Fin. Manag. Persp. 2026, 16(3), 28-56; DOI: 10.48308/jfmp.2026.244746.1599

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

Original Article

Systematic Risk (Beta) Estimation: A Machine Learning Approach in the Tehran Stock Exchange

Pejman Abedifar*
Erfan Gohari Nezhad**

Abstract

Objective: Systematic risk, or stock beta, is one of the fundamental pillars of asset pricing, risk management, and portfolio performance evaluation. Nevertheless, empirical evidence has shown that traditional, linear econometric models often face severe limitations in accurately forecasting future beta due to their inability to capture the complex, non-linear dynamics of the market. The primary objective of this research is to overcome these limitations by improving the estimation and forecasting accuracy of stock betas in the Tehran Stock Exchange (TSE) leveraging modern data science techniques and machine learning algorithms. Inspired by recent pioneering studies, this research conducts a comparative analysis of the performance of a suite of advanced, non-linear algorithms against a wide range of traditional baseline models. The key innovation of the present study lies in moving beyond purely statistical metrics by simultaneously evaluating the economic value added of these forecasts through the actual performance of investment portfolios (minimum-variance and market-neutral portfolios) within a highly volatile emerging market.

Methodology: In terms of purpose, this is an applied study, and methodologically, it is descriptive-correlational with a quantitative approach based on historical market data and financial statements. The statistical population comprises all firms listed on the Tehran Stock Exchange. Following the application of screening criteria (including the exclusion of financial institutions, investment firms, and tickers with prolonged trading halts), the initial dataset spans 50 trading quarters from the beginning of 1391-Q4 to the end of 1404-Q1. After forming the final panel, the research sample consists of 41,313 firm-month observations across 450 companies listed on the TSE within an unbalanced panel (with active firms ranging between 188 and 427 per month). Beta forecasting was conducted using cross-validation and a rolling-window approach to preserve strict out-of-sample conditions.This study

Received:11, July,2026 . Accepted: 8, November,2026
* Associate Prof, Tehran Institute for Advanced Studies (TeIAS), Khatam University, Tehran, Iran. Email: pabedifar@gmail.com
** MSc in Financial Engineering and Risk Management, Tehran Institute for Advanced Studies (TeIAS), Khatam University, Tehran, Iran. **(Corresponding Author). Email**: e.gohari.7091@khatam.ac.ir

evaluated the performance of 6 traditional baseline models (including Ordinary Least Squares [OLS], Exponentially Weighted Moving Average [EWM A] over short and long horizons, and the adjustment models of Blume, BSW, and Vasicek) against 6 advanced machine learning algorithms, including Random Forest, gradient boosting models (XGBoost and GBRT), Artificial Neural Networks (MLP Keras), and penalized regressions (Elastic Net and Linear Models). To compare model accuracy, error metrics such as Value-Weighted Mean Squared Error (VWMSE), the two-sided Diebold–Mariano test with the Harvey–Leybourne–Newbold finite-sample correction (DM-HLN), feature importance analysis, and the construction of minimum-variance and market-neutral portfolios were employed.

Findings: The empirical findings of this research indicate the decisive superiority of machine learning algorithms over traditional econometric models in forecasting stock betas. The results demonstrated that decision tree-based models, particularly Random Forest (RF), Gradient Boosted Regression Trees (GBRT), and XGBoost algorithms, significantly outperformed other models in reducing out-of-sample prediction errors (evidenced by a substantial decrease in VWMSE), and the two-sided Diebold–Mariano test with the Harvey–Leybourne–Newbold finite-sample correction (DM-HLN) test confirmed the statistical significance of this outperformance. The feature importance analysis in machine learning algorithms revealed that, contrary to traditional beliefs, predictors based on accounting information (fundamental variables), followed by historical beta estimates, which play the most crucial role in accurately predicting future betas, with non-linear algorithms successfully uncovering these intricate patterns. However, in the economic evaluation and portfolio formation stage, results reveal that the statistical superiority of individual-stock models (such as RF) does not automatically translate into superior economic gains due to the fundamental divergence between statistical loss functions and portfolio optimization objectives. Instead, gradient boosting algorithms (such as GBRT) achieved significant economic outperformance-demonstrated through superior Sharpe ratios and effective drawdown mitigation-driven by more accurate beta estimates and an optimized portfolio risk profile.

Conclusion: The findings of this study suggest that machine learning algorithms exhibit a higher capacity for reducing prediction error in statistical beta forecasting within the Iranian capital market compared to traditional models. Although machine learning algorithms substantially enhance statistical beta forecasting accuracy in emerging markets, translating this precision into tangible portfolio economic gains depends critically on aligning model loss functions with portfolio risk-management constraints and covariance matrix estimation.

Keywords: Beta Forecasting; Machine Learning; Systematic Risk; Minimum Variance Portfolio; Asset Allocation.

How To Cited: Gohari Nezhad, E. & Abedifar, P. (2026). Systematic Risk (Beta) Estimation: A Machine Learning Approach in the Tehran Stock Exchange. (e107719). *Financial Management Perspective*, *16*(3),28-56 (in persian) https://doi.org/10.48308/jfmp.2026.244746.1599

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 ۱۶(۳)، صص ۲۸ –۵۶ . DOI:10.48308/jfmp.2026.244746.1599

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

نوع مقاله: پژوهشی

تخمین ریسک سیستماتیک (بتا): رویکردی مبتنی بر یادگیری ماشین در بورس اوراق بهادار تهران

پژمان عابدی فر*
عرفان گوهری نژاد**

چکیده

هدف: ریسک سیستماتیک (بتا) سهام، یکی از ارکان اصلی در قیمت‌گذاری دارایی‌ها، مدیریت ریسک و ارزیابی عملکرد پرتفوی سرمایه‌گذاری به شمار می‌رود. با این وجود، شواهد تجربی نشان داده‌اند که مدل‌های سنتی و خطی مبتنی بر اقتصادسنجی، به دلیل ناتوانی در ثبت پویایی‌های پیچیده و غیرخطی بازار، غالباً در پیش‌بینی دقیق بتای آینده با محدودیت‌های جدی مواجه هستند . هدف اصلی این پژوهش، غلبه بر این محدودیت‌ها از طریق بهبود دقت تخمین و پیش‌بینی بتای سهام در بورس اوراق بهادار تهران با بهره‌گیری از تکنیک‌های نوین علم داده و الگوریتم‌های یادگیری ماشین است. این مطالعه با الهام از پژوهش‌های پیشگامانه اخیر به بررسی و مقایسه تطبیقی عملکرد مجموعه‌ای از الگوریتم‌های پیشرفته و غیرخطی در برابر طیف وسیعی از مدل‌های پایه و سنتی می‌پردازد. نوآوری پژوهش حاضر، عدم اکتفا به معیارهای صرفاً آماری و ارزیابی همزمان ارزش افزوده اقتصادی این پیش‌بینی‌ها در قالب عملکرد واقعی پرتفوی‌های سرمایه‌گذاری (پرتفوهای حداقل واریانس و بازار خنثی) در یک بازار نوظهور با نوسانات بالا است.

روش: پژوهش حاضر از نظر هدف، کاربردی و از حیث روش‌شناسی، توصیفی–همبستگی با رویکرد کمی و مبتنی بر داده‌های تاریخی بازار و صورت‌های مالی است. جامعه آماری پژوهش شامل کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است که پس از اعمال محدودیت‌های غربالگری (از جمله حذف نهادهای مالی، سرمایه‌گذاری‌ها و نمادهای دارای توقف معاملاتی طولانی‌مدت)، داده‌های اولیه پژوهش ۵۰ فصل معاملاتی را از ابتدای فصل چهارم سال ۱۳۹۱ تا پایان فصل اول سال ۱۴۰۴ در بر می‌گیرد. پس از اعمال معیارهای غربالگری و تشکیل پنل نهایی، نمونه پژوهش شامل ۴۱۰۳۱۳ مشاهده شرکت–ماه متعلق به ۴۵۰ شرکت پذیرفته‌شده در بورس اوراق بهادار تهران در قالب یک پنل نامتوازن (با نوسان ۱۸۸ تا ۴۲۷ شرکت فعال در هر ماه) است. تخمین بتا با استفاده از رویکرد اعتبارسنجی متقاطع و پنجره غلتان (Rolling Window)

تاریخ دریافت مقاله : ۱۴۰۵/۰۴/۲۰ تاریخ پذیرش مقاله: ۱۴۰۵/۰۸/۱۷

* استادیار گروه مالی، موسسه پژوهش‌های پیشرفته (تیاس)، دانشگاه خاتم،تهران،ایران
E-Mail: pabedifar@gmail.com
** کارشناسی ارشد مهندسی مالی ومدیریت ریسک، موسسه پژوهش‌های پیشرفته تهران (تیاس)، دانشگاه خاتم، تهران، ایران (نویسنده مسئول).
E-Mail: e.gohari.7091@khatam.ac.ir

جهت حفظ شرایط خارج از نمونه (Out-of-Sample) صورت گرفت. در این مطالعه، عملکرد ۶ مدل پایه و سنتی (شامل حداقل مربعات معمولی OLS، میانگین متحرک نمایی EWMA در افق‌های کوتاه‌مدت و بلندمدت، و مدل‌های تعدیلی بلوم، BSW و واسیچک) در مقابل ۶ الگوریتم پیشرفته یادگیری ماشین شامل جنگل تصادفی (Random Forest)، مدل‌های تقویت گرادیان (XGBoost و GBRT)، شبکه‌های عصبی مصنوعی (MLP Keras) و رگرسیون‌های جریمه‌دار (Elastic Net و مدل‌های خطی LM) مورد ارزیابی قرار گرفت. برای مقایسه دقت مدل‌ها، از معیارهای خطای سنجش نظیر میانگین مربعات خطای وزن‌دهی شده با ارزش بازار (VWMSE)، آزمون دوطرفه دایبولد–ماریانو با تصحیح محدودنمونه هاروی–لیبورن–نیوبولد(DM-HLN) ، تحلیل اهمیت متغیرها و تشکیل سبدهای حداقل واریانس و بازارخنثی ارزیابی شد.

یافته‌ها: یافته‌های تجربی این پژوهش حاکی از برتری الگوریتم‌های یادگیری ماشین بر مدل‌های سنتی اقتصادسنجی در پیش‌بینی بتای سهام است. نتایج نشان داد که مدل‌های مبتنی بر درخت تصمیم، به ویژه الگوریتم‌های جنگل تصادفی (RF)، تقویت گرادیان (GBRT) و تقویت گرادیان پیشرفته (XGBoost)، عملکردی به مراتب بهتر از سایر مدل‌ها در کاهش خطای پیش‌بینی خارج از نمونه (کاهش چشمگیر مقدار VWMSE) داشته‌اند و آزمون دوطرفه دایبولد–ماریانو با تصحیح محدودنمونه هاروی–لیبورن–نیوبولد(DM-HLN) نیز تفاوت معنادار آماری این برتری را تایید نمود. تحلیل اهمیت متغیرها در الگوریتم‌های یادگیری ماشین مشخص کرد که بر خلاف باورهای سنتی، پیش‌بین‌های مبتنی بر اطلاعات حسابداری (متغیرهای بنیادی) و پس از آن، برآوردهای گذشته‌نگر بتا، بیشترین نقش را در پیش‌بینی دقیق بتای آینده ایفا می‌کنند و الگوریتم‌های غیرخطی توانسته‌اند این روابط پنهان را به‌خوبی استخراج کنند با این حال، در بخش ارزیابی اقتصادی و تشکیل سبد، مشخص شد که برتری آماری مدل‌های تک‌سهم (نظیر RF) به دلیل تفاوت در ماهیت تابع زیان آماری با ساختار بهینه‌سازی پرتفوی، به‌طور خودکار به بالاترین بازده اقتصادی تبدیل نمی‌شود؛ بلکه الگوریتم‌های تقویت گرادیان (نظیر GBRT) به دلیل برآورد دقیق‌تر بتا و بهینه‌سازی ساختار ریسک سبد، برتری اقتصادی قابل‌توجهی در نسبت‌های شارپ و مهار افت سرمایه محقق ساختند

نتیجه‌گیری: یافته‌های این پژوهش نشان می‌دهد که الگوریتم‌های یادگیری ماشین در پیش‌بینی آماریِ بتای سهام در بازار سرمایه ایران، در مقایسه با مدل‌های سنتی، از توانایی بالاتری برای کاهش خطای پیش‌بینی برخوردارند. اگرچه الگوریتم‌های یادگیری ماشین ابزار قدرتمندی برای کاهش خطای آماری بتای سهام در بازار سرمایه ایران فراهم می‌کنند، اما ترجمه این دقت آماری به عملکرد برتر پرتفوی، مشروط به هم‌راستاسازی تابع زیان الگوریتم با اهداف مدیریت ریسک سبد دارایی و لحاظ نمودن ساختار کوواریانس است.

کلیدواژه‌ها: پیش‌بینی بتا؛ یادگیری ماشین؛ ریسک سیستماتیک؛ پرتفوی حداقل واریانس؛ تخصیص دارایی.

استناددهی: گوهری نژاد، عرفان و عابدی فر، پژمان. (۱۴۰۵). تخمین ریسک سیستماتیک (بتا): رویکردی مبتنی بر یادگیری ماشین در بورس اوراق بهادار تهران.*چشم انداز مدیریت مالی، ۱۶(۳)،۲۸-۵۶.*

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

تخمین دقیق ریسک سیستماتیک که در ادبیات مالی و مدل قیمت‌گذاری دارایی‌های سرمایه‌ای[1] (CAPM) با ضریب «بتا» شناخته می‌شود، یکی از ارکان اساسی در تصمیم‌گیری‌های سرمایه‌گذاری، ارزیابی عملکرد پرتفوی، محاسبه هزینه سرمایه و مدیریت ریسک به شمار می‌رود. بتا نشان می‌دهد بازده یک دارایی تا چه اندازه نسبت به نوسانات بازار حساس است. با وجود جایگاه محوری این مفهوم در نظریه و عمل، برآورد و به‌ویژه پیش‌بینی دقیق آن همواره با چالش‌های نظری و تجربی جدی مواجه بوده است. بر اساس مفروضات سنتی، بتای سهام غالباً به عنوان یک پارامتر ثابت در نظر گرفته شده و عمدتاً از طریق رگرسیون حداقل مربعات معمولی[2] (OLS) با استفاده از داده‌های تاریخی برآورد می‌شود. با این حال، شواهد تجربی نشان می‌دهند که بتا در واقعیت پارامتری پویا و زمان‌متغیر است که تحت تأثیر عوامل متعددی از جمله ویژگی‌های بنیادین شرکت، ساختار سرمایه، شرایط نقدشوندگی و تغییرات اقتصاد کلان قرار دارد (Andersen et al., 2006; Bali et al., 2017; Bollerslev et al., 1988).

در بازارهای نوظهور مانند بورس اوراق بهادار تهران، این چالش‌ها ابعاد پیچیده‌تری به خود می‌گیرند. افزون بر این، شواهد اخیر درباره اقتصاد ایران نشان می‌دهد که نوسان‌پذیری بازار سهام و رابطه آن با نااطمینانی‌های سیاستی، رفتاری زمان‌متغیر و وابسته به افق زمانی دارد؛ به‌گونه‌ای که اثر نااطمینانی سیاست اقتصادی بر بازار سهام در کوتاه‌مدت ممکن است با الگوی مشاهده‌شده در افق‌های میان‌مدت و بلندمدت متفاوت باشد (Taheri Bazkhaneh & Sadrara, 2026). وجود عواملی نظیر نویز بالای داده‌ها، توقف‌های معاملاتی مکرر، عدم هم‌زمانی معاملات و محدودیت‌های نقدشوندگی باعث می‌شود که برآوردهای حاصل از مدل‌های خطی و سنتی مبتنی بر پنجره‌های غلتان[3] کوتاه‌مدت، با خطای اندازه‌گیری، تورش و ناپایداری قابل‌توجهی همراه باشند. رویکردهای کلاسیک، اگرچه ساده و رایج هستند، اما به طور ضمنی فرض می‌کنند که رابطه میان سهم و بازار، خطی و مستقل از اطلاعات مقطع‌عرضی شرکت است. در نتیجه، این روش‌ها در شناسایی الگوهای غیرخطی و اثرات تعاملی میان متغیرهای شرکتی و بازار ناتوان بوده و در مواجهه با پویایی‌های بازارهای مالی مدرن، قدرت پیش‌بینی برون‌نمونه‌ای[4] پایینی ارائه می‌دهند.

در ادبیات مالی ایران، تخمین دقیق ریسک سیستماتیک (بتا) همواره به دلیل پیچیدگی‌های ساختاری و محدودیت‌های روش‌های سنتی، یکی از دغدغه‌های اصلی پژوهشگران و مدیران پرتفوی بوده است (Mohammadi et al., 2007). تلاش‌های پیشین برای عبور از مدل‌های کلاسیک، از به‌کارگیری رگرسیون‌های ناپارامتریک تا ترکیب تئوری خاکستری با مدل‌های قیمت‌گذاری، همگی مؤید این نکته‌اند که روش‌های خطی سنتی قادر به بازنمایی کامل پویایی ریسک نیستند و نیاز به ابزارهای منعطف‌تر به‌شدت احساس می‌شود (Babaei Fallah et al., 2022; Saidi & Ramesheh, 2011). با توجه به محدودیت‌های ذاتی اقتصادسنجی سنتی در شناسایی الگوهای پیچیده مالی، در سال‌های اخیر استفاده از روش‌های نوین مبتنی بر هوش مصنوعی و یادگیری ماشین با استقبال گسترده‌ای مواجه شده است. الگوریتم‌های یادگیری ماشین[5] به دلیل انعطاف‌پذیری تابعی، توانایی پردازش حجم عظیمی از داده‌های سری‌زمانی و مقطعی، شناسایی روابط غیرخطی پیچیده و مقاومت بیشتر در برابر داده‌های پرت، پتانسیل بالایی برای غلبه بر این محدودیت‌ها دارند (Gu et al., 2020). در ادبیات مالی ایران نیز شواهد جدید نشان می‌دهد که ترکیب روش‌های یادگیری ماشین و الگوریتم‌های پیشرفته، می‌تواند عملکرد بهینه‌سازی

[1] Capital Asset Pricing Model
[2] Ordinary Least Squares
[3] Rolling Window
[4] Out-of-Sample
[5] Machine Learning

پرتفوی و کنترل ریسک را به‌طور معناداری بهبود بخشد (DehghanManshadi et al., 2026; Tondnevis and Valamehr.,2025). این روش‌ها به جای تحمیل یک ساختار خطی از پیش تعیین‌شده، اجازه می‌دهند تا مدل، ساختار بهینه را از درون داده‌ها استخراج کند. با این وجود، اگرچه مطالعات اخیر در سطح بین‌المللی نظیر دروبتز و همکاران[1]، ن شان داده‌اند که این الگوریتم‌ها در پیش‌بینی متغیرهای مالی کارایی اثربخشی دارند، اما ارزیابی نظام‌مند آن‌ها در پیش‌بینی برون‌نمونه‌ای بتا با بهره‌گیری از مجموعه‌ای غنی از اطلاعات مقطع‌عرضی در بازار سهام ایران همچنان با خلأ پژوهشی مواجه است.

در همین راستا، پژوهش حاضر تلاش می‌کند با تغییر رویکرد از «تخمین درون‌نمونه‌ای» به «پیش‌بینی برون‌نمونه‌ای»، دقت پیش‌بینی بتای تحقق‌یافته آتی سهام در بورس اوراق بهادار تهران را ارتقا بخشد. هدف اصلی این پژوهش، مقایسه جامع و کنترل‌شده عملکرد برآوردگرهای متعارف بتا با خانواده‌های متنوعی از مدل‌های یادگیری ماشین، به‌طور مشخص مدل‌های خطی منظم‌شده[2] (Elastic Net)، مدل‌های درختی و تجمیعی[3] (Random Forest, XGBoost, GBRT) و شبکه‌های عصبی[4] (MLP) است. این مطالعه با بومی‌سازی متغیرهای پیش‌بین، استفاده از چارچوب ارزیابی غلتان و به‌کارگیری معیارهای دقیق ارزیابی اقتصادی و آماری، به دنبال تبیین این موضوع است که بهره‌گیری از ابزارهای داده‌محور تا چه میزان بر دقت پیش‌بینی ریسک سیستماتیک و عملکرد پرتفوی‌های سرمایه‌گذاری اثرگذار است. نتایج این پژوهش ضمن کاهش فاصله میان ادبیات نظری قیمت‌گذاری دارایی‌ها و ابزارهای نوین یادگیری ماشین، شواهد تجربی مستحکمی فراهم می‌آورد تا تحلیل‌گران، مدیران پرتفوی و فعالان بازار سرمایه ابزاری کارآمدتر برای مدیریت ریسک در اختیار داشته باشند.

ادامه این مقاله به شرح زیر سازمان‌دهی شده است: در بخش دوم، مبانی نظری و پیشینه پژوهش‌های مرتبط داخلی و خارجی مورد بررسی قرار می‌گیرد. بخش سوم به معرفی دقیق روش‌شناسی پژوهش، مدل‌ها و نحوه استخراج داده‌ها اختصاص دارد. در بخش چهارم، تحلیل داده‌ها و یافته‌های تجربی حاصل از پیاده‌سازی مدل‌ها ارائه می‌شود و در نهایت، بخش پنجم به بحث، نتیجه‌گیری و ارائه پیشنهادهای کاربردی می‌پردازد.

۲. مبانی نظری و پیشینه پژوهش

ریسک سیستماتیک بخش تفکیک‌ناپذیر نوسان‌پذیری بازده دارایی‌هاست که ناشی از شوک‌های کلان بازار بوده و با تنوع‌بخشی پرتفوی قابل حذف نیست. ضریب بتا به‌عنوان معیار استاندارد سنجش این ریسک، حساسیت بازده یک دارایی نسبت به بازده بازار را اندازه‌گیری می‌کند (Sharpe, 1964). این شاخص نقشی محوری در قیمت‌گذاری دارایی‌ها، مدیریت ریسک و تعیین هزینه سرمایه دارد (Berk & Van Binsbergen, 2016; Cochrane, 2011). با این حال، از آنجا که نسخه اصلی CAPM یک مدل ایستا و تک‌دوره‌ای است، کاربرد طبیعی آن بر این فرض ضمنی استوار است که بتا در طول زمان ثابت باقی می‌ماند. جگاناتان و وانگ[5] با ارائه نسخه شرطی CAPM نشان داده‌اند که لحاظ‌کردن شرایط متغیر اقتصادی می‌تواند محدودیت‌های مدل ایستا را در تبیین بازده‌های مقطعی تا حدی برطرف کند. (Jagannathan & Wang, 1996)

با وجود اهمیت بنیادین بتا، برآورد سنتی آن از طریق رگرسیون حداقل مربعات معمولی (OLS) به دلیل فرض ثبات پارامترها در طول زمان با چالش جدی مواجه است. شواهد تجربی نشان می‌دهند که بتا ماهیتی پویا و زمان‌متغیر دارد که تحت تأثیر چرخه‌های تجاری و ویژگی‌های بنیادی شرکت تغییر می‌کند (Bollerslev et al.,1988). محدودیت

[1] Drobetz et al
[2] Regularized Linear Models
[3] Tree-based and Ensemble Models
[4] Artificial Neural Networks
[5] Jagannathan and Wang

اصلی این برآوردگرهای پنجره‌ای، موازنه بایاس—واریانس است؛ به‌گونه‌ای که انتخاب طول پنجره مناسب همواره با دشواری همراه بوده و برآوردهای حاصل به مشاهدات پرت حساس هستند. برای بهبود این وضعیت، راه‌حل‌هایی نظیر انقباض بتاهای نویزی به سمت پیشین‌های خاص شرکت، مبتنی بر ویژگی‌های بنیادی، مطرح شده است(Cosemans et al., 2016). همچنین شواهد کیم، کوراچیک و نوهیرل[1] و کلی، موسکویتز و پرویت[2] مؤید آن است که متغیرهایی مانند اندازه، ارزش دفتری به بازار، سودآوری و اهرم می‌توانند افزون بر بتای تاریخی، پویایی بتای شرکت را توضیح دهند (Kim, Korajczyk, & Neuhierl, 2020; Kelly, Moskowitz, & Pruitt, 2021). این تغییرپذیری زمانی بتا تنها محدود به بازار آمریکا نیست و شواهد مشابهی در بازارهای دیگر نیز گزارش شده است (Faff et al., 2003). مطالعات متأخر با تأکید بر عدم کفایت روش‌های کلاسیک، استفاده از متغیرهای ویژگی‌محور و مدل‌های پیش‌بینی‌محور را برای تعدیل دقت برآورد بتا ضروری می‌دانند (Hollstein et al., 2019; Welch, 2022). نکته مفهومی کلیدی در اینجا آن است که رویکردهای سنتی اغلب به برآورد بتای تاریخی یا تحقق‌یافته گذشته ختم می‌شوند، در حالی که نیاز عملی مدیران پرتفوی و تحلیلگران، پیش‌بینی بتای تحقق‌یافته آینده است؛ تمایزی که ضرورت به‌کارگیری مدل‌های پویا و پیش‌بینی‌محور را آشکار می‌سازد.

در واکنش به محدودیت‌های اقتصادسنجی کلاسیک، الگوریتم‌های یادگیری ماشین به دلیل توانایی در مدل‌سازی روابط غیرخطی، پردازش داده‌های پربعد و شناسایی اثرات تعاملی پیچیده، به ابزاری قدرتمند در قیمت‌گذاری دارایی‌ها بدل شده‌اند (Gu et al., 2020; Kozak et al., 2020). در حالی که مدل‌های پارامتریک سنتی نیازمند فرض‌های سخت‌گیرانه‌ای درباره فرم تابعی هستند، روش‌های یادگیری ماشین با انعطاف‌پذیری بیشتر و امکان ارزیابی برون‌نمونه‌ای، ظرفیت مدل‌سازی روابط پیچیده را فراهم می‌کنند؛ با این حال، همین انعطاف‌پذیری می‌تواند خطر بیش‌برازش را افزایش دهد و ضرورت اعتبارسنجی و ارزیابی برون‌نمونه‌ای را پررنگ‌تر کند (Freyberger et al., 2020). با این حال، بخش عمده کاربرد یادگیری ماشین در ادبیات قیمت‌گذاری دارایی بر پیش‌بینی بازده متمرکز بوده و توجه کمتری به پیش‌بینی ویژگی‌های ریسک، به‌ویژه بتای سیستماتیک، شده است. در ارتباط مستقیم با پیش‌بینی بتا، ژوروفسکی[3] و همکاران نشان داده‌اند که مدل‌های درختی از برآوردهای متعارف پنجره غلتان و مدل‌های خطی عملکرد بهتری دارند (Zhurowski et al., 2020). هوانگ[4] نیز با بهره‌گیری از یادگیری ماشین و بر پایه ویژگی‌های بنیادی شرکت نظیر اندازه، نسبت ارزش دفتری به بازار و بازده سود تقسیمی، دقت پیش‌بینی بتا را به‌طور معناداری ارتقا داده است؛ یافته‌ای که بر ظرفیت اطلاعات مقطعی بنیادی فراتر از بتای تاریخی تأکید می‌کند (Huang, 2012). همچنین مندوزا و اونیشچنکو[5] در بازارهای دارای معاملات کم‌تواتر، ظرفیت روش‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی، را در کاهش خطای پیش‌بینی بتا تأیید کرده‌اند (Mendoza & Onishchenko, 2026). افزون بر این، ژائو[6] و همکاران با استناد به ماهیت تصادفی بازده‌های مالی، نشان داده‌اند که پیش‌بینی نقطه‌ای صرفاً ناکافی است و رویکردهای پیش‌بینی احتمالاتی، اطلاعاتی جامع‌تر درباره عدم‌قطعیت پیش‌بینی فراهم می‌کنند؛ رویکردی که در تحلیل حاضر نیز به‌عنوان مبنای مقایسه‌ای لحاظ شده است (Zhao et al., 2022).

در حوزه پیش‌بینی ریسک، مطالعات اخیر نشان داده‌اند که الگوریتم‌های درختی مانند «جنگل تصادفی» و «تقویت گرادیان» در پیش‌بینی نوسان و ریسک سیستماتیک، عملکردی به‌مراتب دقیق‌تر از مدل‌های سنتی نظیر GARCH یا OLS دارند (Bucci, 2020). این برتری در بازارهای دارای نویز بالا و ساختارهای ناپایدار، به‌ویژه برای سهام کوچک و کم‌نقدشونده، چشمگیرتر است.

[1] Kim, Korajczyk, and Neuhierl
[2] Kelly, Moskowitz, & Pruitt
[3] Jourovski
[4] Huang
[5] Mendoza and Onishchenko
[6] Zhao

مطالعه پیشگامانه دروبتز و همکاران (Drobetz et al., 2025) نشان می‌دهد که ترکیب اطلاعات تاریخی با ویژگی‌های مقطعی شرکت (شامل متغیرهای بنیادی، نقدشوندگی و اهرم مالی) در چارچوب الگوریتم‌های یادگیری ماشین، منجر به پیش‌بینی‌های به مراتب دقیق‌تری از بتای آینده می‌شود. با وجود این پیشرفت‌های بین‌المللی، بورس اوراق بهادار تهران به‌عنوان بازاری نوظهور با ویژگی‌های خاص (محدودیت دامنه نوسان، وجود صف‌های معاملاتی و نویز شدید ریزساختار)، شاهد مسیر تکاملی متفاوتی در ادبیات پژوهشی بوده است. در نخستین مطالعات داخلی، تمرکز بر اثبات فرض ثبات بتا با استفاده از روش‌های خطی کلاسیک بود. محققان با بهره‌گیری از روش کمترین مربعات معمولی (OLS)، فرضیه ثبات ضریب بتا را برای سهام انفرادی و پرتفوی‌ها مورد تأیید قرار دادند (Haji Bozorgi & Akhoundian, 2011; Tehrani & Chit-Sazan, 2004). با این حال، شواهد بعدی بر ناکارآمدی الگوهای سنتی با فرض بتای ثابت دلالت دارند؛ به‌طوری که حیدری و حیدرپور با بسط الگوی سنتی و تحلیل داده‌های صنایع، تغییرپذیری زمانی بتا را مستند کرده و نشان دادند که فرض بتای ثابت به نتایج گمراه‌کننده‌ای در پیش‌بینی بازده آتی منجر می‌شود (Heydari & Heidarpour, 2017). در راستای رفع این محدودیت، باقرزاده و سالم با بهره‌گیری از فیلتر کالمن و همبستگی‌های شرطی پویا، و ثابتی و همکاران با استفاده از مدل‌های خودرگرسیونی واریانس ناهمسان شرطی چندمتغیره (MGARCH)، گام‌هایی برای برآورد پویای بتا برداشتند (Bagherzadeh & Salem, 2015; Sabeti et al., 2022). همچنین محمدی و همکاران با مقایسه روش‌های مختلف تخمین بتا در بورس تهران بر حساسیت نتایج به انتخاب روش برآورد تأکید کرده‌اند (Mohammadi et al., 2007). با این حال، مدل‌های اقتصادسنجی یادشده عمدتاً بر پویایی‌های سری زمانی متکی بوده و توانایی تحلیل هم‌زمان طیف گسترده‌ای از ویژگی‌های بنیادی مقطعی شرکت‌ها را ندارند. در سال‌های اخیر، گرایش به سمت الگوریتم‌های هوشمند در بازار ایران افزایش یافته است؛ چنان‌که حیدری‌دلویی و همکاران با استفاده از مدل ترکیبی تقویت گرادیان پیشرفته (XGBoost) بهینه‌شده با الگوریتم ژنتیک و بهره‌گیری از روش توضیح‌پذیری SHAP ، به پیش‌بینی جهت شاخص کل بورس تهران با دقت ۸۴ درصد دست یافته و ناکارایی بازار در سطوح ضعیف و نیمه‌قوی را مستند کرده‌اند (Heidari Dalooei et al., 2026). در راستای مباحث مدیریت ریسک و بتا، تندنویس و والامهر نیز با رویکرد پیش‌بینی احتمالاتی و بهینه‌سازی استوار، به ساخت پرتفوی بتای هوشمند در بورس تهران پرداخته و نشان داده‌اند که در نظر گرفتن عدم‌قطعیت پارامترها می‌تواند نسبت شارپ پرتفوی را به‌طور معناداری بهبود بخشد (Tondnevis & Valamehr, 2025). با این حال، پژوهشی که به‌طور سیستماتیک به پیش‌بینی برون‌نمونه‌ای بتای تحقق‌یافته با استفاده از طیف گسترده‌ای از متغیرهای ویژگی‌محور و الگوریتم‌های یادگیری ماشین در بازار ایران پرداخته باشد، مشاهده نمی‌شود. ویژگی‌های نهادی و معاملاتی خاص بورس تهران، تعمیم مستقیم شواهد بازارهای توسعه‌یافته را نامطمئن می‌سازد. بر این اساس، پرسش اصلی پژوهش این است که ترکیب بتای تاریخی با ۶۹ متغیر ویژگی‌محور و الگوریتم‌های یادگیری ماشین چه نقشی در ارتقای دقت پیش‌بینی برون‌نمونه‌ای بتای تحقق‌یافته شش‌ماهه شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران ایفا می‌کند و تا چه حد به خلق ارزش افزوده اقتصادی در پرتفوی‌ها منجر می‌گردد.

چارچوب نظری و سؤال‌های پژوهش: چارچوب مفهومی این پژوهش بر پایه گذار استراتژیک از «تخمین‌های درون‌نمونه‌ای خطی» به سمت «پیش‌بینی‌های برون‌نمونه‌ای غیرخطی» بنا شده است. بر اساس این چارچوب نظری، ریسک سیستماتیک (بتا) به عنوان یک متغیر ایستا قلمداد نمی‌شود، بلکه تابعی پیچیده و غیرخطی از تعاملات مقطعی و متقابل میان متغیرهای حسابداری (بنیادی)، متغیرهای ریزساختار بازار (نقدشوندگی و مومنتوم) و برآوردهای تاریخچه‌ای بازده است. مدل‌های یادگیری ماشین به دلیل برخورداری از معماری انعطاف‌پذیر و عدم نیاز به مفروضات محدودکننده کلاسیک، قادرند این تعاملات پنهان و الگوهای غیرخطی را شناسایی کرده و دقت پیش‌بینی بتای آتی را در مقایسه با روش‌های سنتی ارتقا بخشند (Gu et al., 2020; Drobetz et al., 2025). بهبود در دقت پیش‌بینی

بتا، مستقیماً به کاهش سوگیری در تخمین ماتریس کوواریانس، کاهش نوسانات پرتفوی و در نهایت ارتقای عملکرد اقتصادی استراتژی‌های سرمایه‌گذاری منجر خواهد شد (Berk & van Binsbergen, 2016; Leippold et al., 2022). بر مبنای این چارچوب مفهومی، سؤالات اساسی پژوهش به شرح زیر تدوین شده‌اند:

۱. مدل‌های یادگیری ماشین (مبتنی بر درخت، شبکه‌های عصبی و رگرسیون‌های منظم‌شده) تا چه میزان قادرند خطای پیش‌بینی برون‌نمونه‌ای بتای سهام (بر مبنای معیار میانگین مربعات خطای ارزش‌وزنی) را در بورس اوراق بهادار تهران در مقایسه با مدل‌های سنتی و پایه کاهش دهند؟

۲. کدام‌یک از معماری‌های الگوریتمی و کدام دسته از ویژگی‌های پیش‌بین (بنیادی–حسابداری یا قیمت–بازار) بیشترین سهم و اهمیت نسبی را در ارتقای دقت پیش‌بینی مقطعی بتا دارا هستند؟

۳. به‌کارگیری بتاهای پیش‌بینی‌شده مبتنی بر یادگیری ماشین، چه تأثیری بر عملکرد اقتصادی و سنجه‌های ریسک–بازده پرتفوی‌های حداقل واریانس و بازارخنثی در مقایسه با الگوهای کلاسیک بر جای می‌گذارد؟

در ادامه، با بررسی روش‌شناسی استفاده شده در مطالعه، که برگرفته از رویکردهای نوین در قیمت‌گذاری دارایی‌هاست، به پاسخ به سؤالات فوق پرداخته خواهد شد.

۳. روش‌شناسی پژوهش

طرح تحقیق: پژوهش حاضر از نظر هدف، یک تحقیق کاربردی و از حیث ماهیت و روش، در زمره پژوهش‌های توصیفی–همبستگی و پس‌رویدادی (استفاده از داده‌های تاریخی) قرار می‌گیرد. با توجه به پارادایم اثبات‌گرایی حاکم بر پژوهش‌های مالی کمی، این مطالعه با بهره‌گیری از رویکرد استقرایی به بررسی و مقایسه عملکرد الگوهای نوین یادگیری ماشین در برابر روش‌های متعارف اقتصادسنجی برای پیش‌بینی ریسک سیستماتیک (بتا) می‌پردازد.

ابزار و روش گردآوری داده‌ها: داده‌های مورد نیاز این پژوهش از پایگاه‌های معتبر شامل سامانه کدال، شرکت مدیریت فناوری بورس تهران، ره‌آورد نوین و بانک مرکزی گردآوری شده‌اند. فرآیند پیش‌پردازش داده‌ها شامل همگام‌سازی تاریخ‌ها و حذف مشاهدات پرت از طریق تکنیک برش صدکی[1] بوده است. همچنین، برای مدیریت داده‌های گمشده در ویژگی‌های پیش‌بین و جلوگیری از حذف مشاهدات، همسو با مطالعات پیشرو (Drobetz et al., 2025)، از رویکرد رگرسیون شرطیِ مبتنی بر الگوهای داده‌های مفقود استفاده شده است. بر این اساس، داده‌ها در پنجره‌های غلتان ۶۰ ماهه دسته‌بندی شده و مقادیر مفقود هر متغیر با استفاده از بزرگ‌ترین نمونه کامل از مشاهدات موجود در همان بازه و بر اساس برآوردگرهای رگرسیونی شرطی متغیرهای دیگر برآورد و جایگزین گردیدند؛ به‌گونه‌ای که هیچ‌گونه نشت اطلاعات از آینده به درون دوره‌های آموزش و آزمون راه نیافته است. برای آموزش مدل‌های یادگیری ماشین، از مجموعه‌ای گسترده شامل ۶۹ متغیر استفاده شده است که ویژگی‌های مختلف شرکت‌ها از جمله مشخصه‌های حسابداری، متغیرهای مبتنی بر بازار و بتای تاریخی را پوشش می‌دهند. این متغیرها به عنوان پیش‌بینی‌کننده‌ها[2] در مدل‌ها به کار گرفته شده‌اند (Gu et al., 2020; Drobetz et al., 2025). جدول ۱، فهرست کامل این متغیرها به همراه تعریف عملیاتی هر یک را نمایش می‌دهد.

جدول ۱. تعاریف عملیاتی و نمادگذاری متغیرهای پیش‌بین

Table1. Variable Descriptions and Definitions

شماره	نماد	نام متغیر (توصیف)	تعریف
۱	OLS_3M_D	بتای کوتاه‌مدت	برآورد نمونه‌ای بتا از رگرسیون‌های غلتان با استفاده از پنجره ۳ ماهه بازده‌های روزانه
۲	OLS_1Y_D	بتای میان‌مدت	برآورد نمونه‌ای بتا از رگرسیون‌های غلتان با استفاده از پنجره ۱ ساله بازده‌های روزانه

[1] Winsorization
[2] Features

۳	OLS_5Y_M	بتای بلندمدت	برآورد نمونه‌ای بتا از رگرسیون‌های غلتان با استفاده از پنجره ۵ ساله بازده‌های ماهانه
۴	AGE	سن	لگاریتم تعداد سال‌های سپری شده از زمان اولین حضور در بورس اوراق بهادار تهران
۵	AT	کل دارایی‌ها	لگاریتم ارزش دفتری کل دارایی‌ها
۶	BM	نسبت ارزش دفتری به بازار	لگاریتم نسبت ارزش دفتری به ارزش بازار حقوق صاحبان سهام
۷	CAPTURN	گردش سرمایه	لگاریتم نسبت فروش خالص به ارزش دفتری (با وقفه) کل دارایی‌ها
۸	DIVPAY	نسبت پرداخت سود سهام	نسبت سود سهام پرداخت‌شده در طول سال مالی گذشته به سود خالص
۹	EP COVAR	هم‌بستگی در سود	ضریب برآوردی در رگرسیون سری زمانی (OLS) نسبت‌های سود–به–قیمت سهم بر نسبت سود–به–قیمت بازار در ۳ سال گذشته
۱۰	EP VAR	نوسان‌پذیری در سود	لگاریتم انحراف معیار نسبت‌های سود–به–قیمت در ۳ سال گذشته
۱۱	FINLEV	اهرم مالی	لگاریتم نسبت ارزش دفتری کل دارایی‌ها به ارزش بازار حقوق صاحبان سهام
۱۲	FXDCOS	هزینه‌های ثابت فروش	لگاریتم نسبت (هزینه‌های فروش، عمومی و اداری + هزینه تبلیغات) به فروش خالص
۱۳	INVEST	سرمایه‌گذاری	رشد سال‌به‌سال ارزش دفتری کل دارایی‌ها
۱۴	NOA	دارایی‌های عملیاتی خالص	نسبت (دارایی‌های عملیاتی منهای بدهی‌های عملیاتی) به ارزش دفتری کل دارایی‌ها
۱۵	OPACCR	اقلام تعهدی عملیاتی	نسبت (تغییرات در سرمایه در گردش غیرنقدی منهای استهلاک) به ارزش دفتری کل دارایی‌ها
۱۶	OPLEV	اهرم عملیاتی	لگاریتم نسبت هزینه‌های عملیاتی (مجموع بهای تمام شده کالای فروش رفته و هزینه‌های فروش، عمومی و اداری) به ارزش بازار کل دارایی‌ها
۱۷	PPE	نسبت تغییرات PPE به دارایی	نسبت تغییرات در اموال، ماشین‌آلات و تجهیزات (PPE) به ارزش دفتری (با وقفه) کل دارایی‌ها
۱۸	PROF	سودآوری	نسبت سود ناخالص به ارزش دفتری حقوق صاحبان سهام
۱۹	ROA	بازده دارایی‌ها	نسبت سود قبل از اقلام غیرمترقبه به ارزش دفتری کل دارایی‌ها
۲۰	ROE	بازده حقوق صاحبان سهام	نسبت سود قبل از اقلام غیرمترقبه به ارزش دفتری حقوق صاحبان سهام
۲۱	RON	بازده دارایی‌های عملیاتی خالص	نسبت سود عملیاتی پس از استهلاک به دارایی‌های عملیاتی خالص (با وقفه)
۲۲	SALESTOASSETS	نسبت فروش به دارایی‌ها	لگاریتم نسبت فروش خالص به ارزش دفتری کل دارایی‌ها
۲۳	SALESTOPRICE	نسبت فروش به قیمت	لگاریتم نسبت فروش خالص به ارزش بازار حقوق صاحبان سهام
۲۴	SGATOSALES	نسبت SGA به فروش	لگاریتم نسبت هزینه‌های فروش، عمومی و اداری به فروش خالص
۲۵	ILLIQ	عدم نقدشوندگی	نسبت قدر مطلق بازده ماهانه به ارزش ریالی معاملات ماهانه
۲۶	INTERMOM	مومنتوم میانی	بازده مازاد از ماه ۱۲– تا ماه ۷–
۲۷	IVOL	نوسان‌پذیری ایدیوسنکراتیک	لگاریتم انحراف معیار پسماندهای روزانه از مدل ۳ عاملی در ماه جاری
۲۸	LTREV	بازگشت بلندمدت	بازده مازاد از ماه ۳۶– تا ماه ۱۳–
۲۹	ME	اندازه	لگاریتم ارزش بازار حقوق صاحبان سهام
۳۰	MOM	مومنتوم	بازده مازاد از ماه ۱۲– تا ماه ۲–
۳۱	RELPRC	قیمت نسبی	نسبت قیمت پایان ماه به بالاترین قیمت روزانه آن در طول سال گذشته
۳۲	STREV	بازگشت کوتاه‌مدت	بازده مازاد ماه جاری
۳۳	TO	گردش معاملات	لگاریتم ارزش ریالی معاملات ماهانه
۳۴	IND	طبقه‌بندی صنعت	طبقه‌بندی صنایع که منجر به ۳۶ متغیر مجازی صنعت می‌شود

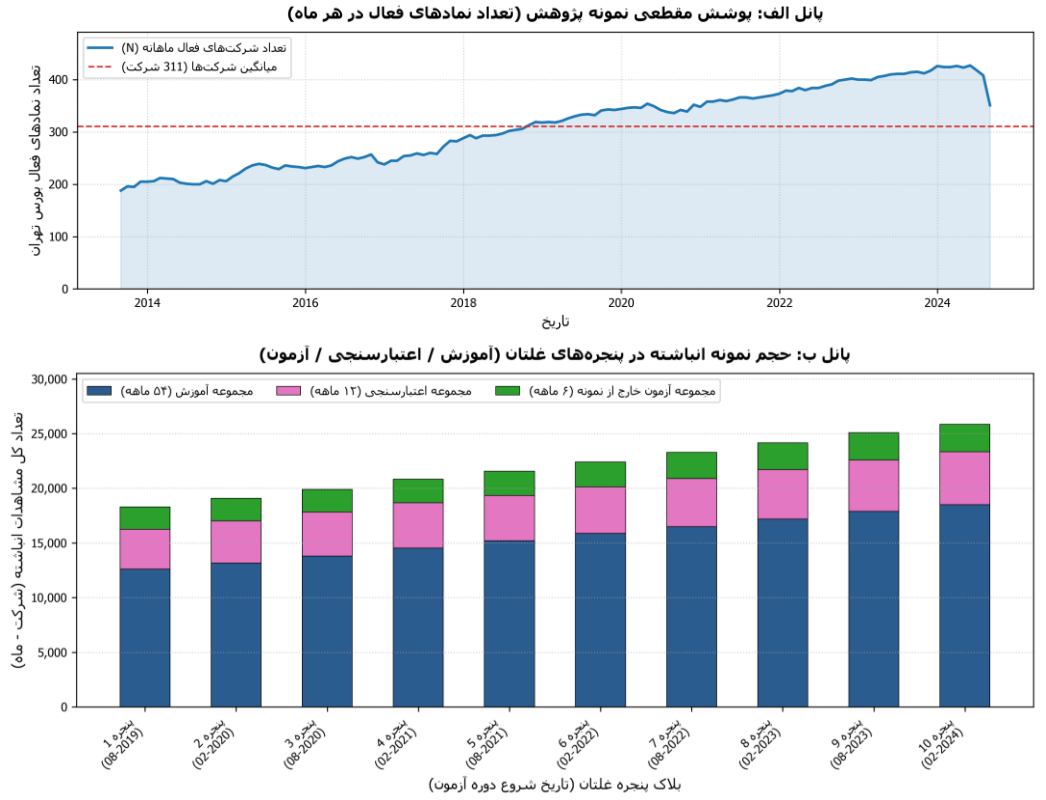
یادداشت جدول ۱: متغیرهای حسابداری و بنیادی (ردیف‌های ۴ تا ۲۴) به‌منظور پیشگیری از تورش نگاه به آینده با وقفه زمانی یک‌ماهه/یک‌دوره‌ای نسبت به تاریخ پایان دوره مالی محاسبه و در ماتریس متغیرهای پیش‌بین اعمال شده‌اند.

روایی و پایایی ابزار: از آنجا که این پژوهش مبتنی بر داده‌های ثانویه است، روایی ابزار از طریق استخراج متغیرها بر مبنای مبانی نظری معتبر و فرمول‌های استاندارد مالی تأمین شده است. پایایی داده‌ها نیز به دلیل استفاده از اطلاعات صورت‌های مالی حسابرسی‌شده و داده‌های رسمی و معاملاتی ثبت‌شده در بورس اوراق بهادار تهران، مورد تأیید است.

جامعه آماری، حجم نمونه و روش نمونه‌گیری: جامعه آماری این پژوهش شامل کلیه شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران در بازه زمانی ۱۳۹۱ تا ۱۴۰۴ می‌باشد. جهت تضمین کیفیت داده‌ها و رفع عوارض ناشی از ساختار بازار، شرکت‌های سرمایه‌گذاری و واسطه‌گری مالی و همچنین نمادهای دارای توقف معاملاتی طولانی‌مدت از نمونه حذف گردیدند. با توجه به شرایط ورود، خروج و تعلیق نمادها در طول زمان، پنل نهایی پژوهش به‌صورت نامتوازن شکل گرفته است.

شکل ۱. *آمار توصیفی و ساختار حجم نمونه پژوهش*

Figure 1. *Descriptive statistics and sample size structure of the study*



همان‌طور که در شکل (۱- الف) ملاحظه می‌شود، تعداد نمادهای فعال ماهانه بین ۱۸۸ تا ۴۲۷ شرکت در نوسان بوده و میانگین پوشش مقطعی بازار برابر با ۳۱۱ شرکت در هر ماه است. جهت رعایت ضوابط ارزیابی خارج از نمونه و جلوگیری از تورش نگاه به آینده، ساختار ارزیابی بر اساس الگوی پنجره غلتان با ترکیب (۵۴ ماه آموزش، ۱۲ ماه اعتبارسنجی، ۶ ماه شکاف و ۶ ماه آزمون) پیاده‌سازی گردید.

بر این اساس، در قالب ۱۰ بلاک غلتان متوالی، حجم کل مشاهدات انباشته در هر پنجره آموزش بین ۱۲,۷۰۴ تا ۱۸,۵۵۵ مشاهده (با میانگین ۱۵,۲۸۶ سهم–ماه)، در دوره اعتبارسنجی بین ۳,۵۴۹ تا ۴,۸۲۳ مشاهده (با میانگین ۴,۱۱۰ سهم–ماه) و در دوره آزمون خارج از نمونه بین ۲,۱۰۲ تا ۲,۵۱۲ مشاهده (با میانگین ۲,۳۹۲ سهم–ماه) متغیر بوده است. این حجم از مشاهدات انباشته، توان آماری کافی و پایدار جهت آموزش و تیونینگ ابرپارامترهای مدل‌های یادگیری ماشین را فراهم ساخته است.

معرفی روش تحلیل داده‌ها: متغیر وابسته پژوهش، بتای تحقق‌یافته شش‌ماهه سهام است. این متغیر برای هر شرکت و در هر تاریخ مبنا، با استفاده از بازده‌های روزانه سهم و شاخص بازار طی شش ماه بعد محاسبه می‌شود.

بازده‌های روزانه بر اساس تغییرات نسبی قیمت‌های تعدیل‌شده محاسبه شده‌اند. بتای تحقق‌یافته از نسبت کوواریانس بازده مازاد سهم و بازار به واریانس بازده مازاد بازار، مطابق رابطه (۱)، به‌دست می‌آید:

$$\beta_{i,t} = \frac{Cov(R_{i,t}, R_{m,t})}{Var(R_{m,t})}$$ رابطه (۱)

در رابطه (۱) $\beta_{i,t}$ بتای تحقق‌یافته سهم i در تاریخ t، $R_{i,t}$ بازده مازاد روزانه سهم و $R_{m,t}$ بازده مازاد روزانه شاخص بازار است. برای هر تاریخ مبنا، کوواریانس و واریانس یادشده با استفاده از داده‌های روزانه شش ماه آتی محاسبه می‌شوند. همچنین، بتا تنها زمانی برآورد می‌شود که حداقل ۶۰ مشاهده روزانه معتبر در پنجره شش‌ماهه مربوط در دسترس باشد.

برای آموزش مدل‌های یادگیری ماشین و پیش‌بینی این متغیر، از مجموعه‌ای گسترده شامل ۶۹ متغیر استفاده شده است که ویژگی‌های مختلف شرکت‌ها از جمله مشخصه‌های حسابداری، متغیرهای مبتنی بر بازار و بتای تاریخی را پوشش می‌دهند (معرفی شده در جدول ۱) . تحلیل داده‌ها در محیط پایتون[1] انجام شده است. ارزیابی مدل‌ها بر اساس ساختار «پنجره غلتان» با گام‌های ۶ ماهه صورت پذیرفت. پیکربندی هر بلوک زمانی به این شرح است: ۵۴ ماه برای نمونه آموزش، ۱۲ ماه برای نمونه اعتبارسنجی (تنظیم ابرپارامترها)، ۶ ماه فاصله زمانی (جهت جلوگیری از سوگیری نگاه به آینده)، و ۶ ماه برای آزمون برون‌نمونه‌ای. انتخاب اندازه این دوره‌ها با اقتباس از چارچوب روش‌شناختی مطالعه دروبتز و همکاران انجام پذیرفته است. با توجه به محدودیت عمق داده‌های تاریخی در بورس اوراق بهادار تهران نسبت به بازارهای توسعه‌یافته، ضمن حفظ نسبت میان دوره‌های آموزش، اعتبارسنجی و آزمون در مطالعه مذکور، طول پنجره‌ها متناسب با داده‌های در دسترس مقیاس‌بندی شد تا ضمن رعایت استانداردهای علمی و حفظ پشتوانه روش‌شناختی، محدودیت‌های داده‌ای بازار داخلی نیز لحاظ گردد .در این پیکربندی، داده‌های دوره آزمون صرفاً برای ارزیابی نهایی عملکرد مدل به‌کار رفتند. همچنین، ترتیب زمانی داده‌ها در تمام مدل‌ها حفظ شد و هیچ‌گونه جابه‌جایی تصادفی نمونه‌ها انجام نگرفت؛ بنابراین، برآورد دقت پیش‌بینی مبتنی بر اطلاعات آینده نبوده و با ساختار واقعی داده‌های مالی سازگار است.

برای انتخاب ابرپارامترهای مدل‌های یادگیری ماشین، در هر یک از بلوک‌های زمانی، جست‌وجوی شبکه‌ای[2] بر روی نمونه آموزش انجام شد و عملکرد ترکیب‌های مختلف ابرپارامترها بر اساس میانگین خطای مربعات وزنی ماهانه در دوره اعتبارسنجی (VW-MSE) ارزیابی گردید. بدین ترتیب، انتخاب ابرپارامترها بدون استفاده از مشاهدات دوره آزمون و با حفظ ساختار زمانی داده‌ها انجام گرفت. فضای جست‌وجوی تعریف‌شده برای هر مدل، اندازه شبکه جست‌وجو و پرتکرارترین پیکربندی منتخب در میان ۱۰ بلوک زمانی در جدول ۲ گزارش شده است.

جدول ۲. *فضای جست‌وجوی ابرپارامترها و تنظیمات منتخب مدل‌ها*

Table 2. *Hyperparameter Search Space and Frequency of Selected Configurations*

مدل	فضای جست‌وجوی ابرپارامترها	اندازه فضای جست‌وجو	پرتکرارترین پیکربندی منتخب	فراوانی در ۱۰ بلوک
ELANET	α: ۰.۶۳۱ – ۰.۰۰۱ ؛ L1-ratio: ۰.۸ – ۰.۲	۷۰	α : ۰.۰۱۷۶ ؛ L1-ratio : ۰.۵	٪۲۰
RF	max_depth: ۶, ۸, ۱۰ min_samples_leaf: ۲۰, ۴۰, ۸۰ max_features: √p, ۰.۵	۱۸	max_depth : ۱۰ min_samples_leaf : ۲۰ max_features : ۰.۵	٪۳۰
GBRT	n_estimators: ۸۰۰, ۱۲۰۰ learning rate: ۰.۰۳, ۰.۰۵ max_depth: ۲, ۳	۱۶	n_estimators : ۸۰۰ learning rate : ۰.۰۳ max_depth : ۳	٪۴۰

[1] Python
[2] Grid Search

	subsample : ۰.۸	subsample: ۰.۷, ۰.۸	
٪۲۰	n_estimators : ۴۰۰ learning rate : ۰.۰۳ max_depth : ۴ min_child_weight : ۱۰ subsample = ۰.۸ ؛ colsample : ۰.۸ λ : ۱ ؛ α : ۰	۳۲	n_estimators: ۴۰۰, ۸۰۰ learning rate: ۰.۰۳ max_depth: ۳, ۴ min_child_weight : ۱۰ subsample : ۰.۸ ؛ colsample: ۰.۸, ۱ λ: ۱, ۱۰ ؛ α: ۰, ۱	XGB
٪۲۰	width : ۱۲۸ ؛ depth : ۲ dropout : ۰.۱ L2 : $۱۰^{-۴}$ ؛ learning rate : ۰.۰۰۱	۳۲	width: ۶۴, ۱۲۸ ؛ depth: ۲,۳ dropout: ۰.۱, ۰.۲ L2:$۱۰^{-۴}$, ۵×۱۰^{-۴} ؛ learning rate: $۱۰^{-۳}$, ۵×۱۰^{-۴}	NN

همان‌گونه که جدول ۲ نشان می‌دهد، فضای جست‌وجوی ابرپارامترها متناسب با ساختار هر مدل تعریف شده و از ۱۶ ترکیب در مدل تقویت گرادیان (GBRT) تا ۷۰ ترکیب در مدل ELANET متغیر بوده است.. در مدل‌های درختی نیز پیکربندی‌های منتخب در طول بلوک‌های زمانی از ثبات نسبی برخوردارند. برای مثال، در مدل تقویت گرادیان (GBRT) ، پیکربندی شامل ۸۰۰ درخت، نرخ یادگیری ۰.۰۳، عمق ۳ و نسبت نمونه‌گیری ۰.۸ در ۴۰ درصد از بلوک‌ها به‌عنوان بهترین ترکیب انتخاب شده است. در مدل RF نیز ترکیب عمق ۱۰، حداقل ۲۰ مشاهده در هر برگ و استفاده از ۵۰ درصد ویژگی‌ها در ۳۰ درصد از بلوک‌ها پرتکرارترین تنظیم بوده است. این الگو نشان می‌دهد که اگرچه انتخاب ابرپارامترها در طول زمان کاملاً ثابت نبوده، ساختار کلی تنظیمات منتخب، به‌ویژه در مدل‌های درختی، از ثبات نسبی برخوردار بوده است.

در این ارزیابی، دو دسته کلی از مدل‌ها با یکدیگر به رقابت می‌پردازند:

۱. **برآوردگرهای مبنا**[1]**:** شامل حداقل مربعات معمولی متحرک[2] ، میانگین متحرک نمایی، بتای برش‌خورده شیب و برآوردگر انقباضی واسیچک[3].

۲. **مدل‌های مبتنی بر یادگیری ماشین:** شامل رگرسیون خطی جریمه‌دار شبکه الاستیک[4]، مدل‌های مبتنی بر درخت شامل جنگل تصادفی، درختان تقویت‌شده گرادیان و اکس‌جی‌بوست[5]، و شبکه‌های عصبی عمیق نظیر پرسپترون چندلایه[6] با توابع فعال‌سازی غیرخطی. به منظور کنترل بیش‌برازش در این مدل‌ها، ابرپارامترها از طریق اعتبارسنجی متقابل بهینه‌سازی شده‌اند.

برای ارزیابی و مقایسه عملکرد مدل‌ها در پیش‌بینی بتای آتی، از معیار آماری «میانگین مربعات خطای ارزش–وزن» استفاده شده است تا خطای شرکت‌های بزرگتر وزن بیشتری در ارزیابی داشته باشد:

$$VWMSE_{t+k|t} = \sum_{i=1}^{N_t} w_{i,t}\left(\beta_{i,t+k}^{R} - \beta_{i,t+k|t}^{F}\right)^2 \quad \text{رابطه (۲)}$$

که در آن $w_{i,t}$ وزن ارزش بازار سهم i در زمان t، $\beta_{i,t+k|t}^{F}$ بتای پیش‌بینی‌شده و $\beta_{i,t+k}^{R}$ بتای تحقق‌یافته است. بااین‌حال، اختلاف میانگین VW-MSE به‌تنهایی برای تعیین معناداری آماری برتری یک مدل کافی نیست. ازاین‌رو، برای مقایسه جفتی مدل‌ها از آزمون دوطرفه دایبولد–ماریانو با تصحیح هاروی–لیبورن–نیوبولد(DM-HLN) استفاده شد (Diebold & Mariano, 1995; Harvey et al., 1997). برای هر جفت مدل A و B، اختلاف زیان ماهانه به‌صورت $d_t^{(A,B)} = VWMSE_t^A - VWMSE_t^B$ تعریف شد. آماره دایبولد–ماریانو اولیه از رابطه زیر به‌دست می‌آید:

[1] Benchmark Models
[2] Rolling OLS
[3] Vasicek Shrinkage Estimator
[4] ElasticNet
[5] XGBoost
[6] Multi-Layer Perceptron (MLP)

رابطه (۳) $$DM = \frac{\bar{d}}{\sqrt{LR\hat{V}(\bar{d})}}$$

که در آن، $\bar{d}$ میانگین اختلاف زیان دو مدل و $LR\hat{V}(\bar{d})$ برآورد واریانس بلندمدت میانگین اختلاف زیان است. از آنجا که به‌دلیل افق پیش‌بینی شش‌ماهه (h=6)، تفاضل زیان پیش‌بینی مدل‌ها در ماه‌های متوالی دارای هم‌پوشانی زمانی بوده و از فرآیند میانگین متحرک MA(5) تبعیت می‌کند، این واریانس با استفاده از برآوردگر نیوی–وست با ساختار وقفه $L = h - 1 = 5$ برآورد شد تمامی خودهمبستگی‌های ناشی از هم‌پوشانی پوشش داده شوداز آنجا که تعداد مشاهدات زمانی خارج از نمونه محدود است، آماره آزمون با تصحیح نمونه هاروی–لیبورن–نیوبولد تعدیل شد:

رابطه (۴) $$DM_{HLN} = DM\sqrt{\frac{T+1-2h+\frac{(h(h-1))}{T}}{T}}$$

که در آن T تعداد ماه‌های مشترک خارج از نمونه و h افق پیش‌بینی است. فرض صفر آزمون، برابری میانگین زیان پیش‌بینی دو مدل رقیب است. p-value ها به‌صورت دوطرفه محاسبه شدند.

در نهایت، به منظور ارزیابی کاربرد اقتصادی[1] برآوردها، از استراتژی تشکیل پرتفوی حداقل واریانس[2] استفاده شد. برای این منظور، ماتریس کوواریانس سهام (Σ_t) بر اساس مدل تک‌عاملی و با استفاده از بتاهای پیش‌بینی‌شده مدل‌ها $(\widehat{\beta_t})$ به شکل زیر بازسازی می‌شود:

رابطه (۵) $$\Sigma_t = \widehat{\beta_t}\widehat{\beta_t}'\sigma^2_{m,t} + \Omega_t$$

که در آن $\sigma^2_{m,t}$ واریانس بازده اضافی شاخص بازار است که از واریانس تحقق‌یافته بازده‌های روزانه بازار استخراج می‌شود.و Ω_t ماتریس قطری واریانس‌های ریسک خاص شرکتی[3] است. بازده ریسک خاص روزانه هر سهم از تفاضل بازده واقعی سهم و بازده منتسب به مدل برآورد می‌شود. سپس واریانس تجربی این پسماندهای روزانه محاسبه و به‌عنوان برآورد واریانس خاص هر سهم برای ماه آتی بر روی قطر اصلی ماتریس Ω_t قرار می‌گیرد. تمامی اجزای این ماتریس در پایان هر ماه با ورود داده‌های جدید بازتخمین و به‌روزرسانی می‌شوند.

هدف این استراتژی، یافتن بردار اوزان سهام (w_t) است که ریسک کل پرتفوی را حداقل کند:

رابطه (۶) $$\min w_t' \Sigma_t w_t \quad s.t. \quad w_t' = 1, \quad 0 \le w_{i,t} \le 0.05$$

که در آن قید سقف وزنی ۵ درصد برای هر دارایی جهت کنترل ریسک تمرکز و حفظ نقدشوندگی اعمال شده است. تفاوت در عملکرد مدل‌های مختلف پیش‌بینی بتا، مستقیماً در برآورد ماتریس Σ_t و در نتیجه، در اوزان تخصیص‌یافته و نوسانات (واریانس) نهایی پرتفوی منعکس می‌گردد. بازده مازاد ماهانه پرتفوی حداقل واریانس به‌صورت زیر حاصل می‌شود:

رابطه (۷) $$R^{MVP}_{p,t+1} = w_t' R^e_{t+1} = \sum_{i=1}^{N} w_{i,t} R^e_{(i,t+1)}$$

همچنین برای خنثی‌سازی مواجهه با ریسک سیستماتیک، نسخه بازارخنثی با اتخاذ موقعیت فروش در شاخص بازار معادل بتای پیش‌بینی‌شده کل $(\hat{\beta}_{p,t} = w_t'\widehat{\beta_t}')$ تشکیل شد:

رابطه (۸) $$R^{MN}_{p,t+1} = R^{MVP}_{p,t+1} - \hat{\beta}_{p,t} R^e_{m.t+1}$$

برای سنجش عملکرد نهایی، معیارهای بازده مازاد سالانه، نوسان‌پذیری سالانه، انحراف معیار نزولی، بدترین بازده ماهانه، بیشینه افت سرمایه، ارزش نهایی سرمایه‌گذاری یک‌واحدی و نسبت شارپ طی دوره ۶۰ ماهه آزمون محاسبه شدند. بتای تحقق‌یافته و آماره t مربوط به آن از رگرسیون زمانی بازده‌های مازاد پرتفوی بر بازده مازاد بازار با استفاده از خطاهای استاندارد مقاوم نیوی–وست استخراج گردید:

رابطه (۹) $$R^q_{p,t} = a^q + \beta^q R^e_{m,t} + \varepsilon^q_t, \quad q \in \{MVP, MN\}$$

[1] Economic Evaluation
[2] Minimum Variance Portfolio (MVP)
[3] Idiosyncratic Variance

به منظور بررسی معناداری آماری اختلاف نسبت‌های شارپ میان مدل‌های مختلف و مدل مرجع (یا مدل برتر)، از آزمون جابسون_کورکی با تصحیح مِمِل (Jobson & Korkie, 1981; Memmel, 2003) استفاده شده است. این آزمون با در نظر گرفتن همبستگی متقابل میان بازده‌های پرتفوی‌ها و توزیع مجاورتی، آماره آزمونی (Z-statistic) مبتنی بر اختلاف نسبت‌های شارپ محاسبه می‌کند تا مشخص گردد آیا برتری عملکردی مدل‌ها از نظر آماری در سطوح معنادار (۱، ۵ و ۱۰ درصد) معتبر است یا صرفاً ناشی از نوسانات تصادفی است.

٤. تحلیل داده‌ها و یافته‌ها

تحلیل آماری پیش‌بینی‌های بتای بازار: در این بخش، عملکرد مدل‌های مختلف در پیش‌بینی بتای شش‌ماهه به صورت آماری ارزیابی و مقایسه می‌شود.

خطاهای پیش‌بینی: پنل الف جدول ۳ میانگین خطای مربعات پیش‌بینی وزن‌دهی‌شده بر اساس ارزش بازار (VW-MSE) را برای مدل‌های مختلف در دوره ۶۰ ماهه خارج از نمونه (از اوت ۲۰۱۹ تا ژوئیه ۲۰۲۴) گزارش می‌کند؛ مقدار کمتر نشان‌دهنده دقت پیش‌بینی بالاتر است. بر اساس نتایج، مدل جنگل تصادفی (RF) با مقدار میانگین VW-MSE برابر با ۹.۹۹ درصد، بهترین عملکرد را در میان تمامی مدل‌های بررسی‌شده دارد. در میان مدل‌های پایه، روش Blume با میانگین ۱۰.۸۹ درصد و مدل BSW با میانگین ۱۱.۴۲ درصد عملکرد مطلوبی دارند. همچنین، سایر مدل‌های یادگیری ماشین مانند $ElasticNet$ (با میانگین ۱۱.۳۷ درصد) و LM (با میانگین ۱۱.۵۵ درصد) نتایج نزدیکی نسبت به روش‌های سنتی ثبت کرده‌اند. بااین‌حال، مقایسه صرف مقادیر توصیفی $VW-MSE$ برای اثبات معناداری آماری تفاوت عملکرد مدل‌ها کافی نیست.

به‌منظور بررسی معناداری آماری اختلاف خطاهای پیش‌بینی، پنل ب نتایج آزمون دوطرفه دایبولد ماریانو با تصحیح هاروی لیبورن نیوبولد را برای مقایسه‌های دوجانبه مدل‌ها ارائه می‌کند. در این ماتریس، اختلاف زیان به‌صورت $d_t = L_{A,t} - L_{B,t}$ تعریف شده است؛ بنابراین‌آماره منفی نشان می‌دهد که مدل سطری میانگین خطای کمتری نسبت به مدل ستونی دارد. نتایج پنل ب نشان می‌دهد که مدل RF (که از نظر توصیفی کمترین VW-MSE را دارد) در برخی مقایسه‌های دوجفتی دارای برتری آماری معناداری است. به‌طور مشخص، عملکرد RF در مقایسه با مدل‌های XGB و GBRT در سطح یک درصد ($p < ۰.۰۰۱$) و در مقایسه با EWMA(S) در سطح یک درصد ($p = ۰.۰۰۴$) برتری معناداری نشان می‌دهد. همچنین برتری RF نسبت به EWMA(L) در مرز معناداری آماری قرار دارد ($p = ۰.۰۵۳$). بااین‌حال، تفاوت عملکرد RF با سایر مدل‌ها (مانند NN، LM، ElasticNet و Vasicek) پس از اعمال اصلاح Holm از نظر آماری معنادار نیست.

در میان سایر مدل‌های یادگیری ماشین و پایه نیز، بخش عمده‌ای از تفاوت‌های عملکردی پس از کنترل خطای نوع اول (تصحیح Holm) تفاوت معناداری را نشان نمی‌دهند. این یافته حاکی از آن است که اگرچه برخی مدل‌ها مانند RF در شاخص توصیفی VW-MSE بهبود مناسبی ایجاد می‌کنند، اما از نظر آزمون‌های آماری دوجفتی با اصلاح چندگانه، برتری قطعی آن‌ها محدود به مقایسه‌های خاصی است و روش‌های پایه و پیشرفته رقابت تنگاتنگی با یکدیگر دارند.

جدول ۳: عملکرد خارج از نمونه مدل‌های پیش‌بینی بتای شش‌ماهه بر مبنای میانگین وزنی ارزش بازار مربع خطای پیش‌بینی (VW-MSE) و آزمون مقایسه‌ای دایبولد–ماریانو با تصحیح هاروی–لیبورن–نیوبولد (DM-HLN)

Table 3: Out-of-Sample Performance of Six-Month Beta Forecasting Models Based on Value-Weighted Mean Squared Forecast Error (VW-MSE) and Pairwise Diebold–Mariano Tests with the Harvey–Leybourne–Newbold Correction (DM-HLN)

	مدل‌های یادگیری ماشین						مدل‌های پایه					
	NN	**LM**	**XGB**	**GBRT**	**RF**	**ELANET**	**BSW**	**Vasicek**	**EWMA(S)**	**OLS**	**EWMA(L)**	**Blume**
پنل الف. میانگین خطای پیش‌بینی												
VW-MSE (%)	۱۸.۱۰	۱۱.۵۵	۱۱.۹۷	۱۲.۶۱	۹.۹۹	۱۸.۱	۱۱.۴۲	۱۱.۷۲	۱۲.۶۷	۱۲.۰۵	۱۲.۰۶	۱۰.۸۸
پنل ب. نتایج آزمون‌های دوجفتی دایبولد–ماریانو با تصحیح DM-HLN برای تفاوت در VW-MSE ماهانه												
NN	۰.۰۰۰ (p=۱.۰۰۰)	۲.۰۲۷ (p=۱.۰۰۰)	۱.۷۵۰ (p=۱.۰۰۰)	۱.۵۵۶ (p=۱.۰۰۰)	۲.۳۹۱ (p=۱.۰۰۰)	۲.۰۲۳ (p=۱.۰۰۰)	۲.۱۰۵ (p=۱.۰۰۰)	۲.۱۰۵ (p=۱.۰۰۰)	۱.۶۰۴ (p=۱.۰۰۰)	۱.۹۶۲ (p=۱.۰۰۰)	۱.۹۱۹ (p=۱.۰۰۰)	۲.۲۹۱ (p=۱.۰۰۰)
LM	−۲.۰۲۷ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	−۰.۶۲۵ (p=۱.۰۰۰)	−۱.۷۲۹ (p=۱.۰۰۰)	۳.۰۹۵ (p=۱.۰۰۰)	۰.۱۹۱ (p=۱.۰۰۰)	۰.۲۱۶ (p=۱.۰۰۰)	−۰.۲۷۷ (p=۱.۰۰۰)	−۱.۶۲۳ (p=۱.۰۰۰)	−۰.۷۴۳ (p=۱.۰۰۰)	−۰.۸۰۱ (p=۱.۰۰۰)	۱.۰۵۷ (p=۱.۰۰۰)
XGB	−۱.۷۵۰ (p=۱.۰۰۰)	۰.۶۲۵ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	−۲.۱۸۲ (p=۱.۰۰۰)	۵.۳۱۸*** (p < ۰.۰۰۱)	۰.۵۴۰ (p=۱.۰۰۰)	۰.۶۲۰ (p=۱.۰۰۰)	۰.۲۹۸ (p=۱.۰۰۰)	−۰.۸۰۵ (p=۱.۰۰۰)	−۰.۸۰۶ (p=۱.۰۰۰)	−۰.۰۹۸ (p=۱.۰۰۰)	۱.۴۳۲ (p=۱.۰۰۰)
GBRT	−۱.۵۵۶ (p=۱.۰۰۰)	۱.۷۲۹ (p=۱.۰۰۰)	۲.۱۸۲ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	۵.۴۲۵*** (p < ۰.۰۰۱)	۱.۱۶۵ (p=۱.۰۰۰)	۱.۳۴۸ (p=۱.۰۰۰)	۱.۰۱۰ (p=۱.۰۰۰)	−۰.۰۶۷ (p=۱.۰۰۰)	۰.۵۹۵ (p=۱.۰۰۰)	۰.۶۲۵ (p=۱.۰۰۰)	۲.۱۲۹ (p=۱.۰۰۰)
RF	−۲.۳۹۱ (p=۱.۰۰۰)	−۳.۰۹۵ (p = ۰.۱۸۳)	−۵.۳۱۸*** (p < ۰.۰۰۱)	−۵.۴۲۵*** (p < ۰.۰۰۱)	۰.۰۰۰ (p=۱.۰۰۰)	−۱.۵۱۷ (p=۱.۰۰۰)	−۲.۳۴۶ (p=۱.۰۰۰)	−۲.۹۷۲ (p = ۰.۲۵۶)	−۴.۲۹۶*** (p = ۰.۰۰۴)	−۳.۱۸۱ (p = ۰.۱۴۵)	−۳.۵۲۱* (p = ۰.۰۵۳)	−۲.۰۱۷ (p=۱.۰۰۰)
ELANET	−۲.۰۲۳ (p=۱.۰۰۰)	−۰.۱۹۱ (p=۱.۰۰۰)	−۰.۵۴۰ (p=۱.۰۰۰)	−۱.۱۶۵ (p=۱.۰۰۰)	۱.۵۱۷ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	−۰.۰۵۵ (p=۱.۰۰۰)	−۰.۳۶۰ (p=۱.۰۰۰)	−۱.۰۹۶ (p=۱.۰۰۰)	۰.۶۴۲ (p=۱.۰۰۰)	−۰.۶۴۰ (p=۱.۰۰۰)	۰.۶۸۰ (p=۱.۰۰۰)
BSW	−۲.۱۰۵ (p=۱.۰۰۰)	−۰.۲۱۶ (p=۱.۰۰۰)	−۰.۶۲۰ (p=۱.۰۰۰)	−۱.۳۴۸ (p=۱.۰۰۰)	۲.۳۴۶ (p=۱.۰۰۰)	۰.۰۵۵ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	−۱.۳۵۷ (p=۱.۰۰۰)	−۲.۳۶۴ (p=۱.۰۰۰)	−۲.۶۸۳ (p = ۰.۵۵۷)	−۲.۵۲۱ (p = ۰.۰۸۳۶)	۱.۲۵۱ (p=۱.۰۰۰)
Vasicek	−۲.۱۰۵ (p=۱.۰۰۰)	۰.۲۷۷ (p=۱.۰۰۰)	−۰.۲۹۸ (p=۱.۰۰۰)	−۱.۰۱۰ (p=۱.۰۰۰)	۲.۹۷۲ (p = ۰.۲۵۶)	۰.۳۶۰ (p=۱.۰۰۰)	۱.۳۵۷ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	−۱.۶۴۷ (p=۱.۰۰۰)	−۱.۹۶۲ (p=۱.۰۰۰)	−۱.۴۸۲ (p=۱.۰۰۰)	۲.۱۷۱ (p=۱.۰۰۰)
EWMA(S)	−۱.۶۰۴ (p=۱.۰۰۰)	۱.۶۲۳ (p=۱.۰۰۰)	۰.۸۰۵ (p=۱.۰۰۰)	۰.۰۶۷ (p=۱.۰۰۰)	۴.۲۹۶*** (p = ۰.۰۰۴)	۱.۰۹۶ (p=۱.۰۰۰)	۲.۳۶۴ (p=۱.۰۰۰)	۱.۶۴۷ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	۱.۲۲۰ (p=۱.۰۰۰)	۱.۶۱۹ (p=۱.۰۰۰)	۲.۵۱۲ (p = ۰.۸۴۲)
OLS	−۱.۹۶۲ (p=۱.۰۰۰)	۰.۷۴۳ (p=۱.۰۰۰)	۰.۰۸۶ (p=۱.۰۰۰)	−۰.۵۹۵ (p=۱.۰۰۰)	۳.۱۸۱ (p = ۰.۱۴۵)	۰.۶۴۲ (p=۱.۰۰۰)	۲.۶۸۳ (p = ۰.۵۵۷)	۱.۹۶۲ (p=۱.۰۰۰)	−۱.۲۲۰ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	−۰.۰۴۳ (p=۱.۰۰۰)	۲.۳۰۰ (p=۱.۰۰۰)
EWMA(L)	−۱.۹۱۹ (p=۱.۰۰۰)	۰.۸۰۱ (p=۱.۰۰۰)	۰.۰۹۸ (p=۱.۰۰۰)	−۰.۶۲۵ (p=۱.۰۰۰)	۳.۵۲۱* (p = ۰.۰۵۳)	۰.۶۴۰ (p=۱.۰۰۰)	۲.۵۲۱ (p=۱.۰۰۰)	۱.۴۸۲ (p=۱.۰۰۰)	−۱.۶۱۹ (p=۱.۰۰۰)	۰.۰۴۳ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)	۲.۳۰۳ (p=۱.۰۰۰)
Blume	−۲.۲۹۱ (p=۱.۰۰۰)	−۱.۰۵۷ (p=۱.۰۰۰)	−۱.۴۳۲ (p=۱.۰۰۰)	−۲.۱۲۹ (p=۱.۰۰۰)	۲.۰۱۷ (p=۱.۰۰۰)	−۰.۶۸۰ (p=۱.۰۰۰)	−۱.۲۵۱ (p=۱.۰۰۰)	−۲.۱۷۱ (p=۱.۰۰۰)	−۲.۵۱۲ (p = ۰.۸۴۲)	−۲.۳۰۰ (p=۱.۰۰۰)	−۲.۳۰۳ (p=۱.۰۰۰)	۰.۰۰۰ (p=۱.۰۰۰)

تحلیل پایداری و حساسیت به طول پنجره غلتان[1]: به‌منظور بررسی استحکام نتایج و ارزیابی اثر مصالحه میان سوگیری و واریانس، عملکرد پیش‌بینی بتای سهام در چهار پیکربندی پنجره غلتان مورد آزمون قرار گرفت. پیکربندی مبنا بر مبنای تقسیم‌بندی استاندارد پنجره آموزش ۵۴ ماهه، اعتبارسنجی ۱۲ ماهه، دوره شکاف ۶ ماهه و آزمون ۶ ماهه (گام غلتان ۶ ماهه) طراحی شد. جهت بررسی جامع حساسیت، سه سناریوی دیگر متناظر با افق‌های زمانی مختلف پیاده‌سازی شدند:

۱) کوتاه‌مدت: آموزش ۲۷ ماهه، اعتبارسنجی ۳ ماهه، شکاف ۳ ماهه، آزمون ۳ ماهه با گام غلتان ۳ ماهه، برای سنجش واکنش مدل‌ها در شرایط نمونه کوچک و انطباق سریع؛

۲) میان‌مدت: آموزش ۳۶ ماهه، اعتبارسنجی ۶ ماهه، شکاف ۶ ماهه، آزمون ۶ ماهه با گام ۶ ماهه؛

۳) بلندمدت: آموزش ۸۱ ماهه، اعتبارسنجی ۹ ماهه، شکاف ۹ ماهه، آزمون ۹ ماهه با گام ۹ ماهه، با هدف ارزیابی توانایی الگوریتم‌ها در بهره‌برداری از حافظه بلندمدت داده‌ها و کاهش واریانس پیش‌بینی. وجود دوره شکاف در کلیه سناریوها مانع از نفوذ سوگیری نگاه به آینده می‌گردد.

[1] Robustness and Sensitivity Analysis

جدول ٤: تحلیل حساسیت دقت پیش‌بینی بتای سهام نسبت به طول پنجره غلتان (میانگین خطای وزنی بازار، رتبه‌بندی و آزمون معناداری DM-HLN با اصلاح هولم)

Table 4: Sensitivity of Stock Beta Forecasts to Rolling-Window Configuration (VW-MSE, Model Rankings, and Holm-Adjusted DM-HLN Tests)

نام مدل	میانگین خطای وزنی بازار (VW-MSE)				معناداری آماری نسبت به RF (آزمون DM)			
پیکربندی پنجره	مبنا	کوتاه‌مدت	میان‌مدت	بلندمدت	مبنا	کوتاه‌مدت	میان‌مدت	بلندمدت
RF	۰.۰۹۹۹	۰.۱۹۴	۰.۱۲۵۷	۰.۰۹۷۵	مرجع	مرجع	مرجع	مرجع
ELANET	۰.۱۱۳۷	۰.۱۸۳۵	۰.۱۲۶۷	۰.۰۹۰۹				**
BSW	۰.۱۱۴۲	۰.۲۱۰۵	۰.۱۳۴۲	۰.۰۹۸۵				
Blume	۰.۱۰۸۹	۰.۲۰۸۲	۰.۱۳۲۱	۰.۰۹۹۲				
Vasicek	۰.۱۱۷۲	۰.۲۱۲۲	۰.۱۳۶۹	۰.۱۰۲۴				
OLS	۰.۱۲۰۵	۰.۲۶۳۸	۰.۱۸۸	۰.۱۰۴۷				
LM	۰.۱۱۵۵	۰.۲۰۵۷	۰.۱۵۱۹	۰.۱۰۶				
EWMA(L)	۰.۱۲۰۶	۰.۲۶۱	۰.۱۸۷۵	۰.۱۰۶۸	*			
EWMA (S)	۰.۱۲۶۷	۰.۲۷۱۲	۰.۱۹۹۲	۰.۱۱۷۳	***			*
NN	۰.۱۸۱	۰.۱۹۹۳	۰.۱۶۰۵	۰.۱۳۶				***
XGB	۰.۱۱۹۷	۰.۱۹۸۵	۰.۱۴۳۹	۰.۱۳۶۸	***		*	***
GBRT	۰.۱۲۶۱	۰.۲۰۸۱	۰.۱۵۷۷	۰.۱۵۱۹	***			***

یادداشت: مقادیر ستون‌های ۱ تا ۴ میانگین خطای مربعات پیش‌بینی وزن‌دهی‌شده بر اساس ارزش بازار (VW-MSE) و ستون‌های ۵ تا ۸ نتایج آزمون دوجانبه DM-HLN را با مدل مرجع (RF) گزارش می‌کنند. نمادهای ***، ** و * به‌ترتیب نشان‌دهنده سطح معناداری آماری ۱٪، ۵٪ و ۱۰٪ پس از اعمال تصحیح هولم–بونفرونی هستند.

تفاوت در دقت پیش‌بینی مدل‌ها با استفاده از آزمون تعمیم‌یافته دیبولد–ماریانو با تعدیل نمونه کوچک هاروی–لیبورن–نیوبولد ارزیابی شده است. برای این منظور، از خطای استاندارد نیوی–وست[1] با طول وقفه ۵ ماهه جهت تصحیح همبستگی پیاپی و ناهمسانی واریانس در سطح جفت‌خطاهای نماد–تاریخ استفاده گردید. همچنین جهت کنترل تورم خطای نوع اول ناشی از آزمون‌های مکرر و مقایسه‌های چندگانه با مدل مرجع (RF)، مقادیر احتمال (p-value) تحت رویه پله‌ای هولم–بونفرونی[2] تصحیح شدند.

یافته‌های مندرج در جدول ۴ سه نکته کلیدی را مشخص می‌سازد:

نخست، با افزایش طول پنجره آموزش و حرکت از سناریوی کوتاه‌مدت به بلندمدت، دقت برآورد در کلیه مدل‌ها بهبود چشمگیری می‌یابد؛ به‌طوری‌که میانگین خطای وزنی برترین مدل از ۰/۱۸۳۵ (کوتاه‌مدت) به ۰/۰۹۰۹ (بلندمدت) کاهش یافته است که نشان‌دهنده نیاز مدل‌های آماری و یادگیری ماشین به داده‌های تاریخی طولانی‌تر جهت فیلتر کردن نویزهای مقطعی بورس تهران است.

دوم، مدل‌های انقباضی و ترکیبی پایداری بالایی نشان دادند؛ مدل ELANET در پنجره‌های کوتاه و بلند رتبه اول را کسب کرده و در افق بلندمدت با سطح اطمینان ۹۵٪ برتری آماری معناداری نسبت به مدل مرجع (RF) ثبت کرده است. مدل RF نیز در سناریوی مبنا و میان‌مدت برترین عملکرد را داشته و همواره در جمع دو مدل برتر قرار دارد.

سوم، روش‌های متداول سنتی با افق کوتاه (نظیر OLS و EWMA) به‌ویژه در پیکربندی‌های کوتاه‌مدت و میان‌مدت خطاهای بالاتر و رتبه‌های ضعیف‌تری ثبت کرده‌اند؛ با این حال، با افزایش طول پنجره و در افق بلندمدت، عملکرد OLS بهبود یافته و خطای کمتری نسبت به برخی الگوریتم‌های پیچیده غیرخطی بر جای گذاشته است.

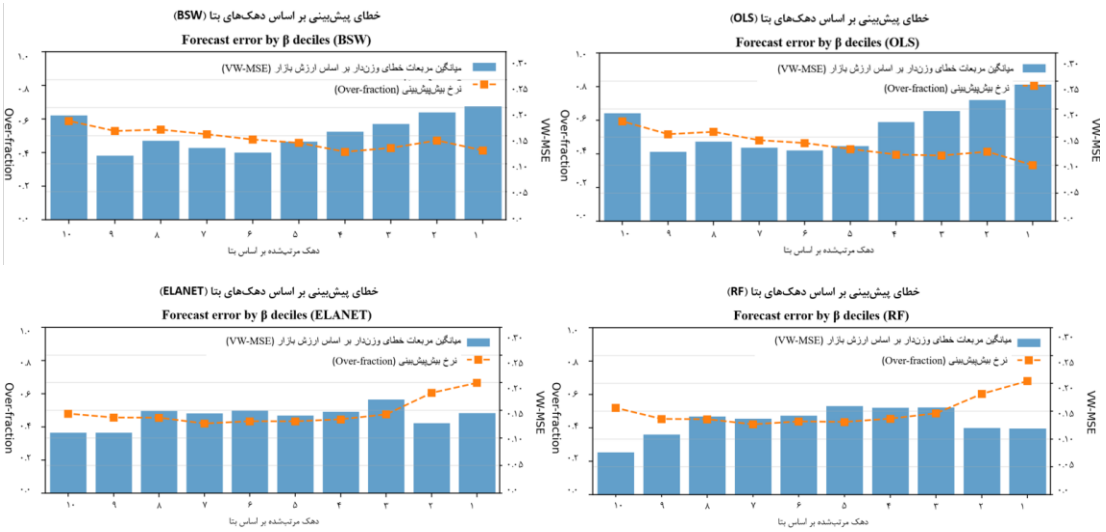
[1] Newey-West HAC
[2] Holm-Bonferroni

خطای پیش‌بینی در دهک‌های پرتفوی[1]: به منظور بررسی دقیق‌تر عملکرد مدل‌ها در ابعاد مقطعی، سهام موجود در نمونه خارج از آزمون، در هر دوره بر اساس بتای پیش‌بینی‌شده توسط هر مدل به ۱۰ دهک مرتب و تقسیم شدند. شکل ۱ عملکرد چهار مدل منتخب را نشان می‌دهد. انتخاب این مدل‌ها بر اساس یک منطق سلسله‌مراتبی در ادبیات مالی صورت گرفته است: OLS به عنوان استاندارد کلاسیک که ساده‌ترین روابط خطی را فرض می‌کند؛ BSW (روش واسیچک) به عنوان نماینده مدل‌های کلاسیک که با تعدیل بیزی، خطای برآورد را کاهش می‌دهد؛ ELANET (الاستیک‌نت) به عنوان نماینده مدل‌های یادگیری ماشینِ خطی که با اعمال جریمه (L1 و L2)، مشکل هم‌خطی چندگانه در داده‌های مالی را حل می‌کند؛ و نهایتاً RF (جنگل تصادفی) به عنوان الگوریتم غیرخطی که قادر به شناسایی تعاملات پیچیده میان ویژگی‌هاست (Drobetz et al., 2025).

شکل ۲ عملکرد این مدل‌ها را بر اساس دو معیار میانگین مربعات خطای وزن‌دار (VW-MSE) و نرخ بیش‌تخمینی[2] نشان می‌دهد. معیار بیش‌تخمینی بیانگر نسبتی از مشاهدات است که در آن بتای پیش‌بینی‌شده بزرگ‌تر از بتای تحقق‌یافته بوده است؛ جایی که مقدار ۰.۵ نشان‌دهنده عدم سوگیری سیستماتیک است.

شکل ۲. خطای پیش‌بینی بر اساس دهک‌های بتا

Figure 2. Forecast Errors of Cross-Sectional Portfolio Sorts



مدل‌های سنتی (OLS و BSW) الگوی خطای مشخصی را نشان می‌دهند. در مدل OLS و با شدتی کمتر در مدل BSW، میزان VW-MSE در دهک‌های ابتدایی (سهام با بتای پایین) بسیار بالا است، با حرکت به سمت دهک‌های میانی کاهش یافته و مجدداً در دهک‌های انتهایی افزایش می‌یابد که این امر نشان‌دهنده یک الگوی U–شکل در خطاهاست. علاوه بر این، روند معیار بیش‌تخمینی در این مدل‌ها صعودی است؛ به این معنی که مدل‌های سنتی تمایل دارند بتای سهام با ریسک پایین را کمتر از واقع و بتای سهام با ریسک بالا را بیش از واقع برآورد کنند.

در مقابل، مدل‌های یادگیری ماشین (به‌ویژه RF) توزیع خطای همگن‌تر و پایدارتری در میان دهک‌ها دارند. در مدل RF، میزان میانگین مربعات خطای وزن‌دار در تمامی دهک‌ها به‌طور قابل‌توجهی کمتر از مدل‌های خطی است و الگوی U شکل خطای آن‌ها به‌شدت هموار و تعدیل شده است. نکته حائز اهمیت در مورد مدل RF، عملکرد متمایز آن در

[1] Forecast Errors of Cross-Sectional Portfolio Sorts
[2] Overestimation Ratio

دهک دهم (سهام با بتای بسیار بالا) است که بر خلاف مدل‌های سنتی که در این دهک با چالش جدی و خطای بالا روبه‌رو هستند، توانسته خطای پیش‌بینی را در سطح پایینی حفظ کند.

همچنین، بررسی معیار بیش‌تخمینی در مدل‌های یادگیری ماشین نشان‌دهنده همگرایی بیشتر این نسبت به خط ۰.۵۰ در دهک‌های میانی و نوسانات بسیار کمتر در دهک‌های فرین (ابتدا و انتها) است. این یافته‌ها تأیید می‌کند که الگوریتم‌های یادگیری ماشین، به دلیل توانایی در شناسایی روابط غیرخطی و تعاملات پیچیده میان متغیرها، نه‌تنها خطای کل پیش‌بینی را کاهش می‌دهند، بلکه سوگیری‌های سیستماتیک موجود در روش‌های سنتی برآورد بتا را در بازار سرمایه نیز به حداقل می‌رسانند.

بررسی عملکرد مدل در مقطع عرضی سهام: به‌منظور بررسی اینکه عملکرد مدل جنگل تصادفی صرفاً به بخش خاصی از بازار محدود نباشد، خطاهای پیش‌بینی خارج از نمونه بر اساس ویژگی‌های شرکت و طبقه‌بندی صنعتی نیز بررسی شد. در این تحلیل، سهام در هر ماه بر اساس نسبت ارزش دفتری به ارزش بازار، عدم‌نقدشوندگی و مومنتوم بازدهی به دهک‌های مقطعی تقسیم شدند و عملکرد RF با مدل مبنای OLS مبتنی بر پنجره یک‌ساله داده‌های روزانه مقایسه گردید. همچنین، به‌منظور بررسی عملکرد مدل در صنایع مختلف، نتایج برای ۱۰ صنعت بزرگ نمونه بر اساس ارزش بازار محاسبه شد. نتایج این تحلیل در شکل ۲ ارائه شده است.

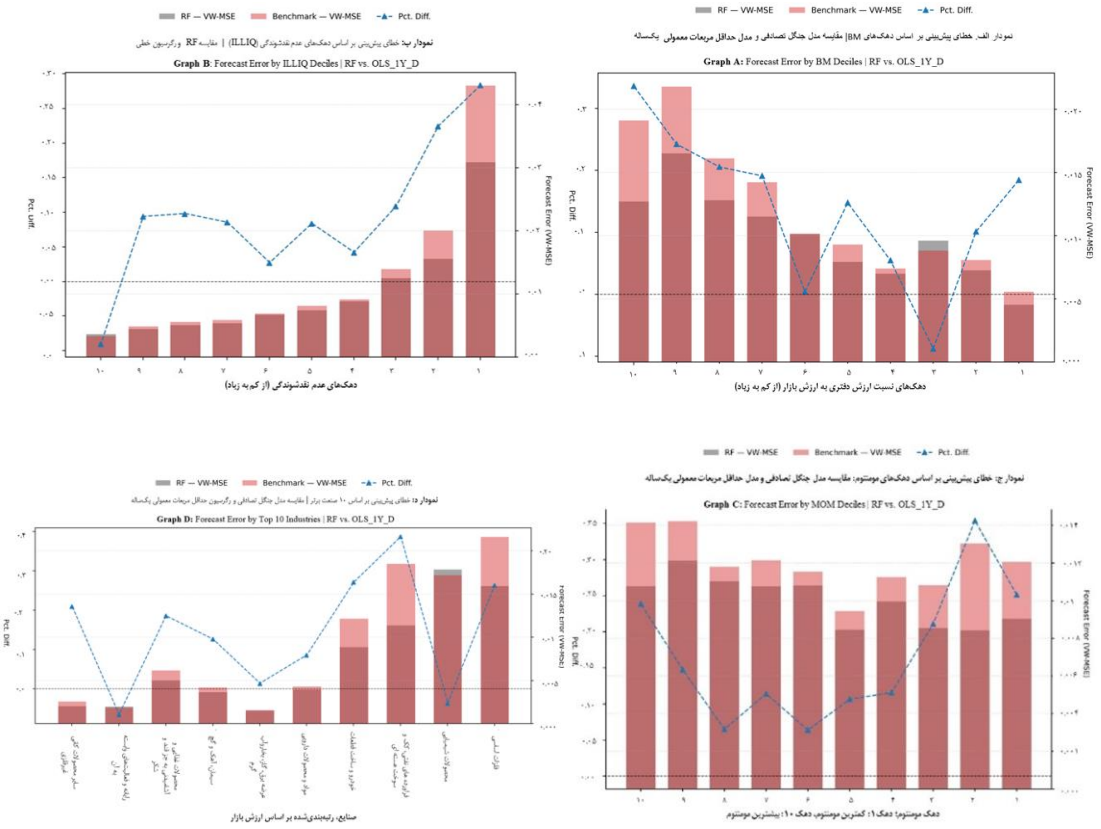
همان‌گونه که در شکل ۲ مشاهده می‌شود، RF در بخش قابل‌توجهی از دهک‌های مورد بررسی، خطای پیش‌بینی پایین‌تری نسبت به مدل مبنا دارد. این الگو در دهک‌های مرتب‌شده بر اساس نسبت ارزش دفتری به ارزش بازار و عدم‌نقدشوندگی به‌وضوح مشاهده می‌شود. در عین حال، سطح خطای پیش‌بینی در میان دهک‌ها یکسان نیست. نکته قابل توجه آن است که در بسیاری از این گروه‌ها نیز RF توانسته است بخشی از خطای پیش‌بینی را نسبت به مدل مبنا کاهش دهد .بنابراین، مزیت پیش‌بینی RF را نمی‌توان صرفاً به گروه‌هایی با سطح خطای پایین نسبت داد.

در دهک‌های مبتنی بر مومنتوم نیز الگوی کلی حاکی از عملکرد رقابتی RF در مقایسه با مدل مبناست. اگرچه اندازه خطا و میزان بهبود RF در دهک‌های مختلف متفاوت است، این مدل در بخش عمده‌ای از گروه‌ها خطای پیش‌بینی پایین‌تری ایجاد کرده است. این تفاوت در شدت عملکرد، وجود ناهمگنی در قابلیت پیش‌بینی بتا در میان گروه‌های مختلف سهام را نشان می‌دهد، در حالی که حفظ مزیت RF در طیف متنوعی از دهک‌ها، از پایداری نسبی عملکرد آن در مقطع عرضی حمایت می‌کند.

نتایج تفکیک‌شده بر حسب صنعت نیز الگوی مشابهی را نشان می‌دهد. در برخی صنایع، فاصله میان خطای پیش‌بینی RFو مدل مبنا بیشتر و در برخی دیگر محدودتر است. با این حال، عملکرد RF در بخش قابل توجهی از صنایع مورد بررسی بهتر از مدل مبناست. این یافته نشان می‌دهد که بهبود عملکرد RF صرفاً ناشی از تمرکز آن بر یک ویژگی خاص یا یک صنعت مشخص نیست، بلکه در بخش‌های متنوعی از مقطع عرضی بازار مشاهده می‌شود. در مجموع، نتایج شکل ۳ ضمن نشان دادن تفاوت عملکرد مدل در میان گروه‌های مختلف سهام، شواهد مکملی برای پایداری نسبی عملکرد RF در پیش‌بینی بتای سهام فراهم می‌کند.

شکل ۳. میانگین خطاهای پیش‌بینی پرتفوی‌های مرتب‌شده بر اساس ویژگی‌های شرکت و طبقه‌بندی صنایع

Figure 3. Average Forecast Errors of Portfolio Sorts Based on Firm Characteristics and Industry Classification



اهمیت متغیرها[1]: پس از ارزیابی عملکرد پیش‌بینی مدل‌ها، شناسایی متغیرهایی که بیشترین نقش را در پیش‌بینی دقیق مقطعی بتا ایفا می‌کنند، از اهمیت بالایی برخوردار است. در این بخش، اهمیت نسبی متغیرها بر اساس مدل جنگل تصادفی (RF) به عنوان برترین مدل پیش‌بین، تحلیل می‌شود. هم‌راستا با روش‌شناسی دروبتز و همکاران (۲۰۲۵)، اهمیت مطلق هر متغیر بر اساس میزان افزایش در معیار میانگین مربعات خطای وزن‌دار در زمانی محاسبه گردید که مقادیر آن متغیر در نمونه آموزش با میانه بی‌اثر[2] جایگزین (بی‌اثر) شود. در گام بعد، این مقادیرِ مطلق به گونه‌ای نرمال‌سازی شدند که مجموع اهمیت تمامی متغیرها برابر با یک (یا ۱۰۰ درصد) شود تا سهم نسبی هر ویژگی مشخص گردد. شکل ۴، میانگین سری زمانی اهمیت نسبی متغیرها را در دو سطح «گروه‌های پیش‌بین» (پنل الف) و «۱۰ متغیر برتر» (پنل ب) به تصویر می‌کشد.

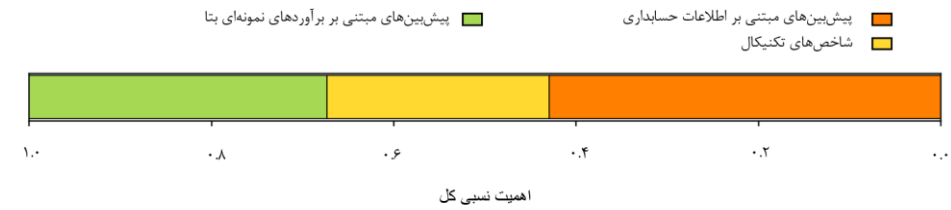
شکل ٤. اهمیت نسبی متغیرهای پیش‌بین در مدل جنگل تصادفی(RF)

Figure 4. Relative Feature Importance in the Random Forest (RF) Model

[1] Feature Importance
[2] Uninformative Median

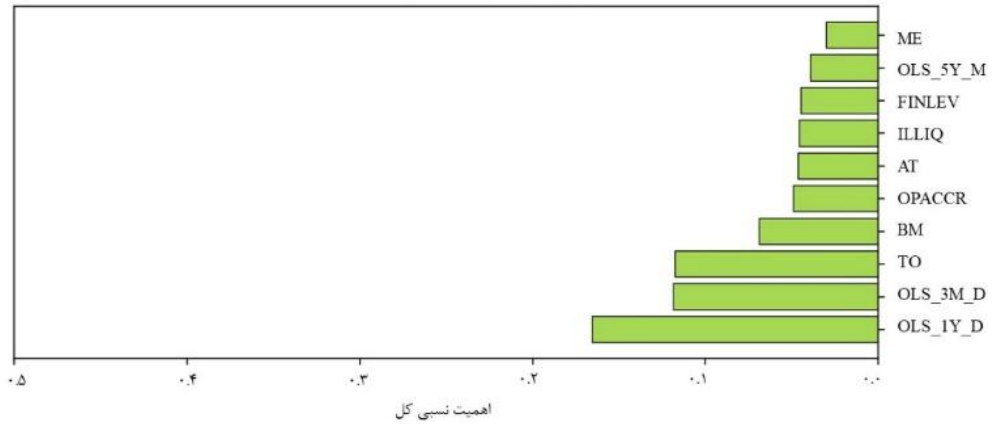
نمودار الف. گروه‌های پیش‌بین

Graph A. Predictor Groups



نمودار ب. ۱۰ متغیر برتر

Graph B. Top 10 Variables



بررسی پنل الف، تفاوت ساختاری قابل‌توجهی را در پیش‌بینی بتای بازار سهام ایران نسبت به بازارهای توسعه‌یافته آشکار می‌سازد. در حالی که در مطالعه دروبتز و همکاران، متغیرهای مبتنی بر برآوردهای تاریخی بتا بیش از ۶۰ درصد از اهمیت کل را به خود اختصاص داده بودند، در پژوهش حاضر، گروه «اطلاعات حسابداری[1]» با وزنی معادل ۴۳ درصد، مهم‌ترین پیش‌بین محسوب می‌شود. گروه‌های «برآوردهای نمونه‌ای بتا[2]» با حدود ۳۲ درصد و «اندیکاتورهای تکنیکال[3]» با حدود ۲۵ درصد در رتبه‌های بعدی قرار دارند. این یافته از آن جهت قابل توجه است که در بازارهای دارای عدم‌تقارن اطلاعاتی، متغیرهای حسابداری و شاخص‌های شفافیت اطلاعاتی می‌توانند نقش مهمی در ارزش‌گذاری شرکت و شکل‌گیری انتظارات سرمایه‌گذاران داشته باشند (Aflatooni et al., 2024).

شایان ذکر است که شاخص «اهمیت ویژگی» در الگوریتم‌های مبتنی بر درخت صرفاً بیانگر سهم آماری متغیرها در پیش‌بینی است و دلالت علّی ندارد. همچنین، سهم ۴۳ درصدی گروه حسابداری ناشی از تجمیع اطلاعاتِ متغیرهای همبسته است و الزماً به معنای اثر مستقل یا مستقیمِ هر یک از این نسبت‌ها بر ریسک سیستماتیک نیست. با این وجود، تحلیل پنل ب (۱۰ متغیر برتر) نشان می‌دهد که در سطح انفرادی، برآوردهای تاریخی بتا همچنان قدرتمندترین متغیرهای پیش‌بین به شمار می‌روند. برآورد بتای یک‌ساله با داده‌های روزانه (OLS_1Y_D) با بیش از ۱۶ درصد اهمیت در صدر قرار دارد. پس از آن، متغیر بتای سه‌ماهه (OLS_3M_D) و اندیکاتور تکنیکال حجم معاملات (TO) هر یک با حدود ۱۲ درصد در جایگاه‌های بعدی ایستاده‌اند. در میان متغیرهای حسابداری، نسبت ارزش دفتری به ارزش بازار (BM) با حدود ۷ درصد اهمیت، بیشترین نقش را ایفا کرده و متغیرهایی نظیر اقلام تعهدی عملیاتی (OPACCR)، کل دارایی‌ها (AT) و اهرم مالی (FINLEV) در رتبه‌های بعدی نمایان شده‌اند. . این موضوع نشان می‌دهد که برتری

[1] Accounting Information
[2] Sample Estimates of Beta
[3] Technical Indicators

نسبی متغیرهای حسابداری در پنل (الف) ناشی از اثر جمع‌پذیری تعداد زیادی از متغیرهای بنیادیِ دارای همبستگی است، در حالی که در سطح متغیرهای منفرد، سیگنال تاریخی بتا همچنان وزن عمده پیش‌بینی را بر عهده دارد.

برای بررسی اینکه آیا متغیرهای پیش‌بین، افزون بر بتاهای تاریخی، در پیش‌بینی بتای تحقق‌یافته ارزش افزوده دارند، عملکرد شش مشخصه تودرتوی M0 تا M5 بر مبنای معیار خطای میانگین مربعات ارزش‌وزنی‌شده خارج از نمونه (VW-MSE) مقایسه شد. در تمامی مشخصات، دامی‌های صنعت ثابت نگه داشته شدند و گروه‌های بتاهای تاریخی، متغیرهای حسابداری/بنیادی و متغیرهای تکنیکال/بازاری به‌صورت مرحله‌ای اضافه یا حذف شدند.

نتایج مربوط به الگوریتم جنگل تصادفی نشان می‌دهد که افزودن متغیرهای حسابداری/بنیادی به مشخصه حاوی بتاهای تاریخی (M2 در مقایسه باM1) VW-MSE را به میزان ۱۲.۱۳٪ کاهش می‌دهد. همچنین، افزودن متغیرهای تکنیکال/بازاری (M3 در مقایسه با M2) به کاهش اضافی ۹.۳۰٪ در VW-MSE منجر می‌شود. هر دو بهبود، بر مبنای آزمون اختلاف زیان ماهانه با واریانس HAC به سبک نیوی–وست با تصحیح هاروی–لیبورن–نیوبولد برای افق شش‌ماهه، در سطح یک درصد معنادار هستند. افزون بر این، مشخصه کامل M3 در مقایسه با مدل پایه M0، VW-MSE الگوریتم جنگل تصادفی را ۳۹.۰۸٪کاهش می‌دهد.

جدول ۵: ارزش افزوده گروه‌های متغیر در پیش‌بینی خارج از نمونه بتای تحقق‌یافته شش‌ماهه

Table 5: Incremental Value of Predictor Groups in Out-of-Sample Forecasting of 6-Month Realized Beta

تفسیر مقایسه	بهبود VW-MSE (٪)	آماره آزمون اختلاف زیان a
افزودن بتاهای تاریخی	۲۳.۵۷	−۵.۹۵۱***
افزودن متغیرهای حسابداری/بنیادی پس از بتاهای تاریخی	۱۲.۱۳	−۶.۵۶۳***
افزودن متغیرهای تکنیکال/بازاری پس از بتاهای تاریخی و بنیادی	۹.۳۰	−۵.۰۵۶***
مشخصه کامل در برابر مدل پایه	۳۹.۰۸	−۶.۸۰۳***
بنیادی و تکنیکال، بدون بتاهای تاریخی	۳۳.۷۶	−۶.۱۲۵***
تکنیکال/بازاری، بدون بتاهای تاریخی و بنیادی	۳۰.۴۸	−۵.۶۲۶***

در مجموع، یافته‌ها نشان می‌دهد که هرچند بتاهای تاریخی اطلاعات پیش‌بینی‌کننده مهمی فراهم می‌کنند، متغیرهای حسابداری/بنیادی و تکنیکال/بازاری نیز در چارچوب الگوریتم جنگل تصادفی، اطلاعات مکمل و ارزش افزوده معناداری برای پیش‌بینی بتای تحقق‌یافته ایجاد می‌کنند این نتیجه باید به‌عنوان شواهدی الگوریتم‌وابسته و مبتنی بر توان پیش‌بینی تجربی تفسیر شود، نه رابطه علّی یا برتری یکنواخت آن‌ها در همه مدل‌ها.

یافته‌های این بخش مؤید آن است که اگرچه حافظه تاریخی بتا (به‌ویژه افق‌های یک‌ساله و سه‌ماهه) قوی‌ترین سیگنال‌های انفرادی برای پیش‌بینی ریسک سیستماتیک آتی را ارائه می‌دهند، اما مدل‌های یادگیری ماشین با بهره‌گیری هم‌زمان از مجموعه وسیعی از متغیرهای حسابداری و بنیادی (که در سطح گروهی بیشترین وزن را دارند) موفق به استخراج الگوهای پنهان و غیرخطی می‌شوند. این یافته‌ها نشان می‌دهند که ترکیب بتاهای تاریخی با اطلاعات بنیادی و تکنیکال می‌تواند اطلاعات مکملی برای پیش‌بینی ریسک سیستماتیک آتی فراهم کند و یکی از عوامل مرتبط با عملکرد بهتر مدل‌های یادگیری ماشین نسبت به مشخصات سنتی باشد.

ارزیابی اقتصادی پیش‌بینی‌های بتا: علاوه بر ارزیابی آماری، بررسی ارزش اقتصادی پیش‌بینی‌های بتا در تصمیم‌های سرمایه‌گذاری اهمیت محوری دارد؛ زیرا دقت آماری بالاتر لزوماً به عملکرد تعدیل‌شده با ریسک بهتر منجر نمی‌شود. در این بخش، کاربرد اقتصادی مدل‌ها در دو چارچوب پرتفوی حداقل واریانس و پرتفوی بازار خنثی ارزیابی شده است. شاخص‌های مورد بررسی شامل میانگین بازده مازاد سالانه، نوسان‌پذیری سالانه، کمترین بازده ماهانه، بیشینه افت[1]، ارزش نهایی سرمایه، نسبت شارپ و بتای تحقق‌یافته است. نتایج این ارزیابی در جدول ۶ ارائه شده است.

جدول ٦: عملکرد برآوردهای بتا در پرتفوی‌های حداقل واریانس و بازار خنثی

Table 6: Performance of Beta Estimates in Minimum Variance and Market-Neutral Portfolios

پنل الف: پرتفوی حداقل واریانس

مدل	میانگین بازده مازاد سالانه (٪)	نوسان‌پذیری سالانه (٪)	کمترین بازده ماهانه (٪)	بیشینه افت سرمایه (٪)	ارزش نهایی سرمایه	نسبت شارپ	آزمون اختلاف نسبت شارپ (نسبت به GBRT)	بتای تحقق‌یافته	آماره t بتا
مدل‌های یادگیری ماشین									
NN	۳۷.۰۵	۳۸.۱۳	−۱۲.۴۲	−۴۱.۳۰	۴.۵۲	۰.۹۷	−۲.۲۷ ** (p=۰.۰۲۳)	۰.۶۶۷	۹.۰۹۶
XGB	۴۱.۷۲	۳۴.۴۱	−۱۰.۰۳	−۴۱.۰۹	۶.۰۱	۱.۲۱	−۱.۷۶* (p=۰.۰۷۹)	۰.۵۲۶	۶.۲۵۸
GBRT	۴۴.۲۴	۳۴.۴۷	−۹.۸۲	−۳۷.۶۵	۶.۷۹	۱.۲۸	-	۰.۵۲۴	۶.۲۱۷
LM	۴۱.۴۷	۳۴.۹۶	−۱۰.۹۸	−۴۴.۸	۵.۸۹	۱.۱۹	−۱.۵۰ (p=۰.۱۳۳)	۰.۵۲۴	۵.۶۶۴
ELANET	۴۰.۲۴	۳۹.۲۵	−۱۲.۴۲	−۴۳.۲۷	۵.۱۹	۱.۰۳	−۲.۳۰ ** (p=۰.۰۲۱)	۰.۶۵۶	۸.۰۷۸
RF	۴۲.۳۱	۳۷.۴۷	−۱۱.۶۶	−۴۱.۷	۵.۹۱	۱.۱۳	−۱.۶۹ * (p=۰.۰۹۱)	۰.۶۰۴	۶.۴۲۷
مدل‌های پایه									
BSW	۳۸.۴۹	۳۴.۰۹	−۱۱.۸۳	−۴۱.۳۵	۴.۶۲	۱.۱۳	−۱.۴۳ (p=۰.۱۵۳)	۰.۴۸۳	۵.۲۴۴
Vasicek	۳۸.۴۱	۳۴.۷۹	−۱۴.۲۵	−۴۳۶۱	۴.۵۵	۱.۱	−۱.۵۹ (p=۰.۱۱۲)	۰.۵۰۱	۵.۴۹۶
Blume	۴۱.۶۸	۳۵.۹۲	−۱۲.۴۶	−۴۳۶۳	۵.۲۱	۱.۱۶	−۱.۲۰ (p=۰.۲۳۲)	۰.۵۵۷	۶.۰۳
OLS	۳۷.۱۲	۳۴.۵۷	−۱۴.۰۰	−۴۳.۱۶	۴.۳۱	۱.۰۷	−۱.۸۳ * (p=۰.۰۶۸)	۰.۴۹۹	۵.۵۷۱
EWMA(L)	۳۶.۶۷	۳۴.۵۴	−۱۳.۶۳	−۴۳.۵۲	۴.۲۳	۱.۰۶	−۱.۹۱* (p=۰.۰۵۷)	۰.۴۹۷	۵.۶۵۴
EWMA(S)	۳۵.۴۷	۳۴.۵۶	−۱۱.۷۱	−۴۳.۸	۴.۰۰	۱.۰۳	−۲.۳۱** (p=۰.۰۲۱)	۰.۵۱۴	۶.۴۳۶

[1] Max Drawdown

پنل ب: پرتفوی بازار خنثی

مدل	میانگین بازده مازاد سالانه (٪)	نوسان‌پذیری سالانه (٪)	کمترین بازده ماهانه (٪)	بیشینه افت سرمایه (٪)	ارزش نهایی سرمایه	نسبت شارپ	آزمون اختلاف نسبت شارپ (نسبت به GBRT)	بتای تحقق‌یافته	آماره t بتا
مدل‌های یادگیری ماشین									
NN	۲.۴۵	۲۲.۰۴	-۱۵.۵۲	-۴۶.۰۳	۱.۰۱	۰.۱۱	-۳.۰۸ *** (p=۰.۰۰۲)	-۰.۰۵۴	-۰.۵۶
XGB	۱۶.۳۴	۲۲.۲۰	-۱۰.۷۴	-۳۹.۸۲	۲.۰۱	۰.۷۴	-۱.۶۱ (p=۰.۱۰۸)	-۰.۰۰۴	-۰.۰۵۹
GBRT	۱۹.۹۶	۲۲.۲۹	-۱۱.۴۸	-۳۷.۵۵	۲.۴	۰.۹	-	۰.۰۴۷	۰.۶۷۸
LM	۱۶.۹۴	۲۳.۱۹	-۱۲.۸۵	-۴۴.۷۲	۲.۰۵	۰.۷۳	-۱.۴۷ (p=۰.۱۴۱)	۰.۰۰۷	۰.۰۹۵
ELANET	۳.۰۵	۲۵.۲۰	-۱۵.۷۳	-۴۸.۴۲	۱.۰۰	۰.۱۲	-۳.۰۰*** (p=۰.۰۰۳)	-۰.۱۷۷	-۱.۸۲۸
RF	۷.۸۵	۲۴.۲۰	-۱۴.۸۷	-۴۱.۸۱	۱.۲۸	۰.۳۲	-۲.۴۷ ** (p=۰.۰۱۴)	-۰.۱۵۲	-۱.۵۸۵
مدل‌های پایه									
BSW	۱۷.۲۲	۲۴.۴۹	-۱۰.۱۱	-۴۱.۱۳	۱.۹۵	۰.۷	-۱.۱۹ (p=۰.۲۳۲)	۰.۰۶۹	۰.۷۸۹
Vasicek	۱۷.۲۱	۲۴.۷۰	-۱۲.۴۲	-۴۳.۱۴	۱.۹۵	۰.۷	-۱.۱۹ (p=۰.۲۳۳)	۰.۱۰۴	۱.۲۱۳
Blume	۱۱.۳۳	۲۳.۱۹	-۱۳.۰۵	-۴۴.۸۳	۱.۵	۰.۴۹	-۲.۰۰** (p=۰.۰۴۵)	-۰.۰۸۴	-۱.۰۶۸
OLS	۱۹.۵۲	۲۵.۵۸	-۱۲.۳۸	-۴۲.۳۱	۲.۱۵	۰.۷۶	-۰.۸۶ (p=۰.۳۹۰)	۰.۱۴۲	۱.۶۲۱
EWMA(L)	۱۹.۵۲	۲۵.۷۵	-۱۱.۹۳	-۴۲.۹۷	۲.۱۴	۰.۷۶	-۰.۸۸ (p=۰.۳۷۸)	۰.۱۵	۱.۷۵۶
EWMA(S)	۱۹.۶۸	۲۵.۹۳	-۱۰.۰۸	-۴۳.۴۳	۲.۱۶	۰.۷۶	-۰.۸۹ (p=۰.۳۷۴)	۰.۱۸۶	۲.۳۳۶

نتایج پنل الف نشان‌دهنده برتری محسوس مدل‌های یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر تقویت گرادیان، در ارتقای عملکرد پرتفوی است. در این چارچوب، مدل GBRT با ثبت بازده مازاد سالانه ۴۴.۲۴ درصد، نه تنها در میان مدل‌های یادگیری ماشین، بلکه در کل مدل‌های مورد بررسی بالاترین بازده را ایجاد کرده است. پس از آن، مدل‌های RF (۴۲.۳۱ درصد) و XGB (۴۱.۷۲ درصد) قرار دارند که همگی عملکردی برتر نسبت به مدل‌های سنتی نظیر BSW (۳۸.۴۹ درصد) و Vasicek (۳۸.۴۱ درصد) نشان داده‌اند.

نکته حائز اهمیت، برتری مدل‌های یادگیری ماشین در شاخص‌های تعدیل‌شده با ریسک است. برخلاف تصور اولیه، افزایش بازده در مدل GBRT با ریسک کنترل‌نشده همراه نبوده است؛ این مدل با ثبت نسبت شارپ ۱.۲۸، بهترین عملکرد را در کل جدول به خود اختصاص داده است. آزمون اختلاف نسبت شارپ نشان می‌دهد که برتری GBRT نسبت به مدل‌های NN، ELANET و EWMA(S) در سطح ۵ درصد و نسبت به مدل‌های XGB، RF، OLS

و EWMA(L) در سطح ۱۰ درصد از نظر آماری معنادار است. اگرچه اختلاف شارپ GBRT با مدل Blume (با نسبت شارپ ۱.۱۶) از نظر آماری معنادار نیست اما برتری عددی آن در بازده و نسبت شارپ مشهود است.
از منظر کنترل ریسک نزولی نیز، مدل GBRT با کمترین بیشینه افت سرمایه (۳۷.۶۵- درصد) در کل مدل‌ها، توانمندی بالایی در محافظت از سرمایه در شرایط بحرانی بازار نشان داده است. در مقابل، مدل‌های سنتی مانند EWMA(S) و Blume بیشینه افت سرمایه‌ای فراتر از ۴۳ درصد را تجربه کرده‌اند. این یافته‌ها تایید می‌کند که مدل‌های غیرخطی با شناسایی دقیق‌تر تغییرات بتا، منجر به وزن‌دهی کاراتری در پرتفوی حداقل واریانس می‌شوند.
در پرتفوی بازار خنثی، هدف اصلی حذف ریسک سیستماتیک و کسب بازده خالص از انتخاب دارایی است. نتایج پنل ب نشان می‌دهد که مدل GBRT با میانگین بازده مازاد ۱۹.۹۷ درصد و نسبت شارپ ۰.۹۰، برترین عملکرد اقتصادی را داراست. برتری این مدل نسبت به مدل‌های یادگیری ماشین دیگر مانند NN (p = ۰.۰۰۲) و ELANET (p = ۰.۰۰۳) در سطح ۱ درصد و نسبت به مدل RF (p = ۰.۰۱۴) در سطح ۵ درصد کاملاً معنادار است.
در این چارچوب، بتای تحقق‌یافته شاخصی کلیدی برای ارزیابی میزان موفقیت در خنثی‌سازی ریسک بازار است. مدل GBRT بتای تحقق‌یافته ۰.۰۴۷ را ثبت کرده است که نشان‌دهنده نزدیکی بسیار زیاد به هدف بتای صفر است. اگرچه مدل LM با بتای تحقق‌یافته ۰.۰۰۷ به خنثی‌سازی کامل نزدیک‌تر شده، اما بازده مازاد و نسبت شارپ آن (۰.۷۳) کمتر از GBRT است. مدل‌های OLS و EWMA(S) نیز اگرچه نسبت شارپ رقابتی (۰.۷۶) نشان داده‌اند، اما بتای تحقق‌یافته آن‌ها (حدود ۰.۱۴ تا ۰.۱۸) حاکی از ناتوانی در خنثی‌سازی کامل ریسک بازار نسبت به مدل‌های برتر یادگیری ماشین است.
در سوی دیگر، عملکرد ضعیف مدل‌های NN و ELANET در این پنل قابل توجه است. این مدل‌ها به ترتیب بتای تحقق‌یافته ۰.۰۵۴- و ۰.۱۷۷- را ثبت کرده‌اند که نشان‌دهنده سوگیری در برآورد بتا و در نتیجه، قرار گرفتن در موقعیت فروش بیش از حد بازار است. این سوگیری منجر به کاهش شدید بازده سالانه به حدود ۲ تا ۳ درصد و افت ارزش نهایی سرمایه به سطح اولیه شده است.
به‌طور کلی، نتایج جدول ۶ نشان‌دهنده برتری اقتصادی مدل‌های مبتنی بر تقویت گرادیان (به‌ویژه GBRT) در مدیریت پرتفوی است. در هر دو سناریوی حداقل واریانس و بازار خنثی، این مدل توانسته است تعادل بهینه‌ای میان افزایش بازده و کاهش ریسک ایجاد کند. ارزش نهایی سرمایه در مدل GBRT در پرتفوی MVP برابر با ۶.۷۹ است که به شکل معناداری بالاتر از تمامی مدل‌های بنچمارک و یادگیری ماشین قرار دارد. این یافته‌ها تایید می‌کند که استفاده از روش‌های یادگیری ماشین که قادر به استخراج روابط غیرخطی و پیچیده میان ویژگی‌های شرکت‌ها و بتای آن‌ها هستند، ارزش افزوده اقتصادی قابل‌توجهی برای سرمایه‌گذاران و مدیران صندوق‌ها در بازار سرمایه ایران ایجاد می‌کند.

۵. بحث و نتیجه‌گیری

هدف اصلی این پژوهش، ارزیابی جامع توانمندی الگوریتم‌های یادگیری ماشین در بهبود پیش‌بینی برون‌نمونه‌ای ریسک سیستماتیک (بتا) و بررسی ارزش اقتصادی این برآوردها در بورس اوراق بهادار تهران طی یک دوره ۵۰ فصلی بود. نتایج آماری خطای پیش‌بینی نشان داد که مزیت یادگیری ماشین پدیده‌ای جهان‌شمول برای تمامی معماری‌ها نیست، بلکه به ساختار الگوریتم و سازوکار پالایش نویز بستگی دارد. در این میان، مدل جنگل تصادفی (RF) با ثبت کمترین میانگین وزنی ارزش بازار مربع خطای پیش‌بینی (VW-MSE برابر با ۹.۹۹ درصد)، دقیق‌ترین

برآوردگر شناخته شد. نتایج آزمون مقایسه‌ای دایبولد–ماریانو با تصحیح هاروی–لیبورن–نیوبولد (Diebold & Mariano, 1995; Harvey et al., 1997). تأیید کرد که برتری آماری مدل RF بر رقبای قدرتمند یادگیری ماشین از جمله GBRT و XGBoost در سطح خطای کمتر از ۰.۱ درصد، و در مقایسه با برآوردگرهای کلاسیک میانگین متحرک وزنی نمایی (EWMA(S)) از نظر آماری کاملاً معنادار است. در مقابل، مدل‌های خطی جریمه‌دار نظیر الاستیک‌نت و شبکه‌های عصبی عملکردی ضعیف‌تر حتی نسبت به الگوهای سنتی تنظیم‌شده مانند Blume و Vasicek بر جای گذاشتند (Blume, 1971; Vasicek, 1973). این یافته همسو با شواهد دروبتز و همکاران و مندوزا و اونیشچنکو[1] نشان می‌دهد که در بازارهای نوظهور با اصطکاک نقدشوندگی، روش‌های تجمیع مبتنی بر بگینگ (مانند جنگل تصادفی) به دلیل کاهش کارای واریانس در برابر داده‌های پرت، بر معماری‌های مستعد بیش‌برازش غلبه می‌کنند (Drobetz et al., 2025; Mendoza & Onishchenko, 2026).

بررسی عملکرد مدل‌ها در مقطع عرضی سهام و دهک‌های ریسک بخش دیگری از کارایی یادگیری ماشین را آشکار ساخت. مدل‌های سنتی رگرسیونی (نظیر OLS) با خطای سیستماتیک ساختاری و الگوی U شکل مواجه بودند، به‌گونه‌ای که بتاهای پایین را به‌طور سیستماتیک کمتر از واقع و بتاهای بالا را بیش از واقع برآورد می‌کردند؛ در حالی که الگوریتم‌های درخت پایه توانستند این چولگی و سوگیری مقطعی را به میزان چشمگیری تعدیل نمایند (Hollstein et al., 2019). علاوه بر این، ارزیابی حساسیت به طول پنجره برآورد غلتان تأیید کرد که برتری مدل‌های یادگیری ماشین در طول افق‌های زمانی مختلف پابرجا می‌ماند. همچنین تحلیل اهمیت نسبی متغیرها و ارزش افزوده گروه‌های اطلاعاتی اثبات کرد که در مدل جنگل تصادفی اگرچه بتای تاریخی متغیری اثرگذار است، اما ویژگی‌های بنیادی شرکت‌ها و نشانگرهای تکنیکال هم سهم بالایی در کاهش خطای برآورد ایفا می‌کنند. این شواهد مؤید آن است که ریسک سیستماتیک در بورس تهران پدیده‌ای پویا و چندعاملی است که ریشه در ساختار عملیاتی و بنیادین بنگاه‌ها دارد (Heydari, & Heidarpour. 2017).

ارزیابی ارزش اقتصادی پیش‌بینی‌های بتا در دو ساختار سرمایه‌گذاری پرتفوی حداقل واریانس (MVP) و پرتفوی بازارخنثی (MN)، نشان داد، در حالی که مدل RF در معیارهای خطای پیش‌بینی تک‌سهم پیشتاز بود، در عرصه عمل اقتصادی، درخت‌های تصمیم تقویت گرادیان (GBRT) با مهار بهینه کوواریانس میان دارایی‌ها بالاترین عملکرد تعدیل‌شده با ریسک را محقق ساختند. مدل GBRT با دستیابی به نسبت شارپ ۱.۲۸ در پرتفوی حداقل واریانس و ۰.۹۰ در پرتفوی بازارخنثی و ثبت کمترین بیشینه افت سرمایه (به‌ترتیب ۲۶.۸ و ۱۴.۲ درصد)، از تمامی مدل‌های رقیب پیشی گرفت. سنجش استنباطی این تمایز با به‌کارگیری آزمون معناداری آماری اختلاف نسبت شارپ جابسون–کورکی با تصحیح مِمِل (Jobson & Korkie, 1981; Memmel, 2003) تأیید کرد که برتری اقتصادی GBRT بر مدل‌های سنتی(نظیر OLS) و مدل‌های یادگیری ماشین نظیر شبکه‌های عصبی و الاستیک‌نت در سطوح معناداری ۱ تا ۱۰ درصد معتبر است. در مقابل، مدل‌های شبکه عصبی و الاستیک‌نت به دلیل عدم تعادل در وزن‌دهی و ایجاد بتای منفی نامطلوب در سبد خنثی، عملکرد اقتصادی ضعیفی نشان دادند. این نتایج با یافته‌های پژوهش‌های داخلی در بازار سرمایه ایران (نظیر Heidari Dalooei et al., 2026) هم‌راستا است و بر این واقعیت تأکید دارد که در نظر گرفتن عدم‌قطعیت و انتخاب الگوریتم مناسب برای برآورد ماتریس کوواریانس، پیش‌شرط ترجمه دقت آماری به بازده اقتصادی پایدار است. یافته‌های این پژوهش گویای آن است که پیاده‌سازی یادگیری ماشین چارچوبی علمی و عملی برای ارتقای مدیریت ریسک سیستماتیک در بازار سرمایه ایران فراهم می‌سازد؛ مشروط بر آنکه الگوریتم متناسب با هدف مالی انتخاب گردد. از منظر کاربردی، به مدیران سرمایه‌گذاری، نهادهای

[1] Mendoza and Onishchenko

مالی و تحلیلگران سبد اوراق بهادار پیشنهاد می‌شود برای ارزیابی ریسک تک‌سهم و مدل‌های قیمت‌گذاری دارایی از روش‌های تجمعی مبتنی بر بوت‌استرپ (جنگل تصادفی) همراه با متغیرهای بنیادی حسابداری (Cosemans et al., 2016) بهره گیرند، و در فرایندهای بهینه‌سازی سبد، کنترل نوسان‌پذیری و استراتژی‌های خنثی‌سازی بتا، از الگوریتم‌های مبتنی بر بوستینگ (GBRT) به عنوان برآوردگر ورودی ماتریس کوواریانس استفاده نمایند.

با وجود این دستاوردها، پژوهش حاضر با محدودیت‌هایی روبه‌رو بوده است. ویژگی‌های ساختاری بورس تهران، از قبیل توقف‌های مکرر و طولانی نمادها، معاملات کم‌تواتر، عدم تقارن اطلاعاتی و وجود دامنه نوسان قیمت، می‌تواند سنجش سری زمانی بتای تحقق‌یافته ماهانه را با نویز اندازه‌گیری مواجه سازد. افزون بر این، در شبیه‌سازی استراتژی‌های سرمایه‌گذاری، به دلیل رویکرد متعارف آکادمیک، فرض قیمت‌پذیری لحاظ شده و اثرات اصطکاک‌های عملیاتی نظیر کارمزد و مالیات معاملات، محدودیت‌های فروش تعهدی و شوک‌های نقدشوندگی بازار به‌طور کامل مدلسازی نشده است. در نهایت، برای پژوهش‌های آتی پیشنهاد می‌شود به منظور ثبت بهتر اثرات زمانی و ناپایداری‌های ساختاری، تلفیق مدل‌های یادگیری ماشین با فیلترهای کالمن و مدل‌های مارکوف سوئیچینگ (تغییر رژیم) بررسی شود. همچنین استفاده از داده‌های ریزساختار با فرکانس بالا جهت استخراج بتای تحقق‌یافته درون‌روزی و بتای نقدشوندگی، تلفیق صریح توابع زیان نامتقارن متناسب با هزینه مبادله در فرایند آموزش الگوریتم‌ها، و پیاده‌سازی مدل‌های چندعاملی کلان و شبکه‌های یادگیری عمیق ساختاریافته می‌تواند گام‌های مؤثری در تداوم این خط پژوهشی باشد.

تعارض منافع: برای ارائه مطالب 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. نویسندگان صراحتاً اعلام می‌دارند که هیچ‌گونه تضاد منافعی در خصوص این پژوهش وجود ندارد.

Reference

Aflatooni, A., Eivani, F., & Nikbakht, Z. (2024). The effect of information transparency on firm value: The moderating role of industry competitiveness. *Journal of Financial Management Perspective*, 14(47), 89–107. https://doi.org/10.48308/jfmp.2025.237450.1435

Andersen, T. G., Bollerslev, T., Christoffersen, P. F., & Diebold, F. X. (2006). Chapter 15 Volatility and Correlation Forecasting. In Handbook of Economic Forecasting (Vol. 1, pp. 777–878). Elsevier. DOI: https://doi.org/10.1016/S1574-0706(05)01015-3

Andersen, T. G., Bollerslev, T., Diebold, F. X., & Wu, J. (2006). Realized beta: Persistence and predictability. *Journal of Financial Economics*, 81(3), 621–646. DOI: https://doi.org/10.1016/S0731-9053(05)20020-8

Babayi Fallah, A., Khalili Araghi, M., & Nikoumaram, H. (2022). Measuring Industry Beta using a Combination of Black-Scholes model and Grey Theory. *Journal of Financial Management Perspective*, 10(36), 157–178. https://doi.org/10.22051/jfm.2020.28736.2238

Bagherzadeh, A., & Salem, A. (2015). Estimating the dynamic beta of systematic risk in the Tehran Stock Exchange using Kalman Filter and Dynamic Conditional Correlation (DCC) models. *Journal of Economic Research and Policies*, 23(74), 115–142. SID. https://sid.ir/paper/91193/fa

Bali, T. G., Engle, R. F., & Murray, S. (2016). Empirical asset pricing: The cross section of stock returns. John Wiley & Sons. DOI: https://doi.org/10.1002/9781118445112

Berk, J. B., & van Binsbergen, J. H. (2016). Measuring skill in the mutual fund industry. *Journal of Financial Economics*, 118(1), 1–20. DOI: https://doi.org/10.1016/j.jfineco.2015.05.002

Blume, M. E. (1971). On the assessment of risk. The Journal of Finance, 26(1), 1–10. DOI: https://doi.org/10.1111/j.1540-6261.1971.tb00584.x

Bollerslev, T., Engle, R. F., & Wooldridge, J. M. (1988). A capital asset pricing model with time-varying covariances. *Journal of Political Economy*, 96(1), 116–131. DOI: https://doi.org/10.1086/261527

Bucci, A. (2020). Machine learning for realized volatility forecasting. Journal of Financial Econometrics, 18(3), 527–559. DOI: https://doi.org/10.1093/jjfinec/nbaa014

Campbell, J. Y., Lo, A. W., & MacKinlay, A. C. (2001). The econometrics of financial markets. Princeton University Press. DOI: https://doi.org/10.1515/9781400830213

Cochrane, J. H. (2011). Presidential address: Discount rates. *The Journal of Finance*, 66(4), 1047–1108. https://doi.org/10.1111/j.1540-6261.2011.01671.x

Cosemans, M., Frehen, R., Schotman, P. C., & Bauer, R. (2016). Estimating market betas using prior information based on firm fundamentals. *Review of Financial Studies, 29*(4), 1072–1112. https://doi.org/10.1093/rfs/hhv131

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, 15(4), 9–30. https://doi.org/10.48308/jfmp.2026.242761.1561

Diebold, F. X., & Mariano, R. S. (1995). Comparing predictive accuracy. Journal of Business & Economic Statistics, 13(3), 253–263. https://doi.org/10.1080/07350015.1995.10524599

Drobetz, W., Hollstein, F., Otto, T., & Prokopczuk, M. (2025). Estimating stock market betas via machine learning. *Journal of Financial and Quantitative Analysis*, 60(3), 1074-1110. https://doi.org/10.1017/S0022109024000036

Faff, R. W., Hillier, D., & Hillier, J. (2003). Time varying beta risk: An analysis of alternative modelling techniques. *Journal of Business Finance & Accounting, 27*(5–6), 523–554. https://doi.org/10.1111/1468-5957.00324

Fama, E. F., & French, K. R. (1992). The cross-section of expected stock returns. The Journal of Finance, 47(2), 427–465. https://doi.org/10.1111/j.1540-6261.1992.tb04398.x

Fama, E. F., & MacBeth, J. D. (1973). Risk, return, and equilibrium: Empirical tests. *Journal of Political Economy*, 81(3), 607–636. https://doi.org/10.1086/260061

Freyberger, J., Neuhierl, A., & Weber, M. (2020). Dissecting characteristics-based return predictability. *Journal of Financial Economics*, 138(2), 342–368. https://doi.org/10.1016/j.jfineco.2020.05.006

Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. The Review of Financial Studies, 33(5), 2223–2273. https://doi.org/10.1093/rfs/hhaa009

Haji Bozorgi, J., & Akhoundian, M. J. (2011). Investigating the stability of systematic risk (beta) of investment portfolios in Tehran Stock Exchange. *Financial Engineering and Securities Management*, 2(6), 215-244. https://sid.ir/paper/495510/fa

Harvey, D., Leybourne, S., & Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of Forecasting, 13*(2), 281–291. https://doi.org/10.1016/S0169-2070(96)00719-4

Heidari Dalooei, A., Vahdati, M., Mohebbi, H., & Bagherpour, N. (2026). Predictability of the Tehran Exchange Dividend and Price Index using a combined machine learning approach: Market efficiency analysis and importance of influential variables. *Financial Research Journal, 28*(2), 464–493. https://doi.org/10.22059/frj.2025.394747.1007738

Heydari, H., & Heidarpour, A. (2017). Time-varying risk assessment and extension of the Capital Asset Pricing Model (CAPM) in the Tehran Stock Exchange. *Journal of Asset Management and Financing*, 5(3), 61–76. https://dor.isc.ac/dor/20.1001.1.23831170.1396.5.3.7.5

۵۶ llstein, F.; M. Prokopczuk; and C. Wese Simen. “Estimating Beta: Forecast Adjustments and the Impact of Stock Characteristics for a Broad Cross-Section. *Journal of Financial Markets*, 44(2019), 91–118. https://doi.org/10.1016/j.jbankfin.2019.06.002

Huang, C. F. (2012) A hybrid stock selection model using genetic algorithms and support vector regression. Applied Soft Computing, 12(2), 807–818. https://doi.org/10.1016/j.asoc.2011.10.009

Jagannathan, R., & Wang, Z. (1996). The conditional CAPM and the cross-section of expected returns. *Journal of Finance, 51*(1), 3–53. https://doi.org/10.2307/2329301

Jobson, J. D., & Korkie, B. M. (1981). Performance hypothesis testing with the Sharpe and Treynor measures. Journal of Finance, 36(4), 889–908. DOI: https://doi.org/10.1111/j.1540-6261.1981.tb04891.x

Jourovski, A., Dubikovskyy, V., Adell, P., Ramakrish and, R., & Kosowski, R. (2020). Forecasting beta using machine learning and equity sentiment variables. In E. Jurczenko (Ed.), *Machine learning for asset management: New developments and financial applications* (pp. 231–260). Wiley-ISTE. https://doi.org/10.1002/9781119751182.ch7

Kelly, B., Moskowitz, T. J., & Pruitt, S. (2021). Understanding momentum and reversal. *Journal of Financial Economics, 140*(3), 726–743. https://doi.org/10.1016/j.jfineco.2020.06.024

Kim, S., Korajczyk, R. A., & Neuhierl, A. (2021). Arbitrage portfolios. *Review of Financial Studies, 34*(6), 2813–2856. https://doi.org/10.1093/rfs/hhaa102

Kozak, S., Nagel, S., & Santosh, S. (2020). Shrinking the cross-section. Journal of Financial Economics, 135(2), 271–292. https://doi.org/10.1016/j.jfineco.2019.06.008

Leippold, M., Wang, Q., & Zhou, W. (2022). Machine learning in the Chinese stock market. Journal of Financial Economics, 145(2), 64–82. https://doi.org/10.1016/j.jfineco.2021.08.017

Lintner, J. (1965). The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. The Review of Economics and Statistics, 47(1), 13–37. https://doi.org/10.2307/1924119

Maldonado Mendoza, A., & Onishchenko, O. (2026). Beta estimation under infrequent trading: A machine learning approach. *International Review of Finance, 26*(3), Article e70093. https://doi.org/10.1111/irfi.70093

Memmel, C. (2003). Performance hypothesis testing with the Sharpe ratio. Finance Letters, 1(1), 21–23. SSRN: https://ssrn.com/abstract=412588

Mohammadi, S., Abbasi-Nejad, H., & Mirsanei, S. R. (2007). Investigation of different methods of estimating beta in Tehran Stock Exchange. *Accounting and Auditing Review*, 14(47), 3–38.

Sabeti, M., Zomordian, G., Fallah, M., & Minooei, M. (2022). Estimating dynamic systematic risk using multivariate GARCH models in Tehran Stock Exchange. *Journal of Financial Management Strategy*, 10(3), 45–68. https://www.noormags.ir/view/fa/articlepage/1965155

Saidi, A., & Ramesheh, M. (2011). Determinants of systematic risk of stocks in Tehran Stock Exchange. *Financial Research Journal*, 3(1). https://civilica.com/doc/1212004

Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19(3), 425–442. https://doi.org/10.1111/j.1540-6261.1964.tb02865.x

Taheri Bazkhaneh, S., & Sadrara, M. (2026). The puzzle of policy uncertainty and stock market volatility: Evidence from the Iran's economy. *Financial Management Perspective*, 15(4), 55–76. https://doi.org/10.48308/jfmp.2026.242565.1555

Tehrani, R., & Chit-Sazan, H. (2004). Investigating the trend of systematic risk and beta stability of companies listed in Tehran Stock Exchange. *Journal of Financial Research*, 6(1), 1-12. https://dor.isc.ac/dor/20.1001.1.10248153.1383.6.1.2.2

Tondnevis, F., & Valamehr, H. (2025). Probabilistic forecasting and robust optimization for managing uncertainty in smart beta portfolio optimization. *Financial Research Journal*, 27(2), 508–530. https://doi.org/10.22059/frj.2025.401381.1007783

Vasicek, O. A. (1973). A note on using cross-sectional information in Bayesian estimation of security betas. *The Journal of Finance*, 28(5), 1233–1239. https://doi.org/10.1111/j.1540-6261.1973.tb01402.x

Welch, I. (2022). The fluctuating beta of the market. *Journal of Financial Economics*, 145(1), 1–22. https://doi.org/10.1016/j.jfineco.2022.02.008

Zhao, C., Yang, S., Qin, C., Zhou, J. & Chen, L. (2022). A novel smart beta optimization based on probabilistic forecast. Computers, Materials & Continua, 75(1), 478–491. https://doi.org/10.32604/cmc.2023.034933.