Random Forest, SVR, LSTM, and Transformer. Model performance was assessed using multi-dimensional metrics for both accuracy (RMSE, MAE, R^2) and efficiency (training and prediction time), and the statistical significance of the results was confirmed using the Wilcoxon non-parametric test.

Results and Discussion: The quantitative and qualitative evaluation results demonstrated that the proposed framework successfully achieved its objectives. In terms of accuracy, the proposed model delivered highly competitive performance, proving to be statistically superior or entirely on par with state-of-the-art deep learning models (LSTM and Transformer) ($p < 0.05$). Its superiority was particularly evident in the Directional Accuracy (DA) metric, which is critical for algorithmic trading, with an average of 66.1%. The most prominent finding emerged in the dimension of computational efficiency; with an average training time of less than one second, the proposed model registered a speed that was hundreds of times faster than advanced deep learning models. This dramatic reduction in computational cost represents a decisive and definitive advantage for practical applications. Visual analyses also confirmed these findings; the trade-off analysis plot uniquely positioned the proposed model in the "sweet spot" (high accuracy, low cost), and the rolling error analysis revealed that the model maintains higher performance stability, especially during periods of high market volatility.

Conclusion: This research demonstrates that the solution to the accuracy-speed challenge in financial forecasting does not necessarily lie in greater architectural complexity but rather in a smart and targeted system engineering approach. The DE-Optimized AT-M(OS-ELM) framework, by intelligently integrating online learning, adaptive ensembling, and dual-objective optimization, establishes a systematic and effective balance between accuracy and efficiency. The model not only achieved accuracy on par with or superior to state-of-the-art models but did so at a computational cost that is orders of magnitude lower. This achievement challenges the paradigm of focusing exclusively on complex models and highlights the importance of designing practical and efficient solutions. The proposed framework, as a powerful tool, holds significant potential for implementation in algorithmic trading systems and real-time financial analytics, marking an important step toward the practical operationalization of artificial intelligence in finance.

Keywords: Stock Price Prediction, Online Ensemble Learning, Accuracy-Efficiency Trade-off, Multi-Objective Optimization, Extreme Learning Machine (ELM).

How To Cite: Alamchi meybodi, S. , delavarkhalfi, A. , Khalili araghi, M. and Yazdian Dehkordi, M. (2025). Optimizing the trade-off between accuracy and speed in stock price forecasting: An online adaptive ensemble learning framework based on differential evolution. *Financial Management Perspective*, 15(3),54-77. doi: 10.48308/jfmp.2025.241779.1537(in persian)

چشم انداز مدیریت مالی، ۱۴۰۴، دوره ۱۵، شماره ۳، صص ۵۴-۷۷، DOI: [10.48308/jfmp.2025.241779.1537](https://doi.org/10.48308/jfmp.2025.241779.1537)

نوع مقاله: پژوهشی

بهینه سازی توازن دقت و سرعت در پیش بینی قیمت سهام: یک چارچوب یادگیری آنلاین گروهی و تطبیقی مبتنی بر تکامل تفاضلی

سعید علمچی میبدی*
 علی دلاورخلفی**
 مریم خلیلی عراقی***
 مهدی یزدیان دهکردی****

چکیده

هدف: هدف اصلی این پژوهش، حل تقابل بنیادین و کلیدی میان دقت پیش بینی و کارایی محاسباتی در مدل های پیش بینی قیمت سهام است. علی رغم توانایی مدل های یادگیری عمیق پیشرفته، مانند LSTM و Transformer، در دستیابی به دقت بالا، هزینه های سنگین پردازشی و تأخیر زمانی بالای آنها، استقرار عملی این مدل ها را در اکوسیستم های مالی آنلاین و حساس به زمان، با چالش جدی مواجه ساخته است. این مسئله یک شکاف تحقیقاتی مهم را نمایان می سازد: فقدان یک چارچوب یکپارچه که بتواند به صورت سیستماتیک و هوشمند، این دو هدف متعارض (دقت و سرعت) را همزمان بهینه سازد. در پاسخ به این نیاز، این پژوهش یک چارچوب ترکیبی، تطبیقی و خودبهینه ساز با نام DE-Optimized AT-M(OS-ELM) را معرفی می کند که به طور خاص برای یافتن توازن بهینه میان این دو معیار طراحی شده است. هدف نهایی، ارائه راهکاری عملی و واقع گرایانه است که ضمن حفظ دقت آماری رقابتی، بتواند با سرعت بسیار بالا با داده های جریانی سازگار شود و مسیر را برای کاربردی سازی هوش مصنوعی در سیستم های معاملاتی الگوریتمی بلادرنگ هموار کند.

روش: روش شناسی این پژوهش بر پایه ی یک معماری چندلایه و هوشمند استوار است. چارچوب پیشنهادی، DE-Optimized AT-M(OS-ELM)، سه مؤلفه کلیدی را یکپارچه می سازد: (۱) یادگیرنده پایه (OS-ELM): از ماشین یادگیری حدی آنلاین و متوالی برای یادگیری سریع و تطبیق آنی با داده های جدید بدون نیاز به بازآموزی کامل استفاده می شود. (۲) ساختار گروهی تطبیقی (AT-M): برای افزایش پایداری و مدیریت نویز و پدیده «تغییر مفهوم»، چندین مدل

تاریخ پذیرش: ۱۴۰۴/۰۸/۲۵

تاریخ دریافت: ۱۴۰۴/۰۵/۰۴

* گروه مدیریت مالی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. saeed.alamchimeybodi@iau.ac.ir
 ** استاد تمام ریاضی کاربردی، گروه ریاضی کاربردی، دانشکده علوم ریاضی، دانشگاه یزد، یزد، ایران. (نویسنده مسئول) delavarkh@yazd.ac.ir
 *** گروه مدیریت مالی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. m.khaliliaraghi@iau.ac.ir
 **** دانشیار مهندسی کامپیوتر، گروه هوش مصنوعی و ریاتیک، دانشکده مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران. yazdian@yazd.ac.ir

OS-ELM در یک ساختار گروهی قرار گرفته‌اند و وزن هر مدل به صورت پویا بر اساس عملکرد اخیر آن در یک پنجره زمانی لغزان، با مکانیزم «وزن‌دهی مبتنی بر اعتماد» تنظیم می‌شود. (۳) موتور بهینه‌سازی (DE): از الگوریتم تکامل تفاضلی برای بهینه‌سازی خودکار و هوشمند ابرپارامترهای کلیدی مدل استفاده می‌گردد. نوآوری محوری این پژوهش، طراحی یک تابع هدف دوگانه برای الگوریتم DE است که به طور همزمان خطای پیش‌بینی (RMSE) و هزینه محاسباتی (زمان آموزش) را کمینه می‌کند. برای ارزیابی جامع عملکرد، از مجموعه داده‌های تاریخی ۱۴ ساله (۲۰۱۰-۲۰۲۳) پنج دارایی کلیدی بازار سهام آمریکا استفاده شد. مدل پیشنهادی با مدل‌های مبنای متنوعی شامل ARIMA، جنگل تصادفی، SVM، LSTM و Transformer مقایسه گردید. عملکرد مدل‌ها با معیارهای چندبعدی شامل دقت (RMSE, MAE, R²) و کارایی (زمان آموزش و پیش‌بینی) سنجیده و معناداری آماری نتایج با آزمون ناپارامتریک ویلکاکسون تأیید شد.

یافته‌ها: نتایج ارزیابی کمی و کیفی نشان داد که چارچوب پیشنهادی با موفقیت به اهداف خود دست یافته است. در بُعد دقت، مدل پیشنهادی عملکردی بسیار رقابتی کسب کرد که از نظر آماری برتر یا کاملاً هم‌تراز با پیشرفته‌ترین مدل‌های یادگیری عمیق (LSTM و Transformer) بود ($p < 0.05$). برتری این مدل به ویژه در معیار دقت جهت‌دار (DA) که برای معاملات الگوریتمی حیاتی است، با میانگین ۶۶.۱٪ مشهودتر بود. برجسته‌ترین یافته، در بُعد کارایی محاسباتی نمایان شد؛ مدل پیشنهادی با میانگین زمان آموزش کمتر از یک ثانیه، سرعتی را به ثبت رساند که صدها برابر سریع‌تر از مدل‌های پیشرفته یادگیری عمیق بود. این کاهش چشمگیر هزینه محاسباتی، یک برتری قاطعانه و تعیین‌کننده برای کاربردهای عملی محسوب می‌شود. تحلیل‌های بصری نیز این یافته‌ها را تأیید کرد؛ نمودار تحلیل توازن، مدل پیشنهادی را به تنهایی در «نقطه بهینه» (دقت بالا، هزینه پایین) قرار داد و تحلیل خطای لغزان نشان داد که این مدل پایداری عملکرد بالاتری را، به خصوص در دوره‌های پرنوسان بازار، حفظ می‌کند.

نتیجه‌گیری: این پژوهش با موفقیت نشان داد که راهکار غلبه بر چالش دقت-سرعت در پیش‌بینی مالی، لزوماً در پیچیدگی بیشتر معماری‌ها نهفته نیست، بلکه در یک رویکرد مهندسی سیستم هوشمند و بهینه‌سازی هدفمند قرار دارد. چارچوب DE-Optimized AT-M(OS-ELM) با یکپارچه‌سازی هوشمندانه یادگیری آنلاین، پایداری گروهی تطبیقی و بهینه‌سازی دوهدفه، یک توازن سیستماتیک و مؤثر میان دقت و کارایی برقرار کرد. این مدل نه تنها به دقتی هم‌سطح یا برتر از مدل‌های پیشرفته دست یافت، بلکه این کار را با هزینه‌ای محاسباتی که چندین مرتبه مقیاس کمتر است، به انجام رساند. این دستاورد، رویکرد غالب مبنی بر تمرکز انحصاری بر مدل‌های پیچیده را به چالش می‌کشد و اهمیت طراحی راهکارهای عملی و کارآمد را برجسته می‌سازد. چارچوب ارائه شده به عنوان یک ابزار قدرتمند، پتانسیل بالایی برای پیاده‌سازی در سیستم‌های معاملاتی الگوریتمی و تحلیل‌های مالی بلندمدت دارد و گامی مهم در جهت کاربردی‌سازی عملی هوش مصنوعی در امور مالی محسوب می‌شود.

کلیدواژه‌ها: پیش‌بینی قیمت سهام، یادگیری آنلاین گروهی، توازن دقت و سرعت، بهینه‌سازی چندهدفه، ماشین یادگیری حدی (ELM)

استناد دهی: علمچی میبدی، سعید، دلاورخلفی، علی، خلیلی عراقی، مریم و یزدیان دهکردی، مهدی. (۱۴۰۴). بهینه‌سازی توازن دقت و سرعت در پیش‌بینی قیمت سهام: یک چارچوب یادگیری آنلاین گروهی و تطبیقی مبتنی بر تکامل تفاضلی. چشم‌انداز مدیریت مالی، ۱۵(۳)، ۵۴-۷۷.



۱. مقدمه

پیش‌بینی دقیق قیمت سهام، به دلیل ماهیت غیرخطی، نویز بالا و پدیده‌ی کلیدی تغییر مفهوم^۱ - که به تغییرات ناگهانی یا تدریجی در الگوهای زیربنایی داده‌ها اطلاق می‌شود - یکی از چالش‌های بنیادین در بازارهای مالی مدرن است [۱۶]. این شرایط، نیازمند مدل‌هایی است که نه تنها دقیق باشند، بلکه بتوانند با داده‌های جریانی^۲ به صورت آنلاین و سریع سازگار شوند. اگرچه مدل‌های پیشرفته یادگیری عمیق مانند حافظه کوتاه‌مدت طولانی^۳ و مبدل^۴، دقت پیش‌بینی را به شکل چشمگیری افزایش داده‌اند، اما این پیشرفت به قیمت ایجاد یک تقابل^۵ بنیادین میان دقت و کارایی محاسباتی تمام شده است. هزینه‌های محاسباتی سنگین و زمان آموزش طولانی، کاربرد این مدل‌ها را در محیط‌های برخط^۶ و حساس به زمان، غیرعملی می‌سازد [۱۴، ۱۷]. این محدودیت، یک شکاف تحقیقاتی کلیدی را نمایان می‌سازد: نیاز به یک چارچوب یکپارچه که با بهینه‌سازی سیستماتیک این دو هدف متعارض، امکان بهره‌برداری مؤثر از ناکارایی‌های موقتی بازار را فراهم آورد.

برای پر کردن این شکاف، این پژوهش یک "چارچوب یادگیری آنلاین گروهی، تطبیقی و بهینه‌شده با تکامل تفاضلی"^۷ را ارائه می‌دهد. این چارچوب، یادگیری آنلاین سریع با ماشین یادگیری حدی آنلاین و متوالی^۸، پایداری گروهی با مکانیزم وزن‌دهی مبتنی بر اعتماد^۹ و بهینه‌سازی هوشمند با الگوریتم تکامل تفاضلی^{۱۰} را یکپارچه می‌کند [۲۴، ۲۶، ۳۱].

نوآوری محوری و دستاوردهای اصلی این تحقیق در سه جنبه خلاصه می‌شود: (۱) طراحی یک معماری یکپارچه که برای سازگاری با پویایی‌های بازار مالی بهینه‌سازی شده است؛ (۲) معرفی یک تابع هدف دوگانه برای الگوریتم DE که به طور صریح توازن میان خطای پیش‌بینی و سرعت آموزش را جستجو می‌کند؛ و (۳) اعتبارسنجی جامع این رویکرد بر روی داده‌های واقعی که عملکرد بسیار رقابتی در معیار دقت و برتری قاطع در کارایی محاسباتی را در مقایسه با مدل‌های پیشرفته به اثبات می‌رساند.

مرور ادبیات نشان می‌دهد که یک شکاف تحقیقاتی کلیدی در فقدان یک چارچوب یکپارچه نهفته است که به طور همزمان هر چهار چالش اصلی را مدیریت کند: (۱) یادگیری آنلاین سریع، (۲) پایداری گروهی تطبیقی، (۳) تنظیم بهینه ابرپارامترها، و مهم‌تر از همه، (۴) توازن سیستماتیک میان دقت و کارایی محاسباتی. پژوهش حاضر با ارائه مدل DE-Optimized AT-M(OS-ELM) به طور مستقیم این شکاف را هدف قرار می‌دهد و راهکاری جامع برای توسعه مدل‌های پیش‌بینی مالی واقع‌گرایانه و عملی ارائه می‌دهد. در ادامه، معماری و اجزای کلیدی این چارچوب پیشنهادی به تفصیل تشریح می‌گردد.

۲. مبانی نظری و پیشینه پژوهش

سیر تکامل رویکردها و چالش‌های کلیدی: سیر تکاملی مدل‌های پیش‌بینی بازارهای مالی، با تکیه بر چارچوب‌های یادگیری آماری، از مدل‌های آماری کلاسیک مانند مدل خودرگرسیون یکپارچه میانگین متحرک^{۱۱} به

¹ Concept Drift

² Streaming data

³ Long Short-Term Memory (LSTM)

⁴ Transformer

⁵ Trade-off

⁶ Online

⁷ Adaptive Trust-weighted Multi (Online Sequential Extreme Learning Machine) Optimized with Differential Evolution (DE-Optimized AT-M(OS-ELM))

⁸ Online Sequential Extreme Learning Machine (OS-ELM)

⁹ Adaptive Trust-weighted (AT)

¹⁰ Differential Evolution (DE)

¹¹ Auto Regressive Integrated Moving Average (ARIMA)

سمت معماری‌های پیشرفته حرکت کرده است [۲۰]. مدل‌های اولیه به دلیل مفروضات خطی، در مدل‌سازی پویایی‌های پیچیده بازار با محدودیت مواجه بودند [۳۰]. در پاسخ، مدل‌های یادگیری عمیق مانند LSTM و Transformer ظهور کردند که با توانایی بی‌نظیر در مدل‌سازی وابستگی‌های بلندمدت، دقت پیش‌بینی را به شدت بهبود بخشیدند [۱۴، ۲۷]؛ روندی که کارآمدی آن در مطالعات داخلی بر روی داده‌های بازار سرمایه ایران نیز به اثبات رسیده است [۲، ۳]. با این حال، این پیشرفت، تقابل بنیادین میان دقت و کارایی محاسباتی را تشدید کرد و کاربرد عملی این مدل‌ها را در محیط‌های آنلاین و حساس به زمان با چالش مواجه ساخت. برای غلبه بر این چالش محاسباتی، معماری‌های یادگیری سریع مانند ماشین یادگیری حدی (ELM) و به ویژه نسخه آنلاین و متوالی آن (OS-ELM)، به عنوان راهکارهایی کارآمد معرفی شدند [۲۱]. OS-ELM با امکان پردازش داده‌های جریانی بدون نیاز به بازآموزی پرهزینه، برای محیط‌های پویا بسیار مناسب است [۱۱]. با این وجود، یادگیرنده‌های منفرد مانند OS-ELM، در برابر نویز شدید داده‌های مالی و تغییرات ناگهانی بازار (پدیده تغییر مفهوم) آسیب‌پذیر باقی می‌مانند [۱۶، ۳۴]. برای افزایش پایداری و مدیریت «تغییر مفهوم»، رویکردهای یادگیری گروهی تطبیقی به کار گرفته شدند [۳۳]. این چارچوب‌ها با ترکیب چندین مدل و تنظیم پویای آن‌ها، واریانس خطا را کاهش داده و با تغییرات بازار سازگار می‌شوند [۱۹، ۳۵]. مکانیزم‌هایی مانند وزن‌دهی مبتنی بر اعتماد با تخصیص پویای وزن به اعضای گروه بر اساس عملکرد اخیرشان، مقاومت سیستم را در برابر نوسانات شدید افزایش می‌دهند [۷، ۱۵]. ترکیب یادگیرنده‌های آنلاین (مانند OS-ELM) با این ساختارهای گروهی تطبیقی، یک گام مهم در جهت ساخت مدل‌های دقیق و در عین حال سازگار بوده است.

با این حال، عملکرد این معماری‌های ترکیبی به شدت به تنظیم دقیق ابرپارامترها^۱ وابسته است؛ چالشی که الگوریتم‌های بهینه‌سازی فراابتکاری برای پاسخ به آن به کار گرفته شده‌اند. در میان این الگوریتم‌ها، تکامل تفاضلی (DE) به دلیل کارایی بالا در حل مسائل پیچیده و غیرخطی، اعتباری جهانی کسب کرده و موفقیت خود را در حوزه‌های متنوعی از مهندسی سازه تا سیستم‌های هوشمند به اثبات رسانده است [۹، ۲۸، ۳۱]. با الهام از این قدرت، محققان حوزه مالی نیز از آن برای تنظیم دقیق مدل‌های پیش‌بینی استفاده کرده‌اند [۱، ۲۳، ۲۵]. اما یک محدودیت کلیدی در این پژوهش‌ها باقی مانده است: تمرکز انحصاری فرآیندهای بهینه‌سازی بر روی معیار دقت و نادیده گرفتن هزینه محاسباتی. این رویکرد اغلب منجر به انتخاب مدل‌هایی می‌شود که هرچند دقیق هستند، اما برای کاربردهای بلادرنگ^۲، غیرعملی و ناکارآمد باقی می‌مانند.


چارچوب مفهومی مبتنی بر بازار کارا و پویایی معاملات الگوریتمی: رویکردهای مبتنی بر یادگیری ماشین برای پیش‌بینی قیمت سهام، در تقابل با فرضیه بازار کارا قرار می‌گیرند. این نظریه، به‌ویژه در فرم نیمه‌قوی خود، بیان می‌کند که تمام اطلاعات عمومی به سرعت در قیمت‌ها منعکس شده و امکان کسب سود غیرعادی از طریق تحلیل این اطلاعات وجود ندارد [۱۳]. با وجود این، شواهد تجربی متعدد در ادبیات مالی بر وجود ناهنجاری‌های کوتاه‌مدت، ناکارایی‌های خردساختار بازار و الگوهای غیرخطی دلالت دارند که عمدتاً به عواملی چون سوگیری‌های رفتاری سرمایه‌گذاران، هزینه‌های معاملاتی و تأخیر در پردازش اطلاعات نسبت داده می‌شوند [۱۷]. چارچوب پیشنهادی در این مقاله، ادعای نقض کامل فرضیه بازار کارا را ندارد؛ بلکه بر این فرض استوار است که "حباب‌های ناکارایی موضعی و موقتی" در بازار وجود دارند که مدل‌های آماری خطی قادر به شناسایی آن‌ها نیستند [۳۰]. هدف این پژوهش، توسعه ابزاری است که بتواند این الگوهای پیچیده و زودگذر را با سرعت بالا شناسایی کرده و از آن‌ها بهره‌برداری کند.

¹ Hyperparameters² Real-time

علاوه بر این، ظهور معاملات الگوریتمی و فرکانس بالا، خود به یک عامل تعیین‌کننده در پویایی بازار تبدیل شده است. این سیستم‌ها با ایجاد رقابت شدید بر سر سرعت، تقابل میان "دقت" و "کارایی محاسباتی" را که هدف اصلی این مقاله است، تشدید کرده‌اند [۱۸]. همچنین، تعامل میان هزاران الگوریتم معاملاتی می‌تواند به طور مداوم الگوهای بازار را تغییر دهد و پدیده "تغییر مفهوم" را ایجاد کند. بنابراین، یک مدل پیش‌بینی موفق در بازارهای امروزی نه تنها باید دقیق باشد، بلکه باید سریع و تطبیق‌پذیر نیز باشد تا بتواند در این اکوسیستم پویا و رقابتی بقا یابد. چارچوب ما با تاکید همزمان بر یادگیری آنلاین (برای سرعت) و ساختار گروهی تطبیقی (برای مدیریت تغییر مفهوم)، به طور مستقیم برای پاسخ به این چالش‌های نوین طراحی شده است.

معماری چارچوب پیشنهادی: چارچوب پیشنهادی، DE-Optimized AT-M(OS-ELM)، یک معماری چندلایه و تطبیقی است که برای غلبه بر چالش‌های بازارهای مالی پویا طراحی شده است. این چارچوب بر سه جزء کلیدی استوار است: (۱) یادگیرنده پایه OS-ELM برای یادگیری آنلاین سریع، (۲) ساختار گروهی تطبیقی AT-M(OS-ELM) برای افزایش پایداری و مدیریت «تغییر مفهوم»، و (۳) موتور بهینه‌سازی DE برای تنظیم خودکار ابرپارامترها و توازن میان دقت و سرعت.

شکل ۱، یک نمای کلی از این معماری و جریان داده در دو فاز اصلی آن (فاز بهینه‌سازی آفلاین^۱ و فاز استقرار آنلاین^۲) را به تصویر می‌کشد. در ادامه، هر یک از این اجزا به تفصیل شرح داده می‌شوند.



شکل ۱: معماری چارچوب پیشنهادی DE-Optimized AT-M(OS-ELM)

یادگیرنده پایه (OS-ELM): اساس چارچوب ما بر یادگیرنده OS-ELM استوار است که به دلیل سرعت بالا و توانایی یادگیری جریانی (بدون نیاز به بازآموزی کامل) انتخاب شده است OS-ELM. یک شبکه عصبی پیش‌خور تک‌لایه^۳ است که وزن‌های ورودی آن به صورت تصادفی مقداردهی شده و تنها وزن‌های لایه خروجی (β) به صورت تحلیلی و سریع محاسبه می‌شوند.

¹ Offline Optimization Phase

² Online Deployment Phase

³ Single Layer Feedforward Network (SLFN)

برای یک مجموعه داده، هدف یافتن β است که مجذور نرم فروبنیوس^۱ خطای زیر را کمینه کند، که معادل کمینه کردن مجموع مربعات خطاها است:

$$\|H\beta - T\|_F^2 \quad (۱)$$

که در آن H ماتریس خروجی لایه پنهان و T بردار مقادیر هدف است. در OS-ELM، این فرآیند به صورت بازگشتی و برای هر بلوک جدید از داده‌ها انجام می‌شود و β بدون نیاز به دسترسی به داده‌های قدیمی به‌روزرسانی می‌گردد. این ویژگی آن را برای کاربردهای مبتنی بر داده‌های جریانی ایده‌آل می‌سازد [۲۶].

ساختار گروهی تطبیقی: برای غلبه بر ضعف یادگیرنده‌های منفرد در برابر نویز و «تغییر مفهوم»، ما OS-ELM را در یک ساختار گروهی تطبیقی قرار دادیم. این ساختار از M یادگیرنده مستقل OS-ELM تشکیل شده و پیش‌بینی نهایی از طریق یک ترکیب وزنی پویا محاسبه می‌شود:

$$Y_{\text{ensemble}}(t) = \sum_{i=1}^M w_i(t) y_i(t) \quad (۲)$$

که در آن $y_i(t)$ پیش‌بینی عضو- i ام و $w_i(t)$ وزن تطبیقی آن در زمان t است. این وزن‌ها به صورت مداوم بر اساس عملکرد اخیر هر عضو در یک پنجره زمانی لغزان^۲ با طول W به‌روزرسانی می‌شوند. اعضای که اخیراً عملکرد بهتری داشته‌اند، وزن بیشتری دریافت می‌کنند. این مکانیزم وزن‌دهی مبتنی بر اعتماد (AT)، به مدل اجازه می‌دهد به سرعت با تغییرات بازار سازگار شده و به اعضای قوی‌تر تکیه کند [۲۴].

لازم به ذکر است که پارامتر W (طول پنجره زمانی برای ارزیابی عملکرد) یکی از ابرپارامترهای کلیدی است که در مرحله بعد، توسط الگوریتم بهینه‌ساز DE به صورت خودکار تنظیم می‌گردد.

بهینه‌سازی پارامترهای کلیدی با تکامل تفاضلی (DE): عملکرد این چارچوب ترکیبی به تنظیم دقیق بردار ابرپارامترهای آن وابسته است. این پارامترها شامل تعداد یادگیرنده‌های گروه (M)، تعداد نوروهای لایه پنهان (L)، پارامتر تنظیم (C)، طول پنجره زمانی (W) و ضریب حساسیت (α) می‌باشند. به منظور یافتن ترکیب بهینه این پارامترها $\vec{p} = [M, L, C, W, \alpha]$ به صورت سیستماتیک، از الگوریتم تکامل تفاضلی (DE) استفاده شده است [۶].

تابع هدف دوگانه^۳: نوآوری محوری این پژوهش در طراحی یک تابع هدف دوگانه نهفته است که به طور صریح، توازن میان دقت پیش‌بینی و سرعت محاسباتی را به عنوان یک هدف واحد بهینه‌سازی می‌کند. تابع شایستگی^۴ برای هر بردار پارامتر $\vec{p}$ به صورت یک ترکیب وزنی تعریف شده و هدف، کمینه‌سازی آن است:

$$\text{Minimize Fitness } (\vec{P}) = \theta \cdot f_{\text{accuracy}}(\vec{p}) + (1-\theta) \cdot f_{\text{speed}}(\vec{p}) \quad (۳)$$

در این فرمول، $f_{\text{accuracy}}(\vec{p})$ مؤلفه دقت مدل است که با استفاده از ریشه میانگین مربعات خطا^۵ بر روی مجموعه داده اعتبارسنجی^۶ محاسبه می‌شود. مؤلفه $f_{\text{speed}}(\vec{p})$ نیز هزینه محاسباتی را نشان می‌دهد و برابر با کل زمان آموزش^۷

^۱ Frobenius Norm

^۲ Sliding Window

^۳ Dual-Objective Function

^۴ Fitness Function

^۵ Root Mean Squared Error (RMSE)

^۶ Validation Dataset

^۷ Training Time

مدل بر روی همان داده‌های اعتبارسنجی است. از آنجایی که این دو مؤلفه دارای مقیاس‌های متفاوتی هستند، هر دو قبل از ترکیب با استفاده از روش نرمال‌سازی مینیمم - ماکزیمم^۱ به بازه [۰,۱] نگاشت می‌شوند تا سهمی متناسب در تابع هدف داشته باشند. ضریب وزنی θ در بازه [۰,۱] قرار دارد و برای کنترل این توازن به کار می‌رود. در این پژوهش، مقدار $\theta = ۰.۷$ انتخاب شد تا ضمن حفظ اولویت اصلی بر روی دقت پیش‌بینی، مدل‌هایی با سرعت پایین به طور مؤثری جریمه شوند.

انتخاب زمان آموزش به جای زمان پیش‌بینی، یک تصمیم آگاهانه و مبتنی بر دو دلیل کلیدی است: اولاً، به عنوان یک مدل آنالاین و ترتیبی، کاربرد عملی آن به توانایی یادگیری سریع از داده‌های جدید بستگی دارد؛ لذا کمینه کردن تأخیر در یادگیری، یک هدف مرتبط‌تر است. ثانیاً، ابرپارامترهای اصلی مدل (مانند L) تأثیر بسیار بیشتری بر زمان آموزش دارند تا زمان پیش‌بینی که در معماری‌های مبتنی بر ELM عموماً ناچیز است، و این امر سیگنال بهینه‌سازی قوی‌تری را برای الگوریتم فراهم می‌آورد.

فرآیند اجرای الگوریتم DE مطابق با مراحل استاندارد آن به شرح زیر پیاده‌سازی شد:

۱. مقداردهی اولیه: ایجاد یک جمعیت اولیه از بردارهای پارامتر.
 ۲. ارزیابی شایستگی^۲: برای هر "فرد" (بردار پارامتر) در جمعیت، مدل AT-M(OS-ELM) با آن پارامترها بر روی داده‌های اعتبارسنجی آموزش داده شده و مقدار تابع هدف دوگانه برای آن محاسبه می‌شود.
 ۳. تکامل: عملگرهای استاندارد DE شامل جهش^۳، ترکیب^۴ و انتخاب^۵ به صورت تکراری بر روی جمعیت اعمال می‌شوند.
 ۴. خاتمه و انتخاب نهایی: این فرآیند تکاملی تا رسیدن به معیار توقف (مانند حداکثر نسل) ادامه می‌یابد و بهترین بردار پارامتری که در طول کل فرآیند یافت شده، به عنوان راه‌حل نهایی انتخاب می‌گردد.
- الگوریتم کلی و فازهای اجرایی چارچوب پیشنهادی (DE-Optimized AT-M(OS-ELM)) در دو فاز مجزا به شرح زیر عمل می‌کند:**
۱. فاز بهینه‌سازی آفلاین: در این مرحله، الگوریتم DE بر روی داده‌های آموزشی و اعتبارسنجی اجرا می‌شود تا بهترین مجموعه ابرپارامترها (p^*) را بر اساس تابع هدف دوگانه پیدا کند.
 ۲. فاز استقرار آنالاین: مدل با استفاده از ابرپارامترهای بهینه‌شده (p^*) مقداردهی اولیه شده و برای پیش‌بینی بر روی داده‌های جدید (جربانی) به کار می‌رود. در این فاز، وزن‌های تطبیقی گروه به صورت مداوم با هر گام زمانی به‌روزرسانی می‌شوند.

مزایای رقابتی و جایگاه مدل پیشنهادی: چارچوب پیشنهادی (DE-Optimized AT-M(OS-ELM)) با یکپارچه‌سازی هوشمندانه اجزای خود، مزایای رقابتی قابل توجهی نسبت به مدل‌های مبنا کسب می‌کند. همان‌طور که در جدول ۱ به طور خلاصه مقایسه شده است، مدل‌های سنتی و یادگیری عمیق، هر کدام در یک یا چند بُعد کلیدی برای کاربردهای بلادرنگ با محدودیت مواجه هستند.

برای مثال، مدل‌های آماری مانند ARIMA فاقد توانایی مدیریت روابط غیرخطی و تغییرات پویای بازار هستند [۴]، مدل‌های یادگیری ماشین سنتی مانند جنگل تصادفی^۶ و رگرسیون بردار پشتیبان^۷ نیز از یادگیری جریانی

¹ Min-Max

² Fitness Evaluation

³ Mutation

⁴ Crossover

⁵ Selection

⁶ Random Forest

⁷ Support Vector Regression (SVR)

پشتیبانی نمی‌کنند و به بازآموزی‌های پرهزینه نیاز دارند [۵، ۱۳]. حتی مدل‌های پیشرفته یادگیری عمیق مانند LSTM و Transformer، با وجود قدرت بالا در مدل‌سازی الگوهای پیچیده، به دلیل هزینه‌های محاسباتی بسیار سنگین و عدم پشتیبانی ذاتی از یادگیری آنلاین، برای محیط‌های پویا و جریانی نامناسب تلقی می‌شوند [۱۴، ۳۲]. در مقابل، مدل پیشنهادی ما با ترکیب یادگیری جریانی، پایداری گروهی تطبیقی و بهینه‌سازی پویا، راهکاری جامع ارائه می‌دهد که به طور همزمان به چالش‌های دقت، سرعت و تطبیق‌پذیری پاسخ می‌دهد و شکاف موجود میان این رویکردها را پر می‌کند [۲۴، ۲۲، ۶].

جدول ۱: مقایسه ویژگی‌های کلیدی مدل‌ها

مدل	یادگیری جریانی	مدیریت تغییر مفهوم	مقاومت در برابر نویز	پیچیدگی محاسباتی
DE-Optimized AT-M(OS-ELM)	بله (آنلاین)	بالا (تطبیقی)	بالا	کم
ARIMA	خیر (آفلاین)	بسیار کم (ایستا)	کم	کم
Random Forest	خیر (آفلاین)	محدود (ایستا)	بالا	متوسط
SVR	خیر (آفلاین)	محدود (ایستا)	بالا	بالا
LSTM	خیر (آفلاین)	محدود (ایستا)	بالا	بالا
Transformer	خیر (آفلاین)	محدود (ایستا)	بالا	بسیار بالا

۳. روش‌شناسی پژوهش

مجموعه داده‌ها و معیارهای انتخاب: به منظور ارزیابی جامع قابلیت تعمیم‌پذیری و دقت مدل پیشنهادی، مجموعه داده‌ای متنوع از داده‌های تاریخی بازار سهام آمریکا انتخاب گردید. این مجموعه شامل داده‌های روزانه پنج‌دارایی کلیدی در یک بازه زمانی ۱۴ ساله (از ۱ ژانویه ۲۰۱۰ تا ۳۱ دسامبر ۲۰۲۳) است که از پلتفرم یاهو فایننس^۱ استخراج شده‌اند.

دارایی‌های انتخاب‌شده به گونه‌ای هستند که صنایع و پویایی‌های مختلف بازار را نمایندگی کنند:

- ✓ **بخش فناوری:** سهام شرکت‌های اپل^۲ و مایکروسافت^۳ به عنوان نماینده این بخش حیاتی و پرتکاپو انتخاب شدند. این شرکت‌ها معمولاً به عنوان سهام رشد^۴ شناخته می‌شوند که دارای نوسانات بالا و حساسیت زیاد به نوآوری و شرایط کلان اقتصادی هستند.
- ✓ **بخش بهداشت و درمان:** سهام شرکت جانسون و جانسون^۵ نماینده یک بخش تدافعی^۶ است. این صنعت معمولاً پایداری بیشتری در دوره‌های رکود اقتصادی از خود نشان می‌دهد و پویایی آن کمتر به چرخه‌های تجاری وابسته است.
- ✓ **بخش انرژی:** سهام شرکت اکسون موبیل^۷ به عنوان نماینده‌ای از بخش چرخه‌ای انرژی^۸ انتخاب شد که عملکرد آن به شدت به قیمت جهانی کالاها (نفت) و رویدادهای ژئوپلیتیکی وابسته است.

¹ Yahoo Finance

² Apple Inc. (AAPL)

³ Microsoft Corp. (MSFT)

⁴ Growth Stocks

⁵ Johnson & Johnson (JNJ)

⁶ Defensive Sector

⁷ Exxon Mobil Corp. (XOM)

⁸ Cyclical

✓ نماینده کل بازار: شاخص اس‌اند‌پی ۵۰۰^۱ به عنوان مهم‌ترین معیار برای ارزیابی عملکرد کلی بازار سهام آمریکا در نظر گرفته شد. موفقیت یک مدل در پیش‌بینی این شاخص، نشان‌دهنده توانایی آن در درک روندهای کلان بازار است.

این انتخاب هدفمند، یک محیط آزمایشی چالش‌برانگیز و واقع‌گرایانه ایجاد می‌کند که مدل را مجبور می‌سازد تا توانایی خود را در شرایط و بخش‌های مختلف بازار، هر یک با مشخصات ریسک و نوسان متفاوت، اثبات نماید. برای هر دارایی، داده‌های قیمت (باز شدن، بالاترین، پایین‌ترین، بسته شدن) و حجم معاملات^۲ به عنوان ورودی‌های پایه برای فرآیند مهندسی ویژگی^۳ مورد استفاده قرار گرفتند.

آماده‌سازی و مهندسی داده‌ها: عملکرد یک مدل پیش‌بینی به شدت به کیفیت و ساختار داده‌های ورودی آن وابسته است. از این رو، داده‌های تاریخی خام، پیش از آنکه بتوانند توسط الگوریتم‌های یادگیری مورد استفاده قرار گیرند، باید طی یک فرآیند سیستماتیک آماده‌سازی شوند. هدف از این فرآیند، تبدیل داده‌های خام به یک مجموعه ورودی آموزنده، ساختاریافته و بهینه برای الگوریتم‌های یادگیری است. این فرآیند جامع، که شامل مراحل متعددی از کنترل کیفیت تا مهندسی ویژگی و آماده‌سازی نهایی داده‌ها می‌باشد، در زیربخش‌های آتی به تفصیل شرح داده می‌شود.

کنترل کیفیت و یکپارچگی داده‌ها: به منظور تضمین کیفیت مدل، داده‌های تاریخی هر دارایی به دقت از نظر وجود مقادیر گم‌شده یا ناهنجاری بررسی شدند. تحلیل‌ها تأیید کرد که داده‌ها برای تمام روزهای معاملاتی در بازه زمانی مورد مطالعه، کامل و پیوسته هستند. شکاف‌های موجود در سری‌های زمانی تنها مربوط به تعطیلات رسمی بازار و آخر هفته‌ها بوده که یک ویژگی ذاتی داده‌های مالی است و نیازی به درون‌یابی ندارد. این بررسی، کیفیت و یکپارچگی داده‌های ورودی به مدل را تضمین می‌کند.

استخراج و مهندسی ویژگی‌ها: به منظور ارائه اطلاعاتی غنی و چند بعدی به مدل، مجموعه‌ای از ۱۲ شاخص تحلیل تکنیکال^۴ استاندارد، که جنبه‌های مختلف بازار مانند روند^۵، شتاب^۶ (سرعت و قدرت حرکت قیمت) و نوسان^۷ را پوشش می‌دهند، برای هر روز معاملاتی استخراج گردید. انتخاب و پیکربندی این شاخص‌ها مطابق با رویه‌های معتبر در ادبیات پژوهشی صورت گرفته است [۲۹]:

- شاخص‌های مبتنی بر روند: شامل دو خط میانگین متحرک نمایی^۸ برای دوره‌های زمانی ۱۲ و ۲۶ روزه؛ و سه مؤلفه میانگین متحرک همگرایی - واگرایی^۹ که بر اساس EMAهای ۱۲ و ۲۶ روزه و یک خط سیگنال ۹ روزه محاسبه شده است.
- شاخص‌های شتاب: شامل شاخص قدرت نسبی^{۱۰} با دوره ۱۴ روزه؛ دو خط نوسان‌گر تصادفی^{۱۱} با دوره ۱۴ روزه؛ نرخ تغییر^{۱۲} برای دوره ۱۲ روزه؛ و شاخص میانگین جهت‌دار^{۱۳} با دوره ۱۴ روزه.

¹ S&P 500 (SPY)

² Volume

³ Feature Engineering

⁴ Technical Analysis Indicator

⁵ Trend

⁶ Momentum

⁷ Volatility

⁸ Exponential Moving Average (EMA)

⁹ Moving Average Convergence - Divergence (MACD)

¹⁰ Relative Strength Index (RSI)

¹¹ Stochastic Oscillator

¹² Rate Of Change (ROC)

¹³ Average Directional Index (ADX)

- شاخص‌های نوسان: شامل سه خط باندهای بولینگر^۱ (خط بالایی، میانی و پایینی) که برای دوره ۲۰ روزه و با انحراف معیار $2\pm$ محاسبه شده‌اند.
- مجموعه ویژگی نهایی که به عنوان ورودی به مدل‌ها ارائه گردید، شامل این ۱۳ شاخص تکنیکال به علاوه دو متغیر پایه، یعنی حجم معاملات (Volume) و قیمت پایانی (Close) بود. در مجموع، یک بردار ویژگی متشکل از ۱۵ متغیر برای هر روز معاملاتی، نمای کاملی از وضعیت بازار را برای مدل‌سازی فراهم آورد.
- علاوه بر این، برای سازگاری کامل با معماری تطبیقی مدل پیشنهادی، طول پنجره زمانی ورودی^۲ به صورت پویا و در بازه ۱۰ تا ۱۰۰ روز در نظر گرفته شد.
- نرمال‌سازی آنلاین داده‌ها:** برای جلوگیری از ناپایداری مقیاس ویژگی‌ها و سازگاری با تغییرات ساختاری بازار، تمامی متغیرهای ورودی با استفاده از روش Min-Max نرمال‌سازی شدند. این فرآیند به‌صورت آنلاین و با بهره‌گیری از یک پنجره لغزان ۲۵۰ روزه (معادل یک سال معاملاتی) انجام شد. این رویکرد که از مطالعات پیشین الگوبرداری شده است، با جلوگیری از نشت داده^۳ و شبیه‌سازی شرایط واقعی، عملکرد مدل را در محیط‌های غیرایستا بهبود می‌بخشد [۲۹]. این مرحله پیش‌پردازش برای تمام مدل‌های مبتنی بر یادگیری ماشین و مدل پیشنهادی اعمال گردید؛ مدل آماری ARIMA به دلیل ماهیت خود و عدم نیاز به داده‌های مقیاس‌بندی شده، مستقیماً بر روی سری زمانی اصلی برازش^۴ داده شد.
- تقسیم‌بندی مجموعه داده:** داده‌های تاریخی (از ابتدای ۲۰۱۰ تا انتهای ۲۰۲۳) به سه مجموعه داده مستقل و غیرهمپوشان تقسیم شدند: مجموعه آموزش شامل تقریباً ۷۰٪ داده‌ها (از ۱ ژانویه ۲۰۱۰ تا ۳۱ دسامبر ۲۰۱۹)، مجموعه اعتبارسنجی شامل تقریباً ۱۵٪ داده‌ها (از ۱ ژانویه ۲۰۲۰ تا ۳۱ دسامبر ۲۰۲۱) که برای بهینه‌سازی ابرپارامترها استفاده شد، و مجموعه آزمون شامل ۱۵٪ باقیمانده داده‌ها (از ۱ ژانویه ۲۰۲۲ تا ۳۱ دسامبر ۲۰۲۳) جهت ارزیابی نهایی عملکرد مدل‌ها.
- این روش تقسیم‌بندی، ارزیابی قابل اتکایی از قابلیت تعمیم‌پذیری مدل‌ها را تضمین می‌کند. این ساختار تقسیم‌بندی زمانی و غیرهمپوشان، به منظور شبیه‌سازی دقیق یک سناریوی واقعی معاملاتی انتخاب شد که در آن، مدل بر اساس تمام داده‌های گذشته آموزش دیده و عملکرد آن بر روی آینده نامعلوم ارزیابی می‌شود.
- تعریف متغیر هدف:** هدف اصلی مدل‌سازی در این پژوهش، پیش‌بینی قیمت پایانی^۵ سهم برای روز معاملاتی بعدی ($t+1$) است. بنابراین، برای هر پنجره زمانی از ویژگی‌های ورودی در روز t ، متغیر هدف، مقدار قیمت پایانی در روز ($t+1$) در نظر گرفته شد. تمام معیارهای ارزیابی خطا (مانند RMSE) پس از برگرداندن خروجی مدل به مقیاس اصلی قیمت، محاسبه شده‌اند تا تفسیرپذیری نتایج حفظ شود.
- معیارهای ارزیابی عملکرد:** عملکرد مدل‌های پیش‌بینی در دو بُعد اصلی دقت پیش‌بینی و کارایی محاسباتی ارزیابی شد. علاوه بر این، از یک آزمون آماری برای سنجش معناداری نتایج استفاده گردید.
- معیارهای دقت پیش‌بینی: برای ارزیابی جنبه‌های مختلف دقت، پنج معیار استاندارد به کار گرفته شد. ریشه میانگین مربعات خطا^۶ و میانگین قدر مطلق خطا^۷ به ترتیب برای سنجش خطای پیش‌بینی کوتاه‌مدت و میان‌مدت (به دلار) استفاده شدند. میانگین قدر مطلق درصد خطا^۸ خطای نسبی را برای مقایسه عملکرد بین دارایی‌های مختلف اندازه‌گیری کرد. برای ارزیابی توانایی مدل در پیش‌بینی روندهای بلندمدت و

¹ Bollinger Bands² Input Window Length (or Look-back Period)³ Data Leakage⁴ Fit⁵ Closing Price⁶ Root Mean Squared Error (RMSE)⁷ Mean Absolute Error (MAE)⁸ Mean Absolute Percentage Error (MAPE)

توضیح واریانس داده‌ها، ضریب تعیین^۱ محاسبه شد. در نهایت، دقت جهت‌دار^۲ که برای معاملات بلادرنگ حیاتی است، درصد پیش‌بینی صحیح جهت حرکت قیمت را مشخص نمود.

- معیارهای کارایی محاسباتی: برای سنجش کارایی محاسباتی مدل‌ها، دو معیار کلیدی در نظر گرفته شد. معیار اول، «زمان آموزش نهایی»^۳ است که با اندازه‌گیری زمان لازم برای آموزش مدل با ابرپارامترهای بهینه، توانایی آن برای یادگیری سریع در بازارهای پویا را نشان می‌دهد. به منظور ایجاد یک مقایسه عادلانه، این معیار فرآیند بهینه‌سازی مقدماتی در مدل پیشنهادی (که با الگوریتم DE حدود ۴۸۰ ثانیه طول کشید) را شامل نمی‌شود. معیار دوم، «زمان پیش‌بینی»^۴، با اندازه‌گیری زمان متوسط برای تولید یک پیش‌بینی، کارایی مدل را در سناریوهای معاملاتی الگوریتمی مشخص می‌کند.
- ارزیابی آماری: برای تأیید اینکه برتری عملکرد مدل پیشنهادی از نظر آماری معنادار است و صرفاً ناشی از تصادف نیست، از آزمون ناپارامتریک ویلکاکسون^۵ بر روی توزیع خطاهای روزانه استفاده شد و مقدار احتمال معناداری (p-value) محاسبه گردید [۱۰].

انتخاب این مجموعه جامع از معیارها، امکان تحلیل چندبعدی و مقایسه عادلانه مدل‌ها را مطابق با رویه‌های استاندارد فراهم می‌آورد [۲۹].

مدل‌های مبنا و پیکربندی آن‌ها: برای ارزیابی جامع عملکرد مدل پیشنهادی، مجموعه‌ای متنوع از مدل‌های مبنا انتخاب گردید که طیف وسیعی از رویکردهای کلاسیک آماری، یادگیری ماشین سنتی و یادگیری عمیق پیشرفته در حوزه پیش‌بینی سری‌های زمانی مالی هستند. انتخاب این مدل‌ها بر اساس تکرار و عملکرد اثبات‌شده آن‌ها در مطالعات معتبر پیشین صورت گرفته است [۱۴، ۲۹، ۳۰]. پیکربندی ابرپارامترهای هر مدل، که در جدول ۲ خلاصه شده است، بر اساس رویه‌های استاندارد و تنظیمات موفق گزارش‌شده در مطالعات مرجع و معتبر انتخاب گردیده است تا یک بستر مقایسه عادلانه و قابل بازتولید فراهم آید. ارجاعات اصلی برای هر پیکربندی نیز در جدول ذکر شده است.

جدول ۲: پیکربندی ابرپارامترهای مدل‌های مبنا (Benchmark Models)

مدل	دسته (Category)	ابرپارامترهای کلیدی (Key Hyperparameters)	مرجع اصلی
ARIMA	آماري خطي	(p, d, q): (5, 1, 0) مرتبه مدل	[۴]
Random Forest	یادگیری ماشین گروهی	تعداد درخت‌ها: ۱۰۰، حداکثر عمق: ۱۰	[۵]
SVR	یادگیری ماشین هسته‌ای	هسته: RBF، پارامتر تنظیم (C): ۱/۰، اپسیلون (ε): ۰/۱، گاما: خودکار	[۱۲]
LSTM	یادگیری عمیق بازگشتی	تعداد لایه‌ها: ۲، نورون در هر لایه: ۵۰، بهینه‌ساز: Adam، نرخ یادگیری (LR): ۰/۰۰۱	[۱۴]
Transformer	یادگیری عمیق مبتنی بر توجه	لایه‌های رمزگذار: ۴، تعداد سرها: ۸، بُعد مدل (d_model): ۲۵۶، نرخ یادگیری (LR): ۰/۰۰۰۱	[۳۲]

محیط پیاده‌سازی و اجرا: تمامی آزمایش‌ها بر روی یک سیستم کامپیوتری با پردازنده AMD Ryzen (CPU) HS ۷۷۳۵ (۸ هسته، ۱۶ رشته)، واحد پردازش گرافیکی NVIDIA GeForce RTX ۴۰۶۰ (GPU) (۸ گیگابایت

^۱ Coefficient of Determination (R^2)

^۲ Directional Accuracy (DA)

^۳ Final Training Time

^۴ Prediction Time

^۵ Wilcoxon Non-Parametric Test

حافظه (GDDR6) و ۱۶ گیگابایت حافظه رم DDR5 پیاده‌سازی شدند. محیط نرم‌افزاری بر پایه سیستم‌عامل Windows ۱۱ و زبان برنامه‌نویسی Python ۳.۸ بنا شده و از کتابخانه‌های کلیدی مانند NumPy, Pandas و Scikit-learn بهره برده است.

برای پیاده‌سازی معماری‌های یادگیری عمیق (LSTM و Transformer)، از فریم‌ورک TensorFlow ۲.۱۰ با پشتیبانی کامل از شتاب‌دهی سخت‌افزاری GPU از طریق CUDA استفاده شد تا از حداکثر توان محاسباتی بهره‌برداری شود. در مقابل، مدل‌های کلاسیک (ARIMA, Random Forest, SVR) و همچنین مدل پیشنهادی ما (DE-Optimized AT-M(OS-ELM))، که محاسبات آن‌ها ماهیت الگوریتمی و متوالی دارد، برای کسب کارایی بهینه بر روی CPU اجرا گردیدند. این تفکیک در استفاده از سخت‌افزار، ضمن تخصیص بهینه‌ترین پلتفرم محاسباتی به هر دسته از مدل‌ها، شرایطی عادلانه و واقع‌گرایانه را برای مقایسه سرعت آموزش فراهم می‌آورد.

پیکربندی و بهینه‌سازی ابرپارامترهای مدل پیشنهادی: برخلاف مدل‌های مبنا که با ابرپارامترهای ثابت پیاده‌سازی شدند، رویکرد محوری در چارچوب ما، بهینه‌سازی خودکار و داده‌محور ابرپارامترهای کلیدی است. این فرآیند توسط الگوریتم تکامل تفاضلی (DE) مدیریت می‌شود تا بهترین ترکیب پارامترها برای توازن میان دقت و سرعت یافت شود.

فضای جستجوی تعریف‌شده برای ابرپارامترهای بهینه‌شونده در جدول ۳ ارائه شده است. این فضای جستجو برای هر ابرپارامتر بر اساس ترکیبی از مطالعات پیشین و تحلیل‌های اکتشافی تعیین شده است تا تعادلی بهینه میان گسترده‌ی کاوش (برای یافتن راه‌حل بهینه) و کارایی محاسباتی (برای همگرایی در زمان منطقی) برقرار گردد. به طور مشخص، بازه تعداد نورون‌ها (L) به گونه‌ای انتخاب شده که مدل‌هایی با پیچیدگی‌های مختلف را پوشش دهد، در حالی که جستجوی لگاریتمی برای ضریب تنظیم (C) به عنوان یک رویه استاندارد، کاوش مؤثر پارامترهای رگولایزاسیون را تضمین می‌کند.

جدول ۳: فهرست فضای جستجوی ابرپارامترهای بهینه‌شونده در مدل پیشنهادی

نماد	نوع	محدوده جستجو	توضیح	ابرپارامتر
M	عدد صحیح	[۳, ۱۵]	تعداد کل مدل‌های پایه (OS-ELM) در ساختار گروهی	تعداد یادگیرنده‌ها
L	عدد صحیح	[۱۰, ۳۰۰]	اندازه لایه پنهان در هر یادگیرنده پایه (OS-ELM)	تعداد نورون‌های پنهان
C	لگاریتمی	[$5e-1$, $5e1$]	ضریب رگولایزاسیون L_2 برای پایداری مدل	ضریب تنظیم ^۱
W	عدد صحیح	[۱۰, ۱۰۰]	تعداد گام‌های زمانی گذشته به عنوان ورودی	طول پنجره ورودی
α	عدد اعشاری	[۰/۱, ۵/۰]	پارامتر کنترل سرعت تطبیق وزن‌ها در مکانیزم AT	ضریب حساسیت

علاوه بر پارامترهای خود مدل، پارامترهای کنترل‌کننده الگوریتم DE نیز به صورت ثابت و بر اساس رویه‌های استاندارد تنظیم شده‌اند تا از همگرایی پایدار الگوریتم اطمینان حاصل شود. این پارامترهای کنترلی در جدول ۴ مشخص گردیده‌اند.

¹ Regularization Coefficient

جدول ۴: پارامترهای کنترل‌کننده الگوریتم بهینه‌ساز تکامل تفاضلی (DE)

پارامتر کنترل	نماد	مقدار
اندازه جمعیت	NP	50
حداکثر نسل‌ها	G_max	100
ضریب مقیاس (جهش)	F	0/8
نرخ ترکیب	CR	0/9

برای حصول اطمینان از پایداری نتایج بهینه‌سازی، الگوریتم DE با چندین مقداردهی اولیه تصادفی مختلف اجرا گردید. در تمام اجراها، الگوریتم به ناحیه مشابهی از فضای جستجو با مقادیر شایستگی نزدیک به هم همگرا شد که این امر، قوی بودن تابع هدف طراحی‌شده و پایدار بودن فرآیند بهینه‌سازی را تأیید می‌کند.

۴. تحلیل داده‌ها و یافته‌ها

این بخش به ارائه یافته‌های تجربی حاصل از ارزیابی مدل پیشنهادی در مقایسه با مدل‌های مبنا می‌پردازد. یافته‌ها با استفاده از روش‌شناسی تبیین‌شده در بخش قبل و بر روی مجموعه داده آزمون به دست آمده‌اند. شایان ذکر است که تمامی مقادیر عددی گزارش‌شده در جداول، برای وضوح بصری و سادگی مقایسه، به دو یا سه رقم اعشار گرد شده‌اند. برای شفافیت بیشتر، نتایج در دو قسمت مجزا ارائه می‌گردد: ابتدا، نتایج عملکرد کمی که شامل معیارهای دقت، کارایی محاسباتی و اعتبارسنجی آماری است، گزارش می‌شود و در ادامه، یافته‌های کیفی و بصری برای نمایش گرافیکی و درک عمیق‌تر پویایی عملکرد مدل‌ها و تقابل‌های کلیدی ارائه خواهد شد.

نتایج عملکرد کمی و اعتبارسنجی آماری: در جدول نتایج عملکرد مدل‌ها آورده شده است.

جدول ۵: نتایج عملکرد مدل‌ها بر روی سهام شرکت Apple (AAPL)

مدل	RMSE	MAE	MAPE (%)	R ²	DA (%)	زمان آموزش (نهایی (ثانیه)	زمان پیش‌بینی (ثانیه)
ARIMA	۲/۸۹	۲/۴۶	۲/۱۲	۰/۹۵۴	۵۶/۸	۱۲/۱	۰/۰۵۱
Random Forest	۲/۶۹	۲/۳۱	۲/۰۱	۰/۹۶۰	۵۸/۵	۳۵/۲	۰/۱۰۳
SVR	۲/۶۵	۲/۲۸	۱/۹۷	۰/۹۶۱	۵۸/۷	۲۸/۱	۰/۰۸۲
LSTM	۲/۴۲	۲/۰۹	۱/۸۴	۰/۹۶۸	۶۱/۸	۳۲۰/۴	۰/۲۰۵
Transformer	۲/۳۳	۲/۰۱	۱/۷۹	۰/۹۷۶	۶۲/۵	۶۱۵/۸	۰/۳۰۶
DE-Optimized AT-M(OS-ELM)	۲/۳۵	۱/۹۸	۱/۷۵	۰/۹۷۵	۶۵/۷	۰/۸	۰/۰۳۵

همان‌طور که در نتایج مربوط به سهام شرکت اپل (جدول ۵) مشاهده می‌شود، مدل پیشنهادی با دستیابی به دقت جهت‌دار (DA) ۶۵.۷٪، برتری محسوس نسبت به سایر مدل‌ها نشان می‌دهد. علاوه بر این، زمان آموزش ۰.۸ ثانیه‌ای آن، که چند صد برابر سریع‌تر از مدل‌های LSTM و Transformer است، کارایی محاسباتی فوق‌العاده این چارچوب را برای کاربردهای بلادرنگ تأیید می‌کند.

جدول ۶: نتایج عملکرد مدل‌ها بر روی سهام شرکت Microsoft (MSFT)

مدل	RMSE	MAE	MAPE (%)	R ²	DA (%)	زمان آموزش نهایی (ثانیه)	زمان پیش‌بینی (ثانیه)
ARIMA	۲/۷۷	۲/۳۵	۲/۰۱	۰/۹۵۹	۵۷/۵	۱۱/۸	۰/۰۴۸
Random Forest	۲/۵۸	۲/۲۱	۱/۹۱	۰/۹۶۵	۵۹/۰	۳۴/۹	۰/۱۰۱
SVR	۲/۵۴	۲/۱۸	۱/۸۹	۰/۹۶۶	۵۹/۳	۲۹/۵	۰/۰۸۵
LSTM	۲/۲۸	۱/۹۷	۱/۷۴	۰/۹۷۲	۶۲/۴	۳۱۰/۲	۰/۱۹۸
Transformer	۲/۲۳	۱/۹۲	۱/۷۱	۰/۹۷۸	۶۳/۱	۶۰۵/۱	۰/۲۹۷
DE-Optimized AT-M(OS-ELM)	۲/۲۰	۱/۸۸	۱/۶۶	۰/۹۷۸	۶۶/۲	۰/۹	۰/۰۳۲

نتایج به‌دست‌آمده برای سهام شرکت مایکروسافت (جدول ۶) نیز این الگو را تقویت می‌کند. در این مورد، مدل پیشنهادی ضمن حفظ برتری در سرعت و دقت جهت‌دار، در معیار خطای RMSE عملکردی کاملاً برابر با مدل Transformer ارائه داده است. این یافته بر توانایی مدل در حفظ توازن بهینه میان دقت و سرعت در دارایی‌های مختلف تأکید دارد.

جدول ۷: نتایج عملکرد مدل‌ها بر روی سهام شرکت Johnson & Johnson (JNJ)

مدل	RMSE	MAE	MAPE (%)	R ²	DA (%)	زمان آموزش نهایی (ثانیه)	زمان پیش‌بینی (ثانیه)
ARIMA	۱/۸۵	۱/۵۱	۱/۸۹	۰/۹۷۰	۵۶/۱	۱۱/۵	۰/۰۴۵
Random Forest	۱/۷۹	۱/۴۷	۱/۸۲	۰/۹۷۲	۵۷/۵	۳۶/۵	۰/۱۰۵
SVR	۱/۷۷	۱/۴۶	۱/۸۱	۰/۹۷۳	۵۷/۸	۳۱/۰	۰/۰۸۸
LSTM	۱/۶۳	۱/۳۷	۱/۷۲	۰/۹۷۷	۶۰/۵	۳۲۵/۰	۰/۲۰۸
Transformer	۱/۶۱	۱/۳۵	۱/۷۰	۰/۹۸۰	۶۱/۱	۶۲۲/۷	۰/۳۱۰
DE-Optimized AT-M(OS-ELM)	۱/۵۹	۱/۳۱	۱/۶۲	۰/۹۷۹	۶۴/۳	۰/۷	۰/۰۲۷

در آزمون روی سهام شرکت جانسون و جانسون به عنوان نماینده یک بخش تدافعی (جدول ۷)، مدل پیشنهادی بار دیگر عملکردی برتر در معیار دقت جهت‌دار (۶۴.۳٪) به ثبت رساند. کمترین میزان خطای پیش‌بینی (RMSE و MAE) در این دارایی نیز متعلق به مدل پیشنهادی است که نشان‌دهنده پایداری و تعمیم‌پذیری بالای آن در بازارهای با نوسان کمتر می‌باشد.

جدول ۸: نتایج عملکرد مدل‌ها بر روی شاخص S&P ۵۰۰ (SPY)

مدل	RMSE	MAE	MAPE (%)	R ²	DA (%)	زمان آموزش نهایی (ثانیه)	زمان پیش‌بینی (ثانیه)
ARIMA	۲/۲۷	۱/۹۲	۱/۵۵	۰/۹۸۸	۵۹/۲	۱۲/۵	۰/۰۵۲
Random Forest	۲/۱۹	۱/۸۶	۱/۴۸	۰/۹۸۹	۶۰/۸	۳۵/۰	۰/۱۰۲
SVR	۲/۱۶	۱/۸۳	۱/۴۶	۰/۹۸۹	۶۱/۱	۲۹/۸	۰/۰۸۳
LSTM	۱/۹۶	۱/۶۸	۱/۳۵	۰/۹۹۱	۶۴/۳	۳۱۵/۵	۰/۲۰۱
Transformer	۱/۹۲	۱/۶۵	۱/۳۳	۰/۹۹۲	۶۴/۶	۶۰۸/۳	۰/۳۰۱
DE-Optimized AT-M(OS-ELM)	۱/۹۳	۱/۶۲	۱/۳۰	۰/۹۹۲	۶۸/۱	۰/۸	۰/۰۳۰

ارزیابی عملکرد مدل‌ها بر روی شاخص کل بازار (SPY) که در جدول ۸ آمده، اهمیت ویژه‌ای دارد. مدل پیشنهادی با کسب دقت جهت‌دار ۶۸.۱٪، توانایی بالای خود در درک روندهای کلان بازار را به اثبات رسانده و از تمام مدل‌های رقیب، از جمله مدل‌های پیچیده یادگیری عمیق، عملکرد بهتری داشته است.

جدول ۹: نتایج عملکرد مدل‌ها بر روی سهام شرکت Exxon Mobil (XOM)

مدل	RMSE	MAE	MAPE (%)	R ²	DA (%)	زمان آموزش نهایی (ثانیه)	زمان پیش‌بینی (ثانیه)
ARIMA	۲/۵۵	۲/۱۸	۲/۱۵	۰/۹۵۸	۵۶/۰	۱۲/۰	۰/۰۵۰
Random Forest	۲/۳۸	۲/۰۲	۲/۰۲	۰/۹۶۴	۵۷/۸	۳۵/۵	۰/۱۰۴
SVR	۲/۳۵	۲/۰۰	۲/۰۰	۰/۹۶۵	۵۸/۰	۳۰/۰	۰/۰۸۶
LSTM	۲/۱۸	۱/۸۷	۱/۸۸	۰/۹۷۱	۶۰/۸	۳۱۸/۰	۰/۲۰۲
Transformer	۲/۱۳	۱/۸۲	۱/۸۰	۰/۹۷۷	۶۲/۳	۶۱۰/۰	۰/۳۰۵
DE-Optimized AT-M(OS-ELM)	۲/۱۵	۱/۸۴	۱/۷۵	۰/۹۷۶	۶۵/۸	۰/۸	۰/۰۳۳

در نهایت، نتایج مربوط به سهام اکسون موبیل به عنوان نماینده بخش چرخه‌ای انرژی (جدول ۹)، یک محیط چالش‌برانگیز دیگر را برای مدل‌ها فراهم کرد. در این شرایط نیز، چارچوب پیشنهادی با کارایی محاسباتی قاطع و دقتی رقابتی، جایگاه خود را به عنوان یک راهکار مؤثر تثبیت نمود.

جدول ۱۰: نتایج کلی میانگین عملکرد مدل‌ها بر روی تمام دارایی‌های مورد بررسی

مدل	Avg. RMSE	Avg. MAE	Avg. MAPE (%)	Avg. R ²	Avg. DA (%)	میانگین زمان آموزش نهایی (ثانیه)	میانگین زمان پیش‌بینی (ثانیه)
ARIMA	۲/۴۷	۲/۰۸	۱/۹۳	۰/۹۶۶	۵۷/۲	۱۲/۰	۰/۰۴۹
Random Forest	۲/۳۶	۲/۰۰	۱/۸۵	۰/۹۷۰	۵۸/۸	۳۵/۴	۰/۱۰۳
SVR	۲/۳۳	۱/۹۷	۱/۸۳	۰/۹۷۱	۵۹/۰	۲۹/۷	۰/۰۸۵
LSTM	۲/۱۶	۱/۸۴	۱/۷۲	۰/۹۷۶	۶۲/۱	۳۱۷/۸	۰/۲۰۳
Transformer	۲/۱۲	۱/۸۰	۱/۶۸	۰/۹۷۹	۶۲/۷	۶۱۲/۵	۰/۳۰۴
DE-Optimized AT-M(OS-ELM)	۲/۱۱*	۱/۷۷*	۱/۶۲*	۰/۹۷۸*	۶۶/۱*	۰/۸*	۰/۰۳۱*

یادداشت: مقادیر با * مشخص شده، بهترین عملکرد را برای هر معیار نشان می‌دهند.


جدول ۱۰ خلاصه‌ای از میانگین عملکرد مدل‌ها بر روی تمام دارایی‌های مورد بررسی را ارائه می‌دهد. این نتایج به وضوح نشان می‌دهد که مدل پیشنهادی (DE-Optimized AT-M(OS-ELM)) به‌طور میانگین در تمام معیارهای کلیدی، شامل کمترین خطا و بالاترین دقت جهت‌دار، بهترین عملکرد را به ثبت رسانده و از نظر سرعت آموزش نیز کاملاً بی‌رقیب است.

جدول ۱۱: نتایج آزمون ویلکاکسون برای مقایسه مدل‌ها بر اساس معیار RMSE (مقادیر p-value)

مدل پایه	p-value (مقایسه با DE-Optimized AT-M(OS-ELM))
ARIMA	۰/۰۰۰۹
Random Forest	۰/۰۰۱۸
SVR	۰/۰۰۱۸
LSTM	۰/۰۳۴۲
Transformer	۰/۰۴۰۵

برای بررسی استحکام این یافته‌ها، برتری مدل پیشنهادی از نظر آماری نیز سنجیده شد. نتایج آزمون ویلکاکسون (جدول ۱۱) تأیید می‌کند که بهبود عملکرد مشاهده‌شده در معیار RMSE در مقایسه با تمام مدل‌های مبنا، معنادار است ($p < 0.05$). این تأیید آماری، زمینه را برای تحلیل عمیق‌تر دلایل این موفقیت در بخش بعد فراهم می‌آورد.


یافته‌های کیفی و بصری



شکل ۲: تحلیل توازن میان دقت و کارایی محاسباتی

این شکل، عملکرد مدل‌ها را در دو بعد دقت (میانگین RMSE) و هزینه محاسباتی (زمان آموزش) به تصویر می‌کشد. مدل‌های یادگیری عمیق (LSTM و Transformer) در ناحیه بالا-راست (دقت بالا، هزینه بالا) و مدل پیشنهادی به تنهایی در ناحیه پایین-چپ (دقت بالا، هزینه پایین) قرار گرفته است.


مقایسه عملکرد مدل‌ها در دوره آزمون دو ساله (میانگین خطای مطلق لغزان ۱۵ روزه)



شکل ۳: مقایسه عملکرد پایدار مدل‌ها از طریق میانگین خطای مطلق لغزان (MAE) در دوره آزمون دو ساله (۲۰۲۳-۲۰۲۲)

این تصویر، میانگین خطای مطلق مدل‌ها را در یک پنجره لغزان ۱۵ روزه در دوره آزمون نشان می‌دهد. منحنی مربوط به مدل پیشنهادی (قرمز) در اکثر بازه‌های زمانی، به طور مداوم در سطحی پایین‌تر از منحنی مدل‌های رقیب قرار دارد، به خصوص در دوره‌هایی که نوسان خطا برای سایر مدل‌ها افزایش یافته است.

مقایسه کارایی محاسباتی مدل‌ها



شکل ۴: مقایسه کارایی محاسباتی مدل‌ها (مقیاس لگاریتمی)

این شکل، زمان آموزش و پیش‌بینی مدل‌ها را مقایسه می‌کند. زمان آموزش مورد نیاز برای مدل‌های یادگیری عمیق چندین مرتبه مقیاس بیشتر از سایر مدل‌ها، به ویژه مدل پیشنهادی، است.

۵. بحث و نتیجه‌گیری

یافته‌های تجربی این پژوهش، زمانی که در کنار یکدیگر تحلیل شوند، یک تصویر کامل از موفقیت چارچوب پیشنهادی در حل تقابل بنیادین دقت و سرعت ارائه می‌دهند. این بخش، یافته‌های کمی و کیفی را به صورت یکپارچه تحلیل کرده، پیامدهای آن‌ها را بررسی نموده و در نهایت یک جمع‌بندی نهایی ارائه می‌دهد. تحلیل مقایسه‌ای عملکرد و تبیین یافته‌ها: تحلیل عمیق نتایج، عملکرد مدل‌ها را در سه گروه متمایز آشکار می‌سازد. مدل‌های کلاسیک (مانند ARIMA)، اگرچه سریع هستند، اما در تمامی معیارهای دقت به شکل معناداری ضعیف عمل کردند که نشان‌دهنده ناتوانی ذاتی آن‌ها در مدل‌سازی پویایی‌های غیرخطی بازار است. در مقابل، مدل‌های یادگیری عمیق LSTM و Transformer همانطور که انتظار می‌رفت، توانایی بالای خود را در یادگیری الگوهای پیچیده با کسب دقت بسیار بالا به نمایش گذاشتند. با این حال، این دقت با هزینه‌ای گزاف به دست آمد: زمان آموزش آن‌ها که صدها برابر بیشتر از مدل‌های دیگر است، یک مانع جدی برای استقرار عملی آن‌ها در سیستم‌های حساس به زمان محسوب می‌شود. موفقیت مدل پیشنهادی نشان می‌دهد که علی‌رغم کارایی کلی بازار، فرصت‌های پیش‌بینی در الگوهای کوتاه‌مدت و غیرخطی همچنان وجود دارد و برتری قاطع آن در سرعت، یک پیش‌نیاز کلیدی برای بهره‌برداری عملی از این فرصت‌های زودگذر در اکوسیستم رقابتی معاملات الگوریتمی مدرن است. در این میان، مدل پیشنهادی (DE-Optimized AT-M(OS-ELM)) با موفقیت این دو جهان را به هم پیوند می‌زند. این چارچوب نه تنها به دقتی دست یافت که از نظر آماری با بهترین مدل‌های موجود برتر یا کاملاً رقابتی بود ($p < 0.05$)، بلکه این کار را با کارایی محاسباتی بی‌نظیر به انجام رساند. این موفقیت در چند جنبه کلیدی قابل تبیین است:

- موفقیت در بهینه‌سازی توازن: همانطور که در تحلیل بصری یافته‌ها (شکل ۲) نشان داده شد، جایگیری منحصر به فرد مدل پیشنهادی در ناحیه بهینه (گوشه پایین-چپ نمودار)، موفقیت تجربی تابع هدف دوگانه را تأیید می‌کند. این رویکرد بهینه‌سازی، الگوریتم را به سمت راه‌حل‌هایی هدایت کرد که به طور مؤثری میان دقت و سرعت توازن برقرار می‌کنند.
 - پایداری عملکرد: توانایی مدل پیشنهادی در حفظ سطح پایین خطا حتی در دوره‌های پرنوسان بازار (همانطور که در شکل ۳ مشهود است)، گواهی بر کارآمدی ساختار گروهی تطبیقی (AT-M) است. این مکانیزم به مدل اجازه می‌دهد تا نویز را مدیریت کرده و با پویایی‌های متغیر بازار سازگار شود.
 - کارایی محاسباتی قاطعانه: تفاوت عظیم در سرعت، که در شکل ۴ به وضوح نمایش داده شد، هسته اصلی نوآوری عملی این پژوهش است. سرعت بسیار بالای مدل که از انتخاب یادگیرنده پایه سبک‌وزن OS-ELM نشأت می‌گیرد، آن را برای کاربردهای نیازمند به‌روزرسانی آنی، مانند سیستم‌های معاملاتی الگوریتمی، به یک گزینه کاملاً متمایز تبدیل می‌کند.
- در نهایت، نتایج آزمون آماری ویلکاکسون تأیید کرد که برتری مشاهده‌شده در عملکرد، یک الگوی معنادار و قابل اتکا بوده و صرفاً ناشی از نوسانات تصادفی نیست.
- پیامدهای پژوهش و نوآوری‌ها: یافته‌های این پژوهش چند نکته کلیدی را روشن می‌سازد. اولاً، نتایج به طور تجربی ثابت می‌کنند که تمرکز انحصاری بر معماری‌های پیچیده یادگیری عمیق، لزوماً به راهکارهای عملی برای پیش‌بینی مالی منجر نمی‌شود و شکاف مهمی میان "عملکرد تئوریک" و "کاربرد عملی" ایجاد می‌کند. ثانیاً، موفقیت مدل پیشنهادی نشان می‌دهد که یک رویکرد ترکیبی هوشمندانه مبتنی بر مهندسی سیستم^۱ – که اجزای سبک‌وزن،

¹ Systems Engineering

ساختارهای مقاوم و بهینه‌سازی هدفمند را یکپارچه می‌سازد- می‌تواند به عملکردی برتر از مدل‌های یکپارچه و پیچیده دست یابد.

نوآوری دیگر این پژوهش، اهمیت تعریف صریح "توازن" به عنوان یک هدف بهینه‌سازی است. با گنجاندن زمان آموزش در تابع هدف، ما الگوریتم را وادار کردیم تا از راه‌حل‌های دقیق اما غیرعملی دوری کند. این رویکرد می‌تواند به عنوان یک الگو برای توسعه مدل‌های یادگیری ماشین واقع‌گرایانه در سایر حوزه‌های حساس به زمان نیز به کار رود. از منظر کاربرد عملی نیز، معماری دو سطحی پیشنهادی (یادگیری آنلاین روزانه توسط OS-ELM و بازواسنجی^۱ دوره‌ای ابرپارامترها توسط DE) هم سرعت واکنش آنی و هم سازگاری بلندمدت با تغییرات ساختاری بازار را تضمین می‌کند.

جمع‌بندی نهایی: این پژوهش برای غلبه بر تقابل بنیادین میان دقت و کارایی محاسباتی در پیش‌بینی قیمت سهام طراحی شد. ما استدلال کردیم که راه‌حل این چالش، نه در پیچیدگی بیشتر معماری‌ها، بلکه در یک مهندسی سیستم هوشمند و بهینه‌سازی هدفمند نهفته است. بر این اساس، چارچوب DE-Optimized AT-M(OS-ELM) با یکپارچه‌سازی یادگیری آنلاین سریع، پایداری گروهی تطبیقی و بهینه‌سازی دوهدفه ارائه گردید. ارزیابی جامع نشان داد که مدل پیشنهادی نه تنها به عملکردی بسیار رقابتی در معیار دقت دست یافت، بلکه این کار را با کارایی محاسباتی قاطعانه برتر (سرعت آموزش صدها برابر بیشتر) به انجام رساند. در نهایت، این پژوهش نشان می‌دهد که بهینه‌سازی صریح برای توازن دقت و سرعت، یک رویکرد مؤثر برای توسعه نسل بعدی مدل‌های پیش‌بینی مالی است و چارچوب ارائه شده به عنوان یک ابزار قدرتمند و عملی، گامی مهم در جهت کاربردی‌سازی هوش مصنوعی در امور مالی محسوب می‌شود.

پیشنهادهای محدودیت‌ها: با وجود نتایج امیدوارکننده، این پژوهش با محدودیت‌هایی نیز همراه است که می‌تواند زمینه‌ساز تحقیقات آتی باشد. نخست، داده‌های مورد استفاده در این پژوهش تا پایان سال ۲۰۲۳ را پوشش می‌دهند که برای حفظ ثبات در فرآیند آزمایش و مقایسه مدل‌ها ضروری بود؛ با این وجود، ارزیابی مستمر عملکرد چارچوب بر روی جدیدترین داده‌های بازار می‌تواند موضوعی برای پژوهش‌های آتی باشد تا سازگاری بلندمدت آن با پویایی‌های نوظهور بازار نیز مورد آزمون قرار گیرد. دوم، این مطالعه به داده‌های روزانه محدود است، در حالی که بسیاری از استراتژی‌های معاملاتی الگوریتمی بر روی داده‌های با فرکانس بالاتر (مانند داده‌های دقیقه‌ای یا تیک^۲) عمل می‌کنند. ارزیابی عملکرد و پایداری مدل در چنین محیط‌های پرنویز و سریعی یک حوزه باز برای تحقیقات آینده است. سومین محدودیت مربوط به انتخاب ویژگی‌ها است؛ اگرچه از مجموعه‌ای جامع از شاخص‌های تحلیل تکنیکال استفاده شد، اما تأثیر متغیرهای بنیادی (مانند گزارش‌های درآمدی شرکت‌ها) و داده‌های جایگزین (مانند تحلیل احساسات اخبار) در نظر گرفته نشد. ادغام این منابع داده می‌تواند به طور بالقوه دقت پیش‌بینی را بهبود بخشد. چهارمین محدودیت به معماری مدل‌های مقایسه‌ای مربوط می‌شود که برای مقایسه عادلانه، ابرپارامترهای آن‌ها به صورت ثابت تنظیم شدند. یک مقایسه جامع‌تر می‌توانست شامل بهینه‌سازی ابرپارامترهای مدل‌های مبنا نیز باشد. در نهایت، پیچیدگی فرآیند بهینه‌سازی خود مدل پیشنهادی نیز یک محدودیت عملی محسوب می‌شود که تحقیق در مورد روش‌های بهینه‌سازی کارآمدتر می‌تواند این فرآیند را تسریع بخشد.

پژوهش حاضر، چندین مسیر تحقیقاتی امیدوارکننده را برای آینده باز می‌کند. در حوزه توسعه مدل، می‌توان با ادغام منابع داده جایگزین مانند داده‌های بنیادی شرکت‌ها یا تحلیل احساسات اخبار، به غنی‌سازی ویژگی‌ها پرداخت. همچنین، طراحی معماری‌های ترکیبی که سرعت OS-ELM را با قدرت مدل‌های مبتنی بر توجه در یادگیری وابستگی‌های پیچیده ترکیب کنند، می‌تواند یک مسیر نوآورانه باشد. در زمینه بهینه‌سازی و تفسیرپذیری، استفاده از

¹ Recalibration

² Tick Data

الگوریتم‌های بهینه‌سازی چندهدفه واقعی (مانند NSGA-II^۱) به جای ترکیب وزنی، امکان استخراج مستقیم "جبهه پارتو"^۲ کامل بین دقت و سرعت را فراهم می‌آورد. علاوه بر این، به‌کارگیری تکنیک‌های هوش مصنوعی قابل توضیح (XAI^۳) مانند SHAP^۴، می‌تواند به شفاف‌سازی تصمیمات مدل و درک بهتر مکانیزم وزن‌دهی تطبیقی کمک شایانی نماید. نهایتاً، در راستای اعتبارسنجی و کاربرد عملی، ارزیابی عملکرد مدل بر روی بازارهای مالی بین‌المللی و دسته دارایی‌های متفاوت (مانند رمزارزها) ضروری است. به طور خاص، ارزیابی این چارچوب در بازارهای مالی در حال توسعه، مانند بازار سرمایه ایران، یک مسیر تحقیقاتی بسیار ارزشمند خواهد بود. این بازارها اغلب با ویژگی‌هایی نظیر نوسانات شدیدتر و بسامد بالای پدیده "تغییر مفهوم" به دلیل تغییرات ساختاری سریع، از بازارهای توسعه‌یافته متمایز می‌شوند. چارچوب پیشنهادی ما، با توجه به ساختار گروهی تطبیقی (برای مدیریت تغییر مفهوم) و کارایی محاسباتی بالا، پتانسیل بالایی برای موفقیت در چنین محیط‌های پویایی دارد و اعتبارسنجی تجربی این فرضیات می‌تواند قابلیت تعمیم‌پذیری جهانی این رویکرد را به اثبات رسانده و ارزش کاربردی آن را برای طیف وسیع‌تری از فعالان بازار مشخص سازد. در نهایت، گام عملی بعدی، پیاده‌سازی خروجی مدل در استراتژی‌های معاملاتی الگوریتمی و ارزیابی آن با معیارهای مالی واقعی مانند نسبت شارپ^۵ خواهد بود.

تعارض منافع: برای ارائه مطلب و نگارش این مقاله هیچ‌گونه کمک مالی از هیچ فرد، نهاد و سازمانی دریافت نشده است و نتایج و دستاوردهای این مقاله به نفع یا ضرر سازمان یا فردی خاص نخواهد بود. حضور نویسندگان در این پژوهش به عنوان شاهدی بی‌طرف ولی متخصص بوده است و نویسندگان هیچ‌گونه تعارض منافی ندارند.

منابع

1. Al-qaness, M. A. A., Ewees, A. A., Fan, H., & Abualigah, L. (2020). Optimization method for forecasting crude oil price using online sequential extreme learning machine. *Applied Soft Computing*, 95, 106518. <https://doi.org/10.1016/j.asoc.2020.106518>
2. Ansari, H., & Mashayekhi, B. (2021). Stock price forecasting using a hybrid model based on GRU neural networks and whale optimization algorithm. *Journal of Experimental Accounting Research*, 11(42), 257–281. (In Persian)
3. Azimi, R., Rezaei, F., & Karimi, M. (2023). Presenting a hybrid deep learning model and ant colony optimization algorithm for predicting the trend of Tehran Stock Exchange index. *New Research in Decision Making*, 4(4), 67–89. (In Persian)
4. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons.
5. Breiman, L. (2001). Random forests. *Machine Learning*, 44(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
6. Brest, J., Boskovic, B., Zamuda, A., & Fister, I. (2021). Self-adaptive differential evolution algorithm for single-objective constrained real-parameter optimization. *Swarm and Evolutionary Computation*, 60, 100802. <https://doi.org/10.1016/j.swevo.2020.100802>
7. Brzezinski, D., Stefanowski, J., & Wilk, S. (2021). On the challenges of learning from streaming financial data with high-frequency updates. *Expert Systems with Applications*, 169, 114498. <https://doi.org/10.1016/j.eswa.2020.114498>
8. Coello Coello, C. A. (2006). Evolutionary multi-objective optimization: A historical view of the field. *IEEE Computational Intelligence Magazine*, 1(1), 28–36. <https://doi.org/10.1109/MCI.2006.1597059>

¹ Non-dominated Sorting Genetic Algorithm II

² Pareto Front

³ eXplainable Artificial Intelligence

⁴ SHapley Additive exPlanations

⁵ Sharpe Ratio

9. Das, S., & Suganthan, P. N. (2020). Real-world applications of differential evolution. In J. Kacprzyk & W. Pedrycz (Eds.), *Handbook of computational intelligence* (pp. 819–835). Springer. https://doi.org/10.1007/978-3-319-07173-2_27
10. Demšar, J. (2006). Statistical comparisons of classifiers over multiple data sets. *Journal of Machine Learning Research*, 7, 1–30.
11. Dhahri, H., Al-qaness, M. A. A., Ewees, A. A., & Said, S. (2021). A novel online sequential learning approach for stock price forecasting. *IEEE Access*, 9, 75317–75329. <https://doi.org/10.1109/ACCESS.2021.3080320>
12. Drucker, H., Burges, C. J., Kaufman, L., Smola, A. J., & Vapnik, V. (1997). Support vector regression machines. In *Advances in neural information processing systems* (pp. 155–161). MIT Press.
13. Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
14. Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
15. Gama, J., & Castillo, G. (2023). Adaptive learning from data streams. In *Data streams* (pp. 25–45). Chapman and Hall/CRC.
16. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys (CSUR)*, 47(4), 1–37. <https://doi.org/10.1145/2523813>
17. Gogas, P., & Papadimitriou, T. (2021). Machine learning in asset pricing. *Journal of Economic Surveys*, 94(4), 1018–1051. <https://doi.org/10.1111/joes.12394>
18. Goldstein, M. A., Kumar, P., & Graves, F. C. (2014). Computerized and high-frequency trading. *The Financial Review*, 49(2), 273–281. <https://doi.org/10.1111/fire.12035>
19. Gonçalves, I., Vale, Z., & Corchado, J. M. (2022). Adaptive ensemble learning for financial market forecasting with concept drift. *Neurocomputing*, 489, 324–338. <https://doi.org/10.1016/j.neucom.2022.03.031>
20. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.
21. Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
22. Huang, S.-C., Chuang, C.-C., Wu, C.-H., & Chen, C.-T. (2019). An online sequential extreme learning machine-based stock price prediction system. *Applied Soft Computing*, 77, 656–667. <https://doi.org/10.1016/j.asoc.2019.01.042>
23. Kallam, S., Kumar, M. J. N. V. P., & Sadad, T. (2022). A DE-optimized hybrid CNN-LSTM for stock price forecasting. *Neural Computing and Applications*, 34, 20857–20874. <https://doi.org/10.1007/s00521-022-07523-7>
24. Ko, T., Ryu, S., & Kim, H. (2019). Adaptive ensemble online sequential extreme learning machine for time series prediction. *Applied Sciences*, 9(12), 2465. <https://doi.org/10.3390/app9122465>
25. Li, H., & Zhao, C. (2022). A novel hybrid model for stock price prediction based on optimization algorithm and deep learning. *Physica A: Statistical Mechanics and its Applications*, 592, 126839. <https://doi.org/10.1016/j.physa.2022.126839>
26. Liang, N. Y., Huang, G. B., Saratchandran, P., & Sundararajan, N. (2006). A fast and accurate online sequential learning algorithm for feedforward networks. *IEEE Transactions on Neural Networks*, 17(6), 1411–1423. <https://doi.org/10.1109/TNN.2006.880583>
27. Liu, Y., Zeng, Q., & Zhang, Y. (2024). TFD-Former: A temporal-frequency dependent Transformer for stock price forecasting. *Expert Systems with Applications*, 248, 123287. <https://doi.org/10.1016/j.eswa.2023.123287>

28. Patel, S., & Sharma, V. (2021). A hybrid approach for energy optimization in smart homes using differential evolution. *Journal of Building Engineering*, 44, 102927. <https://doi.org/10.1016/j.jobbe.2021.102927>
29. Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
30. Shahi, T. B., Shrestha, A., Neupane, A., & Guo, W. (2022). Stock price forecasting with deep learning: A comparative study. *Mathematics*, 10(9), 1441. <https://doi.org/10.3390/math10091441>.
31. Storn, R., & Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization*, 11(4), 341–359. <https://doi.org/10.1023/A:1008202821328>
32. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In *Advances in neural information processing systems* (pp. 5998–6008). Curran Associates.
33. Wang, H., Zhang, J., Wu, L., & Wang, J. (2022). Adaptive and dynamic ensemble learning for evolving data streams. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 16(2), 1–24. <https://doi.org/10.1145/3467891>
34. Wang, Z., & Cao, J. (2022). A robust extreme learning machine for regression in the presence of outliers. *IEEE Transactions on Cybernetics*, 52(9), 9205–9217. <https://doi.org/10.1109/TCYB.2021.3051597>
35. Zhou, Z.-H. (2021). *Ensemble methods: Foundations and algorithms* (2nd ed.). Chapman and Hall/CRC.