Fin. Manag. Persp. 2026, 16(3), 9-27; DOI: 10.48308/jfmp.2026.245240.1616

Financial Management Perspective
Journal homepage: https://jfmp.sbu.ac.ir/

Original Article

Two-Stage Integration of Fundamental and Trading Data for Short-Term Stock Return Prediction Using Residual Learning

Mohsen Kheiroddin*
Shapour Mohammadi**
Reza Raei***

Abstract

Introduction: Fundamental and trading data provide different perspectives on stock return predictability, and their combined predictive value may depend on the forecasting horizon and how the information is integrated. Accounting information is generally updated quarterly or annually, whereas trading data capture daily market developments. Valuation ratios involving market capitalization can also change daily. This study evaluates a two-stage residual learning framework for cross-sectional stock return prediction over horizons of 1, 3, 5, 10, and 15 trading days. Its performance is compared with fundamental-only, trading-only, and direct feature-combination models to examine whether sequential integration improves ranking quality and return separation.

Methods: The study examines manufacturing companies listed on the Tehran Stock Exchange. Financial statement information was obtained from Codal, and daily price and trading data were collected from TSETMC. Fundamental features included trailing-twelve-month earnings-to-market-capitalization and sales-to-market-capitalization ratios, quarterly earnings and sales growth, and changes in gross, operating, and net profit margins. These financial features were transformed into daily cross-sectional percentile ranks across the sample and within industries. Accounting information was incorporated from the day after its official publication. Trading features captured candlestick characteristics, historical returns, and measures related to risk and market movements.

All four designs used XGBoost regression and were evaluated through two successive rolling test windows. Training and validation observations whose target-return intervals crossed the respective period boundaries were excluded. In the two-stage

Received:14, July,2026 . Accepted: 8, November,2026

*PhD Student, Management Department, Tehran University, Tehran, Iran. (Corresponding Author).
E-mail: m.kheirodin@gmail.ir
** Professor, Management Department, Tehran University, Tehran, Iran.
*** Professor, Management Department, Tehran University, Tehran, Iran.

framework, the first model predicted returns using fundamental features, and the second used trading features to learn residuals calculated from the first model's predictions on the same training observations. Target returns were measured from the adjusted closing price on the prediction date to the adjusted opening price at the forecast horizon. Performance was evaluated using the mean daily Spearman Rank Information Coefficient (Rank IC) and the return spread between the highest- and lowest-scoring deciles, with common evaluation filters applied across models.
The sample comprised 274 manufacturing firms listed on the Tehran Stock Exchange and approximately 400,000 firm-day observations from January 2017 to June 2026. Approximately 70,000 observations were used in two consecutive test windows, July 2024–June 2025 and July 2025–June 2026, with the remaining observations used for training and validation.
Findings: The two-stage model achieved the highest mean Rank IC at all five forecasting horizons, with values of 0.32987, 0.04453, 0.03668, 0.05328, and 0.04400 at 1, 3, 5, 10, and 15 days, respectively. At the 1-day horizon, its performance was close to that of the trading-only and direct-combination models, which recorded IC values of 0.32856 and 0.32875. The advantage was more pronounced at 3 days: the two-stage model achieved an IC of 0.04453 and a spread of 0.483%, compared with 0.03103 and 0.332% for the trading-only model and 0.02252 and 0.153% for direct combination.The two-stage model also recorded the largest decile spreads at the 1-, 3-, and 15-day horizons, at 1.847%, 0.483%, and 1.83%, respectively. Direct combination produced higher spreads at 5 and 10 days, while the two-stage model retained the highest mean IC. Across all five horizons, the two-stage model's spread exceeded that of the trading-only model. The fundamental-only model's IC increased from 0.00247 at 1 day to 0.04211 at 15 days, indicating greater standalone predictive value at the longer horizons examined.
Conclusions: The two-stage residual learning framework achieved the highest mean Rank IC across all five forecasting horizons and the largest decile spread at the 1-, 3-, and 15-day horizons. Its spread also exceeded that of the trading-only model at every horizon. These findings support the value of sequentially integrating fundamental and trading information to improve cross-sectional stock ranking. Direct combination produced the largest spreads at 5 and 10 days, indicating that the preferred integration method also depends on the forecasting horizon and evaluation objective

Keywords: Stock Return Prediction; Fundamental Data; Trading Data; Residual Learning; Two-Stage Integration; XGBoost; Cross-Sectional Ranking.

How to Cite Kheiroddin, M.* , Mohammadi, S. M. , and Raei, R. (2026). Two-Stage Integration of Fundamental and Trading Data for Short-Term Stock Return Prediction Using Residual Learning. *Financial Management Perspective*,16(3),9-27.(in persian) doi: 10.48308/jfmp.2026.245240.1616

Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (*https://creativecommons.org/licenses/by/4.0/*)

چشم انداز مدیریت مالی ۱۴۰۵ دوره ۱۶ شماره ۳، صص ۹ –۲۷، DOI: 10.48308/jfmp.2026.245240.1616



چشم انداز مدیریت مالی
Journal homepage: https://jfmp.sbu.ac.ir/

نوع مقاله: پژوهشی

ترکیب دومرحله‌ای داده‌های بنیادین و معاملاتی برای پیش‌بینی کوتاه‌مدت بازده سهام با استفاده از یادگیری باقیمانده‌ها

محسن خیرالدین *
شاپور محمدی
رضا راعی

چکیده

هدف: اطلاعات بنیادین و معاملاتی، جنبه‌های متفاوتی از قابلیت پیش‌بینی بازده سهام را منعکس می‌کنند و ارزش استفاده مشترک از آن‌ها می‌تواند به افق پیش‌بینی و نحوه ترکیب اطلاعات وابسته باشد. اقلام حسابداری معمولاً با بسامد فصلی منتشر می‌شوند، درحالی‌که داده‌های معاملاتی، تحولات روزانه بازار را بازتاب می‌دهند؛ البته نسبت‌های بنیادین مبتنی بر ارزش بازار نیز قابلیت تغییر روزانه دارند. هدف این پژوهش، ارزیابی یک چارچوب دومرحله‌ای مبتنی بر یادگیری باقیمانده‌ها برای پیش‌بینی مقطعی بازده سهام در افق‌های یک، سه، پنج، ده و پانزده روز معاملاتی و مقایسه آن با رویکردهای صرفاً بنیادین، صرفاً معاملاتی و ترکیب مستقیم ویژگی‌هاست.

روش: پژوهش بر شرکت‌های تولیدی پذیرفته‌شده در بورس اوراق بهادار تهران متمرکز است. اطلاعات صورت‌های مالی از سامانه کدال و داده‌های قیمتی و معاملاتی از پایگاه مدیریت فناوری بورس تهران گردآوری شدند. ویژگی‌های بنیادین شامل نسبت سود خالص و فروش دوازده‌ماهه اخیر به ارزش بازار، رشد فصلی سود خالص و فروش و تغییرات حاشیه سود ناخالص، عملیاتی و خالص بودند که به رتبه صدکی در سطح کل نمونه و درون صنعت تبدیل شدند. زمان دسترسی به اطلاعات مالی بر اساس انتشار رسمی گزارش‌ها لحاظ شد. ویژگی‌های معاملاتی نیز وضعیت کندل، بازده‌های تاریخی و سنجه‌های مرتبط با ریسک و حرکت بازار را پوشش دادند. چهار طراحی مبتنی بر رگرسیون XGBoost در یک طرح ارزیابی زمانی غلتان با دو پنجره آزمون متوالی مقایسه شدند. در هر پنجره، مدل‌ها با داده‌های آموزش برازش و ابرپارامترها با استفاده از دوره اعتبارسنجی انتخاب شدند. مشاهداتی که بازده هدف آن‌ها از مرز آموزش یا اعتبارسنجی عبور می‌کرد، از مجموعه مربوط حذف شدند. در چارچوب دومرحله‌ای، مدل نخست با ویژگی‌های بنیادین بازده را پیش‌بینی کرد و مدل دوم با ویژگی‌های معاملاتی، باقیمانده

تاریخ دریافت: ۱۴۰۵/۰۴/۲۳ تاریخ پذیرش:۱۴۰۵/۰۸/۱۷

* دانشجو دکتری مدیریت مالی، دانشگاه تهران، تهران، ایران. (نویسنده مسئول). E-Mail: m.kheirodin@gmail.com

** استاد، گروه مدیریت، دانشگاه تهران، تهران، ایران.

*** استاد، گروه مدیریت، دانشگاه تهران، تهران، ایران.

پیش‌بینی مرحله نخست را آموخت. بازده هدف از قیمت پایانی تعدیل‌شده روز مبنا تا قیمت آغازین تعدیل‌شده انتهای افق محاسبه شد. ارزیابی بر اساس میانگین روزانه ضریب اطلاعاتی رتبه‌ای و اسپرد بازدهی دهک‌های بالا و پایین، با اعمال قواعد پالایش مشترک، انجام گرفت.

نمونه پژوهش شامل ۲۷۴ شرکت تولیدی پذیرفته‌شده در بورس اوراق بهادار تهران و حدود ۴۰۰ هزار مشاهده شرکت—روز از دی ۱۳۹۵ تا تیر ۱۴۰۵ بود. حدود ۷۰ هزار مشاهده به دو پنجره آزمون متوالی، از تیر ۱۴۰۳ تا تیر ۱۴۰۴ و از تیر ۱۴۰۴ تا تیر ۱۴۰۵، اختصاص یافت و مشاهدات باقی‌مانده برای آموزش و اعتبارسنجی به کار رفتند.

یافته‌ها: مدل دو مرحله‌ای در هر پنج افق، بالاترین میانگین ضریب اطلاعاتی رتبه‌ای را ثبت کرد. مقادیر این معیار در افق‌های یک، سه، پنج، ده و پانزده‌روزه به‌ترتیب برابر با ۰٫۳۲۹۸۷، ۰٫۰۴۴۵۳، ۰٫۰۳۶۶۸، ۰٫۰۵۳۲۸ و ۰٫۰۴۴۰۰ بود. در افق یک‌روزه، عملکرد این مدل به مدل معاملاتی و ترکیب مستقیم نزدیک بود؛ اما در افق سه‌روزه، فاصله عملکرد بیشتر شد و ضریب اطلاعاتی آن از مقادیر ۰٫۰۳۱۰۳ و ۰٫۰۲۲۵۲ دو مدل مذکور فراتر رفت. مدل دومرحله‌ای همچنین در افق‌های یک، سه و پانزده‌روزه، با اسپردهای ۱٫۸۴۷، ۰٫۴۸۳ و ۱٫۸۳ درصد، بیشترین تفکیک بازده دهک‌ها را ایجاد کرد. در افق‌های پنج و ده‌روزه، ترکیب مستقیم اسپرد بالاتری داشت، درحالی‌که مدل دومرحله‌ای همچنان از نظر میانگین ضریب اطلاعاتی در رتبه نخست قرار گرفت. اسپرد مدل دومرحله‌ای در تمام افق‌ها از مدل صرفاً معاملاتی بیشتر بود. همچنین، افزایش ضریب اطلاعاتی مدل بنیادین از ۰٫۰۰۲۴۷ در افق یک‌روزه به ۰٫۰۴۲۱۱ در افق پانزده‌روزه، با افزایش ارزش پیش‌بینی مستقل اطلاعات بنیادین در افق‌های طولانی‌تر سازگار بود.

نتیجه‌گیری: نتایج نشان می‌دهند که نحوه سازمان‌دهی اطلاعات بنیادین و معاملاتی در فرایند یادگیری، در بهبود کیفیت رتبه‌بندی سهام اهمیت دارد. مدل دومرحله‌ای با ثبت بالاترین میانگین ضریب اطلاعاتی در تمامی افق‌ها، بیشترین اسپرد در سه افق و اسپرد بالاتر از مدل صرفاً معاملاتی در تمام افق‌ها، عملکرد قابل اعتنایی ارائه کرد. این یافته‌ها از کاربرد یادگیری باقیمانده‌ها برای ترکیب اطلاعات بنیادین و معاملاتی و توسعه مدل‌های پیش‌بینی مقطعی بازده سهام پشتیبانی می‌کنند.

کلیدواژه‌ها: پیش‌بینی بازده سهام؛ داده‌های بنیادین؛ داده‌های معاملاتی؛ یادگیری باقیمانده‌ها؛ ترکیب دو مرحله‌ای؛ ایکس‌جی‌بوست؛ رتبه‌بندی مقطعی.

استناددهی: خیرالدین, محسن , محمدی, شاپور و راعی, رضا . (۱۴۰۵). ترکیب دومرحله‌ای داده‌های بنیادین و معاملاتی برای پیش‌بینی کوتاه‌مدت بازده سهام با استفاده از یادگیری باقیمانده‌ها. *چشم‌انداز مدیریت مالی*،۱۶(۳)،۹-۲۷.

Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (*https://creativecommons.org/licenses/by/4.0/*)

۱. مقدمه

پیش‌بینی مقطعی بازده سهام و شناسایی پیشران‌های بازدهی، هسته اصلی تحقیقات حوزه مالی محاسباتی و مدیریت سبد دارایی فعال را تشکیل می‌دهد. برای دهه‌ها، مدل‌های عاملی کلاسیک مبنای تبیین صرف ریسک در بازارها بودند (Fama & French, 1993). بااین‌حال، وجود روابط غیرخطی، تعامل میان ویژگی‌ها و تعداد زیاد متغیرهای مالی، استفاده از روش‌های یادگیری ماشین را در کنار مدل‌های متعارف گسترش داده است؛ این روش‌ها امکان بررسی روابط انعطاف‌پذیرتری میان ویژگی‌ها و بازده سهام فراهم می‌کنند (Gu et al., 2020). یکی از ملاحظات ترکیب ویژگی‌های مالی، تفاوت در بسامد به‌روزرسانی آن‌هاست. پژوهش حاضر بر دو گروه اطلاعات بنیادین و معاملاتی تمرکز دارد. اقلام حسابداری، وضعیت مالی و عملکرد شرکت را توصیف می‌کنند و معمولاً به‌صورت فصلی یا سالانه منتشر می‌شوند، درحالی‌که داده‌های قیمتی و معاملاتی روزانه، تحولات بازار را منعکس می‌کنند. البته نسبت‌های بنیادینی که قیمت در محاسبه آن‌ها دخالت دارد، می‌توانند روزانه تغییر کنند (Gu et al., 2020). در افق‌های کوتاه‌مدت پیش‌بینی، پرسش اصلی آن است که اطلاعات بنیادی چه ارزش افزوده‌ای در کنار ویژگی‌های معاملاتی ایجاد می‌کنند و این ارزش چگونه به شیوه ترکیب اطلاعات وابسته است. ورود همزمان همه ویژگی‌ها امکان یادگیری مشترک روابط و تعاملات آن‌ها را فراهم می‌کند؛ در مقابل، معماری ترتیبی می‌تواند استفاده از هر گروه اطلاعات را در مرحله‌ای جداگانه سازمان دهد. شواهد مربوط به اهمیت بالاتر برخی ویژگی‌های تکنیکال در پیش‌بینی مالی، به‌تنهایی ناکارآمدی ترکیب مستقیم یا بی‌فایده‌بودن اطلاعات بنیادی را اثبات نمی‌کند (Gu et al., 2020; Raei et al., 2025). ازاین‌رو، پژوهش حاضر تفاوت عملکرد ترکیب مستقیم و ترکیب دومرحله‌ای مبتنی بر یادگیری باقیمانده‌ها را به‌عنوان یک پرسش تجربی بررسی می‌کند.

هدف این پژوهش، ارزیابی ترکیب دومرحله‌ای اطلاعات بنیادی و معاملاتی برای پیش‌بینی و رتبه‌بندی مقطعی بازده سهام در افق‌های ۱ تا ۱۵ روز معاملاتی است. در این چارچوب، مدل نخست صرفاً با استفاده از ویژگی‌های بنیادی، بازده آتی را تخمین می‌زند و مدل دوم با ویژگی‌های قیمتی، باقیمانده پیش‌بینی مدل نخست را یاد می‌گیرد. خروجی نهایی از جمع پیش‌بینی دو مدل حاصل می‌شود. برای بررسی ارزش اطلاعات هر گروه و نقش شیوه ترکیب آن‌ها، عملکرد این معماری با مدل‌های صرفاً بنیادی، صرفاً معاملاتی و ترکیب مستقیم مقایسه می‌شود. این مقایسه در شرکت‌های تولیدی بورس تهران و بر اساس ضریب اطلاعاتی رتبه‌ای و اختلاف بازده دهک‌های بالایی و پایینی انجام می‌شود.

۲. مبانی نظری و پیشینه پژوهش

پیش‌بینی مقطعی بازده سهام به بررسی تفاوت بازده آتی شرکت‌ها در یک افق زمانی مشترک می‌پردازد. برای تبیین جایگاه پژوهش حاضر، لازم است مبانی اقتصادی متغیرهای ورودی، شیوه مدل‌سازی روابط میان ویژگی‌ها و بازده، و نحوه ترکیب اطلاعات بررسی شود. ادبیات این حوزه نشان می‌دهد که انتخاب الگوریتم تنها یکی از اجزای مسئله است و تعریف متغیر هدف، بازنمایی اطلاعات و معیار ارزیابی نیز بر تفسیر نتایج اثر می‌گذارند.

مبانی اقتصادی اطلاعات بنیادین و معاملاتی؛ مدل‌های عاملی، چارچوبی برای ارتباط میان ریسک و بازده فراهم می‌کنند. فاما و فرنچ با معرفی عوامل مشترک در بازده سهام و اوراق بدهی، نقش اندازه شرکت و نسبت ارزش دفتری به ارزش بازار را در ساخت عوامل مرتبط با بازده بررسی کردند (Fama & French, 1993). در امتداد این ادبیات، کلی و همکاران ویژگی‌های شرکت را در مدلی از بارهای عاملی متغیر وارد کردند (Kelly et al., 2019). این مطالعات، مبنایی برای بررسی اطلاعات شرکتی فراهم می‌کنند؛ بااین‌حال، تبیین ساختار ریسک و بازده به‌تنهایی به معنای اثبات قدرت پیش‌بینی هر نسبت بنیادین در افق‌های روزانه نیست.

اطلاعات معاملاتی، جنبه دیگری از رفتار بازده را پوشش می‌دهند. جگادیش و تیتمن شواهد مومنتوم را در دوره‌های نگهداری سه تا دوازده‌ماهه گزارش کردند (Jegadeesh & Titman, 1993). آمیهود نیز ارتباط نقدشوندگی و بازده سهام را در ابعاد مقطعی و زمانی بررسی کرد (Amihud, 2002). از این مطالعات می‌توان ضرورت توجه به سابقه بازده و شرایط نقدشوندگی را استنباط کرد؛ اما انتقال نتایج آن‌ها به افق یک تا پانزده روز معاملاتی نیازمند ارزیابی مستقل است. بر این اساس، استفاده هم‌زمان از اطلاعات بنیادین و معاملاتی در پژوهش حاضر، با هدف آزمون ارزش پیش‌بینی مجموعه‌های اطلاعاتی متفاوت انجام می‌شود. تفکیک این دو گروه باید با توجه به ماهیت هر متغیر صورت گیرد. اقلام صورت‌های مالی معمولاً در فاصله‌های زمانی طولانی‌تر منتشر می‌شوند، اما نسبت‌هایی که قیمت در محاسبه آن‌ها دخالت دارد، مانند نسبت قیمت به سود، می‌توانند با تغییر قیمت روزانه تغییر کنند. بنابراین، قرارگرفتن یک متغیر در گروه بنیادین لزوماً به معنای ثابت‌بودن آن در طول فصل نیست. از نظر مفهومی نیز این دو گروه مستقل نیستند؛ زیرا قیمت می‌تواند بخشی از اطلاعات بنیادین و انتظارات درباره آینده شرکت را منعکس کند.

یادگیری ماشین و پیش‌بینی مقطعی بازده: روش‌های یادگیری ماشین امکان برآورد روابط انعطاف‌پذیر میان تعداد زیادی ویژگی و متغیر هدف را فراهم می‌کنند. بریمن، جنگل تصادفی را بر پایه تجمیع درخت‌های تصادفی معرفی کرد (Breiman, 2001) و فریدمن، تقویت گرادیانی را در چارچوب تقریب افزایشی تابع صورت‌بندی کرد (Friedman, 2001). چن و گسترین نیز الگوریتم XGBoost را با تابع هدف منظم‌سازی‌شده و سازوکارهای محاسباتی کارآمد توسعه دادند (Chen & Guestrin, 2016). این مبانی، استفاده از مدل‌های درختی را برای بررسی روابط غیرخطی توجیه می‌کنند، اما برتری آن‌ها بر مدل‌های ساده‌تر باید در داده و مسئله مورد مطالعه سنجیده شود.

در کاربردهای مالی، کراوس و همکاران شبکه‌های عصبی عمیق، درخت‌های تقویت‌شده و جنگل تصادفی را در مسئله آربیتراژ آماری سهام شاخص S&P ۵۰۰ بررسی کردند (Krauss et al., 2017). فیشر و کراوس نیز کاربرد شبکه حافظه بلندمدت کوتاه‌مدت را در پیش‌بینی بازار سهام مطالعه کردند (Fischer & Krauss, 2018). این دو پژوهش، به‌ترتیب بر مقایسه روش‌های یادگیری و مدل‌سازی وابستگی‌های زمانی تمرکز دارند. بنابراین، ارتباط آن‌ها با پژوهش حاضر در امکان استفاده از الگوهای معاملاتی برای پیش‌بینی است؛ از نتایج آن‌ها نمی‌توان به‌طور مستقیم درباره برتری یک روش خاص ترکیب اطلاعات بنیادین و قیمتی نتیجه گرفت.

گو و همکاران در بررسی گسترده پیش‌بینی بازده سهام، نشان دادند که مدل‌های غیرخطی می‌توانند از تعامل میان ویژگی‌های متعدد بهره بگیرند (Gu et al., 2020). فریبرگر و همکاران با رویکرد ناپارامتری و انتخاب متغیر نشان دادند که بسیاری از پیش‌بین‌های شناخته‌شده، در حضور سایر ویژگی‌ها اطلاعات افزوده‌ای ارائه نمی‌کنند (Freyberger et al., 2020). در مقابل، هان و همکاران با توسعه رگرسیون‌های فاما–مکبث، منظم‌سازی، انتخاب پیش‌بین و ترکیب پیش‌بینی‌ها، شواهدی از اهمیت مجموعه نسبتاً بزرگی از ویژگی‌ها ارائه کردند (Han et al., 2024). کنار هم قرارگرفتن این نتایج نشان می‌دهد که ارزش هر ویژگی به مجموعه اطلاعات و روش برآورد وابسته است و صرف افزایش تعداد ورودی‌ها، معیار کافی برای بهبود مدل نیست. بخشی از ادبیات، انعطاف مدل را با ساختار اقتصادی پیوند می‌دهد. گو و همکاران از خودرمزگذارها برای مدل‌سازی عاملی غیرخطی استفاده کردند (Gu et al., 2021). چن و همکاران قید نبود آربیتراژ را در برآورد مبتنی بر یادگیری عمیق وارد کردند (Chen et al., 2024). بریزگالووا و همکاران نیز درخت‌های تصمیم را برای تشکیل سبدهای مبتنی بر ویژگی‌ها و ساخت مقاطع بازده به کار گرفتند (Bryzgalova, Pelger, et al., 2025). گیگلیو و شیو، مسئله برآورد صرف ریسک در حضور عوامل حذف‌شده را بررسی کردند (Giglio & Xiu, 2021). این مطالعات اهمیت ساختار اقتصادی را روشن می‌کنند، ولی روش پژوهش

حاضر یک مدل پیش‌بینی بازده است و نباید با برآورد مدل ساختاری قیمت‌گذاری دارایی یا شناسایی علّی عوامل یکسان تلقی شود.

ترکیب اطلاعات و یادگیری دومرحله‌ای؛ ترکیب اطلاعات با بسامدهای متفاوت می‌تواند در سطح ورودی‌ها، بازنمایی‌های آموخته‌شده یا پیش‌بینی مدل‌ها انجام شود. بیانکی و همکاران در بازار اوراق بدهی نشان دادند که استفاده از اطلاعات اقتصاد کلان در کنار اطلاعات بازده تا سررسید می‌تواند ارزش پیش‌بینی ایجاد کند (Bianchi et al., 2021). لیپولد و یانگ در پژوهش خود، رگرسیون‌های پیش‌بینی با بسامد مختلط و یادگیری ترتیبی پارامترها را بررسی کردند و بر حفظ اطلاعات پربسامد، از جمله پویایی نوسان، تأکید داشتند (Leippold & Yang, 2023). این شواهد، اهمیت نحوه ترکیب اطلاعات را نشان می‌دهند؛ بااین‌حال، هیچ‌یک اثبات نمی‌کنند که ترکیب مستقیم متغیرهای بنیادین و معاملاتی در همه مدل‌ها موجب افت عملکرد می‌شود.

در ادبیات معماری‌های ترکیبی، کیم و کیم بازنمایی سری زمانی و تصویری یک مجموعه داده قیمتی را در مدل LSTM-CNN ادغام کردند (Kim & Kim, 2019). موضوع این مطالعه، ترکیب بازنمایی‌های متفاوت از داده مشترک بود. نوسدا و همکاران نیز در یک پیش‌چاپ، ترکیب ویژگی‌های بنیادین، تکنیکال و احساسات اخبار را برای پیش‌بینی جهت قیمت در روزهای اعلام سود بررسی کردند (Noseda et al., 2026). این مطالعات نشان می‌دهند که اطلاعات یا بازنمایی‌های متفاوت را می‌توان در معماری‌های مشترک به کار گرفت، اما ارزیابی آن‌ها با هدف و نمونه پژوهش حاضر تفاوت دارد. رویکرد دومرحله‌ای نیز تعریف یگانه‌ای ندارد. ژانگ و همکاران ابتدا مقادیر آتی شاخص‌های تکنیکال را با رگرسیون بردار پشتیبان پیش‌بینی کردند و سپس پیش‌بینی‌های مرحله اول را به یک مدل تجمیعی استنتاج عصبی‌فازی برای پیش‌بینی قیمت پایانی دادند (Zhang et al., 2021). بنابراین، شباهت این پژوهش با مطالعه حاضر در ترتیب مراحل یادگیری است؛ در روش آنان، متغیر هدف مرحله دوم باقیمانده یک مدل بنیادین نیست.

در پژوهش حاضر، مدل نخست با ویژگی‌های بنیادین، بازده همان افق مورد بررسی را پیش‌بینی می‌کند. سپس اختلاف بازده واقعی و پیش‌بینی مدل نخست، به‌عنوان متغیر هدف مدل دوم با ویژگی‌های قیمتی و معاملاتی استفاده می‌شود و جمع دو پیش‌بینی، خروجی نهایی را تشکیل می‌دهد. این ترتیب از نظر استفاده از خطای پیش‌بینی برای اصلاح مدل، با منطق عمومی یادگیری افزایشی ارتباط دارد (Friedman, 2001). بااین‌حال، تفکیک دو مجموعه ویژگی میان دو مدل مستقل، یک انتخاب مشخص در طراحی پژوهش حاضر است و با مراحل درونی تقویت گرادیانی در هر مدل یکسان نیست (Chen & Guestrin, 2016). همچنین، یادگیری باقیمانده‌ها به‌خودی‌خود متعامدبودن آماری دو خروجی یا حذف کامل اطلاعات بنیادین از خطا را تضمین نمی‌کند. ازاین‌رو، عنوان «ترکیب دومرحله‌ای مبتنی بر یادگیری باقیمانده‌ها» برای این روش به کار می‌رود.

بازنمایی ویژگی‌ها و ارزیابی پیش‌بینی: بازنمایی ویژگی‌ها بر نوع اطلاعات قابل استفاده مدل اثر می‌گذارد. گو و همکاران از تبدیل رتبه‌ای مقطعی ویژگی‌های شرکت استفاده کردند (Gu et al., 2020). در پژوهش حاضر نیز ویژگی‌های بنیادین به صدک رتبه، در سطح کل شرکت‌ها و درون صنعت، تبدیل می‌شوند. این تبدیل جایگاه نسبی شرکت را حفظ می‌کند، اما سطح مطلق ویژگی و فاصله عددی میان شرکت‌ها را نگه نمی‌دارد. بنابراین، تفسیر خروجی مدل بنیادین باید با توجه به همین بازنمایی نسبی انجام شود؛ رتبه‌بندی مقطعی را نمی‌توان معادل حفظ کامل پویایی تاریخی متغیر خام دانست.

انتخاب معیار ارزیابی نیز باید با هدف مدل سازگار باشد. پوه و همکاران مسئله تشکیل راهبردهای مقطعی را با روش‌های یادگیری رتبه‌بندی بررسی کردند (Poh et al., 2021) و هان و همکاران سنجه‌هایی برای ارزیابی پیش‌بینی مقطعی بازده ارائه دادند (Han et al., 2024). در مطالعه حاضر، مدل‌ها بازده را با رویکرد رگرسیونی تخمین می‌زنند

و رتبه پیش‌بینی‌ها در ارزیابی استفاده می‌شود؛ بنابراین، کاربرد سنجه رتبه‌ای به معنای آموزش مستقیم یک الگوریتم یادگیری رتبه‌بندی نیست.

تفسیر عملکرد مالی مستلزم توجه به ترکیب نمونه و محدودیت‌های بازار است. آوراموف و همکاران نشان دادند که حذف برخی گروه‌های سهام دشوارمعامله و لحاظ‌کردن هزینه‌ها می‌تواند سودآوری منتسب به سیگنال‌های یادگیری ماشین را کاهش دهد (Avramov et al., 2023). بریزگالووا و همکاران نیز نشان دادند که فقدان داده‌های مالی الگوهای نظام‌مند دارد و نحوه برخورد با آن بر تحلیل بازده و تشکیل سبد اثر می‌گذارد (Bryzgalova, Lerner, et al., 2025). در نتیجه، یافته‌های پیش‌بینی باید در ارتباط با قواعد نمونه‌گیری و شرایط ارزیابی تفسیر شوند و نباید بدون بررسی امکان اجرا، به سودآوری یک راهبرد قابل معامله تعمیم داده شوند.

پژوهش‌های داخلی و جایگاه پژوهش حاضر: در بورس اوراق بهادار تهران، غلامی و شمس قارنه مدل‌های ترکیبی LSTM-CNN و CNN-LSTM را با بهینه‌سازی ابرپارامترها برای پیش‌بینی قیمت سهام بررسی کردند. ورودی‌ها شامل اطلاعات قیمتی، شاخص‌های تکنیکال و برخی متغیرهای کلان بود و مدل LSTM-CNN در مقایسه‌های گزارش‌شده عملکرد مطلوب‌تری داشت (Gholami & Shams Gharne, 2024). تمرکز آن پژوهش بر پیش‌بینی قیمت و بهینه‌سازی معماری شبکه است؛ درحالی‌که مطالعه حاضر نحوه تخصیص دو گروه ویژگی به مراحل پیش‌بینی بازده مقطعی را بررسی می‌کند. راعی و همکاران با استفاده از جنگل تصادفی و ابزار توضیح‌پذیری SHAP، نقش ویژگی‌ها را در پیش‌بینی بازده شاخص صنایع تولیدی بررسی کردند (Raei et al., 2025). این مطالعه به استفاده و تفسیر هم‌زمان اطلاعات تکنیکال، بنیادین و کلان مربوط است، اما اهمیت کمتر یک ویژگی در مدل، به‌تنهایی نشان‌دهنده مضر بودن ورود آن نیست. قدس و همکاران نیز از تقویت گرادیانی طبیعی و SHAP برای پیش‌بینی و تفسیر شاخص کل بورس استفاده کردند (Ghods et al., 2025). متغیر هدف هر دو مطالعه با رتبه‌بندی بازده تک‌شرکت‌ها در افق‌های کوتاه‌مدت تفاوت دارد. دهقان‌منشادی و همکاران چارچوبی مبتنی بر یادگیری گروهی و الگوریتم فراابتکاری عقاب را برای پیش‌بینی بازده، انتخاب دارایی و بهینه‌سازی سبد ارائه کردند (DehghanManshadi et al., 2026). این پژوهش ارتباط میان پیش‌بینی و تصمیم تخصیص دارایی را بررسی می‌کند؛ توالی مراحل آن با یادگیری باقیمانده مدل بنیادین در مطالعه حاضر متفاوت است. مجموع مطالعات داخلی مرورشده، کاربرد معماری‌های ترکیبی، روش‌های تجمیعی و توضیح‌پذیری را در بازار ایران نشان می‌دهد و زمینه‌ای برای مقایسه دقیق‌تر شیوه‌های ترکیب اطلاعات فراهم می‌کند.

بر پایه این مرور، پرسش پژوهش حاضر آن است که آیا تخصیص ویژگی‌های بنیادین و معاملاتی به دو مرحله یادگیری، در مقایسه با استفاده جداگانه از هر گروه و ترکیب مستقیم آن‌ها، با بهبود عملکرد پیش‌بینی در افق‌های یک، سه، پنج، ده و پانزده روز معاملاتی همراه است. سهم مورد بررسی، مقایسه تجربی این چهار طراحی در شرکت‌های تولیدی بورس تهران است. اصل یادگیری باقیمانده‌ها و مدل‌سازی دومرحله‌ای پیش‌تر در ادبیات مطرح شده‌اند؛ ازاین‌رو، تمایز مطالعه به نحوه تخصیص گروه‌های اطلاعاتی، افق‌های ارزیابی و بستر بازار مربوط می‌شود. برتری روش دومرحله‌ای نیز یک نتیجه از پیش مفروض نیست و باید برای هر افق بر اساس شواهد گزارش‌شده تفسیر شود.

۳. روش‌شناسی پژوهش

این پژوهش با نگرشی تجربی انجام شده است و عملکرد مدل‌ها بر اساس شواهد مشاهده‌شده در دوره آزمون ارزیابی می‌شود. طرح پژوهش کمّی، مشاهده‌ای و مقایسه‌ای است. از نظر زمانی، پژوهش طولی است و هر مشاهده به یک شرکت در یک روز معاملاتی مربوط می‌شود. دوره در نظر گرفته‌شده برای آموزش، اعتبارسنجی و آزمون مدل‌ها از دی

۱۳۹۵ تا تیر ۱۴۰۵ است و ارزیابی خارج از نمونه در دو پنجره متوالی دوازده‌ماهه انجام شده است. منطق طرح پرسش و تعیین مقایسه‌ها عمدتاً قیاسی است. پرسش پژوهش درباره ارزش پیش‌بینی ترکیب دومرحله‌ای اطلاعات بر پایه ادبیات صورت‌بندی شد و برای پاسخ به آن، عملکرد چهار طراحی در داده‌های خارج از نمونه مقایسه شد.

جامعه آماری و منابع داده و تقسیم زمانی: جامعه آماری پژوهش شامل شرکت‌های تولیدی پذیرفته‌شده در بورس اوراق بهادار تهران است. دلیل محدود کردن نمونه مورد بررسی به شرکت‌های تولیدی این است که شرکت‌های غیرتولیدی یا مانند موسسات مالی تفاوت در ساختار صورت‌های مالی و سنجه‌های سودآوری دارند یا مانند شرکت‌های خدماتی و رایانه‌ای محرک‌های بنیادین متفاوتی داشته و تحلیل و مقایسه آن‌ها به سادگی شرکت‌های تولیدی نمی‌باشد. تعداد شرکت‌های مورد استفاده در این تحقیق ۲۷۴ می‌باشد که البته برخی از آن‌ها به تدریج و پس از گذشت مدتی از عرضه اولیه به لیست شرکت‌های مورد بررسی اضافه شدند و در کل بازه وجود نداشتند. به منظور اینکه خروجی بازه تست از بازه عرضه اولیه مصون باشد، سهامی که پس از بازه تست به مجموعه اضافه شدند در بررسی دوره تست لحاظ نشدند و لذا تعداد کل سهام ثابت مانده است. کل داده‌های مورد استفاده حدود ۴۰۰ هزار بوده است که حدود ۷۰ هزار عدد از این داده‌ها مربوط به بازه تست می‌باشد و مابقی در مراحل آموزش و اعتبارسنجی ماشین مورد استفاده قرار گرفتند. اطلاعات صورت‌های مالی از سامانه جامع اطلاع‌رسانی ناشران، کدال، و داده‌های قیمتی و معاملاتی روزانه از پایگاه مدیریت فناوری بورس تهران، TSETMC، گردآوری شدند.

برای ورود هر مشاهده به نمونه آموزش و ارزیابی، سهم باید در پایان روز مبنای پیش‌بینی فاقد صف خرید یا فروش قفل‌شده می‌بود و قیمت‌های معاملاتی لازم برای محاسبه بازده هدف در روز مبنا و روز انتهای افق در دسترس می‌بودند. افق‌ها بر اساس تقویم معاملاتی شاخص کل تعیین شدند و نبود قیمت لازم به‌دلیل توقف نماد در هر یک از این دو روز، موجب حذف مشاهده در همان افق شد. این قواعد برای همه مدل‌ها یکسان بود. مقادیر مفقود در ویژگی‌های ورودی به صورت NaN به مدل XGBoost داده شدند و به تنهایی موجب حذف مشاهده نشدند. به‌منظور آموزش، انتخاب ابرپارامترها و ارزیابی مدل‌ها، از طرح ارزیابی زمانی غلتان با دو پنجره آزمون متوالی استفاده شد. طول پنجره آموزش ۷۸ ماه، دوره اعتبارسنجی ۱۲ ماه و هر پنجره آزمون ۱۲ ماه تعیین شد. در پنجره نخست، بازه آموزش از دی‌ماه سال ۱۳۹۵ (ابتدای ژانویه ۲۰۱۷) تا تیرماه ۱۴۰۲ (پایان ژوئن ۲۰۲۳)، اعتبارسنجی از تیرماه ۱۴۰۲ (ابتدای ژوئیه ۲۰۲۳) تا تیرماه ۱۴۰۳ (پایان ژوئن ۲۰۲۴) و آزمون از تیر ۱۴۰۳ (ابتدای ژوئیه ۲۰۲۴) تا تیرماه ۱۴۰۴ (پایان ژوئن ۲۰۲۵) تنظیم شد. در پنجره دوم، بازه آموزش یکسال به جلو منتقل شد تا انتهای بازه تست اول گسترش پیدا کرد و بازه تست دوم از تیرماه ۱۴۰۴ (ابتدای ژوئیه ۲۰۲۵) تا تیرماه ۱۴۰۵ (پایان ژوئن ۲۰۲۶) در نظر گرفته شد.

در هر پنجره زمانی، مدل‌ها بر مجموعه آموزش همان پنجره برازش شدند و ابرپارامترها بر اساس عملکرد در دوره اعتبارسنجی متناظر انتخاب شدند. مدل منتخب در طول پنجره آزمون مربوط ثابت ماند و هنگام انتقال به پنجره دوم، فرایند آموزش و انتخاب ابرپارامترها با داده‌های به‌روزشده تکرار شد. داده‌های آزمون هر پنجره در برازش یا انتخاب مدل همان پنجره دخالت نداشتند. نتایج نهایی از تجمیع پیش‌بینی‌های خارج از نمونه دو پنجره به دست آمدند.

متغیر هدف، بازده حاصل از تغییر قیمت پایانی تعدیل‌شده سهم در روز مبنای پیش‌بینی به قیمت آغازین تعدیل‌شده آن در روز انتهای افق است. برای سهم i، روز مبنای t و افق h روز معاملاتی، بازده هدف از تقسیم قیمت آغازین تعدیل‌شده در روز t+h بر قیمت پایانی تعدیل‌شده در روز t و کسر عدد یک محاسبه می‌شود:

$$r_{i,t,h} = \frac{O^{\text{adj}}_{i,t+h}}{C^{\text{adj}}_{i,t}} - 1. \qquad (1)$$

در این رابطه، $C_{i,t}^{\mathrm{adj}}$ قیمت پایانی تعدیل‌شده سهم در روز مبنا و $O_{i,t+h}^{\mathrm{adj}}$ قیمت تعدیل‌شده بازگشایی سهم در h روز بعد است. افق‌های پژوهش شامل ۱، ۳، ۵، ۱۰ و ۱۵ روز معاملاتی هستند و $t+h$ بر اساس تقویم روزهای معاملاتی شاخص کل تعیین می‌شود؛ بنابراین، منظور از افق، تعداد روزهای معامله‌شدن خود سهم نیست.

تخصیص مشاهدات به مجموعه‌های آموزش، اعتبارسنجی و آزمون بر اساس تاریخ مبنای پیش‌بینی انجام شد. در هر پنجره و برای هر افق، مشاهدات انتهایی آموزش که تاریخ تحقق بازده هدف آن‌ها به دوره اعتبارسنجی وارد می‌شد، پیش از برازش حذف شدند. به همین ترتیب، مشاهدات انتهایی اعتبارسنجی که محاسبه بازده آن‌ها مستلزم استفاده از قیمت‌های دوره آزمون بود، پیش از انتخاب مدل کنار گذاشته شدند. این پالایش برای هر افق به‌صورت جداگانه انجام شد تا برچسب‌های آموزش و اعتبارسنجی از قیمت‌های دوره بعد استفاده نکنند.

پیش‌بینی‌های آزمون بر اساس تاریخ صدور پیش‌بینی به پنجره مربوط اختصاص یافتند. در ارزیابی هر افق، تنها مشاهداتی منظور شدند که بازده هدف آن‌ها به‌طور کامل قابل محاسبه بود و تاریخ انتهای افق از پایان بازه کلی آزمون فراتر نمی‌رفت. عبور تاریخ تحقق بازده از مرز میان دو پنجره آزمون، به‌تنهایی موجب حذف مشاهده نشد؛ زیرا بازده تحقق‌یافته صرفاً برای ارزیابی پیش‌بینی صادرشده استفاده می‌شود. در نتیجه، تعداد مشاهدات و آخرین تاریخ مبنای قابل ارزیابی می‌تواند میان افق‌های مختلف متفاوت باشد.

ویژگی‌های بنیادین و معاملاتی: ویژگی‌های بنیادین پژوهش شامل نسبت سود خالص دوازده‌ماهه اخیر به ارزش بازار شرکت (E/P)، نسبت فروش دوازده‌ماهه اخیر به ارزش بازار شرکت (S/P)، رشد فصلی سود خالص و درآمد فروش، و تغییرات فصلی حاشیه سود ناخالص، عملیاتی و خالص هستند. نسبت‌های E/P و S/P برای هر شرکت در هر روز، از تقسیم سود خالص و فروش کل دوازده‌ماهه اخیر (TTM)، بر اساس آخرین گزارش‌های مالی در دسترس، بر ارزش بازار همان روز شرکت محاسبه شدند. در نسبت E/P، سود در صورت کسر قرار دارد؛ بنابراین، سود منفی به نسبت منفی منجر می‌شود و صفرشدن سود موجب نامعین‌شدن نسبت نمی‌شود. این نسبت‌ها، علاوه بر انتشار اطلاعات مالی جدید، با تغییر ارزش بازار روزانه شرکت نیز تغییر می‌کنند.

رشد سود خالص و رشد درآمد فروش با مقایسه مقادیر آخرین فصل مالی دارای گزارش منتشرشده با فصل بلافاصله پیش از آن محاسبه شدند. برای هر متغیر، اختلاف مقدار فصل جاری و فصل قبل بر مجموع قدر مطلق مقدار فصل قبل و یک ثابت مثبت کوچک تقسیم شد. استفاده از این ثابت برای جلوگیری از صفرشدن مخرج است. روابط محاسبه رشدها به‌صورت زیر هستند:

$$g_{i,q}^{E} = \frac{E_{i,q} - E_{i,q-1}}{\left|E_{i,q-1}\right| + \varepsilon}$$

$$g_{i,q}^{S} = \frac{S_{i,q} - S_{i,q-1}}{\left|S_{i,q-1}\right| + \varepsilon}$$

در این روابط، $(E_{i,q})$ و $(S_{i,q})$ به‌ترتیب سود خالص و درآمد فروش شرکت (i) در فصل (q) هستند و (ε) ثابت مثبت کوچک افزوده‌شده به مخرج است. همچنین، حاشیه سود ناخالص، عملیاتی و خالص از نسبت سود متناظر به درآمد فروش همان فصل محاسبه شدند. تغییر هر حاشیه سود، تفاضل مقدار آن در فصل جاری و فصل قبل است.

بنابراین، مبنای متغیرهای رشد و تغییر حاشیه سود، مقایسه فصل‌به‌فصل است، نه مقایسه با فصل مشابه سال قبل؛ درحالی‌که نسبت‌های E/P و S/P از سود خالص و فروش دوازده‌ماهه اخیر استفاده می‌کنند.

برای رعایت زمان دسترسی به اطلاعات، داده‌های صورت‌های مالی از روز پس از انتشار رسمی در سامانه کدال در محاسبه ویژگی‌های بنیادین استفاده شدند. پیش از آن، تنها اطلاعات گزارش‌های منتشرشده قبلی مبنای محاسبات

بود. همچنین، تعداد روزهای معاملاتی سپری‌شده از انتشار آخرین گزارش و تعداد روزهای تقویمی سپری‌شده از پایان آخرین فصل مالی، به‌عنوان ویژگی‌های زمانی به مدل افزوده شدند. این متغیرها قدمت اطلاعات و موقعیت زمانی مشاهده نسبت به دوره گزارشگری را نشان می‌دهند و به معنای اطلاع از تاریخ انتشار گزارش بعدی نیستند.

برای بازنمایی جایگاه نسبی شرکت‌ها، در هر روز معاملاتی، رتبه صدکی نسبت‌های ارزش‌گذاری، رشدها و تغییرات حاشیه سود در دو سطح محاسبه شد: در میان تمامی شرکت‌های نمونه و در میان شرکت‌های هم‌صنعت. هر دو دسته رتبه صدکی به‌عنوان ورودی مدل استفاده شدند و مقادیر خام این متغیرهای مالی مستقیماً وارد مدل نشدند. رتبه‌بندی در سطح کل نمونه، موقعیت نسبی شرکت را در مجموعه مورد بررسی نشان می‌دهد و رتبه‌بندی درون‌صنعتی، مقایسه آن را با شرکت‌های دارای فعالیت مشابه فراهم می‌کند. استفاده از تبدیل رتبه‌ای ویژگی‌های شرکتی در پژوهش‌های پیش‌بینی بازده مبتنی بر یادگیری ماشین نیز سابقه دارد (Gu et al., 2020).

تبدیل به رتبه صدکی، جایگاه نسبی شرکت‌ها را در اختیار مدل قرار می‌دهد. متغیرهای رشد و تغییرات حاشیه سود نیز بخشی از پویایی عملکرد مالی را در همین قالب نسبی بازنمایی می‌کنند. سطح مطلق متغیرها و تغییرات مشترکی که ترتیب شرکت‌ها را تغییر نمی‌دهند، مستقیماً در این بازنمایی حفظ نمی‌شوند.

ویژگی‌های قیمتی و معاملاتی از داده‌های روزانه TSETMC محاسبه شدند و شامل سنجه‌های وضعیت کندل، بازدهی‌های تاریخی و ویژگی‌های مرتبط با ریسک و حرکت بازار، از جمله بتای سهم و بازدهی شاخص کل، هستند. مجموعه یکسانی از این ویژگی‌ها در مدل صرفاً معاملاتی، مدل ترکیب مستقیم و مرحله دوم طراحی پیشنهادی استفاده شد. در ادامه، بردار ویژگی‌های بنیادین با $(X_{i,t}^{F})$ و بردار ویژگی‌های قیمتی و معاملاتی با $(X_{i,t}^{P})$ نشان داده می‌شود.

مدل‌های مورد مقایسه و معماری دومرحله‌ای: برای هر افق پیش‌بینی، چهار طراحی مبتنی بر رگرسیون XGBoostمقایسه شدند. مدل صرفاً بنیادین از ویژگی‌های بنیادین و مدل صرفاً معاملاتی از ویژگی‌های قیمتی و معاملاتی برای پیش‌بینی بازده استفاده می‌کنند. در مدل ترکیب مستقیم، دو گروه ویژگی در یک بردار ورودی مشترک قرار می‌گیرند و یک مدل واحد، بازده را پیش‌بینی می‌کند. در طراحی دومرحله‌ای، این دو گروه ویژگی به‌ترتیب برای پیش‌بینی بازده و باقیمانده مدل نخست به کار می‌روند.

در طراحی پیشنهادی، برای هر یک از افق‌های ۱، ۳، ۵، ۱۰ و ۱۵ روز معاملاتی و در هر پنجره زمانی، یک جفت مدل مستقل آموزش داده شد. ابتدا مدل مرحله اول، صرفاً با استفاده از ویژگی‌های بنیادین و با هدف پیش‌بینی بازده همان افق، بر داده‌های آموزش پنجره مربوط برازش شد. پیش‌بینی این مدل به‌صورت زیر تعریف می‌شود:

$$\hat{r}_{i,t,h}^{F} = \hat{f}_h\left(X_{i,t}^{F}\right). \qquad (2)$$

پس از آموزش مدل نخست، پیش‌بینی آن برای همان مشاهدات مجموعه آموزش محاسبه می‌شود. باقیمانده هر مشاهده، اختلاف بازده واقعی و پیش‌بینی مدل بنیادین است:

$$e_{i,t,h} = r_{i,t,h} - \hat{r}_{i,t,h}^{F},\ (i,t) \in \mathcal{D}_{\text{train},h}. \qquad (3)$$

در این رابطه، $\mathcal{D}_{\text{train},h}$ مجموعه مشاهدات آموزش برای افق hاست. بنابراین، باقیمانده‌های مورد استفاده در آموزش مرحله دوم از پیش‌بینی‌های درون‌نمونه‌ای مدل نخست به دست می‌آیند.

در مرحله دوم، یک مدل مجزای XGBoost، با استفاده از ویژگی‌های قیمتی و معاملاتی و با هدف پیش‌بینی باقیمانده‌های رابطه (۳)، آموزش داده می‌شود. خروجی این مدل عبارت است از:

$$\hat{e}_{i,t,h} = \hat{g}_h\left(X_{i,t}^{P}\right). \qquad (4)$$

در زمان پیش‌بینی، خروجی نهایی از جمع پیش‌بینی مدل بنیادین و باقیمانده پیش‌بینی‌شده حاصل می‌شود:

$$\hat{r}_{i,t,h} = \hat{r}_{i,t,h}^{F} + \hat{e}_{i,t,h}. \qquad (5)$$

سپس سهام در هر روز، بر اساس مقادیر $\hat{r}_{i,t,h}$ رتبه‌بندی می‌شوند. محاسبه پیش‌بینی نهایی به ویژگی‌های در دسترس در روز مبنا و مدل‌های آموزش‌دیده وابسته است و به بازده واقعی آینده نیاز ندارد. بازده تحقق‌یافته در دوره آزمون، برای ارزیابی پیش‌بینی‌ها استفاده می‌شود.

این معماری به مدل معاملاتی امکان می‌دهد بخش قابل پیش‌بینی خطای مدل بنیادین را یاد بگیرد. بااین‌حال، باقیمانده‌ها الزاماً فاقد اطلاعات بنیادین نیستند و تشکیل آن‌ها از طریق تفریق، متعامدبودن آن‌ها با ویژگی‌های بنیادین یا متعامدبودن خروجی دو مدل را تضمین نمی‌کند. ازاین‌رو، این طراحی «ترکیب دومرحله‌ای مبتنی بر یادگیری باقیمانده‌ها» نامیده می‌شود.

قواعد پالایش نمونه: تعدیل سری قیمت‌ها توسط پژوهشگران و با استفاده از داده‌های معاملاتی و اطلاعات بنیادین شرکت‌ها انجام شد. در این فرایند، آثار سود نقدی و افزایش سرمایه در سری قیمت‌ها تعدیل شدند. قیمت پایانی تعدیل‌شده روز مبنا و قیمت آغازین تعدیل‌شده روز انتهای افق، مطابق رابطه (۱)، برای محاسبه بازده هدف استفاده شدند.

در پیش‌پردازش ویژگی‌های بنیادین، مقادیر صرفاً به دلیل بزرگی یا کوچکی غیرمعمول حذف یا محدود نشدند. این مقادیر، همانند سایر مشاهدات، در تبدیل مقطعی به رتبه صدکی شرکت کردند و جایگاه نسبی آن‌ها در کل نمونه و درون صنعت به مدل ارائه شد. این تبدیل فاصله عددی میان مقادیر را حذف می‌کند، اما به معنای شناسایی یا تصحیح خطاهای احتمالی داده نیست. پیش از محاسبه ویژگی‌های بنیادین، وجود و کامل‌بودن اطلاعات موردنیاز در فصل‌های متوالی بررسی شد. مقادیر مفقود باقی‌مانده در ویژگی‌های ورودی با مقدار ثابت جایگزین نشدند و مشاهدات نیز صرفاً به دلیل وجود این مقادیر حذف نشدند؛ بلکه مقادیر مفقود با نمایش NaN به مدل XGBoost ارائه شدند. این رویه از قاعده حذف مشاهدات فاقد قیمت لازم برای محاسبه بازده هدف متمایز است؛ نحوه برخورد با این مشاهدات و توقف نمادها در ادامه توضیح داده می‌شود. برای تعیین نمونه مورد استفاده در آموزش و ارزیابی، مشاهدات بر اساس وضعیت صف در روز مبنای پیش‌بینی و وجود قیمت معاملاتی در ابتدا و انتهای افق پالایش شدند. قواعد پالایش برای مدل‌های مورد مقایسه یکسان بود و مشاهدات حذف‌شده در رتبه‌بندی و تشکیل دهک‌ها وارد نشدند.

نمادهایی که در پایان روز مبنای پیش‌بینی در وضعیت صف خرید یا صف فروش قفل‌شده قرار داشتند، از نمونه آن روز حذف شدند. ملاک این حذف، وضعیت مشاهده‌شده صف در پایان روز پیش‌بینی بود. همچنین، با توجه به تعریف افق‌ها بر اساس تقویم معاملاتی شاخص کل، در صورتی که سهم در روز مبنا یا روز انتهای افق به دلیل توقف نماد معامله نشده بود، مشاهده مربوط از نمونه آن افق حذف شد. این قاعده، ارزیابی را به مشاهداتی محدود می‌کند که قیمت لازم برای محاسبه بازده آن‌ها موجود است.

معیارهای ارزیابی: عملکرد چهار مدل با دو معیار ضریب اطلاعاتی رتبه‌ای و اسپرد بازدهی دهک‌ها ارزیابی شد. هر دو معیار، ابتدا برای هر روز و هر افق پیش‌بینی محاسبه شدند و سپس میانگین حسابی مقادیر روزانه در دوره آزمون گزارش شد. ضریب اطلاعاتی رتبه‌ای، همبستگی رتبه‌ای اسپیرمن میان بازده پیش‌بینی‌شده و بازده تحقق‌یافته سهام نمونه در هر روز است:

$$IC_{t,h} = \rho_{\text{Spearman}}\left(\{\hat{r}_{i,t,h}\}_{i\in U_{t,h}}, \{r_{i,t,h}\}_{i\in U_{t,h}}\right). \qquad (6)$$

در این رابطه، $U_{t,h}$ مجموعه سهام باقی‌مانده پس از پالایش نمونه در روز t و افق h است. مقدار گزارش‌شده برای هر مدل و افق، میانگین حسابی ضرایب روزانه قابل محاسبه در دوره آزمون است. این معیار کیفیت رتبه‌بندی را در کل مقطع سهام ارزیابی می‌کند.

برای محاسبه اسپرد، سهام در هر روز و هر افق بر اساس بازده پیش‌بینی‌شده مرتب و به دهک‌ها تقسیم شدند. بازده هر دهک، میانگین ساده بازده تحقق‌یافته سهام عضو آن است؛ بنابراین، سهام درون هر دهک وزن برابر دارند. اسپرد روزانه به‌صورت زیر محاسبه می‌شود:

$$S_{t,h} = \frac{1}{\mid D_{t,h}^{\text{top}} \mid} \sum_{i \in D_{t,h}^{\text{top}}} r_{i,t,h} - \frac{1}{\mid D_{t,h}^{\text{bottom}} \mid} \sum_{i \in D_{t,h}^{\text{bottom}}} r_{i,t,h} . \qquad (7)$$

در این رابطه، $D_{t,h}^{\text{top}}$ دهک دارای بالاترین بازده پیش‌بینی‌شده و $D_{t,h}^{\text{bottom}}$ دهک دارای پایین‌ترین بازده پیش‌بینی‌شده است. مقدار گزارش‌شده برای هر مدل و افق، میانگین حسابی اسپردهای روزانه در دوره آزمون است.

ضریب اطلاعاتی رتبه‌ای، معیار اصلی ارزیابی کیفیت رتبه‌بندی کل مقطع سهام است و اسپرد دهک‌ها، توان تفکیک بازده در دو انتهای رتبه‌بندی را به‌عنوان معیار مکمل نشان می‌دهد. کاربرد ضریب اطلاعاتی رتبه‌ای برای ارزیابی پیش‌بینی بازده سهام در مطالعات پیشین نیز سابقه دارد، زیرا این معیار میزان هم‌خوانی ترتیب سهام بر اساس بازده پیش‌بینی‌شده با ترتیب آن‌ها بر اساس بازده تحقق‌یافته را می‌سنجد (Cao et al., 2024; Li et al., 2024).

استفاده هم‌زمان از این دو معیار، امکان مقایسه کیفیت رتبه‌بندی عمومی و تمایز بازدهی سهام منتخب را فراهم می‌کند. اسپردهای گزارش‌شده بیانگر اختلاف بازده دهک‌ها هستند و با بازده تجمعی یک راهبرد معاملاتی یکسان نیستند.

٤. یافته‌های پژوهش

در این بخش، نتایج ارزیابی چهار مدل شامل مدل صرفاً بنیادین، مدل صرفاً معاملاتی، مدل ترکیب مستقیم ویژگی‌ها و مدل ترکیب دومرحله‌ای مبتنی بر یادگیری باقیمانده‌ها گزارش می‌شود. عملکرد مدل‌ها در دوره آزمون و در افق‌های یک، سه، پنج، ده و پانزده روز معاملاتی، بر اساس دو معیار ضریب اطلاعاتی رتبه‌ای و اسپرد بازدهی دهک‌های بالا و پایین مقایسه می‌شود. ابتدا نتایج مربوط به کیفیت رتبه‌بندی و سپس نتایج مربوط به اختلاف بازدهی دهک‌ها ارائه می‌شود.

نتایج ارزیابی کیفیت رتبه‌بندی: جدول ۱ میانگین ضریب اطلاعاتی رتبه‌ای چهار مدل را در افق‌های یک، سه، پنج، ده و پانزده روز معاملاتی نشان می‌دهد. این معیار، همبستگی رتبه‌ای میان امتیاز پیش‌بینی مدل و بازده تحقق‌یافته سهام را در مقطع روزانه ارزیابی می‌کند. در افق یک‌روزه، مدل دومرحله‌ای با ضریب اطلاعاتی ۰٫۳۲۹۸۷، بالاترین مقدار را ثبت کرده است. مدل ترکیب مستقیم و مدل صرفاً معاملاتی به‌ترتیب با مقادیر ۰٫۳۲۸۷۵ و ۰٫۳۲۸۵۶ در رتبه‌های بعد قرار دارند. مقادیر این سه مدل بسیار نزدیک به یکدیگر و به‌مراتب بالاتر از مقدار ۰٫۰۰۲۴۷ برای مدل صرفاً بنیادین هستند. در افق سه‌روزه، مدل دومرحله‌ای با ضریب اطلاعاتی ۰٫۰۰۴۴۵۳، بالاترین مقدار را در میان چهار مدل دارد. مدل صرفاً معاملاتی و مدل ترکیب مستقیم به‌ترتیب مقادیر ۰٫۰۰۳۱۰۳ و ۰٫۰۰۲۲۵۲ را ثبت کرده‌اند و مقدار مدل صرفاً بنیادین برابر با ۰٫۰۰۰۶۴۲ است. در این افق، ترکیب مستقیم ویژگی‌ها نسبت به استفاده صرف از ویژگی‌های معاملاتی، ضریب اطلاعاتی پایین‌تری دارد؛ درحالی‌که مقدار متناظر برای طراحی دومرحله‌ای بالاتر است. در افق پنج‌روزه نیز مدل دومرحله‌ای با ضریب اطلاعاتی ۰٫۰۰۳۶۶۸، بالاتر از مدل ترکیب مستقیم با مقدار ۰٫۰۰۲۸۶۱ و مدل صرفاً معاملاتی با مقدار ۰٫۰۰۲۸۳۳ قرار می‌گیرد. ضریب اطلاعاتی مدل صرفاً بنیادین در این افق ۰٫۰۰۲۱۷۷ است. برخلاف افق سه‌روزه، ترکیب مستقیم مقدار اندکی بالاتر از مدل معاملاتی ثبت کرده است، هرچند اختلاف این دو مدل بسیار کوچک است. این مقایسه‌ها عملکرد پیش‌بینی مدل‌ها را توصیف می‌کنند و به‌تنهایی سازوکار ایجاد اختلاف میان آن‌ها را مشخص نمی‌سازند.

در افق ده‌روزه، مدل دومرحله‌ای ضریب اطلاعاتی ۰٫۰۵۳۲۸ را ثبت می‌کند که از مقادیر مدل معاملاتی، ترکیب مستقیم و بنیادین، به‌ترتیب برابر با ۰٫۰۴۶۱۹، ۰٫۰۴۲۵۹ و ۰٫۰۳۰۲۶، بالاتر است. در مقایسه با افق پنج‌روزه، ضریب اطلاعاتی هر چهار مدل افزایش یافته است؛ بااین‌حال، ترتیب عملکرد مدل‌ها همچنان نشان‌دهنده بالاتر بودن مقدار این معیار برای طراحی دومرحله‌ای است. در افق پانزده‌روزه، مدل دومرحله‌ای با ضریب اطلاعاتی ۰٫۰۴۴۰۰، بالاترین مقدار را ثبت می‌کند و مدل صرفاً بنیادین با مقدار نزدیک ۰٫۰۴۲۱۱ در رتبه دوم قرار می‌گیرد. مقادیر مدل ترکیب مستقیم و مدل معاملاتی نیز به‌ترتیب ۰٫۰۳۷۱۷ و ۰٫۰۲۶۷۴ هستند. در مقایسه با افق ده‌روزه، ضریب اطلاعاتی مدل بنیادین افزایش یافته، درحالی‌که مقدار این معیار برای سه مدل دیگر کاهش یافته است.

در مجموع، مدل دومرحله‌ای در هر پنج افق، بالاترین میانگین ضریب اطلاعاتی رتبه‌ای را ثبت کرده است که نشان‌دهنده بهبود کیفیت رتبه‌بندی در مقایسه‌های گزارش‌شده است؛ هرچند این برتری عددی به معنای تأیید معناداری آماری تمامی تفاوت‌ها نیست.

جدول ۱ *– مقایسه میانگین ضریب اطلاعاتی رتبه‌ای مدل‌ها در افق‌های مختلف پیش‌بینی، در دوره آزمون از میانه سال ۲۰۲۴ تا میانه سال ۲۰۲۶ .*

Table 1. Comparison of the Mean Rank Information Coefficient (Rank IC) Across Models and Forecast Horizons During the Test Period from Mid-2024 to Mid-2026

افق	بنیادین IC	معاملاتی IC	ترکیب IC مستقیم	IC دومرحله‌ای
۱ روز	0.00247	0.32856	0.32875	0.32987
۳ روز	0.00642	0.03103	0.02252	0.04453
۵ روز	0.02177	0.02833	0.02861	0.03668
۱۰ روز	0.03026	0.04619	0.04259	0.05328
۱۵ روز	0.04211	0.02674	0.03717	0.04400

در مورد جدول بالا و جدول شماره ۲ باید توجه شود که نتایج مربوط به دوره آزمون از میانه سال ۲۰۲۴ تا میانه سال ۲۰۲۶ است. در هر افق پیش‌بینی، مشاهدات انتهای دوره که بازده آتی آن‌ها تا پایان دوره آزمون به‌طور کامل قابل محاسبه نبود، از ارزیابی همان افق حذف شدند؛ ازاین‌رو، آخرین تاریخ مبنای پیش‌بینی قابل ارزیابی و تعداد مشاهدات می‌تواند میان افق‌ها متفاوت باشد.

نتایج ارزیابی اسپرد بازدهی دهک‌ها: جدول ۲ میانگین اسپرد بازدهی دهک‌های چهار مدل را در افق‌های یک، سه، پنج، ده و پانزده روز معاملاتی نشان می‌دهد. این معیار از تفاضل میانگین بازده تحقق‌یافته سهام دهک بالای رتبه‌بندی و دهک پایین آن به دست می‌آید و توان مدل را در تفکیک سهام با بازده بالاتر و پایین‌تر ارزیابی می‌کند. مقادیر جدول به‌صورت درصد گزارش شده‌اند. در افق یک‌روزه، مدل دومرحله‌ای با اسپرد ۱٫۸۴۷٪، بالاترین مقدار را ثبت کرده است. مدل ترکیب مستقیم و مدل صرفاً معاملاتی به‌ترتیب با مقادیر ۱٫۸۴۲٪ و ۱٫۸۳۱٪ در رتبه‌های بعد قرار دارند. اختلاف این سه مدل محدود است، درحالی‌که اسپرد مدل صرفاً بنیادین برابر با منفی ۰٫۰۰۷٪ و نزدیک به صفر است. بنابراین، در این افق، سه مدل دارای ویژگی‌های معاملاتی تفکیک بازدهی بیشتری میان دو دهک ایجاد کرده‌اند، اما مزیت عددی مدل دومرحله‌ای نسبت به دو مدل دیگر اندک است.

در افق سه‌روزه، مدل دومرحله‌ای با اسپرد ۰٫۴۸۳٪، بالاتر از مدل معاملاتی با مقدار ۰٫۳۳۲٪ و مدل ترکیب مستقیم با مقدار ۰٫۱۵۳٪ قرار می‌گیرد. اسپرد مدل صرفاً بنیادین نیز منفی ۰٫۰۲۵٪ است. ترتیب مدل‌ها در این افق با ترتیب ضریب اطلاعاتی رتبه‌ای سازگار است؛ به‌طوری‌که طراحی دومرحله‌ای در هر دو معیار بالاترین مقدار را دارد و ترکیب مستقیم ویژگی‌ها نسبت به مدل صرفاً معاملاتی مقدار پایین‌تری ثبت کرده است. در افق پنج‌روزه، مدل ترکیب مستقیم با اسپرد ۰٫۵۳۴٪، بالاترین مقدار را ثبت می‌کند و مدل دومرحله‌ای با مقدار ۰٫۴۹۴٪ در رتبه بعد قرار می‌گیرد. مقادیر مدل معاملاتی و مدل بنیادین به‌ترتیب ۰٫۳۶۰٪ و ۰٫۲۷۱٪ هستند. بنابراین، اگرچه مدل دومرحله‌ای در این افق بالاترین ضریب اطلاعاتی رتبه‌ای را دارد، بیشترین فاصله بازدهی میان دهک بالا و پایین به مدل ترکیب مستقیم تعلق دارد. این تفاوت نشان می‌دهد رتبه‌بندی مدل‌ها بر اساس کیفیت رتبه‌بندی کل مقطع و تفکیک بازدهی دو دهک انتهایی الزاماً یکسان نیست. در افق ده‌روزه نیز مدل ترکیب مستقیم با اسپرد ۱٫۰۹۶٪، بالاتر از مدل دومرحله‌ای با مقدار ۰٫۸۲۰٪ قرار می‌گیرد. مدل معاملاتی و مدل بنیادین به‌ترتیب مقادیر ۰٫۵۲۹٪ و ۰٫۲۹۷٪ را ثبت کرده‌اند. در مقایسه با افق پنج‌روزه، اسپرد هر چهار مدل افزایش یافته و ترتیب آن‌ها حفظ شده است. در این افق نیز بالاتر بودن ضریب اطلاعاتی مدل دومرحله‌ای با بالاترین اسپرد همراه نیست. در افق پانزده‌روزه، مدل دومرحله‌ای با اسپرد ۱٫۸۳ درصد، بالاترین مقدار را ثبت می‌کند. مدل ترکیب مستقیم با مقدار ۱٫۵۱۰ درصد در رتبه دوم قرار دارد و مقادیر مدل معاملاتی و مدل بنیادین به‌ترتیب ۰٫۵۱۷ و ۰٫۳۹۵ درصد هستند. بنابراین، مدل دومرحله‌ای در این افق، هم در ضریب اطلاعاتی رتبه‌ای و هم در تفکیک بازده دهک‌های انتهایی، بهترین عملکرد را در میان چهار مدل ارائه می‌کند. در مجموع، مدل دومرحله‌ای در افق‌های یک، سه و پانزده‌روزه و ترکیب مستقیم در افق‌های پنج و ده‌روزه بیشترین اسپرد را دارند؛ همچنین، اسپرد مدل دومرحله‌ای در تمامی افق‌ها از مدل صرفاً معاملاتی بیشتر است.

جدول ۲ *– مقایسه میانگین اسپرد بازدهی دهک‌های بالا و پایین مدل‌ها در افق‌های مختلف پیش‌بینی، در دوره آزمون از میانه سال ۲۰۲۴ تا میانه سال ۲۰۲۶؛ مقادیر به درصد.*

Table 2. Comparison of the Mean Return Spread Between the Top and Bottom Deciles Across Models and Forecast Horizons During the Test Period from Mid-2024 to Mid-2026 (Values in Percent).

افق	بنیادین	معاملاتی	ترکیب مستقیم	دومرحله‌ای
۱ روز	-0.007%	1.831%	1.842%	1.847%
۳ روز	-0.025%	0.332%	0.153%	0.483%
۵ روز	0.271%	0.360%	0.534%	0.494%
۱۰ روز	0.297%	0.529%	1.096%	0.820%
۱۵ روز	0.395%	0.517%	1.510%	1.830%

۵. بحث و نتیجه‌گیری

در این بخش، ابتدا یافته‌های پژوهش تفسیر و با مطالعات پیشین مقایسه می‌شوند؛ سپس ملاحظات اصلی و پیشنهادهای کاربردی و پژوهشی بیان می‌شوند. مقایسه چهار رویکرد صرفاً بنیادین، صرفاً معاملاتی، ترکیب مستقیم ویژگی‌ها و ترکیب دومرحله‌ای نشان داد که سازمان‌دهی اطلاعات در فرایند یادگیری با کیفیت پیش‌بینی ارتباط دارد. مهم‌ترین یافته پژوهش، ثبت بالاترین میانگین ضریب اطلاعاتی رتبه‌ای توسط مدل دومرحله‌ای در هر پنج افق پیش‌بینی است. این مدل همچنین در افق‌های یک، سه و پانزده‌روزه بیشترین اسپرد بازدهی را ثبت کرد و در تمام

افق‌ها، اسپردی بالاتر از مدل صرفاً معاملاتی داشت. این نتایج، ظرفیت یادگیری دومرحله‌ای باقیمانده‌ها را برای استفاده مشترک از اطلاعات بنیادین و معاملاتی در رتبه‌بندی مقطعی سهام نشان می‌دهند.

در افق یک‌روزه، مدل دومرحله‌ای با ضریب اطلاعاتی ۰٫۳۲۹۸۷ و اسپرد ۱٫۸۴۷ درصد، در هر دو معیار بالاتر از مدل معاملاتی و ترکیب مستقیم قرار گرفت، هرچند فاصله عملکرد این سه مدل اندک بود. نزدیکی عملکرد مدل‌های دارای ویژگی‌های معاملاتی و فاصله آن‌ها با مدل صرفاً بنیادین، نقش برجسته اطلاعات معاملاتی را در کوتاه‌ترین افق بررسی‌شده نشان می‌دهد. در افق سه‌روزه، مزیت مدل دومرحله‌ای آشکارتر شد؛ ضریب اطلاعاتی و اسپرد آن به‌ترتیب به ۰٫۰۴۴۵۳ و ۰٫۴۸۳ درصد رسید، درحالی‌که مدل معاملاتی مقادیر ۰٫۰۳۱۰۳ و ۰٫۳۳۲ درصد و ترکیب مستقیم مقادیر ۰٫۰۲۲۵۲ و ۰٫۱۵۳ درصد را ثبت کردند. بنابراین، در این افق، استفاده مرحله‌ای از اطلاعات با بهبود هم‌زمان کیفیت رتبه‌بندی و تفکیک بازده دهک‌ها همراه بود. در افق‌های پنج و ده‌روزه نیز مدل دومرحله‌ای با ضرایب اطلاعاتی ۰٫۰۳۶۶۸ و ۰٫۰۵۳۲۸، بالاترین کیفیت رتبه‌بندی را بر اساس میانگین این معیار ارائه کرد. اسپرد این مدل در دو افق مذکور به‌ترتیب ۰٫۴۹۴ و ۰٫۸۲۰ درصد بود که از مدل صرفاً معاملاتی بیشتر، اما از ترکیب مستقیم کمتر بود. این تفاوت، مکمل‌بودن دو معیار ارزیابی را روشن می‌کند: ضریب اطلاعاتی رتبه‌ای، تطابق ترتیب پیش‌بینی‌ها با بازده تحقق‌یافته را در کل مقطع سهام می‌سنجد، درحالی‌که اسپرد بر فاصله بازدهی دو انتهای رتبه‌بندی تمرکز دارد. با توجه به هدف اصلی پژوهش، یعنی رتبه‌بندی مقطعی سهام، برتری مدل دومرحله‌ای در میانگین ضریب اطلاعاتی، مزیت اصلی این طراحی محسوب می‌شود. در افق پانزده‌روزه، مدل دومرحله‌ای با ضریب اطلاعاتی ۰٫۰۴۴۰۰ و اسپرد ۱٫۸۳ درصد، در هر دو معیار بالاترین مقدار را ثبت کرد. مدل صرفاً بنیادین با ضریب اطلاعاتی ۰٫۰۴۲۱۱ در رتبه دوم قرار گرفت و اسپرد مدل ترکیب مستقیم برابر با ۱٫۵۱۰ درصد بود. افزایش ضریب اطلاعاتی مدل بنیادین از ۰٫۰۰۲۴۷ در افق یک‌روزه به ۰٫۰۴۲۱۱ در افق پانزده‌روزه، با افزایش ارزش پیش‌بینی مستقل ویژگی‌های بنیادین در افق‌های طولانی‌ترِ بررسی‌شده سازگار است. در همین حال، عملکرد مدل دومرحله‌ای نشان می‌دهد که استفاده از اطلاعات معاملاتی در کنار مرحله بنیادین می‌تواند به ارتقای کیفیت رتبه‌بندی و تفکیک بازده سهام کمک کند.

برای تبیین جایگاه این یافته‌ها در ادبیات، می‌توان به پژوهش‌هایی اشاره کرد که ارزش اطلاعات شرکتی را وابسته به روابط غیرخطی، مجموعه ویژگی‌ها و روش برآورد می‌دانند. گو و همکاران بر ظرفیت مدل‌های غیرخطی برای استفاده از تعامل میان ویژگی‌ها تأکید کرده‌اند و فریبرگر و همکاران نشان داده‌اند که ارزش افزوده برخی پیش‌بین‌ها به حضور سایر ویژگی‌ها وابسته است (Freyberger et al., 2020; Gu et al., 2020). هان و همکاران نیز اهمیت انتخاب پیش‌بین و ترکیب پیش‌بینی‌ها را در ارزیابی مقطعی بازده بررسی کرده‌اند (Han et al., 2024). پژوهش حاضر این بحث را در بستر بورس تهران گسترش می‌دهد و نشان می‌دهد که علاوه بر انتخاب متغیرها، نحوه تخصیص اطلاعات بنیادین و معاملاتی به مراحل یادگیری نیز در عملکرد پیش‌بینی اهمیت دارد.

یک تفسیر از مزیت مشاهده‌شده آن است که برآورد اولیه بازده با ویژگی‌های بنیادین و سپس یادگیری باقیمانده‌ها با ویژگی‌های معاملاتی، به مدل دوم امکان می‌دهد بر بخش توضیح‌داده‌نشده بازده تمرکز کند. این سازمان‌دهی، چارچوبی مشخص برای استفاده از دو مجموعه اطلاعاتی فراهم می‌کند و در مقایسه‌های انجام‌شده، با بالاترین میانگین کیفیت رتبه‌بندی در تمام افق‌ها همراه بوده است. سهم اصلی پژوهش نیز ارائه شواهد تجربی درباره کارایی این شیوه سازمان‌دهی اطلاعات در پیش‌بینی کوتاه‌مدت بازده سهام است. در تفسیر یافته‌ها، نتایج به نمونه شرکت‌های تولیدی بورس تهران، بازنمایی صدکی ویژگی‌ها و قواعد پالایش پژوهش مربوط‌اند و برتری عددی گزارش‌شده نیز به معنای تأیید معناداری آماری همه تفاوت‌ها نیست. بااین‌حال، ثبت بالاترین میانگین ضریب اطلاعاتی در تمام افق‌ها و بیشترین

اسپرد در سه افق، جایگاه مدل دومرحله‌ای را به‌عنوان رویکردی قابل اعتنا برای ترکیب اطلاعات بنیادین و معاملاتی برجسته می‌کند.

از منظر نتیجه‌گیری، شواهد پژوهش از ترکیب دومرحله‌ای مبتنی بر یادگیری باقیمانده‌ها به‌عنوان رویکردی قابل اعتنا برای تلفیق اطلاعات بنیادین و معاملاتی پشتیبانی می‌کنند. ثبت بالاترین میانگین ضریب اطلاعاتی در هر پنج افق، بیشترین اسپرد در سه افق و اسپرد بالاتر از مدل صرفاً معاملاتی در تمام افق‌ها، نشان می‌دهد که این طراحی در نمونه بررسی‌شده به بهبود کیفیت پیش‌بینی و تفکیک بازده کمک کرده است. بنابراین، برای کاربردهایی که هدف اصلی آن‌ها رتبه‌بندی مقطعی سهام است، چارچوب دومرحله‌ای گزینه‌ای مناسب برای بررسی و توسعه محسوب می‌شود. در کاربردهای متمرکز بر انتخاب دهک‌های انتهایی، نتایج اسپرد می‌توانند انتخاب روش متناسب با افق پیش‌بینی را هدایت کنند. در مجموع، یافته‌ها نشان می‌دهند که ارزش افزوده استفاده مشترک از اطلاعات بنیادین و معاملاتی به شیوه ترکیب آن‌ها وابسته است؛ در این میان، طراحی دومرحله‌ای با ثبت بالاترین میانگین ضریب اطلاعاتی در تمام افق‌ها و بیشترین اسپرد در سه افق، عملکرد برجسته‌تری ارائه کرده است.

در خصوص محدودیت‌های پژوهش باید اشاره شود که ارزیابی مدل‌ها به شرکت‌های تولیدی بورس اوراق بهادار تهران، دوره زمانی مطالعه و افق‌های کوتاه‌مدت بررسی‌شده محدود است و تعمیم یافته‌ها به سایر صنایع، بازارها و دوره‌ها به بررسی جداگانه نیاز دارد. به دلیل نبود داده‌های تاریخی منسجم، ثبات فعالیت اصلی شرکت‌ها و حضور پیوسته آن‌ها در فهرست شرکت‌های پذیرفته‌شده طی دوره پژوهش به‌طور نظام‌مند بررسی نشد. همچنین، حذف مشاهدات فاقد قیمت معاملاتی در انتهای افق، نمونه ارزیابی را به اطلاعاتی وابسته می‌کند که در زمان پیش‌بینی در دسترس نیست. اعمال این قاعده به‌صورت یکسان برای همه مدل‌ها، مقایسه آن‌ها را در نمونه پالایش‌شده ممکن می‌سازد و نتایج نیز باید در چارچوب همان نمونه تفسیر شوند. در نهایت، اختلاف‌های گزارش‌شده میان مدل‌ها باید به‌عنوان تفاوت‌های عددی در معیارهای ارزیابی تفسیر شوند.

برای توسعه این پژوهش، گسترش ارزیابی به دوره‌های زمانی طولانی‌تر و سایر صنایع و بازارها، مقایسه شیوه‌های ساخت باقیمانده‌ها و استفاده از الگوریتم‌های پایه متفاوت پیشنهاد می‌شود. بررسی هم‌زمان سطح خام، تغییرات تاریخی و رتبه مقطعی ویژگی‌های بنیادین نیز می‌تواند ظرفیت اطلاعاتی این گروه را بیشتر آشکار کند. افزودن گزارش‌های ماهانه، اطلاعات بورس کالا و متغیرهای کلان، همراه با مقایسه مدل‌های مشترک و مدل‌های اختصاصی صنایع، مسیرهای دیگری برای ارتقای چارچوب پیشنهادی هستند.

تعارض منافع: برای ارائه مطالب و نگارش این مقاله هیچ گونه 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 هیچ گونه تعارض منافعی ندارند.

Reference

Amihud, Y. (2002). Illiquidity and stock returns: Cross-section and time-series effects. *Journal of Financial Markets*, *5*(1), 31–56.

Avramov, D., Cheng, S., & Metzker, L. (2023). Machine learning vs. Economic restrictions: Evidence from stock return predictability. *Management Science*, *69*(5), 2587–2619.

Bianchi, D., Büchner, M., & Tamoni, A. (2021). Bond risk premiums with machine learning. *The Review of Financial Studies*, *34*(2), 1046–1089.

Breiman, L. (2001). Random Forests. *Machine Learning*, *45*(1), 5–32.

Bryzgalova, S., Lerner, S., Lettau, M., & Pelger, M. (2025). Missing Financial Data. *The Review of Financial Studies*, *38*(3), 803–882.

Bryzgalova, S., Pelger, M., & Zhu, J. (2025). Forest through the Trees: Building Cross-Sections of Stock Returns. *The Journal of Finance*, *80*(5), 2447–2506.

Cao, H., Zou, J., Liu, Y., Zhang, Z., Abbasnejad, E., Hengel, A. van den, & Shi, J. Q. (2024). InvariantStock: Learning Invariant Features for Mastering the Shifting Market. *arXiv Preprint arXiv:2409.00671*.

Chen, L., Pelger, M., & Zhu, J. (2024). Deep learning in asset pricing. *Management Science*, *70*(2), 714–750.

Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '16*, 785–794.

DehghanManshadi, S., Rostami, M., & Khadivar, A. (2026). An Intelligent Integrated Framework for Return Prediction, Asset Selection, and Portfolio Optimization Based on Ensemble Learning and the Aquila meta-heuristic optimization algorithm. *Financial Management Perspective*, *14*(4), 9–30.

Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, *33*(1), 3–56.

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.

Freyberger, J., Neuhierl, A., & Weber, M. (2020). Dissecting Characteristics Nonparametrically. *The Review of Financial Studies*.

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, *29*(5), 1189–1232.

Ghods, M., Amiry, M., Forooshani, M. P., & Dehnavi, M. D. (2025). Prediction of Tehran Stock Exchange Total Index Using Natural Gradient Boosting and SHAP Values. *Financial Management*, *15*(1), 34–53.

Gholami, N., & Shams Gharne, N. (2024). Presenting an optimized CNN-LSTM model for stock price forecasting in the tehran stock exchange. *Financial Management Perspective*, *14*(45), 123–147.

Giglio, S., & Xiu, D. (2021). Asset pricing with omitted factors. *Journal of Political Economy*, *129*(7), 1947–1990.

Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, *33*(5), 2223–2273.

Gu, S., Kelly, B., & Xiu, D. (2021). Autoencoder asset pricing models. *Journal of Econometrics, Annals Issue: Financial Econometrics in the Age of the Digital Economy*, *222*(1, Part B), 429–450.

Han, Y., He, A., Rapach, D. E., & Zhou, G. (2024). Cross-sectional expected returns: New Fama–MacBeth regressions in the era of machine learning. *Review of Finance*, *28*(6), 1807–1831.

Jegadeesh, N., & Titman, S. (1993). Returns to buying winners and selling losers: Implications for stock market efficiency. *The Journal of Finance*, *48*(1), 65–91.

Kelly, B. T., Pruitt, S., & Su, Y. (2019). Characteristics are covariances: A unified model of risk and return. *Journal of Financial Economics*, *134*(3), 501–524.

Kim, T., & Kim, H. Y. (2019). Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data. *PLOS ONE*, *14*(2), e0212320.

Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, *259*(2), 689–702.

Leippold, M., & Yang, H. (2023). Mixed-frequency predictive regressions with parameter learning. *Journal of Forecasting*, *42*(8), 1955–1972.

Li, T., Liu, Z., Shen, Y., Wang, X., Chen, H., & Huang, S. (2024). *Master: Market-guided stock transformer for stock price forecasting*. *38*(1), 162–170.

Noseda, M., Soldati, N., & Paina, M. (2026). Predicting Stock Price Direction on Earnings Announcement Days using Multi-modal Deep Learning. *arXiv Preprint arXiv:2605.25894*.

Poh, D., Lim, B., Zohren, S., & Roberts, S. (2021). Building cross-sectional systematic strategies by learning to rank. *The Journal of Financial Data Science*.

Raei, R., Vahdati, M., Mohebbi, H., & Heydari Delooei, A. (2025). Interpreting Forecast the Return of the Price Index of Manufacturing Industries in the Tehran Stock Exchange Using Explainable Ensemble Learning. *Financial Management Perspective*, *14*(48), 55–78.

Zhang, J., Li, L., & Chen, W. (2021). Predicting Stock Price Using Two-Stage Machine Learning Techniques. *Computational Economics*, *57*(4), 1237–1261.