



## Financial Management Perspective

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



Original Article

# An Intelligent Integrated Framework for Return Prediction, Asset Selection, and Portfolio Optimization Based on Ensemble Learning and the Aquila meta-heuristic optimization algorithm

Samane DehghanManshadi\*

Mohammadreza Rostami\*\*

Ameneh Khadivar\*\*\*

## Abstract

**Introduction:** Predicting asset returns, managing tail risk, and constructing efficient portfolios are major challenges in financial markets, particularly in highly volatile and non-stationary environments such as the Iranian capital market. Most previous studies have focused on only one component return prediction, asset selection, or portfolio optimization and few have offered an integrated framework capable of performing these tasks simultaneously and intelligently. To address this gap, the present study proposes an innovative framework for intelligent stock portfolio optimization based on ensemble machine learning and the Aquila metaheuristic optimization algorithm, designed to improve return prediction accuracy and reduce tail risk using the Conditional Value-at-Risk (CVaR) criterion.

**Methods:** Daily data from all listed and over-the-counter companies in Iran from April 2013 to October 2024 were used in this study. After data preprocessing and the removal of inconsistent or insufficiently covered symbols, 370 stocks were retained. In the first stage, an ensemble learning model comprising Random Forest, Adaptive Boosting, and Extreme Gradient Boosting was developed. The Aquila metaheuristic algorithm simultaneously performed three tasks: identifying influential features, tuning hyperparameters, and optimizing the weights of the base algorithms. The fitness function combined the mean squared error of stock returns with a penalty for feature set size. The optimized model was then used to predict future returns for all stocks,

Received: November . 4, 2025

Accepted: February. 2, 2026

\*PhD Student, Department of Management, Alzahra University, Tehran, Iran. (Corresponding Author).

E-mail: [s.dehghanmanshadi@alzahra.ac.ir](mailto:s.dehghanmanshadi@alzahra.ac.ir)

\*\* Associate Professor, Department of Management, Alzahra University, Tehran, Iran.

\*\*\* Associate Professor, Department of Management, Alzahra University, Tehran, Iran.

and based on prediction error, 30 stocks with the highest behavioral stability were selected. In the second stage, these 30 stocks were incorporated into the convex optimization framework of Rockafellar and Uryasev's CVaR model to determine optimal portfolio weights for target returns of 0.2%, 0.5%, and 0.8%. Portfolio performance was evaluated using the Sortino & Sharp ratios, and the Acerbi–Szekely backtesting procedure was employed to assess the accuracy of tail-risk estimation.

**Finding:** The ensemble learning model enhanced by the Aquila metaheuristic algorithm successfully identified a compact yet highly effective set of price-, trend-, volatility-, and volume-based features, achieving a high level of predictive accuracy. The portfolio constructed with a target return of 0.5% demonstrated the best overall performance, achieving the highest Sortino & Sharp ratios at both the 95% and 99% confidence levels. Compared with an index-based portfolio, this strategy improved risk-adjusted performance by approximately 24%. Additionally, around 76% of the optimal portfolio weight was allocated to only eight top-performing stocks, mainly from the refining, petrochemical, and investment industries, which exhibited low correlation during market stress. The Acerbi–Szekely test confirmed that the CVaR model was well-calibrated and free from risk underestimation.

**Conclusions:** This study introduces the first integrated framework that unifies three core components of financial decision-making and return prediction, intelligent asset selection, and advanced portfolio optimization-within a single, intelligent hybrid system. The results demonstrate that integrating ensemble learning with the Aquila metaheuristic algorithm under the CVaR framework can meaningfully reduce portfolio downside risk while enhancing risk-adjusted returns. This framework offers practical value for investment funds, asset managers, and institutional investors and can be extended to other emerging markets.

**Keywords:** Aquila metaheuristic optimization algorithm; Conditional Value-at-Risk; Ensemble learning; Machine learning; Portfolio optimization.

**How to Cite** Dehghanmanshadi, .<sup>1</sup>, Rostami, . M. and 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. doi: 10.48308/jfmp.2026.242761.1561 (In Persian).





نوع مقاله: پژوهشی

## چارچوب یکپارچه هوشمند برای پیش بینی بازده، انتخاب دارایی و بهینه سازی پرتفوی مبتنی بر یادگیری گروهی و الگوریتم بهینه سازی فراابتکاری عقاب

سمانه دهقان منشادی \*

محمد رضا رستمی \*\*

آمنه خدیور \*\*\*

### چکیده

**هدف:** پیش بینی بازده دارایی ها، مدیریت ریسک دنباله ای و تشکیل پرتفوی کارا از چالش های اصلی بازارهای مالی، به ویژه در محیط های پرنوسان و غیرایستایی مانند بازار سرمایه ایران است. بسیاری از پژوهش ها هر یک تنها بر یکی از مراحل پیش بینی بازده، انتخاب دارایی یا بهینه سازی پرتفوی تمرکز کرده اند و رویکردی یکپارچه که بتواند این مراحل را همزمان و به صورت هوشمند انجام دهد، کمتر ارائه شده است. پژوهش حاضر باهدف رفع این شکاف، چارچوبی نوین برای بهینه سازی هوشمند پرتفوی سهام ارائه می کند که مبتنی بر یادگیری گروهی ماشین و الگوریتم بهینه سازی فراابتکاری عقاب جهت پیش بینی دقیق بازده و کمینه سازی ریسک دنباله به کمک ارزش در معرض خطر شرطی است.

**روش:** پژوهش حاضر از داده های روزانه کلیه شرکت های بورسی و فرابورسی ایران طی دوره فروردین ۱۳۹۲ تا مهر ۱۴۰۳ استفاده کرده است. پس از پیش پردازش و حذف داده های غیرمنطقی و نمادهای فاقد پوشش کافی، ۳۷۰ نماد انتخاب شد. در مرحله اول، یک مدل یادگیری گروهی شامل سه الگوریتم جنگل تصادفی، تقویت تطبیقی و تقویت گرادیان شدید توسعه یافت. الگوریتم بهینه سازی فراابتکاری عقاب به طور همزمان سه وظیفه را انجام داد: انتخاب ویژگی های مؤثر، تنظیم ابرپارامترها و تعیین وزن بهینه الگوریتم های پایه. معیار ارزیابی تابع برآزش، ترکیبی از میانگین خطای مجذور میانگین مربعات سهام و جریمه اندازه ویژگی ها بود. سپس مدل بهینه شده بازده آتی همه نمادها را پیش بینی کرده و بر اساس خطای پیش بینی، ۳۰ سهم با بالاترین ثبات رفتاری انتخاب شدند. در مرحله دوم، این ۳۰ سهم در مدل بهینه سازی محدب ارزش در معرض خطر شرطی راکفلار و اوریاسف قرار گرفتند تا وزن های بهینه پرتفوی برای سطوح بازده موردانتظار ۰/۲٪، ۰/۵٪ و ۰/۸٪ تعیین شود. عملکرد پرتفوی ها نیز با معیار های شارپ و سورتینو ارزیابی شد. همچنین برای اطمینان از دقت ریسک دنباله ای، آزمون بازآزمایی آسربی-زکلی انجام گرفت.

تاریخ پذیرش: ۱۴۰۴/۱۱/۱۳

تاریخ دریافت: ۱۴۰۴/۰۸/۱۳

E-Mail: [s.dehghanmanshadi@alzahra.ac.ir](mailto:s.dehghanmanshadi@alzahra.ac.ir)

\* دانشجو دکتری مالی، گروه مدیریت، دانشگاه الزهراء، تهران، ایران. (نویسنده مسئول).

\*\* دانشیار، گروه مدیریت، دانشگاه الزهراء، تهران، ایران.

\*\*\* دانشیار، گروه مدیریت، دانشگاه الزهراء، تهران، ایران.

**یافته‌ها:** نتایج نشان داد مدل یادگیری گروهی با بهینه‌سازی الگوریتم فراابتکاری عقاب توانست مجموعه‌ای کوچک اما بسیار مؤثر از ویژگی‌های قیمتی، روند، نوسان و حجم را انتخاب کند و به‌دقت پیش‌بینی قابل‌توجهی دست یابد. پرتفوی مبتنی بر بازده موردانتظار ۵/۰٪ بهترین عملکرد را ثبت کرد و در سطوح اطمینان ۹۵٪ و ۹۹٪، بالاترین نسبت شارپ و سورتینو را داشت. این پرتفوی نسبت به پرتفوی شاخص‌محور حدود ۲۴٪ بهبود در کارایی ریسک‌تعدیل‌شده ایجاد کرد. همچنین حدود ۷۶٪ وزن پرتفوی بهینه تنها به هشت سهم برتر اختصاص یافت که عمدتاً از صنایع پالایشی، پتروشیمی و سرمایه‌گذاری با همبستگی پایین در بحران‌ها بودند. آزمون آسربی-زکلی نیز نشان داد مدل ارزش در معرض خطر شرطی کاملاً کالیبره و فاقد کم‌برآورد ریسک است.

**نتیجه‌گیری:** این پژوهش نخستین چارچوب یکپارچه را ارائه می‌کند که سه عنصر کلیدی تصمیم‌گیری مالی و پیش‌بینی بازده، انتخاب هوشمند دارایی و بهینه‌سازی پیشرفته پرتفوی را در قالب یک سیستم هوشمند ترکیبی گرد هم آورده است. نتایج تأیید می‌کنند که ادغام یادگیری گروهی و بهینه‌سازی با الگوریتم فراابتکاری عقاب بر اساس رویکرد ارزش در معرض خطر شرطی، می‌تواند به شکل معناداری ریسک نزولی پرتفوی را کاهش داده و بازده تعدیل‌شده مبتنی بر ریسک را بهبود بخشد. این چارچوب قابلیت استفاده عملی توسط صندوق‌های سرمایه‌گذاری، سیدگردانان و سرمایه‌گذاران نهادی را داشته و قابل‌تعمیم به سایر بازارهای نوظهور است.

**کلیدواژه‌ها:** یادگیری ماشین؛ یادگیری گروهی؛ الگوریتم بهینه‌سازی فراابتکاری عقاب؛ بهینه‌سازی پرتفوی؛ ارزش در معرض خطر شرطی

**استناد دهی:** دهقان منشادی، سمانه، رستمی، محمدرضا و خدیور، آمنه. (۱۴۰۴). چارچوب یکپارچه هوشمند برای پیش‌بینی بازده، انتخاب دارایی و بهینه‌سازی پرتفوی مبتنی بر یادگیری گروهی و الگوریتم بهینه‌سازی فراابتکاری عقاب. چشم‌انداز مدیریت مالی، ۱۵(۴)، ۹-۳۰.



## ۱. مقدمه

انتخاب دارایی و تخصیص بهینه ثروت یکی از مهم‌ترین مسائل در مدیریت پرتفوی به شمار می‌رود و نیازمند تحلیل دقیق بازده، ریسک و ترجیحات سرمایه‌گذار است. (Asawa, 2021) دقت پیش‌بینی بازده، اندازه‌گیری ریسک و بهینه‌سازی پرتفوی از ارکان اصلی موفقیت در بازارهای مالی هستند؛ هرگونه خطا در این حوزه می‌تواند پیامدهای گسترده‌ای در سطح فردی و حتی ملی به همراه داشته باشد. بازار سهام ایران به دلیل ماهیت غیرخطی، پویا، پرنویز و تأثیرپذیری از عوامل متعدد سیاسی، اقتصادی و رفتاری، پیش‌بینی بسیار دشواری دارد. (Zamani, 2024) در محیط‌های پرنوسان و غیرایستایی مانند بازار سرمایه ایران، پیش‌بینی بازده دارایی‌ها، مدیریت ریسک دنباله‌ای و تشکیل پرتفوی کارا با چالش‌های جدی مواجه است. بسیاری از پژوهش‌های پیشین، تنها بر یکی از مراحل پیش‌بینی بازده، انتخاب دارایی یا بهینه‌سازی پرتفوی تمرکز کرده‌اند و رویکرد یکپارچه‌ای که بتواند این مراحل را هم‌زمان و به‌صورت هوشمند انجام دهد، کمتر ارائه شده است. این شکاف پژوهشی موجب کاهش کارایی کلی استراتژی‌های سرمایه‌گذاری، افزایش خطای پیش‌بینی و ناتوانی در کنترل مؤثر ریسک‌های شدید نزولی به‌ویژه در بازارهای نوظهور که نوسانات ساختاری بالایی دارند، می‌شود. پژوهش حاضر با هدف رفع این شکاف، چارچوبی نوین برای بهینه‌سازی هوشمند پرتفوی سهام ارائه می‌کند که مبتنی بر یادگیری گروهی<sup>۱</sup> و الگوریتم بهینه‌سازی فراابتکاری عقاب<sup>۲</sup> جهت پیش‌بینی دقیق بازده و کمینه‌سازی ریسک دنباله به کمک ارزش در معرض خطر شرطی است. نوآوری اصلی پژوهش در ارائه نخستین چارچوب یکپارچه در بازار ایران است که سه عنصر کلیدی تصمیم‌گیری مالی، پیش‌بینی بازده، انتخاب هوشمند دارایی و بهینه‌سازی پیشرفته پرتفوی را در قالب یک سیستم هوشمند ترکیبی گرد هم می‌آورد. این چارچوب با ادغام هم‌زمان یادگیری گروهی (شامل سه الگوریتم جنگل تصادفی<sup>۳</sup>، تقویت تطبیقی<sup>۴</sup> و تقویت گرادیان شدید<sup>۵</sup>) و الگوریتم بهینه‌سازی فراابتکاری عقاب (برای انجام هم‌زمان سه وظیفه: انتخاب ویژگی‌های مؤثر، تنظیم ابرپارامترها و تعیین وزن بهینه الگوریتم‌های پایه) و سپس بهینه‌سازی پرتفوی بر مبنای کمینه‌سازی ارزش در معرض خطر شرطی با برنامه‌ریزی خطی دقیق، نه تنها دقت پیش‌بینی را افزایش می‌دهد، بلکه ریسک نزولی را به طور معناداری کاهش می‌دهد. این رویکرد، برخلاف مطالعات پیشین که مراحل را جداگانه بررسی کرده‌اند، مرحله پیش‌انتخاب هوشمند سهام را با تنظیم مدل ادغام کرده و امکان تصمیم‌گیری آگاهانه‌تر و کاهش ریسک را برای سرمایه‌گذاران فراهم می‌آورد. همچنین این چارچوب با ترکیب رویکردهای پیشرفته یادگیری ماشین و بهینه‌سازی ریسک دنباله‌ای، گامی مؤثر در جهت ارتقای کارایی استراتژی‌های سرمایه‌گذاری در بازار پرنوسان ایران برمی‌دارد.

## ۲. مبانی نظری و پیشینه پژوهش

یادگیری ماشین به عنوان زیرمجموعه‌ای از هوش مصنوعی، سیستم‌های کامپیوتری را قادر می‌سازد تا از داده‌ها الگوهای پنهان را استخراج کنند و بدون نیاز به برنامه‌نویسی صریح، پیش‌بینی یا تصمیم‌گیری انجام دهند. (Hull, 2021) در بازارهای مالی با داده‌های پرتلاطم، پرنویز و غیرخطی، این قابلیت اهمیت ویژه‌ای دارد، زیرا روابط پیچیده قیمتی، بنیادی و رفتاری را شناسایی کرده و برای پیش‌بینی بازده دارایی‌ها به کار می‌رود. (Ahmadian, 2022) یادگیری گروهی در یادگیری ماشین، با ترکیب چندین الگوریتم پایه برای بهبود دقت، پایداری و تعمیم‌پذیری عمل

<sup>1</sup>. Ensemble Learning

<sup>2</sup>. Aquila meta-heuristic optimization algorithm

<sup>3</sup>. Random forest

<sup>4</sup>. AdaBoost

<sup>5</sup>. XGBoost

می‌کند. (Dogan, 2019) در این روش، الگوریتم‌های مستقل مانند جنگل تصادفی، تقویت تطبیقی و تقویت گرادیان شدید با هم تجمیع می‌شوند تا واریانس کاهش یابد و عملکرد در برابر نوسانات شدید بازارهای مالی بهبود یابد. (Deng, 2013) این رویکرد در سیستم‌های پیچیده و غیرایستا مانند بازار سهام، دقت پیش‌بینی بازده را افزایش می‌دهد. (Behera, 2023) الگوریتم بهینه‌سازی فراابتکاری عقاب بر اساس رفتار شکار عقاب مدل‌سازی شده و شامل چهار فاز اصلی شامل کاوش گسترده (پرواز بلند با شیرجه عمودی برای جستجوی فضای وسیع)، کاوش متمرکز (کاوش در فضای متنوع با پرواز چرخشی)، بهره‌برداری گسترده (پرواز کوتاه با حمله آهسته برای نزدیک شدن به هدف) و بهره‌برداری متمرکز (پیاده‌روی روی زمین برای شکار دقیق) است. از نظر نظری، این الگوریتم با ایجاد تعادل پویا بین کاوش و بهره‌برداری، از گیر افتادن در بهینه محلی جلوگیری کرده و همگرایی سریع‌تری نسبت به الگوریتم‌های سنتی مانند الگوریتم بهینه‌سازی ازدحام ذرات<sup>۱</sup> یا الگوریتم ژنتیک<sup>۲</sup> ارائه می‌دهد. (Abualigah, 2021) این ویژگی‌ها، الگوریتم بهینه‌سازی را برای مسائل چندبعدی مالی، مانند انتخاب همزمان ویژگی‌ها، تنظیم ابرپارامترها و وزن‌دهی الگوریتم‌های یادگیری گروهی در محیط‌های پرنوسان، ایده‌آل می‌سازد و پایداری مدل را افزایش می‌دهد.

در سال‌های اخیر استفاده از الگوریتم‌های یادگیری ماشین در حوزه مالی رشد چشمگیری داشته و بخشی از مطالعات نیز به گنجانیدن مرحله پیش‌انتخاب دارایی‌ها در فرایند تشکیل پرتفوی با کمک این الگوریتم‌ها پرداخته‌اند. پیشرفت‌های علوم داده و یادگیری ماشین امکان ارائه پیش‌بینی‌های دقیق‌تر، ارزیابی بهینه‌تر ریسک و تصمیم‌گیری مؤثرتر را فراهم کرده است. در سطح بین‌المللی، پژوهش‌های متعددی کارایی یادگیری ماشین را در انتخاب سهام، مدیریت ریسک و تشکیل پرتفوی بررسی کرده‌اند. دنگ و مین<sup>۳</sup> (۲۰۱۳) با استفاده از رگرسیون خطی چندعاملی به تشکیل پرتفوی میانگین-واریانس پرداختند و نشان دادند که عملکرد مدل جهانی بهتر از مدل داخلی است. (Deng, 2013) آریان و همکاران<sup>۴</sup> (۲۰۲۲) ارزش در معرض خطر کُگذار شده را با روش‌های مختلف یادگیری ماشین مقایسه کردند. (Arian, 2022) بهرا و همکاران<sup>۵</sup> (۲۰۲۳) بهینه‌سازی پرتفوی میانگین ارزش در معرض خطر را با رگرسیون‌های مبتنی بر یادگیری ماشین مانند جنگل تصادفی، تقویت گرادیان شدید، تقویت تطبیقی و ماشین بردار پشتیبان بررسی کردند و نشان دادند تقویت تطبیقی بهترین عملکرد را دارد. (Behera, 2023) ایلدیز و اسکندراغلو<sup>۶</sup> (۲۰۲۳) با استفاده از مدل‌های طبقه‌بندی یادگیری ماشین، جهت حرکت شاخص سهام را پیش‌بینی کردند و شبکه‌های عصبی، رگرسیون لجستیک و ماشین بردار پشتیبان بهترین نتایج را ارائه دادند. (Ayyıldız, 2023) لوئیس و همکاران<sup>۷</sup> (۲۰۲۳) کارایی یادگیری ماشین را در مدیریت فعال پرتفوی با درآمد ثابت بررسی کرده و نقش مکمل آن در کنار تحلیل بنیادی را نشان دادند. (Luis, 2023) همچنین کمپسی و همکاران<sup>۸</sup> (۲۰۲۴) نشان دادند مدل‌های یادگیری ماشین مانند جنگل تصادفی در پیش‌بینی جهت بازار بهتر از رگرسیون خطی عمل می‌کنند. این مطالعات بر برتری یادگیری ماشین در محیط‌های پیچیده تأکید دارند، اما اغلب فاقد ادغام همزمان پیش‌بینی، انتخاب دارایی و بهینه‌سازی ریسک هستند. (Campisi, 2024) در ایران نیز پژوهش‌های قابل توجهی انجام شده است؛ دهقانی و همکاران (۱۳۹۸) کارایی ماشین بردار پشتیبان و شبکه‌های عصبی را در پیش‌بینی سری‌های زمانی مالی تأیید کردند. (Dehghani, 2019) نوراحمدی و صادقی (۱۴۰۱) نشان دادند رویکرد سلسله‌مراتبی برابری ریسک نسبت به حداقل واریانس عملکرد بهتری دارد،

<sup>1</sup>. Particle Swarm Optimization (PSO)

<sup>2</sup>. Genetic Algorithm (GA)

<sup>3</sup>. Deng & Min

<sup>4</sup>. Arian et al.

<sup>5</sup>. Behera et al.

<sup>6</sup>. Ayyıldız & İskenderoğlu

<sup>7</sup>. Luis et al.

<sup>8</sup>. Campisi et al.

هرچند فاقد تمرکز بر ریسک دنباله‌ای است. (Noorahmadi, 2022) فریدی و همکاران (۱۴۰۱) مدل ترکیبی امگا-مارکوئیتز مبتنی بر یادگیری جمعی را برای بهینه‌سازی پرتفوی پیشنهاد کردند اما بدون ادغام الگوریتم فراابتکاری برای بهینه‌سازی همزمان. (Faridi, 2022) هراتی‌زاده و رضایی (۱۴۰۲) یک چارچوب دو مرحله‌ای پیش‌بینی بازده و انتخاب وزن پرتفوی ارائه دادند اما از الگوریتم‌های فراابتکاری مانند عقاب غفلت شده است. (Heratizadeh, 2023) اسفندیار و همکاران (۱۴۰۲) از یادگیری تقویتی کیو عمیق برای بهینه‌سازی پرتفوی استفاده کردند و کارایی آن را در بورس تهران نشان دادند. این مطالعه بر یادگیری تقویتی تک‌عاملی تمرکز دارد و فاقد ارائه چارچوب یکپارچه پیش‌بینی بازده، انتخاب هوشمند دارایی و مدیریت ریسک نزولی است. (Esfandiar, 2024) همچنین، زمانی و همکاران (۱۴۰۳) نیز نشان دادند ترکیب هوش مصنوعی و روش‌های نیمه‌پارامتریک مانند بوت‌استرپ می‌تواند کارایی پیش‌بینی ارزش در معرض خطر را در بازار ایران افزایش دهد. (Zamani, 2024) دلیلی و همکاران (۱۴۰۳) با استفاده از یادگیری تقویتی عمیق و ادغام با نظریه مدرن پرتفوی، بهینه‌سازی سبد سهام را بررسی کردند و نشان دادند که این رویکرد در بازار ایران، بازده را بهبود می‌بخشد، اما فاقد ادغام با معیارهای ریسک دنباله‌ای مانند ارزش در معرض خطر شرطی است. (Dalili, 2014) این پژوهش‌ها بر اهمیت یادگیری ماشین در بازار ایران تأکید دارند، اما اغلب مراحل پیش‌بینی و بهینه‌سازی را جداگانه بررسی کرده‌اند. با وجود پیشرفت‌های قابل توجه در ادبیات داخلی و خارجی، خلأ پژوهشی در ارائه چارچوب یکپارچه برای بازار پرتلاطم ایران مشهود است. پژوهش حاضر این خلأ را با ادغام یادگیری گروهی، الگوریتم بهینه‌سازی عقاب (برای بهینه‌سازی همزمان) و ارزش در معرض خطر شرطی پر می‌کند و مدلی ارائه می‌دهد که دقت پیش‌بینی را افزایش داده و ریسک دنباله‌ای را به طور مؤثر مدیریت می‌کند. پژوهش حاضر با ارائه چنین چارچوبی، شکاف موجود در پیشینه پژوهش را پوشش داده و رویکردی عملی و قابل‌انکاس برای تصمیم‌گیری سرمایه‌گذاری در بازار سهام ایران ارائه می‌دهد.

### ۳. روش‌شناسی پژوهش

در این پژوهش داده‌های روزانه قیمت و حجم معاملات کلیه شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران و فرابورس ایران از فروردین ۱۳۹۲ تا مهر ۱۴۰۳، از پایگاه داده رسمی شرکت مدیریت فناوری بورس تهران استخراج گردیده است. داده‌های خام شامل قیمت‌های باز، بسته، بالا، پایین و حجم معاملات بوده و برای اطمینان از صحت، با داده‌های تکمیلی از سایت رسمی بورس اوراق بهادار تهران تطبیق داده شده است. پیش‌پردازش داده‌ها که شامل پاکسازی داده‌ها برای مدیریت مقادیر گمشده و غیرمنطقی است انجام شده و در مرحله پاکسازی موارد زیر اعمال گردید:

۱. حذف ردیف‌هایی که اطلاعات ناقص یا گمشده داشتند.

۲. حذف رکوردهای غیرمنطقی (مانند حجم صفر در روزهای باز بودن بازار).

۳. حذف نمادهایی که تعداد مشاهدات معتبر آنها کمتر از ۹۰٪ دوره زمانی بود.

در نهایت، ۳۷۰ نماد به‌عنوان مجموعه نمونه معتبر انتخاب شدند. برای هر نماد، بازده روزانه به‌عنوان یک ویژگی ورودی در کنار سایر ویژگی‌ها، محاسبه گردید. به منظور تقویت توان مدل در تشخیص الگوهای رفتاری قیمت و فرآیندهای درون‌ساختاری بازار، مجموعه‌ای از ویژگی‌های آماری و تحلیل تکنیکال استخراج شدند. برای اینکه مدل‌ها نسبت به مقیاس ویژگی‌ها سوگیری نداشته باشند، تمامی ویژگی‌ها با استفاده از مقیاس‌سازی Min-Max به بازه [۰, ۱] منتقل شده و نرمالسازی شدند:

$$X_{\text{scaled}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad \text{رابطه (۱)}$$

در ادامه، داده‌ها بدون هیچ‌گونه تصادفی‌سازی و با حفظ ترتیب زمانی به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم شدند. ۶۰٪ ابتدایی برای آموزش مدل، ۲۰٪ میانی برای ارزیابی روی داده‌های دیده‌نشده و تنظیم ابرپارامترها در الگوریتم بهینه‌سازی فراابتکاری عقاب و ۲۰٪ پایانی برای آزمون نهایی عملکرد مدل، مورد استفاده قرار گرفت. این نوع تفکیک زمانی، مانع نشت اطلاعات از آینده به گذشته می‌شود و تضمین می‌کند مدل تنها بر پایه داده‌های تاریخی آموزش ببیند. در نتیجه، سنجش مدل در مجموعه آزمون، واقع‌بینانه بوده و رفتار آن در شرایط واقعی پیش‌بینی بازارهای مالی به‌درستی منعکس می‌شود. این پژوهش شامل چند مرحله اصلی است. مرحله اول شامل استفاده از مدل یادگیری گروهی برای پیش‌بینی بازده، مرحله دوم شامل انتخاب ویژگی‌ها و تنظیم ابرپارامترها، مرحله سوم شامل آموزش مدل، رتبه‌بندی سهام با استفاده از الگوریتم بهینه‌سازی فراابتکاری عقاب و مرحله چهارم تشکیل پرتفوی بهینه مبتنی بر کمینه سازی ارزش در معرض خطر شرطی است. در ادامه به توضیح هر مرحله پرداخته می‌شود.

**استفاده از مدل یادگیری گروهی برای پیش‌بینی بازده؛** هدف این مرحله ارزیابی میزان پیش‌بینی‌پذیری سهام و انتخاب ۳۰ نماد با بالاترین ثبات رفتاری و کمترین خطای پیش‌بینی است تا تنها سهم‌هایی وارد مرحله تشکیل پرتفوی بهینه شوند که الگوی قیمتی قابل‌اعتمادتر و نوسانات غیرقابل‌پیش‌بینی کمتری دارند. برای این منظور، یک ساختار یادگیری گروهی متشکل از چند مدل یادگیری ماشین آموزش داده شد و الگوریتم بهینه‌سازی فراابتکاری عقاب به‌طور هم‌زمان بهترین ویژگی‌ها، ابرپارامترها و وزن‌های ترکیب را استخراج کرد. در این ساختار، سه الگوریتم قدرتمند شامل جنگل تصادفی، تقویت تطبیقی و تقویت گرادیان شدید به‌عنوان مدل‌های پایه به کار گرفته شدند؛ جنگل تصادفی برای مدیریت داده‌های پرنویز و روابط غیرخطی، تقویت تطبیقی برای بهبود عملکرد از طریق تمرکز بر نقاط دشوار و تقویت گرادیان شدید برای ارائه دقت بالا و کنترل بیش‌برازش (Zhang, 2012) ترکیب این سه روش، پوشش مناسبی از الگوهای خطی و غیرخطی بازار فراهم کرده و مبنایی کارآمد برای شناسایی سهم‌هایی با بیشترین قابلیت پیش‌بینی ایجاد کرده است.

جدول ۱. الگوریتم‌های یادگیری ماشین مورد استفاده در مدل یادگیری گروهی

Table 1. Machine learning algorithms used in the Ensemble Learning model

ماهیت	دلیل انتخاب	الگوریتم
درخت‌های تصمیم تجمیعی	مقاومت در برابر نویز و داده‌های غیرخطی	جنگل تصادفی
یادگیری افزایشی مبتنی بر وزن‌دهی خطا	تمرکز بر مشاهدات سخت	تقویت تطبیقی
تقویت گرادیان بهبودیافته	دقت بالا و کنترل بیش‌برازش	تقویت گرادیان شدید

**انتخاب ویژگی‌ها و تنظیم ابرپارامترها با استفاده از الگوریتم بهینه‌سازی عقاب؛** الگوریتم بهینه‌سازی فراابتکاری عقاب، یک روش فراابتکاری مبتنی بر جمعیت است که در سال ۲۰۲۱ معرفی شد و با الهام از رفتارهای شکار عقاب چهار راهبرد کاوش و بهره‌برداری را شامل کاوش گسترده، کاوش متمرکز، بهره‌برداری گسترده و بهره‌برداری متمرکز، مدل‌سازی می‌کند. الگوریتم در ابتدا با کاوش سراسری فضای جست‌وجو را بررسی می‌کند تا نواحی مناسب را بیابد و سپس به تدریج وارد فاز بهره‌برداری می‌شود تا بهترین راه‌حل‌ها را دقیق‌تر پالایش کند. این گذار تدریجی بین کاوش و بهره‌برداری باعث جلوگیری از گیر افتادن در بهینه‌های محلی و دستیابی سریع‌تر به پاسخ بهینه می‌شود. در کاوش گسترده، الگوریتم با شبیه‌سازی پروازهای بلند بخش وسیعی از فضا را جست‌وجو می‌کند؛ در کاوش متمرکز، با الگوی پرواز دایره‌ای نواحی امیدبخش را دقیق‌تر ارزیابی می‌کند. مرحله بهره‌برداری نیز ابتدا با جست‌وجوی وسیع اطراف بهترین پاسخ‌ها آغاز می‌شود و سپس با حرکات کوچک‌تر و هدفمند به سمت بهینه نهایی حرکت می‌کند. ترکیب این چهار سازوکار، توانایی الگوریتم بهینه‌سازی فراابتکاری عقاب را برای حل مسائل پیچیده،

غیرخطی و ابعاد بالا به‌ویژه در تنظیم ابرپارامتر و انتخاب ویژگی، بسیار کارآمد و قابل اتکا می‌سازد. (Abualigah, 2021) به‌منظور ارزیابی کیفیت هر راه حل، تابع هدف زیر تعریف شده است:

$$Fitness = RMSE_{overall} + \lambda \times \frac{\text{Number of Selected Features}}{\text{Number of Total Features}} \quad \text{رابطه (۲)}$$

که در آن خطای مجذور میانگین مربعات<sup>۱</sup>، معیار خطای پیش‌بینی مدل یادگیری گروهی است و عبارت دوم یک جریمه مبتنی بر تعداد ویژگی‌های انتخاب‌شده است. در این تابع ضریب  $\lambda$  یک مقدار کوچک و کنترل‌شده است که مانع استفاده بی‌رویه از ویژگی‌ها شده و مدل را به سمت انتخاب مجموعه‌ای کم‌حجم، کارا و فاقد افزونگی هدایت می‌کند. به این ترتیب، الگوریتم بهینه‌سازی فراابتکاری عقاب، تعادل مناسبی میان دقت پیش‌بینی و سادگی مدل برقرار می‌سازد و بدین‌وسیله مجموعه‌ای از تنظیمات بهینه و ویژگی‌های مؤثر را استخراج می‌کند. در ساختار این الگوریتم، هر راه‌حل یک نمایه کامل از تنظیمات مدل را نشان می‌دهد و شامل سه بخش اصلی است:

۱. اعمال ماسک ویژگی‌ها که مشخص می‌کند کدام ویژگی‌ها انتخاب شده و کدام حذف می‌شوند.
  ۲. مقادیر ابرپارامترهای سه الگوریتم جنگل تصادفی، تقویت تطبیقی و تقویت گرادیان شدید که تعیین‌کننده پیچیدگی، عمق یادگیری و میزان انعطاف‌پذیری هر مدل هستند.
  ۳. وزن‌های ترکیب الگوریتم‌های پایه در ساختار یادگیری گروهی که میزان اثرگذاری هر الگوریتم پایه بر خروجی نهایی را مشخص می‌کند.
- در ادامه، میانگین مقدار خطای مجذور میانگین مربعات تمام سهم‌ها به‌عنوان معیار خطای کلی پیکربندی راه‌حل استفاده می‌شود.

$$RMSE_{overall} = \frac{1}{N} \sum_{i=1}^N RMSE_i \quad \text{رابطه (۳)}$$

به‌کارگیری میانگین خطای مجذور میانگین مربعات موجب ارزیابی منصفانه سهم می‌شود و از تأثیر نوسانات یا مقیاس قیمتی متفاوت جلوگیری می‌کند. سپس با افزودن جریمه‌ای متناسب با تعداد ویژگی‌های انتخاب‌شده، تابع برازش نهایی شکل می‌گیرد تا مدل هم خطای پیش‌بینی را کاهش دهد و هم از استفاده از ویژگی‌های غیرضروری پرهیز کند. (Rockafellar, 2002) با این حال، کمترین خطا تنها در بهینه‌سازی همزمان هر سه مؤلفه حاصل شده که اثر هم‌افزایی آن‌ها را تأیید کرده و ضرورت رویکرد یکپارچه پیشنهادی را به‌طور تجربی اثبات می‌کند.

**تحلیل تفکیکی نقش الگوریتم بهینه‌سازی فراابتکاری عقاب؛** در این مطالعه، معیار ارزیابی عملکرد مدل، خطای کلی پیش‌بینی<sup>۲</sup> است که به‌صورت میانگین خطای مجذور میانگین مربعات، مربوط به ۳۰ سهم منتخب محاسبه می‌شود. برای تحلیل تفکیکی، چندین پیکربندی جایگزین در نظر گرفته شده‌اند که در هر یک، الگوریتم عقاب صرفاً برای بهینه‌سازی یکی از مؤلفه‌ها فعال بوده و سایر مؤلفه‌ها ثابت نگه داشته شده‌اند. عملکرد این پیکربندی‌ها با مدل پایه بدون استفاده از الگوریتم عقاب و همچنین مدل نهایی پیشنهادی مقایسه شده است. نتایج این مقایسه در جدول زیر ارائه شده است.

<sup>۱</sup>. Root Mean Square Error (RMSE)

<sup>۲</sup>. RMSEoverall

جدول ۲. مطالعه تفکیکی نقش مؤلفه‌های بهینه‌سازی

Table2. A disaggregated study of the role of optimization components

خطای کلی پیش‌بینی	پیگر بندی مدل	خطای کلی پیش‌بینی	پیگر بندی مدل
۰/۰۲۲۳۱	تنظیم ابرپارامترها با جستجوی شبکه‌ای <sup>۱</sup>	۰/۰۲۳۱۵	مدل پایه بدون الگوریتم عقاب
۰/۰۲۱۹۹	تنظیم ابرپارامترها با بهینه‌سازی بیزی <sup>۲</sup>	۰/۰۲۱۸۲	الگوریتم عقاب فقط انتخاب ویژگی
۰/۰۲۲۱۸	الگوریتم عقاب فقط وزن‌دهی	۰/۰۲۱۴۱	الگوریتم عقاب فقط ابرپارامترها
۰/۰۲۱۰۳	الگوریتم عقاب کامل (پیشنهادی)	۰/۰۲۲۶۴	تنظیم ابرپارامترها با جستجوی تصادفی <sup>۳</sup>

نتایج نشان می‌دهد که هر مؤلفه بهینه‌سازی به‌طور مستقل خطای کلی پیش‌بینی را نسبت به مدل پایه با بیشترین تأثیر از تنظیم ابرپارامترها، کاهش می‌دهد. همچنین الگوریتم عقاب در مقایسه با روش‌های سنتی تنظیم ابرپارامترها عملکرد برتری دارد.

**آزمایش مقایسه‌ای کنترل‌شده برای ارزیابی اثربخشی الگوریتم عقاب؛** برای ارزیابی اثربخشی الگوریتم عقاب و اطمینان از عدم وابستگی بهبود عملکرد به الگوریتم خاص، آزمایش مقایسه‌ای کنترل‌شده‌ای با الگوریتم‌های بهینه‌سازی ازدحام ذرات، بهینه‌سازی گرگ خاکستری<sup>۴</sup> و بهینه‌سازی زنبک‌ها<sup>۵</sup> انجام شد. این الگوریتم‌ها در ۳۰ اجرای مستقل تحت شرایط یکسان (فضای جستجو، تابع برازش، اندازه جمعیت و تعداد تکرار) مقایسه گردیدند و نتایج آماری در جدول زیر ارائه شده است.

جدول ۳. مقایسه آماری الگوریتم‌های فراابتکاری در بهینه‌سازی مدل یادگیری گروهی

Table3. Statistical comparison of metaheuristic algorithms in Ensemble Learning optimization

الگوریتم	بیشینه	کمینه	انحراف معیار	میانگین
عقاب	۰/۰۲۳۰۱۳	۰/۰۲۲۲۱۳	۰/۰۰۰۲۲۰	۰/۰۲۲۶۱۳
گرگ خاکستری	۰/۰۲۳۷۲۶	۰/۰۲۲۷۷۶	۰/۰۰۰۲۲۹	۰/۰۲۳۱۵۹
زنبک‌ها	۰/۰۲۳۹۲۶	۰/۰۲۲۸۴۶	۰/۰۰۰۲۴۵	۰/۰۲۳۲۹۳
ازدحام ذرات	۰/۰۲۴۴۲۶	۰/۰۲۲۹۶۶	۰/۰۰۰۳۳۶	۰/۰۲۳۸۷۶

نتایج نشان می‌دهد، الگوریتم عقاب کمترین میانگین خطای کلی پیش‌بینی، پایین‌ترین انحراف معیار و محدودترین بازه تغییرات را داشته که بیانگر دقت بالاتر، پایداری بیشتر و همگرایی متعادل‌تر نسبت به سایر الگوریتم‌ها است و برتری آن در چارچوب پیشنهادی را تأیید می‌کند.

**بررسی معناداری آماری تفاوت عملکرد با آزمون دیبولد ماریانو؛** به‌منظور بررسی معناداری آماری تفاوت عملکرد در مطالعه تفکیکی، آزمون دیبولد ماریانو بر سری‌های زمانی خطای پیش‌بینی خارج از نمونه در سطح هر سهم اعمال شد. اختلاف خطای مربعی بین روش پیشنهادی الگوریتم بهینه‌سازی عقاب کامل با بهینه‌سازی هم‌زمان انتخاب

<sup>1</sup>. Grid Search

<sup>2</sup>. Bayesian Optimization

<sup>3</sup>. Random Search

<sup>4</sup>. Grey Wolf Optimization(GWO)

<sup>5</sup>. Whale Optimization Algorithm(WOA)

<sup>6</sup>. Diebold-Mariano

ویژگی‌ها، تنظیم ابرپارامترها و وزن‌دهی مدل‌های پایه و پیکربندی‌های مقایسه‌ای محاسبه گردید و با برآورد واریانس مقاوم، نتایج با روش‌های تجمیع فیشر<sup>۱</sup> و استوفر<sup>۲</sup> گزارش شد. نتایج در جدول زیر قابل مشاهده است.

**جدول ۴.** نتایج آزمون دیبولد ماریانو برای مقایسه زوجی الگوریتم عقاب کامل در برابر پیکربندی‌های مختلف

**Table4.** Diebold Mariano test results for pairwise comparison of the full Aquila algorithm against different configurations

مقایسه الگوریتم عقاب کامل در برابر...	Z استوفر	p-value استوفر	p-value فیشر
مدل پایه بدون الگوریتم عقاب	۹/۸۵	۰	۰
الگوریتم عقاب فقط انتخاب ویژگی	۶/۱۰	۰	۰
الگوریتم عقاب فقط ابرپارامترها	۴/۳۵	۰/۰۰۰۰۰۶۸	۰/۰۰۰۰۰۰۰۰۸۹
تنظیم ابرپارامترها با جستجوی تصادفی	۷/۰۵	۰	۰
تنظیم ابرپارامترها با جستجوی شبکه ای	۶/۴۵	۰	۰
تنظیم ابرپارامترها با بهینه‌سازی بی‌زی	۵/۱۰	۰/۰۰۰۰۰۰۱۷	۰
الگوریتم عقاب فقط وزن‌دهی	۵/۶۵	۰	۰

نتایج نشان می‌دهد روش پیشنهادی در مقایسه زوجی با تمامی پیکربندی‌های جایگزین شامل حالت‌های مطالعه تفکیکی و روش‌های متداول تنظیم ابرپارامترها، برتری آماری معناداری در کاهش خطای پیش‌بینی دارد. مقادیر مثبت و بزرگ آماره استوفر نیز تأیید می‌کند که این برتری سیستماتیک، پایدار و مستقل از نوسانات تصادفی است. معناداری آماری در مقایسه با روش‌های متداول تنظیم ابرپارامترها نشان می‌دهد مزیت الگوریتم عقاب کامل، ناشی از بهینه‌سازی یکپارچه مؤلفه‌های کلیدی با تابع برازش مشترک است. در مجموع، نتایج آزمون دیبولد ماریانو بهبود عددی خطای کلی پیش‌بینی گزارش شده در جدول ۲ را از منظر آماری معتبر ساخته و ادعای اصلی مقاله در خصوص ضرورت و هم‌افزایی بهینه‌سازی همزمان را به‌طور مستدل پشتیبانی می‌کند.

**آموزش مدل و رتبه‌بندی سهام؛** پس از همگرایی الگوریتم بهینه‌سازی فراابتکاری عقاب و استخراج بهترین مجموعه ویژگی‌ها، ابرپارامترهای سه مدل پایه و وزن‌های ساختار یادگیری گروهی، مرحله نهایی شامل بازآموزی مدل و رتبه‌بندی سهام آغاز می‌شود. در این مرحله، مدل یادگیری گروهی با پیکربندی بهینه‌شده بار دیگر بر کل داده‌های آموزشی، آموزش داده می‌شود تا از تمام اطلاعات تاریخی برای افزایش دقت پیش‌بینی استفاده شود. سپس مدل بر داده‌های آزمون اعمال شده و برای هر سهم بازده آتی پیش‌بینی و خطای مجذور میانگین مربعات محاسبه می‌شود تا میزان ثبات رفتاری و قابلیت پیش‌بینی هر نماد سنجیده شود. سهم‌هایی که خطای کمتر و پایداری بیشتری دارند، رتبه بالاتری می‌گیرند و در نهایت ۳۰ سهم باکیفیت به‌عنوان خروجی مرحله انتخاب سهام، تعیین می‌شوند. خروجی

<sup>1</sup>. Fisher

<sup>2</sup>. Stouffer

نهایی این بخش شامل ویژگی‌های منتخب بهینه، بهترین ابرپارامترهای سه الگوریتم جنگل تصادفی، تقویت تطبیقی و تقویت گرادبان شدید، وزن‌های بهینه مدل یادگیری گروهی و ۳۰ سهم منتخب است که به‌عنوان ورودی مرحله بهینه‌سازی پرتفوی مبتنی بر محاسبه ارزش در معرض خطر شرطی به کار می‌روند.

جدول ۵. خروجی‌های مرحله اول

Table 5. Outputs of the first stage

خروجی	توضیح
مجموعه ویژگی‌های منتخب بهینه	مجموعه‌ای فشرده، بدون افزونگی، و مؤثر که مبنای آموزش مدل نهایی قرار می‌گیرد.
ابریارامترهای بهینه ۳ الگوریتم پایه	بهترین تنظیمات استخراج‌شده توسط الگوریتم بهینه‌سازی فراابتکاری عقاب که دقت پیش‌بینی را به حداکثر می‌رسانند.
وزن‌های بهینه ساختار یادگیری گروهی	ترکیب وزن‌دار مدل‌های پایه که بالاترین عملکرد پیش‌بینی را فراهم می‌کند.
۳۰ سهم منتخب با قابلیت پیش‌بینی بالا	نمادهایی که کمترین خطای مجذور میانگین مربعات و رفتار قیمتی پایدار داشته‌اند و ورودی مرحله بهینه‌سازی ارزش در معرض خطر شرطی هستند.

**تشکیل پرتفوی بهینه؛** هدف این مرحله، تخصیص بهینه وزن دارایی‌ها در پرتفوی به‌منظور کمینه‌سازی ریسک دنباله‌ای<sup>۱</sup> و دستیابی به بازده مورد انتظار است، که با استفاده از معیار ارزش در معرض خطر شرطی به‌عنوان تابع هدف ریسک انجام می‌شود. ورودی این مرحله شامل ۳۰ سهم منتخب از مرحله پیشین است و مدل بهینه‌سازی محدب راکفلار و اوریاسف (۲۰۰۲) با افزودن قید بازده پیش‌بینی‌شده و حداقل بازده مطلوب، ریسک نزولی را کمینه می‌کند. در این پژوهش برای اطمینان از تحقق بازده مطلوب، بردار بازده‌های پیش‌بینی‌شده به‌عنوان قید بازدهی و حداقل بازده مورد انتظار به مدل افزوده شده است؛ بنابراین ساختار نهایی بهینه‌سازی ارزش در معرض خطر شرطی بر کمینه‌سازی ریسک نزولی همراه با رعایت حد بازده مدنظر سرمایه‌گذار است. فرض کنید:

$\mu = (\mu_1, \dots, \mu_n)^T$  بردار بازده‌های پیش‌بینی‌شده باشد و  $\mu$  حداقل بازده مورد انتظار سرمایه‌گذار باشد. در این صورت قید زیر به مدل اضافه می‌شود:

$$w^T \mu \geq \mu_0$$

بنابراین مدل نهایی مورد استفاده در پژوهش به شکل زیر خواهد بود:

$$\min_{w, \xi, z} \xi + \frac{1}{(1-\alpha)N} \sum_{i=1}^N z_i \quad \text{رابطه (۴)}$$

به طوری که:

$$z_i \geq -w^T R_i - \xi, \quad i = 1, \dots, N,$$

$$z_i \geq 0, \quad i = 1, \dots, N,$$

$$w^T \mu \geq \mu_0,$$

$$\sum_{j=1}^n w_j = 1,$$

<sup>۱</sup>. Tail Risk

$$w_j \geq 0, \quad j = 1, \dots, n.$$

\_(Rockafellar, 2002)

آزمون بازآزمایی آسربی-زکلی<sup>۱</sup>؛ برای ارزیابی صحت پیش‌بینی ریسک دنباله‌ای مدل ارزش در معرض خطر شرطی بهینه طراحی شده در این پژوهش، از آزمون بازآزمایی آسربی-زکلی بر روی بازده‌های واقعی پرتفوی در دوره آزمون استفاده شده است. هدف از این آزمون بررسی آن است که آیا مقدار ارزش در معرض خطر شرطی بهینه پیش‌بینی شده توسط مدل، با زبان‌های واقعی مشاهده شده در دنباله توزیع منطبق است یا خیر. در این آزمون، نمرات خطا بر اساس رابطه زیر محاسبه گردیده است.

$$W_t = \frac{\max(0, L_t - VaR_t)}{1 - \alpha} - (ES_t - VaR_t) \quad \text{رابطه (۵)}$$

جدول ۶. توضیح نمادهای رابطه

Table 6. Explanation of relationship symbols

نماد	توضیح
$VaR_t$	مقدار ارزش در معرض خطر پیش‌بینی شده در روز $t$
$ES_t$	مقدار ارزش در معرض خطر شرطی پیش‌بینی شده در روز $t$
$\alpha$	سطح اطمینان

میانگین این نمرات در دوره آزمون برابر است با:

$$\bar{W} = \frac{1}{T} \sum_{t=1}^T W_t \quad \text{رابطه (۶)}$$

و آماره آزمون  $t$  به صورت زیر تعریف می‌شود:

$$t_{NW} = \frac{\bar{W}}{SE_{NW}(\bar{W})} \quad \text{رابطه (۷)}$$

که در آن  $SE_{NW}(\bar{W})$  بر اساس برآوردگر نیووست محاسبه شده تا اثر خودهمبستگی در داده‌های مالی لحاظ شود. اگر مدل پیش‌بینی مناسب باشد، میانگین نمره‌های خطا باید برابر با صفر باشد. بنابراین فرضیات آزمون آماری به شکل زیر است:

$$H_0: E[W_t] = 0$$

مدل ارزش در معرض خطر شرطی به درستی کالیبره شده است.

$$H_1: E[W_t] > 0$$

مدل ارزش در معرض خطر شرطی، ریسک دنباله‌ای را دست کم گرفته است.

تفسیر نهایی این آماره به شکل زیر است:

اگر  $t_{NW}$  نزدیک به صفر یا منفی باشد و  $p > 0.05$  ← مدل ارزش در معرض خطر شرطی معتبر یا محافظه‌کار است (عدم رد فرض صفر).

<sup>1</sup>. Acerbi-Szekely

<sup>2</sup>. Newey-West

اگر  $t_{NW}$  بزرگ و مثبت باشد و  $p > 0.05$  ← مدل ارزش در معرض خطر شرطی ریسک دنباله ای را دست‌کم گرفته است (رد فرض صفر). (Acerbi, 2024)

#### ۴. تحلیل داده‌ها و یافته‌های پژوهش

در این پژوهش، انتخاب ویژگی‌ها و تنظیم هم‌زمان ابرپارامترهای سه الگوریتم پایه به‌صورت یکپارچه و با استفاده از الگوریتم بهینه‌سازی فراابتکاری عقاب انجام شده است. این رویکرد، مدل نهایی را قادر می‌سازد تا مجموعه‌ای از ویژگی‌های مؤثر و غیربازتکراری را انتخاب کرده و بهترین ترکیب ابرپارامترها و وزن‌های مدل‌های پایه در یادگیری گروهی را بیاموزد. پارامترهای الگوریتم به‌صورت تجربی بر اساس حداکثر تعداد تکرار ۲۰۰، اندازه جمعیت اولیه ۱۰۰ و ضریب جریمه ( $\lambda$ ) برابر ۰/۰۱ تعیین شدند. این تنظیمات تعادل بین اکتشاف و بهره‌برداری را تضمین کرده و منجر به انتخاب بهینه ویژگی‌ها، ابرپارامترها و وزن‌ها شد. به‌منظور بررسی پایداری مدل نسبت به پارامتر منظم‌سازی  $\lambda$ ، تحلیل حساسیت با مقادیر مختلف  $\lambda$  انجام و فرآیند بهینه‌سازی الگوریتم عقاب (شامل انتخاب ویژگی‌ها، تنظیم ابرپارامترها و وزن‌دهی) برای هر مقدار به‌طور کامل با اجرا شد.

##### جدول ۷. نتایج تحلیل حساسیت پارامتر $\lambda$

مقدار $\lambda$	تعداد ویژگی‌های منتخب	خطای کلی پیش‌بینی
۰/۰۰۰	۲۲	۰/۰۲۲۴۵
۰/۰۰۵	۱۶	۰/۰۲۱۶۲
۰/۰۱۰	۱۲	۰/۰۲۱۰۳
۰/۰۵۰	۸	۰/۰۲۱۸۸
۰/۱۰۰	۵	۰/۰۲۲۹۱

نتایج نشان می‌دهد با افزایش  $\lambda$  از ۰ تا ۰/۰۱، تعداد ویژگی‌ها از ۲۲ به ۱۲ کاهش یافته و خطای کلی پیش‌بینی از ۰/۰۲۲۴۵ به ۰/۰۲۱۰۳ (بهینه) بهبود می‌یابد که بیانگر حذف ویژگی‌های کم‌اطلاع و کاهش بیش‌برازش است. برای مقادیر بزرگتر از ۰/۰۵، حذف بیش‌ازحد ویژگی‌ها موجب افزایش مجدد خطا می‌شود. مقدار ۰/۰۱ نقطه بهینه است که کمترین خطای پیش‌بینی را همراه با مجموعه ویژگی فشرده فراهم می‌کند و با پیکربندی پیشنهادی مطابقت دارد. این تحلیل تأیید می‌کند عملکرد مدل نسبت به تغییرات معقول  $\lambda$  پایدار بوده و انتخاب مقدار نهایی بر پایه شواهد تجربی و تعادل دقت و سادگی انجام شده است. نتیجه این فرآیند، انتخاب مجموعه‌ای از ویژگی‌های متنوع مرتبط با رفتار قیمت، نوسان، روند و حجم است. ویژگی‌های منتخب نهایی به شرح جدول زیر است.

##### جدول ۸. ویژگی‌های منتخب نهایی پس از الگوریتم بهینه‌سازی فراابتکاری عقاب

Table 8. Final selected features after the Aquila meta-heuristic optimization algorithm

ویژگی منتخب نهایی	دسته ویژگی
Close Price (t-1)	قیمت <sup>۱</sup>
EMA_10	میانگین‌های متحرک <sup>۲</sup>

<sup>۱</sup>. Price Dynamics

<sup>۲</sup>. Moving Averages

ویژگی منتخب نهایی	دسته ویژگی
RSI(14), MACD	مومنتوم و روند <sup>۱</sup>
ATR(14), Returns Std(10), Rolling Std(10)	نوسان‌پذیری <sup>۲</sup>
Bollinger Upper	باند‌های داینامیک قیمت <sup>۳</sup>
MFI, OBV, Volume Ratio	ویژگی‌های حجمی <sup>۴</sup>
Skewness	ساختار آماری <sup>۵</sup>

حضور ویژگی‌ها و پارامترهای منتخب نشان می‌دهد که الگوریتم بهینه‌سازی، به‌صورت تجربی به ترکیبی رسیده است که ضمن حفظ تنوع اطلاعاتی، مقدار تابع برازش را به حداقل رسانده و بهترین عملکرد پیش‌بینی را فراهم می‌کند. در مجموع، ابرپارامترهای استخراج‌شده بیانگر حرکت الگوریتم به‌سوی مدل‌هایی هستند که هم پیچیدگی لازم برای یادگیری روابط غیرخطی و پرنویز بازار را دارند و هم با منظم‌سازی مناسب از بیش‌برازش جلوگیری می‌کنند. این پیکربندی، بهینه‌ترین ترکیب میان هزاران حالت ممکن بوده و به‌عنوان بهترین مجموعه ابرپارامترهای مدل یادگیری گروهی انتخاب شده است.

جدول ۹. ابرپارامترهای نهایی انتخاب‌شده توسط الگوریتم بهینه‌سازی فراابتکاری عقاب

Table 9. Final hyperparameters selected by the Aquila meta-heuristic optimization algorithm

مقدار نهایی انتخاب‌شده	ابریارامتر	الگوریتم
۲۴۷	n_estimators	جنگل تصادفی
۸	max_depth	
۰/۴۷	max_features	
۶	min_samples_split	
۳	min_samples_leaf	
۱ (True)	bootstrap	
۱ (Entropy)	criterion	تقویت تطبیقی
۱۸۳	n_estimators	
۰/۰۸۷	learning_rate	
۱	max_depth	
۳۱۲	n_estimators	
۰/۰۷۱	learning_rate	
۴	max_depth	تقویت گرادینان شدید
۷	min_child_weight	
۰/۸۱	subsample	
۰/۵۸	colsample_bytree	
۸/۶	reg_lambda ( $\lambda$ )	
۲/۱	reg_gamma ( $\gamma$ )	

در طول فرآیند بهینه‌سازی توسط الگوریتم بهینه‌سازی فراابتکاری عقاب نه تنها ویژگی‌ها و ابرپارامترهای مدل تعیین شد بلکه وزن‌های ترکیب سه الگوریتم در ساختار یادگیری گروهی نیز به‌صورت هم‌زمان بهینه‌سازی گردید. این وزن‌ها صرفاً براساس مقدار تابع برازش (متشکل از خطای پیش‌بینی و جمله جریمه اندازه ویژگی‌ها) استخراج شده‌اند و میزان

<sup>۱</sup>. Momentum & Trend Strength

<sup>۲</sup>. Volatility Structure

<sup>۳</sup>. Dynamic Bounds

<sup>۴</sup>. Volume-Flow Indicators

<sup>۵</sup>. Distributional Structure

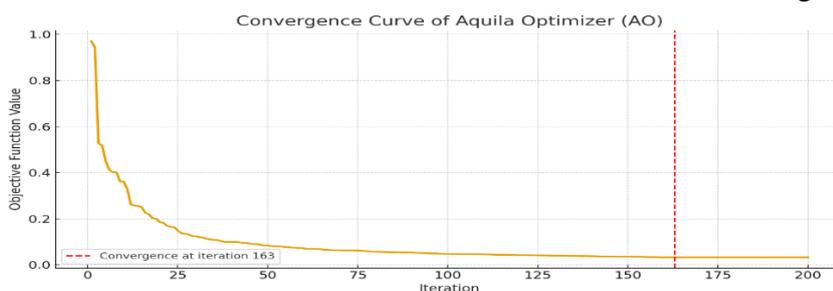
اهمیت نسبی هر مدل در ارتقای دقت نهایی مدل یادگیری گروهی را نشان می‌دهند. نتایج در جدول زیر قابل مشاهده هستند.

جدول ۱۰. وزن‌های نهایی الگوریتم‌های پایه در ساختار مدل یادگیری گروهی

Table 10. Final weights of basic algorithms in the structure of the Ensemble Learning model

الگوریتم پایه	وزن نهایی انتخاب‌شده توسط الگوریتم بهینه‌سازی فراابتکاری عقاب
جنگل تصادفی	۰/۴۸۷
تقویت گرادیان شدید	۰/۳۷۴
تقویت تطبیقی	۰/۱۳۹

نمودار همگرایی الگوریتم بهینه‌سازی فراابتکاری عقاب نشان می‌دهد که مقدار تابع برازش طی ۲۰۰ تکرار کاهش یافته و الگوریتم در دو فاز «کاوش» و «بهره‌برداری» عمل می‌کند. در فاز کاوش (تکرارهای ۱ تا ۱۳۳)، الگوریتم با استفاده از راهبردهای کاوش گسترده و متمرکز، فضای جست‌وجو را به‌صورت وسیع بررسی می‌کند؛ موضوعی که در نمودار با افت‌های بزرگ و نوسانات ملایم قابل مشاهده است. از تکرار ۱۳۴ به بعد، الگوریتم وارد فاز بهره‌برداری می‌شود و با راهبردهای بهره‌برداری گسترده و متمرکز، بر بهبود دقیق راه‌حل‌های برتر تمرکز می‌کند؛ به همین دلیل روند نمودار در این بخش آرام‌تر و هموارتر است. در نهایت، الگوریتم در حدود تکرار ۱۶۳ به مقدار ثابت ۰/۰۳۲۶ همگرا شده که نشان‌دهنده ایجاد تعادل مناسب میان کاوش و بهره‌برداری و دستیابی به یک ساختار بهینه برای مسئله انتخاب ویژگی و تنظیم مدل است.



شکل ۱. نمودار همگرایی الگوریتم بهینه‌سازی فراابتکاری عقاب

Figure 1. Convergence diagram of the Aquila meta-heuristic optimization algorithm

در مرحله بعد ۳۰ سهم باکیفیت انتخاب‌شده از مرحله اول، مشخص شدند. بازده‌های روزانه تاریخی این ۳۰ سهم در بازه مورد تحلیل و بازده‌های پیش‌بینی‌شده توسط مدل یادگیری گروهی مرحله اول است. بازده پیش‌بینی‌شده نقش برآورد بازده مورد انتظار را دارد و بازده تاریخی نقش مبنای سنجش ریسک دنباله‌ای را ایفا می‌کند. براساس داده‌های مدیریت فناوری بورس تهران از فروردین ۱۳۹۲ تا مهر ۱۴۰۳، میانگین بازده روزانه شاخص کل ۰/۱۹۱٪ و شاخص فرابورس ۰/۲۰۳٪ بوده است، که میانگین وزنی آن‌ها تقریباً ۰/۱۹۲٪ می‌باشد. بر همین اساس، سه سطح بازده روزانه مورد انتظار شامل: ۰/۲٪ (نمایانگر پرتفوی شاخص مانند)، ۰/۵٪ (هدف بازده متوسط تا تهاجمی) و ۰/۸٪ (هدف بسیار جاه‌طلبانه) برای تحلیل انتخاب شدند. این سطوح بر اساس داده‌های تاریخی بازار ایران تعیین و امکان مقایسه پرتفوی‌های محافظه‌کارانه، بهینه و تهاجمی را فراهم می‌کند. در ادامه برای پرتفوی شامل ۳۰ سهم منتخب الگوریتم یادگیری گروهی، انحراف معیار، ارزش در معرض خطر و ارزش شرطی بهینه با روش تاریخی در سطوح اطمینان ۹۵٪ و ۹۹٪ محاسبه شد. همچنین برای بررسی سطح مناسب بهینگی پرتفوی از نسبت‌های شارپ و سورتینو استفاده شد. نسبت شارپ، معیاری برای سنجش بازده یک سرمایه‌گذاری نسبت به ریسک آن است که با کم کردن نرخ بازده بدون ریسک از بازده مورد انتظار پرتفوی و تقسیم آن بر انحراف معیار پرتفوی محاسبه می‌شود. نسبت سورتینو تنها بر ریسک نزولی تمرکز دارد، که برای سرمایه‌گذارانی که به کاهش ضرر اهمیت بیشتری می‌دهند،

مناسب‌تر است. این نسبت طبق رابطه شماره ۸، از طریق کم کردن نرخ بازده بدون ریسک از بازده مورد انتظار پرتفوی و تقسیم آن بر انحراف معیار نزولی (ریسک نامطلوب) پرتفوی محاسبه می‌شود. (Rom, 1994)

$$S = \frac{(R_p - R_f)}{\sigma_d} \quad \text{رابطه (۸)}$$

بر اساس گزارش‌های رسمی بانک مرکزی و مدیریت فناوری بورس تهران، در طی دوره زمانی ۱۳۹۲ تا اواسط ۱۴۰۳، نرخ بازده بدون ریسک به صورت میانگین برابر با ۱۹/۵٪ سالانه و ۰/۰۵۳٪ روزانه محاسبه شده است. بنابراین از نرخ بازده بدون ریسک برابر با ۰/۰۵۳٪ در محاسبه نسبت سورتینو استفاده شد. نتایج محاسبات در جدول زیر قابل مشاهده است.

جدول ۱۱. مقادیر انحراف معیار، ارزش در معرض خطر و ارزش در معرض خطر شرطی بهینه پرتفوی منتخب

Table 11. Values of standard deviation, value at risk and optimal conditional value at risk of the selected portfolio

بازده مورد انتظار	سطح اطمینان	انحراف معیار	ارزش در معرض خطر	ارزش در معرض خطر شرطی بهینه	نسبت شارپ	نسبت سورتینو	بازده سالانه (درصد)	نوسان سالانه (درصد)
۰/۲٪	۹۵٪	۰/۰۰۶۰۰۱	۰/۰۰۰۱۱۴	۰/۰۰۰۲۷۹	۴/۸۲	۵/۲۷	۶۵/۴۵	۹/۵۳
۰/۵٪	۹۹٪	۰/۰۰۵۸۹۶	۰/۰۰۰۳۰۸	۰/۰۰۰۳۰۸	۴/۹۱	۴/۷۶	۶۵/۴۵	۹/۳۶
۰/۸٪	۹۵٪	۰/۰۰۸۳۵۴	۰/۰۰۰۵۰۳	۰/۰۰۰۶۸۵	۱۷/۴۹	۶/۵۲	۲۵۱/۴۴	۱۳/۲۶
۰/۱٪	۹۹٪	۰/۰۰۷۹۵۶	۰/۰۰۰۹۰۳	۰/۰۰۰۹۰۳	۱۸/۶۳	۴/۹۵	۲۵۱/۴۴	۱۲/۶۳
	۹۵٪	۰/۰۲۳۴۱۲	۰/۰۰۶۷۳۳	۰/۰۰۷۳۸۲	۱۶/۸۳	۰/۰۱	۶۴۴/۸۲	۳۷/۱۷
	۹۹٪	۰/۰۲۳۲۲۵	۰/۰۰۷۸۳۶	۰/۰۰۷۸۳۶	۱۶/۹۶	۰/۹۵	۶۴۴/۸۲	۳۶/۸۷

تحلیل نتایج نشان می‌دهد که پرتفوی با بازده مورد انتظار روزانه ۰/۵٪ در هر دو سطح اطمینان ۹۵٪ و ۹۹٪ بالاترین نسبت شارپ و نسبت سورتینو را کسب کرده و به طور معناداری دو پرتفوی دیگر را پشت سر گذاشته است. این پرتفوی با افزایش ۲/۵ برابری بازده نسبت به پرتفوی با بازده مورد انتظار ۰/۲ درصد تنها ۲/۴۵ برابر ریسک نزولی اضافی متحمل شده و در نتیجه نسبت بازده اضافی به ریسک نزولی آن حدود ۲۴٪ بهبود یافته است. در مقابل، افزایش بازده از ۰/۵٪ به ۰/۸٪ با ۱۰/۷ برابر شدن ریسک نزولی همراه بوده که منجر به افت شدید معیار سورتینو به کمتر از ۱ گردیده است. این امر بیانگر آن است که بخش قابل توجهی از بازده اضافی پرتفوی صرف جبران ریسک‌های شدید نزولی شده و از منظر سرمایه‌گذاران ریسک‌گریز فاقد جذابیت است. بنابراین، با توجه به معیار سورتینو به عنوان شاخصی که صرفاً ریسک‌های نزولی را تنبیه می‌کند، پرتفوی با بازده مورد انتظار روزانه ۰/۵٪ به عنوان نقطه بهینه بر مرز کارایی ریسک نزولی شناسایی شد و بالاترین کارایی ریسک تعدیل‌شده را در میان گزینه‌های بررسی‌شده ارائه می‌دهد.

**ارزیابی بازآموزی غلتان<sup>۱</sup> و بازتوازن‌سازی پرتفوی؛** به منظور ارزیابی واقع‌گرایانه عملکرد چارچوب پیشنهادی در شرایط غیرایستای بازار و جلوگیری از نشت اطلاعاتی، یک پروتکل بازآموزی غلتان طراحی و اجرا شد. در این چارچوب، چرخه کامل بازآموزی مدل، پیش‌بینی بازده، انتخاب سهام و تشکیل یا بازتوازن‌سازی پرتفوی به صورت تکرارشونده و منطبق با ترتیب زمانی داده‌ها انجام می‌شود تا پایداری مدل در دوره‌های مختلف بازار مورد سنجش قرار گیرد. با توجه به دوره زمانی داده‌ها (۱۲۰ ماه)، در هر گام از ارزیابی، داده‌ها به سه بازه شامل ۱۸ ماه آموزش، ۳ ماه اعتبارسنجی و ۳ ماه آزمون تقسیم شدند و پنجره زمانی با گام ۳ ماه به جلو حرکت داده شد. بدین ترتیب، در کل دوره مطالعه، ۳۳ پنجره ارزیابی هم‌پوشان به دست آمد که این ساختار با منطق عملی بازار سازگار بوده و منجر به استفاده از اطلاعات آینده نمی‌شود. در هر پنجره، پس از بازآموزی مدل یادگیری گروهی، الگوریتم فراابتکاری عقاب برای بهینه‌سازی هم‌زمان

<sup>۱</sup>. Walk-Forward

انتخاب ویژگی‌ها، تنظیم ابرپارامترها و وزن‌دهی مدل‌ها اجرا شد و سپس پرتفوی با هدف کمینه‌سازی ریسک نزولی و با قید حداقل بازده مورد انتظار و قیود استاندارد تشکیل گردید.

جدول ۱۲. خلاصه آماری شاخص‌های ریسک در ارزیابی بازآموزی غلتان

Table 12. Statistical summary of risk indicators in Walk-Forward assessment

شاخص	بازده مورد انتظار	سطح اطمینان	ارزش در معرض خطر شرطی بهینه	ارزش در معرض خطر	انحراف معیار
میانگین	۰/۲٪	۹۵٪	۰/۰۰۰۲۹۵	۰/۰۰۰۲۴۲	۰/۰۰۶۱۳۰
	۰/۲٪	۹۹٪	۰/۰۰۰۳۵۳	۰/۰۰۰۳۲۰	۰/۰۰۶۰۹۴
	۰/۵٪	۹۵٪	۰/۰۰۰۷۰۸	۰/۰۰۰۵۲۶	۰/۰۰۸۷۰۵
	۰/۵٪	۹۹٪	۰/۰۰۰۹۳۸	۰/۰۰۰۹۲۸	۰/۰۰۸۰۴۲
	۰/۸٪	۹۵٪	۰/۰۰۰۷۳۹۶	۰/۰۰۰۶۸۵۷	۰/۰۰۲۳۸۷۰
	۰/۸٪	۹۹٪	۰/۰۰۰۷۸۷۹	۰/۰۰۰۷۷۹۰	۰/۰۰۲۳۳۳۷
انحراف معیار	۰/۲٪	۹۵٪	۰/۰۰۰۰۱۱۱	۰/۰۰۰۰۱۱	۰/۰۰۰۰۰۴۲
	۰/۲٪	۹۹٪	۰/۰۰۰۰۱۱۰	۰/۰۰۰۰۱۰۹	۰/۰۰۰۰۰۴۴
	۰/۵٪	۹۵٪	۰/۰۰۰۰۱۱۱	۰/۰۰۰۰۱۱۱۷	۰/۰۰۰۰۰۲۷۳
	۰/۵٪	۹۹٪	۰/۰۰۰۰۱۱۲	۰/۰۰۰۰۱۱۱۵	۰/۰۰۰۰۰۲۷۸
	۰/۸٪	۹۵٪	۰/۰۰۰۰۲۸	۰/۰۰۰۰۲۷	۰/۰۰۰۰۳۴۰
	۰/۸٪	۹۹٪	۰/۰۰۰۰۸۳	۰/۰۰۰۰۸۵	۰/۰۰۰۰۵۹۰
کمینه	۰/۲٪	۹۵٪	۰/۰۰۰۲۷۴	۰/۰۰۰۲۲۱	۰/۰۰۶۰۲۷
	۰/۲٪	۹۹٪	۰/۰۰۰۳۳۲	۰/۰۰۰۲۹۸	۰/۰۰۵۹۹۴
	۰/۵٪	۹۵٪	۰/۰۰۰۶۸۷	۰/۰۰۰۵۰۵	۰/۰۰۸۶۱۲
	۰/۵٪	۹۹٪	۰/۰۰۰۹۱۶	۰/۰۰۰۹۰۷	۰/۰۰۷۹۴۸
	۰/۸٪	۹۵٪	۰/۰۰۰۷۳۰۱	۰/۰۰۰۶۷۶۳	۰/۰۰۲۳۲۱۸
	۰/۸٪	۹۹٪	۰/۰۰۰۷۶۲۱	۰/۰۰۰۷۵۲۲	۰/۰۰۲۰۹۵۱
بیشینه	۰/۲٪	۹۵٪	۰/۰۰۰۳۱۸	۰/۰۰۰۲۶۵	۰/۰۰۶۳۴۷
	۰/۲٪	۹۹٪	۰/۰۰۰۳۷۶	۰/۰۰۰۳۴۳	۰/۰۰۶۲۱۴
	۰/۵٪	۹۵٪	۰/۰۰۰۷۳۱	۰/۰۰۰۵۴۹	۰/۰۰۸۷۳۵
	۰/۵٪	۹۹٪	۰/۰۰۰۹۶۷	۰/۰۰۰۹۵۱	۰/۰۰۸۰۷۹
	۰/۸٪	۹۵٪	۰/۰۰۰۷۴۳۵	۰/۰۰۰۶۸۸۷	۰/۰۰۲۴۵۹۸
	۰/۸٪	۹۹٪	۰/۰۰۰۷۹۸۵	۰/۰۰۰۷۹۳۱	۰/۰۰۲۳۷۰۶

متطابق نتایج، مقادیر شاخص‌های ریسک شامل انحراف معیار، ارزش در معرض خطر و ارزش در معرض خطر شرطی در طول ۳۳ پنجره بازآموزی غلتان از نوسانات محدودی برخوردار بوده و حول مقادیر میانگین پایداری تغییر می‌کنند که نشان‌دهنده ثبات عملکرد چارچوب پیشنهادی در طول زمان است. همچنین جدول ۱۲، عملکرد پرتفوی را تحت سه سطح بازده هدف و دو سطح اطمینان گزارش می‌کند. نتایج نشان می‌دهد که با افزایش بازده هدف، سطح ریسک پرتفوی به صورت منطقی افزایش می‌یابد و در سطوح اطمینان بالاتر نیز مقادیر ارزش در معرض خطر و ارزش در معرض خطر شرطی، بزرگ‌تر می‌شود؛ رفتاری که بیانگر رعایت مبادله ریسک، بازده و حساسیت مناسب مدل نسبت به ریسک‌های دنباله‌ای است. به‌طور کلی، پایداری شاخص‌های ریسک بین پنجره‌ها و عدم مشاهده رفتارهای افراطی، حاکی از آن است که چارچوب پیشنهادی توانایی کنترل مؤثر ریسک نزولی و حفظ ثبات عملکرد در محیط‌های مالی غیرایستا را داراست.

به منظور ارزیابی جامع‌تر عملکرد چارچوب پیشنهادی و سنجش ارزش افزوده آن نسبت به راهبردهای متداول مدیریت پرتفوی، مجموعه‌ای از بنچمارک‌های پرکاربرد در ادبیات پژوهشی به تحلیل‌های تجربی افزوده شد. برای تضمین مقایسه‌ای منصفانه، تمامی بنچمارک‌ها بر روی یک مجموعه ثابت شامل ۳۰ سهم منتخب اجرا شدند تا تفاوت‌های عملکرد صرفاً ناشی از منطق تخصیص وزن و مدیریت ریسک باشد. در همه روش‌ها، برآورد پارامترها تنها بر اساس داده‌های تاریخی انجام شده و عملکرد پرتفوی در بازه آزمون خارج از نمونه ارزیابی گردید. بنچمارک‌های مورد بررسی شامل پرتفوی هم‌وزن، میانگین-واریانس با کوواریانس کوچک‌سازی شده، برابری ریسک، کم‌نوسانی و مومنتوم هستند. در هر روش، وزن‌ها مطابق قاعده تخصیص مربوطه محاسبه و با رعایت قیود استاندارد پرتفوی نرمال‌سازی شدند و بازتوازن‌سازی با تناوب زمانی یکسان انجام گرفت. معیارهای مقایسه شامل بازده، انحراف معیار، ارزش در معرض خطر و ارزش در معرض خطر شرطی در سطح اطمینان ۹۵٪ بوده است. جدول زیر خلاصه نتایج عملکرد روش پیشنهادی و بنچمارک‌ها را ارائه می‌دهد.

جدول ۱۳. خلاصه نتایج عملکرد روش پیشنهادی و بنچمارک‌های متداول

Table 13. Summary of the performance results of the proposed method and common benchmarks

ارزش در معرض خطر	ارزش در معرض		روش
	خطر شرطی	درصد بازده	
۰/۰۱۱۰۷۹	۰/۰۱۶۷۳۴	۰/۲۳۶۵۴۴	پرتفوی هم‌وزن <sup>۱</sup>
۰/۰۰۹۹۴۲	۰/۰۱۴۶۱۲	۰/۷۲۰۶۶۷	پرتفوی میانگین-واریانس با کوواریانس کوچک‌سازی شده <sup>۲</sup>
۰/۰۰۳۳۵۹	۰/۰۰۴۶۲۶	۰/۱۰۶۵۸۰	پرتفوی برابری ریسک <sup>۳</sup>
۰/۰۰۴۶۶۷	۰/۰۰۶۲۳۹	۰/۱۴۰۴۶۳	پرتفوی کم‌نوسان <sup>۴</sup>
۰/۰۱۶۶۹۸	۰/۰۲۳۸۲۶	۰/۱۹۸۷۸۵	راهبرد مومنتوم (تداوم بازده) <sup>۵</sup>
۰/۰۰۰۶۸۵	۰/۰۰۰۵۰۳	۰/۵	پیشنهادی

نتایج نشان می‌دهد که پرتفوی هم‌وزن، اگرچه بازده مثبتی ایجاد کرده، اما به دلیل عدم توجه به ساختار ریسک‌دارایی‌ها، با مقادیر بالای ارزش در معرض خطر و ارزش در معرض خطر شرطی همراه بوده است. روش میانگین-واریانس بالاترین بازده را در میان بنچمارک‌ها محقق کرده، اما این بازده با افزایش قابل توجه ریسک نزولی همراه بوده که بیانگر ماهیت بازده‌محور و حساسیت آن به خطای برآورد پارامترهاست. در مقابل، راهبردهای برابری ریسک و کم‌نوسانی موفق به کاهش ریسک نزولی شده‌اند، اما این کنترل ریسک با افت محسوس بازده همراه بوده است. راهبرد مومنتوم نیز در این آزمایش بیشترین مقادیر ارزش در معرض خطر و ارزش در معرض خطر شرطی را نشان داده که حاکی از حساسیت بالای آن به تغییرات ناگهانی بازار است. در مقابل تمامی بنچمارک‌ها، روش پیشنهادی با بهینه‌سازی مستقیم معیار ارزش در معرض خطر شرطی و اعمال قید بازده هدف ۰/۵٪ کمترین مقادیر ارزش در معرض خطر و ارزش در معرض خطر شرطی را به‌طور هم‌زمان ارائه داده است. در این چارچوب، بازده به‌عنوان یک قید کنترلی تعریف شده و نه یک خروجی تصادفی، که امکان مقایسه منصفانه و معنادار ریسک نزولی را فراهم می‌سازد. به‌طور

<sup>1</sup>. Equal-weight

<sup>2</sup>. Shrunken Mean-Variance

<sup>3</sup>. Risk-parity

<sup>4</sup>. Low-Volatility

<sup>5</sup>. Momentum

کلی، نتایج نشان می‌دهد که چارچوب پیشنهادی، در مقایسه با بنچمارک‌های متداول، تعادل مطلوب‌تری میان کنترل ریسک‌های شدید و دستیابی به بازده هدف برقرار کرده و از منظر کاربردهای عملی مدیریت پرتفوی در بازارهای پرنوسان، گزینه‌ای کارتر و قابل اتکاتر محسوب می‌شود.

در ادامه وزن نمادهای منتخب در پرتفوی بر اساس ارزش در معرض خطر شرطی بهینه با بازده مورد انتظار ۵٪/۰ در سطوح اطمینان ۹۵٪ و ۹۹٪ در جدول زیر نشان داده شده است.

جدول ۱۴. وزن ۳۰ نماد منتخب در پرتفوی بهینه

Table 14. Weight of 30 selected stocks in the optimal portfolio

ردیف	سطح اطمینان ۹۵٪		سطح اطمینان ۹۹٪	
	نماد	وزن	نماد	وزن
۱	دسبجا	۰/۱۴۱۷۴۰	دسبجا	۰/۱۱۷۵۶۳
۲	داسوه	۰/۱۰۵۳۸۹	داسوه	۰/۱۰۹۹۴۸
۳	پیزد	۰/۱۰۰۹۶۷	کروی	۰/۱۰۸۴۹۲
۴	پارسان	۰/۰۸۴۷۴۳	پارسان	۰/۰۹۶۶۲
۵	ونفت	۰/۰۸۱۲۸۵	پیزد	۰/۰۸۹۱۱۵
۶	شصبیر	۰/۰۸۰۸۸۲	شصبیر	۰/۰۷۹۱۰۲
۷	سپاها	۰/۰۷۶۵۰۹	ونفت	۰/۰۷۳۰۹۱
۸	شخارک	۰/۰۶۹۸۰۶	سپاها	۰/۰۷۱۶۴۵
۹	کروی	۰/۰۶۷۹۴۸	سفانو	۰/۰۶۳۵۱۲
۱۰	سفانو	۰/۰۵۲۳۱۳	کرازی	۰/۰۴۰۱۰۵
۱۱	کرازی	۰/۰۴۹۵۸۶	شخارک	۰/۰۳۶۱۷۲
۱۲	خدیزل	۰/۰۱۹۲۰۲	دپارس	۰/۰۲۸۰۲۳
۱۳	مارون	۰/۰۱۵۴۹۰	سغرب	۰/۰۲۶۶۷۰
۱۴	دتولید	۰/۰۱۵۳۴۹	دتولید	۰/۰۱۹۴۴۸
۱۵	دپارس	۰/۰۱۴۴۵۵	سرود	۰/۰۱۳۹۲۲
۱۶	شبهرن	۰/۰۰۹۷۰۷	شبهرن	۰/۰۰۸۶۸۰
۱۷	سشرق	۰/۰۰۷۲۰۰	سشرق	۰/۰۰۷۴۹۹
۱۸	وپترو	۰/۰۰۶۴۳۵	خدیزل	۰/۰۰۴۱۳۷
۱۹	افرا	۰/۰۰۰۹۹۳	وپترو	۰/۰۰۳۳۹۷
۲۰	دفرا	۰	دافرا	۰
۲۱	خمحرکه	۰	دتماد	۰
۲۲	دتماد	۰	افرا	۰
۲۳	لبوتان	۰	مارون	۰
۲۴	کلوند	۰	لبوتان	۰
۲۵	ثعمرا	۰	خمحرکه	۰
۲۶	سغرب	۰	کلوند	۰
۲۷	ثغرب	۰	ثغرب	۰
۲۸	شگل	۰	ثعمرا	۰
۲۹	سرود	۰	شگل	۰
۳۰	زکوثر	۰	زکوثر	۰

با توجه به نتایج جدول بالا، مشخص است، ۸ سهم برتر در سطح اطمینان ۹۵٪ حدود ۷۶٪ و در سطح اطمینان ۹۹٪ حدود ۷۵٪ از وزن پرتفوی را تشکیل می‌دهند. این تمرکز بالا کاملاً با ماهیت بهینه‌سازی ارزش در معرض خطر شرطی سازگار است؛ زیرا مدل برای کاهش ریسک‌های شدید دنباله، به‌طور طبیعی به سمت سهم‌هایی با رفتار همبستگی پایین در روزهای بحران (مانند دسبجا، داسوه، پارسان، نفت و شبصیر) متمایل می‌شود.

همچنین ۷ سهم از ۸ سهم برتر در هر دو سطح اطمینان یکسان هستند و فقط رتبه‌های سوم تا پنجم جابه‌جا می‌شوند. این ثبات نشان‌دهنده پایداری قوی پرتفوی بهینه در برابر تغییر سطح اطمینان است. وزن دسبجا (بزرگ‌ترین پالایشی کشور) از ۱۴/۲٪ به ۱۱/۸٪ کاهش یافته و وزن کروی و سفانو (دو سهم پتروشیمی با نوسان بالا در بحران‌ها) به‌طور معناداری افزایش می‌یابد. همچنین وزن سهام‌های کوچک و پرنوسان (مانند خدیزل، مارون، افرا) به شدت کاهش می‌یابد.

پرتفوی عمدتاً از صنایع دفاعی-پالایشی (دسبجا، داسوه)، پتروشیمی (پارسان، شبصیر)، سرمایه‌گذاری (ونفت، سپاها) و فلزات اساسی تشکیل شده که کمترین همبستگی را در دوران سقوط بازار دارند. پرتفوی ارائه‌شده نه تنها از نظر معیار سورتینو بهینه است، بلکه از نظر ترکیب نیز کاملاً پایدار و منطبق بر رفتار واقعی بازار ایران در ۱۲ سال گذشته می‌باشد و می‌تواند به‌عنوان یک استراتژی فعال قابل اجرا برای صندوق‌های سرمایه‌گذاری و سبدگردانان مورد استفاده قرار گیرد. در ادامه، جدول زیر خلاصه نتایج آزمون بازآزمایی آسربی-زکلی را در دو سطح اطمینان ۹۵٪ و ۹۹٪ نشان می‌دهد.

جدول ۱۵. نتایج آزمون بازآزمایی آسربی-زکلی در دو سطح اطمینان ۹۵٪ و ۹۹٪

Table 15. Results of the Acerbi-Szekely test-retest at two confidence levels of 95% & 99%

شاخص	نماد / رابطه	سطح اطمینان ۹۵٪	تفسیر	سطح اطمینان ۹۹٪	تفسیر
میانگین نمرات خطا	$\bar{W}$	.	کالیبراسیون مدل کاملاً صحیح است.	.	کالیبراسیون مدل کاملاً صحیح است.
انحراف معیار نمرات خطا	$S_W$	۰/۰۰۲۴۲	بسیار پایین، ثبات و پایداری بالای نمرات خطا	.	ثبات مطلق و عدم وجود هرگونه نوسان غیرعادی
آماره آزمون t نیووست	$t_{NW} = \frac{\bar{W}}{SE_{NW}(\bar{W})}$	.	هیچ انحرافی از کالیبراسیون صحیح وجود ندارد.	-۰/۳۴۴۷۱۲	منفی و بسیار کوچک، مدل حتی اندکی محافظه‌کارانه‌تر از واقعیت است.
مقدار احتمال یک‌طرفه	$p = 0/5$	۰/۵	عدم رد فرض صفر، مدل معتبر و کالیبره است.	۰/۶۲۷۰۰۵	عدم رد فرض صفر، مدل معتبر و کالیبره است.
میانگین تجربی زیان‌های دنباله	$ES_{emp}$	۰/۰۰۰۶۵۲	بسیار نزدیک به پیش‌بینی مدل	۰/۰۰۰۹۰۳	دقیقاً برابر با مقدار پیش‌بینی شده مدل

شاخص	نماد/ رابطه	سطح اطمینان ۹۵٪	تفسیر	سطح اطمینان ۹۹٪	تفسیر
میانگین پیش‌بینی شده توسط مدل	$ES_{model}$	۰/۰۰۰۶۸۵	اندکی بالاتر از زیان واقعی، مدل محافظه‌کارانه و ایمن است.	۰/۰۰۰۹۰۳	دقیقاً برابر با زیان واقعی، کالیبراسیون ایده‌آل است.

نتایج نشان می‌دهد در هر دو سطح اطمینان ۹۵٪ و ۹۹٪، فرض صفر با قدرت بسیار بالا تأیید شد به این معنی که مدل ارزش در معرض خطر شرطی موجود کاملاً کالیبره، معتبر و فاقد هرگونه کم‌برآورد ریسک دنباله‌ای است و حتی در سطح اطمینان ۹۵٪ اندکی محافظه‌کارانه عمل می‌کند.

## ۵. بحث و نتیجه‌گیری

ترکیب مرحله انتخاب سهام بر اساس یادگیری گروهی و بهینه‌سازی با الگوریتم فراابتکاری عقاب، با مرحله بهینه‌سازی پرتفوی مبتنی بر کمینه‌سازی ارزش در معرض خطر شرطی، موجب شکل‌گیری مدلی شد که هم از نظر دقت پیش‌بینی و هم از نظر مدیریت ریسک دنباله‌ای عملکردی برتر نسبت به رویکردهای متداول بازار دارد چرا که مرحله پیش‌انتخاب هوشمند سهام به صورت هم‌زمان با تنظیم مدل ادغام شده است. یافته‌های این مطالعه نشان می‌دهد که ترکیب رویکردهای پیشرفته یادگیری ماشین با معیارهای ریسک دنباله‌ای، نه تنها دقت پیش‌بینی بازده را افزایش می‌دهد، بلکه ریسک‌های شدید نزولی را به طور مؤثری مدیریت می‌کند. نتایج مرحله اول حاکی از کاهش قابل توجه خطای پیش‌بینی و انتخاب ۳۰ سهم پایدار است. این یافته‌ها فراتر از مطالعات داخلی مانند دهقانی و همکاران (۱۳۹۸) و پژوهش‌های خارجی مانند آیلدیز و اسکندراگو (۲۰۲۳) است که عمدتاً از مدل‌های تک‌الگوریتمی استفاده کرده‌اند. در مرحله دوم، پرتفوی با بازده هدف روزانه ۵٪/۰ بالاترین نسبت شارپ و نسبت سورتینو را در سطوح اطمینان ۹۵٪ و ۹۹٪ کسب کرد و حدود ۲۴٪ بهبود در کارایی ریسک‌تعدیل‌شده نسبت به پرتفوی شاخص محور ایجاد نمود. در مقایسه با بهرا و همکاران (۲۰۲۳) که تقویت تطبیقی را در مدل میانگین ارزش در معرض خطر برتر دانستند و آریان و همکاران (۲۰۲۲)، مدل پیشنهادی با ادغام پیش‌انتخاب هوشمند و بهینه‌سازی هم‌زمان، ریسک نزولی را به صورت مؤثرتری کاهش داد. همچنین نسبت به مطالعات داخلی مانند فریدی و همکاران (۱۴۰۱)، هراتی‌زاده و رضایی (۱۴۰۲)، اسفندیار و همکاران (۱۴۰۲)، زمانی و همکاران (۱۴۰۳) و دلیلی و همکاران (۱۴۰۳) که اغلب فاقد چارچوب یکپارچه یا تمرکز بر ریسک دنباله‌ای بودند، برتری معناداری نشان داد. بیش از ۷۵٪ وزن پرتفوی به ۸ سهم کم‌همبستگی از صنایع پالایشی، پتروشیمی و سرمایه‌گذاری اختصاص یافت و آزمون آسربی-زکلی کالیبراسیون کامل و رفتار کمی محافظه‌کارانه مدل ارزش در معرض خطر شرطی را تأیید کرد. به طور خلاصه، پژوهش حاضر نشان داد که ایجاد یک چارچوب یکپارچه می‌تواند در بازار پرتلاطم و غیرایستای ایران، عملکردی بسیار بهتر از استراتژی‌های سنتی یا شاخص‌محور ارائه دهد. این مدل قابلیت کاربرد عملی برای صندوق‌های سرمایه‌گذاری، سبدگردان‌ها و سرمایه‌گذاران بزرگ را داراست و می‌تواند مبنایی برای توسعه نسل جدید استراتژی‌های سرمایه‌گذاری هوشمند در بازار ایران باشد.

**پیشنهادهای کاربردی:** با توجه به یافته‌های پژوهش، پیشنهاد می‌شود که سرمایه‌گذاران نهادی و سبیدگردانان از این چارچوب برای تشکیل پرتفوی‌های واقعی استفاده کنند، به ویژه در شرایط بحران اقتصادی. همچنین، برای تحقیقات آینده، می‌توان این مدل را با ویژگی‌های بنیادی بیشتر (مانند نسبت‌های مالی) گسترش داد تا دقت پیش‌بینی افزایش یابد. همچنین آزمون مدل در بازه‌های هفتگی، ماهانه یا چندماهه می‌تواند استراتژی‌های مناسب برای صندوق‌ها یا سرمایه‌گذاران بلندمدت ارائه دهد.

**محدودیت‌ها:** پژوهش حاضر مانند هر مطالعه تجربی دارای محدودیت‌هایی است که باید در تفسیر نتایج مدنظر قرار گیرد. عملکرد مدل بر مبنای داده‌های تاریخی ۱۱ ساله بازار ایران ارزیابی شده است؛ بنابراین در صورت وقوع شوک‌های ساختاری جدید (مانند تغییرات مقرراتی، تحریم‌ها، یا بحران‌های ژئوپلیتیک)، دقت پیش‌بینی ممکن است دچار کاهش شود. اگرچه مجموعه‌ای گسترده از شاخص‌های تکنیکال و آماری استفاده شد، اما داده‌های بنیادی مانند سودآوری، جریان‌های نقدی و متغیرهای کلان اقتصادی لحاظ نشده‌اند.

**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 منافی ندارند.

## منابع

- Aboufazeli, Sh., Ebrahimi, S. B., & Kasaei, S. M. (2023). Portfolio optimization using a hybrid of Omega ratio and Markowitz mean-variance model based on two-level collective machine learning. *Journal of Financial Management Perspective*, 13(41), 33–58. (in Persian)
- Abualigah, L., Yousri, D., Abd Elaziz, M., Ewees, A. A., Al-Qaness, M. A., & Gandomi, A. H. (2021). Aquila optimizer: A novel meta-heuristic optimization algorithm. *Computers & Industrial Engineering*, 157, Article 107250.
- Acerbi, C., & Szekely, B. (2024). Backtestability and the ridge backtest. In *Peter Carr Gedenkschrift: Research advances in mathematical finance* (pp. 61–100). World Scientific.
- Ahmadian, H., & Mirzaei, M. (2022). *Machine learning in financial industry*. Naghus Publisher.
- Arian, H., Moghimi, M., Tabatabaei, E., & Zamani, S. (2022). Encoded Value-at-Risk: A machine learning approach for portfolio risk measurement. *Mathematics and Computers in Simulation*, 202, 500–525.
- Asawa, Y. S. (2021). Modern machine learning solutions for portfolio selection. *IEEE Engineering Management Review*, 50(1), 94–112.
- Ayyıldız, N., & İskenderoğlu, Ö. (2023). Prediction of stock index movement using machine learning methods: An application on BIST 100 index. *Journal of Economics and Entrepreneurship Policy*, 2(1), 1–18.
- Behera, J., Pasayat, A. K., Behera, H., & Kumar, P. (2023). Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets. *Engineering Applications of Artificial Intelligence*, 120, Article 105843.

- Campisi, G., Muzzioli, S., & De Baets, B. (2024). A comparison of machine learning methods for predicting the direction of the US stock market on the basis of volatility indices. *International Journal of Forecasting*, 40(3), 869–880.
- Dalili S., Rezaei Pitehnoei Y., Kabiri M., Safari Graili M., and Arabzadeh M. . (2014). Stock portfolio optimization using deep reinforcement learning based on modern portfolio theory. *Accounting, Finance and Computational Intelligence*, 2(4), 276-293. (in Persian)
- Davallou, M., & Javadian, J. (2023). Investigating the effect of investors' behavioral biases on the performance of risk-adjusted portfolios in the Tehran Stock Exchange. *Journal of Financial Management Perspective*, 13(40), 101–124. (in Persian)
- Deep, A. (2024). Advanced financial market forecasting: Integrating Monte Carlo simulations with ensemble machine learning models. *Quantitative Finance and Economics*, 8(2), 286–314.
- Dehghani, M., Ghasemzadeh, M., & Ansari Samani, H. (2019). Machine learning algorithms for time series in financial markets. *Journal of Soft Computing and Information Technology*, 8(3), 60–67. (in Persian)
- Deng, S., & Min, X. (2013). Applied optimization in global efficient portfolio construction using earning forecasts. *The Journal of Investing*, 22(4), 104–114.
- Dogan, A., & Birant, D. (2019). A weighted majority voting ensemble approach for classification. In *Proceedings of the 2019 4th International Conference on Computer Science and Engineering (UBMK)* (pp. 1–6). IEEE.
- Dowd, K. (2007). *Measuring market risk* (2nd ed.). John Wiley & Sons.
- Elfti, S., & Ohadi, F. (2022). Designing a commercial risk prediction model using machine learning techniques. *Journal of Accounting Knowledge and Management Auditing*, 11(42), 121–134. (in Persian)
- 18.Esfandiar,M.,Keramati.,M.,Gholami Jamkarani,R.,&Kashfi Neishabouri,M.(2024). Stock portfolio optimization using deep Q reinforcement learning strategy based on state-action matrix. *Financial Engineering and Securities Management*. 59, 23-51. (in Persian)
- Faridi, S., Madanchi Zaj, M., Daneshvar, A., Shahverdiani, Sh., & Rahnama Roudposhti, F. (2022). Portfolio optimization based on hybrid Omega–Markowitz model using two-level collective machine learning. *Financial Knowledge of Securities Analysis*, 15(55), 33–54. (in Persian)
- Greene, W. H. (2018). *Econometric analysis*" (8th ed.). Pearson.
- Gupta, P., Mehlawat, M. K., & Mittal, G. (2012). Asset portfolio optimization using support vector machines and real-coded genetic algorithm. *Journal of Global Optimization*, 53(2), 297–315.
- Heratzadeh, S., & Rezaei, F. (2023). Presenting a new method for utilizing machine learning in the stock portfolio optimization process. *Journal of Decisions and Operations Research*, 8(2), 527–539. (in Persian)
- Hull, J. C. (2021). *Machine learning in business: An introduction to the world of data science*. Independently published.

- Luis, M. D., Rodríguez Alfonso, E., & Torres, D. (2023). Machine learning applied to active fixed-income portfolio management: A Lasso logit approach (*Banco de España Working Paper No. 2324*).
- Noorahmadi, M., & Sadeghi, H. (2022). Machine learning based on hierarchical risk parity approach (Case study: Portfolio of 30 top companies in Tehran Stock Exchange). *Financial Research Journal*, 24(2), 236–256. (in Persian)
- Rockafellar, R. T., & Uryasev, S. (2002). Conditional value-at-risk for general loss distributions. *Journal of Banking & Finance*, 26(7), 1443–1471.
- Rom, B. M., & Sortino, F. A. (1994). The downside risk approach to risk measurement. *Journal of Portfolio Management*, 20(4), 51–59.
- Wang, J.-Z., Wang, J.-J., Zhang, Z.-G., & Guo, S.-P. (2011). Forecasting stock indices with back propagation neural network. *Expert Systems with Applications*, 38(11), 14346–14355.
- Zamani, M., Emamverdi, G., Nourifard, Y., Hamidian, M., & Jafari, S. M. (2024). Predicting value at risk with artificial intelligence approach. *Journal of Quantitative Economics*, 21(2), 1–33. (in Persian)
- Zhang, C., & Ma, Y. (2012). *Ensemble machine learning: Methods and applications* (Vol. 144). Springer.