



Paper Type: Original Article



A Novel Machine Learning Approach for Portfolio Optimization

Saman Haratizadeh^{1,*} , Fatemeh Rezaee¹

¹ Department of Decision Sciences and Knowledge, Faculty of New Sciences and Technologies, University of Tehran, Tehran, Iran; fatemehrezaee@ut.ac.ir; haratizadeh@ut.ac.ir.

Citation:



Haratizadeh, S., & Rezaee, F. (2023). A novel machine learning approach for portfolio optimization. *Journal of decisions and operations research*, 8(2), 527-539.

Received: 28/09/2021

Reviewed: 29/10/2021

Revised: 14/11/2021

Accepted: 26/12/2021

Abstract

Purpose: Selection of the best stocks for the portfolio as well as allocating the optimal amount of capital per stock in the portfolio are serious challenges in investing in the stock market. The use of machine learning capacities in the process of optimal capital allocation among portfolio assets has received less attention and usually, the same weight is assigned to portfolio stocks or traditional risk assessment methods are used to divide capital between portfolio stocks. The common disadvantage of these methods is that they all use simple and inflexible mechanisms to estimate the performance of a set. The purpose of this paper is to show for the first time, that machine learning can be used to create a more effective mechanism for estimating performance, which leads to a more efficient allocation of capital to portfolio stocks.

Methodology: Our proposed framework, uses two predictive models based on machine learning. In the first step, stocks historical information is used in a return forecasting model, then based on the predicted returns, the appropriate stocks of the portfolio are selected. In the second step, a separate forecasting model predicts portfolio returns by taking into account both the forecasted returns in the first model and the expected risk of the stocks. At the end based on the predicted return of the numerous random portfolios, the appropriate weight for each asset is selected.

Findings: Comparing the returns of adjusted portfolios with this model and adjusted portfolios with other portfolio optimization methods shows the superiority of the proposed model.

Originality/Value: In this paper, by using machine learning models, the process of selecting the appropriate stock of the portfolio and allocating capital among the candidate stocks is done optimally.

Keywords: Portfolio selection, Portfolio optimization, Deep learning, Machine learning.

Corresponding Author: fatemehrezaee@ut.ac.ir

 <http://dorl.net/dor/20.1001.1.25385097.1402.8.2.14.8>



Licensee. **Journal of Decisions and Operations Research**. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0>).



نوع مقاله: پژوهشی



ارایه روشی جدید برای بهره‌گیری از یادگیری ماشین در فرآیند بهینه‌سازی سبد سهام

سامان هراتی‌زاده^۱، فاطمه رضایی^۱

^۱گروه علوم تصمیم و دانش، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران.

چکیده

هدف: انتخاب سهام برای قرار گرفتن در یک سبد سهام و هم‌چنین تخصیص میزان مناسبی از سرمایه به هر یک از سهام درون سبد، چالش‌های جدی سرمایه‌گذاری در بازار سهام هستند. تاکنون در پژوهش‌های متعددی از روش‌های پیشرفته یادگیری ماشین برای انتخاب سهام درون سبد سهام استفاده شده است، استفاده از ظرفیت‌های یادگیری ماشین در فرآیند تخصیص کارآمد سرمایه میان سهام سبد کم‌تر مورد توجه قرار گرفته است و معمولاً وزن یکسان به سهام سبد تخصیص داده می‌شود یا از روش‌های سنتی ارزیابی ریسک برای تقسیم سرمایه میان سهام سبد استفاده می‌شود. نقطه ضعف مشترک این روش‌ها این است که در همه آن‌ها از مکانیزم‌های ساده و انعطاف‌ناپذیر برای تخمین کارایی یک سبد سهام استفاده می‌شود. در این مقاله ما برای نخستین بار نشان می‌دهیم که با استفاده از یادگیری ماشین می‌توان مکانیزم موثرتری برای این تخمین کارایی ساخت که منجر به تخصیص پربازده‌تر سرمایه به سهام سبد می‌شود.

روش‌شناسی پژوهش: چارچوب پیشنهادی ما موسوم به *Per-Learner* از دو مدل پیش‌بینی مبتنی بر یادگیری ماشین استفاده می‌کند. در گام ۱ با استفاده از اطلاعات تاریخی سهام در یک مدل پیش‌بینی بازده سهم، سهام مناسب سبد انتخاب می‌شود و در گام ۲ به کمک یک مدل پیش‌بینی مجزا سعی می‌شود با در نظر گرفتن هم‌زمان سود پیش‌بینی شده در مدل اول و ریسک مورد انتظار هر یک از سهم‌های سبد، بازده سبد در آینده پیش‌بینی شده و بر این اساس ترکیب وزن مناسب برای سهام سبد انتخاب و پیشنهاد گردد.

یافته‌ها: مقایسه بازده تجمعی سبدهای تنظیم‌شده با این مدل و سبدهای تنظیم‌شده با سایر روش‌های بهینه‌سازی سبد سهام، برتری مدل پیشنهادی را نشان می‌دهد.

اصالت/ارزش‌افزوده علمی: در این مقاله با بهره‌گیری از مدل‌های یادگیری ماشین، فرآیند انتخاب سهام سبد و تخصیص سرمایه مناسب میان سهام سبد به صورت خودکار انجام شده است و تاثیر آن در کارایی سبد به وضوح دیده می‌شود.

کلیدواژه‌ها: انتخاب سبد سهام، بهینه‌سازی سبد سهام، یادگیری عمیق، یادگیری ماشین.

۱- مقدمه

متداول‌ترین استراتژی سرمایه‌گذاری در بازارهای مالی، سرمایه‌گذاری روی مجموعه‌ای از سهام‌هاست. تقسیم سرمایه بین مجموعه‌ای از سهام‌ها در درجه اول ریسک سرمایه‌گذاری را در مقایسه با حالتی که تمام سرمایه به یک سهم خاص تخصیص می‌یابد، کاهش می‌دهد؛ چراکه اگر یک یا چند سهم از سبد با رکود یا کاهش قیمت مواجه شوند، کل سرمایه به خطر نمی‌افتد و در درجه دوم به صورت متوسط سود بیش‌تری در طولانی‌مدت برای سرمایه‌گذار محقق می‌کند. یک سبد بهینه‌ی سهام به نحوی تنظیم می‌شود که سهم‌های سبد تا حد امکان نوسانات قیمتی نامطلوب یکدیگر را پوشش دهند و به صورت هم‌زمان دچار رکود و زیان نشوند. با این حال تنوع سهام و پیچیدگی رابطه‌های

* نویسنده مسئول

fatemehrezaee@ut.ac.ir

<http://dorl.net/dor/20.1001.1.25385097.1402.8.2.14.8>





میان آن‌ها و نیز گستردگی عوامل تاثیرگذار روی رفتار بازار بورس باعث شده انتخاب سهام مناسب و بازتخصیص بهینه سرمایه روی آن‌ها، به سادگی عملی نباشد. در سال‌های اخیر توسعه الگوریتم‌های یادگیری ماشین و پیشرفت‌های یادگیری عمیق [1] و نیز اثبات اثربخشی آن‌ها در حل مسایل پیچیده حوزه‌های گوناگون، پژوهشگران را به استفاده از این الگوریتم‌ها برای حل چالش‌های بازار سهام سوق داده است. انتخاب سهام مناسب و تخصیص بهینه وزن به آن‌ها دو فاکتور موثر در موفقیت یک سبد سهام هستند. به همین دلیل می‌توان ساخت سبد را در دو گام مجزا بررسی کرد [2] در گام ۱ سهام‌های مناسب برای سرمایه‌گذاری تعیین می‌شوند. برای این منظور معمولاً سعی می‌شود سودآورترین سهام برای سبد انتخاب شوند [3].

مقالات متعددی [4] و [5] کارایی روش‌های یادگیری ماشین را در پیش‌بینی بازده سهام نشان می‌دهند. در پژوهش‌های اخیر معمولاً به کمک این روش‌ها سود آتی هر یک از سهام‌ها تخمین زده می‌شود و سهامی که بالاترین تخمین سود را دارند در سبد قرار می‌گیرند. به میزانی که مدل‌های پیش‌بینی بازده سهام، تخمین دقیق‌تری از بازده به دست دهند، سهام مناسب‌تری در سبد قرار می‌گیرند [6]. در گام ۲ ساخت سبد لازم است وزن بهینه نظیر هر یک از سهام‌های سبد معین شود. منظور از وزن بهینه بخشی از سرمایه است که به سهم مربوطه تخصیص داده می‌شود. بدیهی است تخصیص نامناسب سرمایه به سهام داخل سبد می‌تواند منجر به افت بازده سبد سهام شود. با این حال تاکنون عمده پژوهش‌ها در زمینه بهینه‌سازی و مدیریت سبد سهام تنها به بهبود گام ۱، یعنی انتخاب سهام مناسب برای سبد پرداخته‌اند، برای نمونه مقاله‌های [8]-[6] از مدل‌های پیش‌بینی مبتنی بر یادگیری ماشین برای تخمین بازده آتی سهام‌ها از رفتار گذشته هر یک از آن‌ها استفاده کرده‌اند تا سهامی که بازده بیشتری در آینده دارند در سبد قرار بگیرند و در نتیجه بازده بالاتری برای سبد محقق کنند. در واقع تمرکز این تحقیقات روی نشان دادن تاثیر مثبت مدل‌های پیش‌بینی در انتخاب صحیح سهام سبد است؛ به میزانی که مدل پیش‌بینی استفاده‌شده در گام ۱ دقیق‌تر باشد، سهام‌های سودآورتر با احتمال بالاتری در سبد قرار می‌گیرند و در نتیجه بازده سبد بیشتر می‌شود. با این حال انتخاب سهام مناسب نیمی از مسیر موفقیت یک سبد سهام است و نباید تاثیر تخصیص بهینه سرمایه میان سهام سبد را در سود نهایی سبد نادیده گرفت [2].

از بین روش‌های تقسیم سرمایه میان سهام سبد، تخصیص وزن (سرمایه) یکسان به تمام سهام‌های سبد ساده‌ترین استراتژی است. این استراتژی تاثیر عواملی چون تفاوت بازده سهام مختلف و ریسک حاصل از تخصیص سرمایه به سهامی با رفتار مشابه را در بازده نهایی سبد نادیده می‌گیرد، به همین دلیل یک استراتژی بهینه برای تخصیص وزن سهام سبد تلقی نمی‌شود. میانگین واریانس^۱ یکی دیگر از استراتژی‌های متداول تقسیم سرمایه است که برخلاف روش قبل با توجه به میزان همبستگی بازده سهام‌های سبد در گذشته و نیز بازده مورد انتظار برای هر یک از آن‌ها، طبق یک الگوی ثابت سرمایه را توزیع می‌کند. در این استراتژی که در واقع نوعی مصالحه میان بازده و ریسک است، به سهام‌هایی که بازده مورد انتظار بالاتری دارند وزن بیشتری در سبد تعلق می‌گیرد و در عین حال هر دو سهمی که از نظر بازده همبستگی بالایی در گذشته داشته‌اند به صورت هم‌زمان وزن بالایی از سبد را در اختیار نخواهند داشت؛ چراکه افت بازده یک سهم منجر به کاهش بازده سایر سهام‌هایی می‌شود که رفتار مشابه این سهم دارند، در نتیجه زیان بیشتری به سبد تحمیل می‌شود و همین امر متوسط سود سرمایه‌گذاری را در بلندمدت کاهش می‌دهد. از این رو تصمیم‌گیری براساس میانگین واریانس در طولانی مدت نسبت به استراتژی هم‌وزن، کارآمدتر است.

با این وجود، این تخصیص وزن عمدتاً گذشته‌نگر و ایستا و در تضاد با ماهیت پویای بازارهای مالی است؛ تصمیم‌گیری در این فضای پویا نیازمند انطباق‌پذیری بیشتری است که بتواند عوامل اثرگذار در کارایی بلندمدت سبد را در نظر بگیرد و براساس استنباطی که از این عوامل به دست می‌آورد به صورت پویا وزن هر یک از سهام را در شرایط فعلی بازار تعیین نماید. در واقع فرآیند تصمیم‌گیری بایستی با توجه به تغییرات رفتاری سهام‌های سبد از گذشته تا به امروز، الگویی استخراج کند که کارایی سبد را در آینده پیش‌بینی نماید و براساس آن سبدهای مختلف را ارزش‌گذاری نماید. ما در این پژوهش سعی کرده‌ایم چارچوبی موسوم به *Per-Learner* برای استفاده از پتانسیل یادگیری ماشین در پیش‌بینی بازده سبدهای سهام ارائه دهیم که بتواند براساس شرایط بازار، پیش‌بینی بازده سهام‌ها و تخمین ریسک سرمایه‌گذاری، کارایی سبد را پیش‌بینی کند و به کمک آن وزن مناسب سهام سبد را انتخاب نماید. این چارچوب شامل دو مرحله پیش‌بینی مبتنی بر یادگیری ماشین است.

¹ Mean-Variance (MV)



Per-Learner در گام ۱ با استفاده از اطلاعات تاریخی هر سهم در یک مدل پیش‌بینی بازده، میزان بازده آن را برای روز معاملاتی آتی پیش‌بینی و سهم‌هایی که بالاترین تخمین بازده را دارند برای قرارگیری در سبد انتخاب می‌کند. در گام بعد با استفاده از یک مدل پیش‌بینی کننده بازده سبد، میزان بازده سهام منتخب را به‌ازای تخصیص‌های شدنی متفاوتی تخمین می‌زند و نهایتاً تخصیصی که بالاترین تخمین کارایی را روی سهام منتخب دارا باشد به‌عنوان سبد نهایی برمی‌گزیند. مدل پیش‌بینی کننده بازده سبد، تخمین بازده را براساس ویژگی‌هایی که هر یک توصیف کننده یک جنبه به‌خصوص از آن سبد است انجام می‌دهد. این ویژگی‌ها علاوه بر رفتار گذشته و بازده پیش‌بینی شده سهم‌های سبد، اطلاعاتی پیرامون ریسک پیش‌بینی و روابط متقابل سهم‌ها را نیز در برمی‌گیرد؛ از آن‌جا که هر مدل پیش‌بینی خطایی دارد و ریسک حاصل از این خطا بر متوسط بازده مورد انتظار سبد تاثیرگذار است، بایستی در فرآیند تصمیم‌گیری تخصیص وزن‌ها این خطا نیز مورد توجه قرار بگیرد تا ریسک سرمایه‌گذاری کاهش یابد. از سوی دیگر تعامل سهم‌ها و همبستگی رفتار آن‌ها نیز از جمله فاکتورهایی است که سود مورد انتظار سرمایه‌گذاری را تحت تاثیر قرار می‌دهد؛ بنابراین، در زمان تصمیم‌گیری درباره میزان سرمایه تخصیص یافته به هر سهم، باید همبستگی رفتار سهام نیز مدنظر قرار گیرد تا تصمیمات کم‌خطرتری اتخاذ شود.

به این ترتیب مدل پیشنهادی ما برخلاف ساختار صلب مدل‌های تصمیم‌گیری پیشین، یک ساختار تصمیم‌گیری انطباقی دارد که از اطلاعات پیش‌بینی بازده و خطای آن و همین‌طور اطلاعات تاریخی مربوط به رفتار سهام‌ها برای استخراج الگوهایی که بازده سبد را پیش‌بینی می‌کنند، استفاده می‌کند تا کارایی تخصیص‌های مختلف سرمایه به سهام منتخب را تخمین بزند و یک ترکیب وزنی مناسب را که معادل یک تخصیص سرمایه مشخص به سهام منتخب است انتخاب نماید. این ترکیب وزنی تنها نسبت تخصیص سرمایه به هر یک از سهام درون سبد را مشخص می‌کند و لذا به‌ازای هر مقداری از سرمایه قابل استفاده است. در چارچوب پیشنهادی وزن‌دهی مبتنی بر کاهش ریسک، با یک مکانیزم پویای انطباق پذیر که مستقیماً بازده سبد را تخمین می‌زند جایگزین می‌شود. ارزیابی‌های ما نشان می‌دهد سرمایه‌گذاری با روش پیشنهادی در مقایسه با استراتژی میانگین واریانس و استراتژی سبد هم‌وزن، به بازده بالاتری منجر می‌شود. آن‌چه که مدل ما را در مقایسه با سایر روش‌های بهینه‌سازی سبد سهام متمایز می‌سازد، سازگاری تصمیم‌گیری با شرایط است؛ یعنی در هر زمان بسته به شرایط و وضعیت سهم‌های مختلف، مدل تصمیم‌بینه را براساس تخمین وضعیت آتی سبد اتخاذ می‌کند و همین سازگاری منجر به تصمیمات هوشمندانه می‌شود که در طولانی مدت کارایی بیش‌تری برای سرمایه‌گذار محقق نماید. در ادامه این مقاله در بخش ۲ کارهای مرتبط انجام شده در حوزه بهینه‌سازی سبد سهام را مرور می‌کنیم. در بخش ۳ به تفصیل به معرفی چارچوب *Per-Learner* می‌پردازیم. در بخش ۴ شیوه ارزیابی، آزمایش‌ها و نتایج آن‌ها مورد بررسی قرار می‌گیرند و در نهایت در بخش ۵ نتایج پژوهش حاضر جمع‌بندی می‌شود و پیشنهادهای پژوهشی برای ادامه تحقیق ارایه می‌گردد.

۲- پیشینه تحقیق

رویکرد بسیاری از مقالات ساخت سبد بهینه مبتنی بر یادگیری ماشین، استفاده از یک مدل پیش‌بینی بازده سهم برای شناسایی سهم‌های پربازده و قرار دادن آن‌ها در سبد سهام و تقسیم سرمایه به‌طور برابر میان سهام منتخب است. از جمله [3] یک مدل ترکیبی با استفاده از ماشین بردار پشتیبان^۱ و الگوریتم ژنتیک برای بهینه‌سازی سبد سهام معرفی کرده است. در این مقاله از *SVM* برای پیش‌بینی بازده سهم و از الگوریتم ژنتیک برای بهینه‌سازی پارامترهای مدل پیش‌بینی استفاده شده است. سپس سهم‌هایی که پیش‌بینی بازدهی بالاتر از یک حد آستانه دارند انتخاب می‌شوند و با وزن یکسان در سبد قرار می‌گیرند.

روش پیشنهادی در مقاله [9] از حافظه کوتاه-مدت ماندگار^۲ برای پیش‌بینی جهت حرکت سهام استفاده کرده‌اند و پس از انتخاب سهام مناسب برای خرید و فروش استقراری^۳ سبدی شامل $2k$ سهم با وزن برابر می‌سازد. در این مقاله نشان داده شده است که سبدهایی که براساس پیش‌بینی مدل‌های طبقه‌بندی بدون حافظه مثل جنگل تصادفی^۴، شبکه‌ی عصبی عمیق^۵ یا رگرسیون خطی^۶ ساخته شده‌اند از بازدهی کم‌تری نسبت به سبدهای ساخته شده با حافظه کوتاه-مدت ماندگار برخوردارند. در پژوهشی دیگر [10] به جای استفاده مستقیم از بازده پیش‌بینی شده برای انتخاب سهام، یک روش ترکیبی دو مرحله‌ای مبتنی بر یادگیری ماشین برای رتبه‌بندی سهام از طریق پیش‌بینی قیمت آتی سهم ارایه داده است. در مدل پیشنهادی این مقاله در فاز اول، به کمک یک شبکه عصبی پیش‌خور^۷، بازده آتی هر سهم محاسبه

¹ Support Vector Machine (SVM)

² Long Short-Term Memory (LSTM)

³ Short selling

⁴ Random Forest (RF)

⁵ Deep Neural Network (DNN)

⁶ Linear Regression (LR)

⁷ Feed-forward neural network



می‌شود. این بازده‌ها به‌عنوان ورودی به مرحله ۲ مدل که همان رتبه‌بندی سهام طی یک فرآیند امتیازدهی خطی است، داده می‌شوند. در این مرحله هر سهم به کمک یک جمع وزن‌دار از تعدادی فاکتورهای بنیادین و بازده آتی سهم امتیازدهی می‌شود و ۵٪ سهم برتر با وزن یکسان در سبد قرار می‌گیرند.

در مقاله [5] عملکرد شبکه عصبی واحد بازگشتی دروازه‌ای^۱، شبکه عصبی بازگشتی^۲ و LSTM برای پیش‌بینی بازده سهام مقایسه شده است و نشان داده شده است که LSTM در مقایسه با دو مدل دیگر کارایی بالاتری در پیش‌بینی بازده سهام داشته است. هم‌چنین به کمک پیش‌بینی‌های مدل سهم‌هایی که بازدهی بالاتری از یک حد آستانه داشتند انتخاب شده و با وزن یکسان در سبد نهایی قرار گرفته‌اند.

در این دسته از مقالات هدف اصلی استفاده از مدل‌های پیش‌بینی کارآمد برای انتخاب سهام سبد است و همان‌طور که پیش‌تر اشاره شد، ضعف عمده این دسته از مقاله‌های این است که سرمایه را به‌طور مساوی میان سهام سبد تقسیم می‌کنند و تخصیص وزن یکسان به سهام سبد به‌وضوح بهترین استراتژی برای یک سرمایه‌گذاری نیست و همین امر باعث می‌شود در طولانی‌مدت متوسط بازده سبدهای ساخته‌شده به این روش بهینه نباشد.

دسته دیگر پژوهش‌های این حوزه پژوهش‌هایی هستند که مشابه دسته اول از مدل‌های پیش‌بینی برای تشخیص سهم‌های مناسب برای قرارگیری در سبد استفاده می‌کنند ولی به‌جای تخصیص وزن یکسان به همه سهم‌ها از تئوری پرتفوی مدرن برای بهینه‌سازی وزن تخصیص‌یافته به سهم‌های سبد استفاده می‌کنند به این امید که در طولانی‌مدت بازده بالاتری داشته باشند.

تئوری پرتفوی مدرن نخستین‌بار توسط مارکوویتز [11] با مدل میانگین-واریانس معرفی شد. در مدل پیشنهادی مارکوویتز [11] وزن هر یک از سهم‌ها براساس یک مصالحه بین بازده مورد انتظار R^* و ریسک حاصل از همبستگی رفتاری سهام سبد تعیین می‌شود.

$$\begin{aligned} \min \sum_{i=1}^N \sum_{j=1}^N w_i w_j \sigma_{i,j} & \quad (1-الف) \\ \sum_{i=1}^N w_i r_i = R^* & \quad (1-ب) \\ \sum_{i=1}^N w_i = 1 & \quad (1-ج) \\ 0 \leq w_i \leq 1, \quad i = 1, 2, \dots, N & \quad (1-د) \end{aligned}$$

رابطه (۱)، یعنی سهمی که بازده مورد انتظار r_i بالاتری دارند به‌دلیل پتانسیل رشد بالاتر، وزن بیشتری در سبد می‌گیرند **رابطه (۱-الف)**، درعین‌حال سهم‌هایی که در طول زمان همبستگی رفتاری بالایی از خود نشان داده‌اند به‌صورت هم‌زمان وزن بالایی در سبد را نخواهند داشت. در رابطه واریانس سبد **فرمول (۱-ب)**، w_i ، w_j و $\sigma_{i,j}$ به ترتیب وزن سهم i th، وزن سهم j th و کوواریانس دو سهم i و j را در سبد نشان می‌دهند، هم‌چنین N مشخص‌کننده تعداد سهم‌های سبد است. شرط **(۱-ج)** تضمین‌کننده این است که تمام سرمایه میان‌ها تخصیص می‌یابد. **نامساوی (۱-د)** نشان می‌دهد فروش استقرایی در این مدل‌سازی مجاز نیست.

ازجمله تحقیقاتی که در آن از ترکیب یک مدل پیش‌بینی با میانگین واریانس برای بهینه‌سازی سبد استفاده کرده‌اند می‌توان به مقاله [12] اشاره کرد. این مقاله از پیش‌بینی‌های یک مدل پیش‌بینی مبتنی بر SVM برای انتخاب سهام و از روش میانگین واریانس برای تنظیم وزن سهام‌ها استفاده کرده است. برای نشان دادن کارایی مدل، بازده سبدهای به‌دست‌آمده با بازده سبدهای هم‌وزن و نیز سبدهایی که به‌صورت تصادفی انتخاب و وزن‌های آن‌ها براساس مدل میانگین واریانس بهینه شدند، مقایسه شده است که برتری مدل پیشنهادی را نشان می‌دهد. در یک پژوهش جدید دیگر [7] رویکردی مشابه مقاله قبلی اتخاذ شده است؛ با این تفاوت که در مرحله ۱، از یک مدل یادگیری ماشین با ترکیب الگوریتم ارتقا‌گرایان^۳ و الگوریتم کرم‌شب‌تاب بهبودیافته برای پیش‌بینی قیمت سهام استفاده شده است که ابرپارامترهای الگوریتم XG-Boost با الگوریتم کرم‌شب‌تاب به‌صورت بهینه تعیین می‌شوند.

مقاله [8] از پیش‌بینی‌های یک شبکه عصبی LSTM برای ساخت سبد با رویکردهای متفاوت استفاده کرده است. رویکردهای پیشنهادی، میانگین واریانس و هم‌وزن بودند. برای ارزیابی نتایج دو مدل SVM و LR به‌عنوان رقیب در نظر گرفته شده است. نتایج نشان می‌دهد LSTM

¹ Gated Recurrent Unit (GRU)

² Recurrent Neural network (RNN)

³ Extreme Gradient Boosting (-XG Boost)



دقت بالاتری در مقایسه با دو مدل دیگر دارد و در نتیجه سبدهای ساخته‌شده براساس پیش‌بینی‌های این مدل بازدهی بالاتری نسبت به سایر مدل‌ها دارند. تحقیق [2] هم مشابه از ترکیب *LSTM* و میانگین واریانس برای طراحی و بهینه‌سازی سبد سهام استفاده کرده است. این مقاله کارایی مدل *LSTM* را با مدل‌های *SVM*، *RF* و میانگین متحرک خود همبسته یکپارچه^۱ در انتخاب سهام مقایسه کرده است. نتایج نشان داده که مدل پیشنهادی، بازده بالاتری در مقایسه با سایر مدل‌ها دارد.

از آن‌جا که معمولاً مدل‌های پیش‌بینی خطا دارند و این خطا در انتخاب سهام سبد و تعیین وزن بهینه آن‌ها تاثیرگذار است، مقاله [6]، متوسط خطای مدل در پیش‌بینی بازده سهم در یک بازه زمانی کوتاه‌مدت، به مقدار بازده پیش‌بینی‌شده برای آن سهم اضافه می‌شود و مقدار حاصل به‌عنوان بازده مورد انتظار آن سهم در نظر گرفته می‌شود تا تاثیر خطای پیش‌بینی در فرآیند تصمیم‌گیری درباره وزن هر سهم کاهش یابد. مقاله [13] از نتایج مقاله [6] استفاده کرده است و مدل‌های پیش‌بینی متنوعی را با میانگین واریانس بهبودیافته معرفی شده در مقاله قبلی ترکیب کرده است تا سبدهای سودآورتری ایجاد کند. در این مقاله الگوریتم‌های *SVM*، *RF* و سه مدل پیش‌بینی مبتنی بر شبکه عصبی؛ *DNN*، *LSTM* و شبکه عصبی پیچشی^۲ برای پیش‌بینی بازده آتی سهم استفاده شده‌اند. در ادامه با هر مجموعه سهام پیشنهادی متناظر مدل‌های پیش‌بینی بازده، براساس مدل میانگین واریانس سبد سهام بهینه ساخته می‌شود. مقایسه بازده متوسط سبدهای ساخته‌شده با در نظر گرفتن ۱٪ هزینه تراکنش نشان می‌دهد ترکیب مدل *RF* و میانگین واریانس برای پیشنهاد سرمایه‌گذاری بازده بالاتری نسبت به سایر ترکیبات دارد.

این دسته از مقاله‌ها با وجود آن‌که اثربخشی استفاده از مدل‌های پیش‌بینی را در افزایش کارایی سبدهای سهام نشان می‌دهند، در مرحله تعیین وزن سهام‌های سبد از این مدل‌ها استفاده نمی‌کنند. پیش‌تر اشاره کردیم میانگین واریانس یک مدل تصمیم‌گیری ایستا است که در شرایط گوناگون الگو تخصیص وزن ثابتی دارد. این الگو ثابت با ماهیت پویا بازار سهام سازگار نیست و برای معاملات روزانه سهام اثربخشی کافی ندارد. از این‌رو نیاز است مدل‌های موجود به‌گونه‌ای توسعه یابند که بتوانند براساس شرایط سهام‌ها، درباره وزن‌هایی که کارایی سبد را افزایش می‌دهند تصمیم‌گیری کنند. در بخش بعد به معرفی مدل پیشنهادی می‌پردازیم.

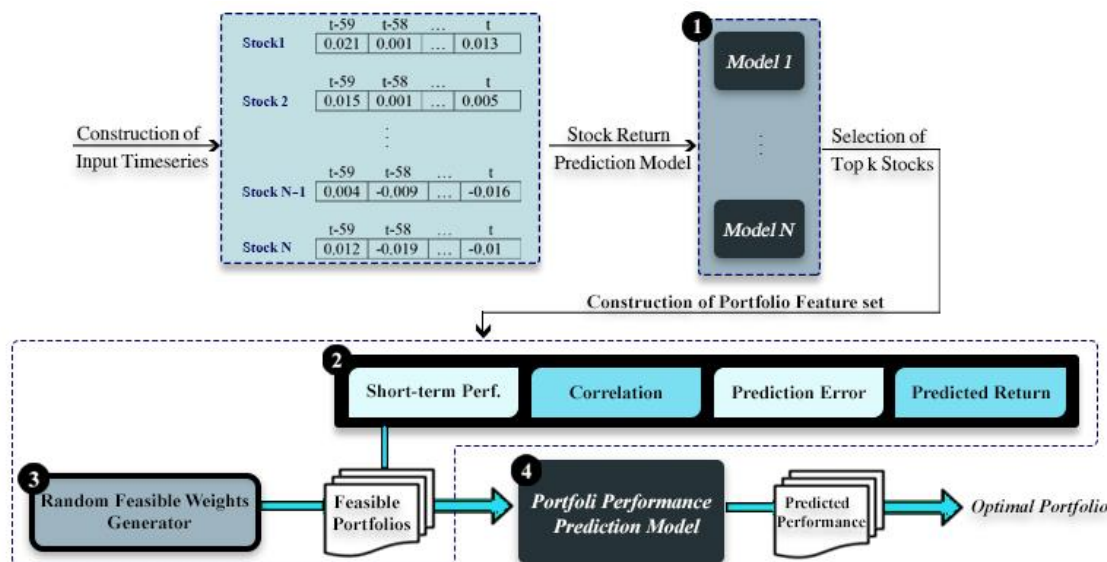
۳- مدل Per-Learner

مدل *Per-Learner* با توجه به شرایط بازار سهام‌های مناسب سبد و وزن بهینه هر یک از سهام‌ها در سبد را تخمین می‌زند. این مدل از چندین مولفه تشکیل شده است که هر کدام بخشی از اطلاعات لازم برای برآورد کارایی یک سبد را تأمین می‌کنند. به‌طور کلی مدل *Per-Learner* با استفاده از ویژگی‌های سهام یک سبد، کارایی آن سبد را تخمین می‌زند و بر مبنای این کارایی درباره ترکیب وزنی مناسب سهام‌های آن سبد تصمیم‌گیری می‌کند؛ این مدل تعیین می‌کند که در هر شرایطی از بازار، چه وزنی از سهام، بازدهی بیش‌تری از خود نشان می‌دهد.

شکل ۱ شمای کلی این مدل و الگوریتم ۱ شبه کد آن را نشان می‌دهد. این چارچوب شامل یک مدل پیش‌بینی بازده برای هر سهم بازار و یک مدل پیش‌بینی بازده برای سبد سهام است. مدل‌های پیش‌بینی بازده سهام با داده‌های تاریخی هر سهم آموزش داده می‌شوند. پس از آن با توجه به مقادیر پیش‌بینی‌شده بازده برای هر سهم، یک مجموعه از سهام منتخب برای سبد روز بعد انتخاب می‌شود. با استفاده از ترکیبات وزنی شدنی تصادفی، روی سهام‌های منتخب سبدهای متفاوتی ساخته می‌شود پس از آن براساس ویژگی‌های هر سبد به‌دست‌آمده از سهام‌های منتخب و تخصیص‌های شدنی، مدل پیش‌بینی کارایی سبد نیز آموزش داده می‌شود؛ بنابراین، *Per-Learner* در دو مرحله سبد بهینه را پیش‌بینی می‌کند. مرحله ۱ سهام منتخب را تعیین می‌کند و در مرحله بعد وزن مناسب متناظر هر سهم در سبد را برآورد می‌کند.

¹ Auto-Regressive Integrated Moving Average (ARIMA)

² Convolutional Neural Network (CNN)



شکل ۱ - شمای کلی چارچوب پیشنهادی.

Figure 1- Outline of the proposed framework.

۳-۱- مولفه‌های چارچوب Per-Learner

الگوریتم ۱- الگوریتم Per-Learner.

Algorithm 1- Algorithm of per-learner framework.

Input: The historical stock price

Output: The optimal weights of the candidate stocks ($W_{optimal}$)

1: Select the top k stocks from Stock return prediction models as *Candidate stocks*

2: $\widehat{R} \leftarrow [r_1, \dots, r_k]$; # \widehat{R} is the predicted return of the candidate stocks

3: $\leftarrow [\varepsilon_1, \dots, \varepsilon_k]$; # ε is the mean of prediction errors

4: $R \leftarrow [r_1, \dots, r_k]$; # R is the last day return of the candidate stocks

5: **for** i in *Candidate stocks* **do**:

6: **for** j in *Candidate stocks* **do**:

7: $Cov_{i,j} \leftarrow Covariance(i,j)$;

8: **end for**

9: **end for**

Featureset contains portfolio features

10: *Featureset* $\leftarrow Concatenate(\widehat{R}, \varepsilon, R, Flatten(Cov))$;

Predicted_Per is the predicted performance of the feasible portfolios

11: *Predicted_Per* $\leftarrow []$;

12: **for** $i = 1$ **to** *num_of_feasible_weights* **do**:

13: Generate a random weight set as w_n ;

14: *FeasiblePortfolio* $\leftarrow Concatenate(Featureset, w_n)$;

15: *Predicted_Per*[n] $\leftarrow PortfolioPerformancePredictionModel(FeasiblePortfolio)$;

16: **end for**

17: $W_{optimal} \leftarrow argmax Predicted_{per}$

18: **return** $W_{optimal}$

مدل پیشنهادی شامل چهار مولفه اصلی است که در ادامه به معرفی هر یک می‌پردازیم.

مولفه ۱: در این مولفه به‌ازای تمامی سهم‌های بازار یک مدل پیش‌بینی در نظر گرفته شده است. منظور از مقدار بازده یک سهم درصد تغییرات

قیمتی آن سهم طی دو روز متوالی است؛ رابطه (۲) بازده قیمتی سهم i را در زمان t نشان می‌دهد.

$$r_{i,t} = \frac{close_{price_{i,t}} - close_{price_{i,t-1}}}{close_{price_{i,t-1}}} \quad (2)$$

هر یک از این مدل‌ها با دریافت یک توالی ۶۰ تایی از بازده آن سهم در ۶۰ روز گذشته، بازده روز بعد آن سهم را پیش‌بینی می‌کند.

$$Model_input_{i,t+1} = [r_{i,t-59}, r_{i,t-58}, \dots, r_{i,t-1}, r_{i,t}]. \quad (3)$$

بنابراین، ورودی مدل پیش‌بینی‌کننده بازده متناظر سهم i th برای پیش‌بینی بازده روز $(t+1)$ مطابق رابطه (۳)، یک سری زمانی به طول ۶۰ خواهد بود. براساس بازده پیش‌بینی‌شده تمامی مدل‌ها k سهمی که بازده بالاتری نسبت به سایر سهام دارند به‌عنوان سهام منتخب در سبد روز آینده قرار می‌گیرند. انتخاب سهام مناسب یک فاکتور تعیین‌کننده در کارایی یک سبد سرمایه‌گذاری است و مقدار بازده هر سهم به‌عنوان اطلاعاتی از آینده آن، در مکانیزم تصمیم‌گیری درباره وزن آن سهم در سبد اثرگذار است؛ بنابراین، هرچه مدل پیش‌بینی به‌کار رفته در این مرحله برآورد دقیق‌تری از بازده آتی سهم‌ها ارائه دهد، فرآیند انتخاب و تخصیص وزن‌ها با دقت بالاتری انجام می‌شود و در نتیجه کارایی سبد بهبود می‌یابد. ما در این پژوهش برای آن‌که اثربخشی مکانیزم تخصیص وزن مبتنی بر یادگیری را نشان دهیم، چندین مدل پیش‌بینی مختلف را برای تعیین سهام سبد آزمایش کردیم تا اطمینان داشته باشیم اثربخشی مکانیزم بهینه‌سازی سبد صرفاً به‌دلیل انتخاب‌های مناسب یک مدل پیش‌بینی خاص نیست. از این‌رو براساس پیشینه تحقیق، مدل‌های DNN ، CNN ، RF ، $LSTM$ ، در این پژوهش به‌عنوان پیش‌بینی‌کننده بازده سهم در نظر گرفته شده‌اند. جزییات معماری هر یک از این مدل‌ها به‌صورت زیر است:

۱. DNN : یک شبکه‌ی عصبی با ۳ لایه مخفی با تعداد نرون‌های ۱۵، ۸، و ۳ برای پیش‌بینی بازده سهم استفاده شده است. برای آموزش شبکه، از الگوریتم یادگیری کاهش گرادینان استفاده شده است؛ به‌نحوی که تابع هزینه (۴) طی فرآیند تنظیم وزن‌های شبکه حداقل گردد. در رابطه (۴) مقدار بازده پیش‌بینی‌شده توسط مدل و r_i مقدار بازده واقعی نمونه آموزشی i th هستند و n تعداد کل نمونه‌های آموزشی را نشان می‌دهد.

$$Cost_function = \frac{1}{n} \sum |r_i - \hat{r}_i|. \quad (4)$$

۲. CNN : در این مقاله مدل پیش‌بینی CNN ، از یک لایه کانولوشن دوبعدی با کرنل سایز $(2*1)$ ، یک لایه $maxpooling$ به سایز $(2*1)$ و سه لایه دنس به سایز ۲ تشکیل شده است. مشابه مدل قبلی تابع هزینه (۴) طی فرآیند یادگیری بهینه می‌شود.

۳. $LSTM$: معماری استفاده‌شده در این مدل از یک لایه $LSTM$ با ۳ نرون تشکیل شده است. در این مدل به کمک الگوریتم کاهش گرادینان پارامترهای مدل در جهت کاهش تابع هزینه (۴) بهینه‌سازی شده‌اند.

۴. RF : مدل استفاده‌شده در این پژوهش شامل یک جنگل ۴۰۰ تایی است که درخت‌های آن حداکثر به عمق ۲۰ و شامل حداقل ۱۰ نمونه در برگ و نودهای میانی هستند.

مولفه ۲: در چارچوب تصمیم‌گیری $Per-Learner$ برای یافتن سبد مناسب، بازده یک سبد پیش‌بینی می‌شود و براساس این بازده درباره کیفیت وزن تخصیص داده‌شده به سهام در آن سبد تصمیم‌گیری می‌شود؛ بنابراین، باید هر سبد با مجموعه‌ای از ویژگی‌های موثر در بازده آن توصیف شود. مولفه ۲ این چارچوب این ویژگی‌ها را جمع‌آوری می‌کند.

۵. $Predicted Return$: مقدار بازده پیش‌بینی‌شده برای هر یک از k سهم سبد \hat{R} اطلاعاتی از وضعیت آینده سهام است که در فرآیند تصمیم‌گیری درباره وزن تخصیص‌یافته به هر سهم و نیز بازده سبد اثرگذار است. r_i در رابطه (۵) مقدار بازده پیش‌بینی‌شده در مرحله قبل برای i th سهم از k سهم سبد را نشان می‌دهد.

$$\hat{R} = [r_1, r_2, \dots, r_k]. \quad (5)$$

۶. $Prediction Error$: سهم‌های سبد براساس پیش‌بینی‌های یک مدل تخمین بازده انتخاب شده‌اند. هر مدل پیش‌بینی متناسب با دقتی که دارد شامل یک خطای پیش‌بینی است از آن‌جاکه این خطا در فرآیند تصمیم‌گیری درباره وزن هر سهم در سبد موثر است لازم است در مکانیزم تصمیم‌گیری لحاظ شود تا ریسک تصمیم‌گیری کاهش یابد. خطای مدل در پیش‌بینی مقدار بازده باعث می‌شود یک سهم کم‌تر (بیش‌تر) از پتانسیل رشدی که دارد در سبد وزن دریافت کند، در نتیجه بازده محقق‌شده سبد کم‌تر (بیش‌تر) از مقدار مورد انتظار بازده آن سبد خواهد بود و همین امر تصمیم‌گیری مدل تخصیص سرمایه را با ریسک همراه می‌کند. برای جلوگیری از بروز این ریسک باید متوسط خطای مدل در پیش‌بینی هر سهم، به‌عنوان یک ویژگی موثر در تصمیم‌گیری درباره وزن آن سهم در سبد در نظر گرفته شود. در این پژوهش ما مشابه مقاله [6] متوسط خطای مدل در پیش‌بینی بازده را به‌عنوان خطای مدل در نظر گرفته‌ایم؛ بنابراین، خطای پیش‌بینی ϵ عبارت است از متوسط اختلاف مقدار واقعی بازده از مقدار پیش‌بینی‌شده توسط مدل روی یک بازه زمانی معین. اگر مقدار بازده واقعی سهم i در زمان t را $r_{i,t}$ و بازده پیش‌بینی‌شده توسط مدل در همین زمان را با $r_{i,t}$ نشان دهیم، آن‌گاه خطای پیش‌بینی مدل روی سهم i در یک بازه m روزه منتهی به زمان t مطابق رابطه (۷) محاسبه می‌شود. مولفه $Prediction risk$ ریسک پیش‌بینی تمام سهم‌های سبد را به‌عنوان خروجی برمی‌گرداند.





$$\epsilon = [\epsilon_{1,t}, \epsilon_{2,t}, \dots, \epsilon_{k,t}] \tag{۶}$$

$$\epsilon_{i,t} = \frac{1}{m} \sum_{s=1}^{s=m} r_{i,t-s} - r_{i,t-s} \tag{۷}$$

Correlation: میزان همبستگی رفتار سهم‌های یک سبد در طول زمان از دیگر فاکتورهای تاثیرگذار روی میزان وزن تخصیص‌یافته به سهم‌های یک سبد است. کوواریانس معیاری است که میزان تغییرات هم‌زمان دو متغیر تصادفی را اندازه می‌گیرد؛ بنابراین، محاسبه آن روی بازده سهم‌ها در بلندمدت، برآورد مناسبی از رفتار متقابل سهم‌ها در طول زمان است. کوواریانس بازده دو سهم i و j از روی بازه زمانی T براساس رابطه (۸) محاسبه می‌شود که در آن λ_i و λ_j به ترتیب متوسط بازده دو سهم i و j از روی بازه زمانی T ، $r_{i,t}$ و $r_{j,t}$ بازده هر یک از سهم‌های سهم i و j در روز t نشان می‌دهند.

$$Cov_{i,j} = \frac{1}{T} \sum_{t=1}^T (r_{i,t} - \lambda_i)(r_{j,t} - \lambda_j) \tag{۸}$$

Short-Term Prerf: تا این‌جا علاوه بر اطلاعاتی از وضعیت آینده سهم‌های سبد، اطلاعاتی از گذشته سهم‌ها و رفتار متقابل آن‌ها به‌عنوان ویژگی‌های موثر در وزن تخصیص‌یافته به هر یک از وزن‌های سبد و موثر در بازده سبد استخراج شده است. برای این‌که توصیف شرایط سهم‌های سبد کامل شود، بازده واقعی یک روز پیش از روز تست تمام سهم‌های سبد را به‌عنوان کارایی کوتاه‌مدت هر سهم R_t به مجموعه اطلاعات توصیف‌کننده شرایط سهم‌ها اضافه می‌شود.

$$R_t = [r_{t,1}, r_{t,2}, \dots, r_{t,k}] \tag{۹}$$

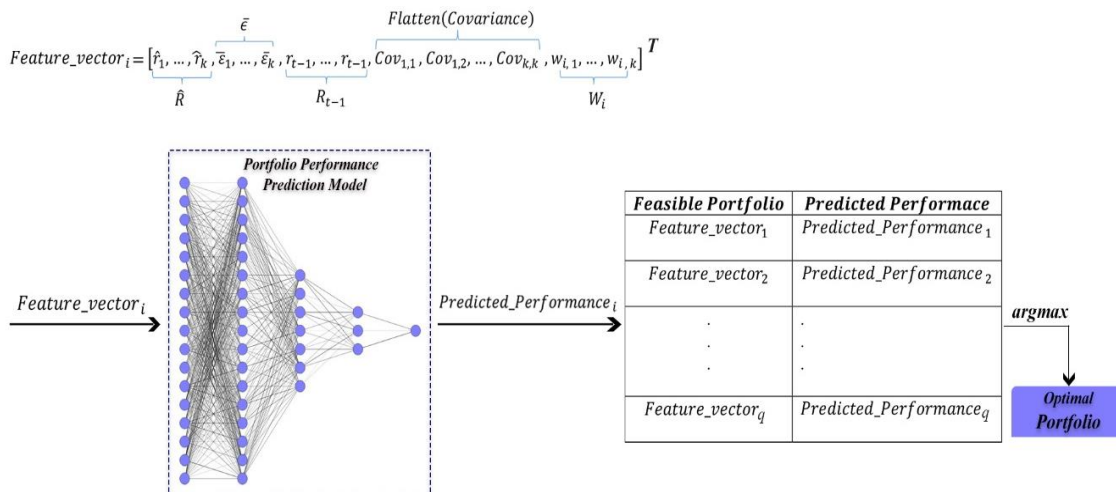
مؤلفه ۳: در گام قبلی اشاره کردیم که در این مقاله هر سبد را با یک مجموعه ویژگی توصیف می‌کنیم. ویژگی‌های مربوط به وضعیت سهام سبد در گام قبلی جمع‌آوری گردید. برای آن‌که توصیف یک سبد کامل شود کافی است وزن نظیر هر یک سهم‌های سبد تعیین و به ویژگی‌های قبلی اضافه شود. بدین منظور در این مرحله با در نظر گرفتن ترکیبات وزنی متعدد W_q روی سهم‌های سبد، سبدهای شدنی متعددی ساخته شود که هر یک از آن‌ها در محدودیت‌های مدل مارکوویتز [11] صدق می‌کند؛ یعنی تمام بودجه برای سرمایه‌گذاری مورد استفاده قرار می‌گیرد و فروش استقراضی مجاز نیست. رابطه (۱۰) محدودیت‌های هر یک از این ترکیبات تصادفی را نشان می‌دهد. در نهایت هر یک از سبدهای شدنی به‌صورت یک مجموعه ویژگی به‌عنوان بردار ورودی در اختیار مدل پیش‌بینی بازده سبد قرار می‌گیرد.

$$W_q = [w_{q,1}, w_{q,2}, \dots, w_{q,k}] \tag{۱۰}$$

$$\sum_{i=1}^k w_{q,i} = 1,$$

$$0 \leq w_{q,i} \leq 1, \quad i = 1, 2, \dots, k.$$

مؤلفه ۴: این مدل یک شبکه عصبی عمیق است که در چارچوب *Per-Learner* بازده هر یک از سبدهای شدنی ساخته‌شده در مرحله قبل را پیش‌بینی می‌کند. هر سبد شدنی که بالاترین بازده پیش‌بینی شده را در مجموعه‌ی سبدهای شدنی داشته باشد، به‌عنوان سبد نهایی معرفی می‌شود. شکل ۲ معماری این شبکه و بردار ویژگی‌های ورودی آن را نشان می‌دهد. مدل دارای ۳ لایه مخفی است که تعداد نرون‌های لایه‌های مخفی آن براساس تعداد سهم‌های سبد و سبدهای ورودی بهینه شده است. مطابق شکل ۲ ورودی این شبکه از الحاق ویژگی‌های استخراج‌شده در گام ۲ و وزن‌های شدنی به‌دست آمده است.



شکل ۲- مدل پیش‌بینی بازده سبد.

Figure 2- Portfolio performance prediction model.



مدل پیش‌بینی کارایی سبد از پیش‌بینی‌های مدل پیش‌بینی بازده سبد استفاده می‌کند؛ بنابراین، نمونه‌های آموزشی آن هم باید شامل این پیش‌بینی‌ها باشند؛ بنابراین، لازم است ابتدا مدل‌های پیش‌بینی بازده سهام آموزش ببینند. با این توضیحات مجموعه داده به سه بخش تقسیم می‌شود، بخش اول این داده‌ها برای آموزش مدل‌های پیش‌بینی بازده سهام استفاده می‌شود. پس از آن از پیش‌بینی‌های مدل‌های پیش‌بینی بازده سهام روی بخش دوم داده‌ها برای تولید نمونه‌های آموزشی لازم برای آموزش مدل پیش‌بینی کارایی سبد استفاده می‌شود. بدین منظور سبدهای متعدد فرضی با وزن‌های تصادفی روی مجموعه‌ی سهام منتخب هر روز تولید می‌شود با این شرط که حاصل جمع وزن سهام هر یک از سبدهای تولیدشده برابر یک بوده و هیچ سهمی وزن منفی نداشته باشد. پس از آن هر مجموعه وزن متناظر با یک سبد با ویژگی‌های توصیف‌کننده شرایط سهام‌های آن سبد الحاق می‌شود. سپس بازدهی هر سبد در روز بعد محاسبه شده و به‌عنوان مقادیر هدف (برچسب) نمونه‌ها در نظر گرفته می‌شود. در نهایت با نمونه‌های آموزشی به‌دست آمده از بخش دوم داده‌ها، مدل پیش‌بینی کارایی سبد آموزش داده می‌شود. شبکه عصبی آموزش دیده در واقع نگاشتی است از شرایط هر سبد دلخواه از سهام‌های برتر، به کارایی متناظر آن سبد. از بخش سوم داده‌ها نیز برای تست این چارچوب استفاده شده است. برای استفاده از مدل *Per-Learner* روی داده تست، برای هر روز تعداد دلخواهی سبد تصادفی تولید و کارایی آن‌ها پیش‌بینی خواهد شد. سبدهای که بالاترین مقدار کارایی برای آن پیش‌بینی شود سبد منتخب مدل خواهد بود.

۴- ارزیابی مدل

برای ارزیابی کارایی مدل پیشنهادی از داده‌های ۴۹ سهم شاخص *S&P500* در بازه زمانی بین مارس ۲۰۱۱ تا مارس ۲۰۲۰ برای آموزش و آزمایش چارچوب *Per-Learner* استفاده کرده‌ایم که داده‌های ۷ سال اول برای آموزش مدل پیش‌بینی بازده سهام به‌کار رفته‌اند. از آنجا که ۷ هدف ما معرفی یک مکانیزم تطبیق‌پذیر برای بهینه‌سازی وزن سبد بود و این مکانیزم می‌بایست به‌ازای هر مدل پیش‌بینی دلخواه قابلیت اجرا داشته، کارایی *Per-Learner* را به‌ازای مدل‌های متعدد پیش‌بینی سهام ارزیابی کردیم. ما از مدل‌های *RF*، *DNN*، *CNN* و *LSTM* به‌عنوان پیش‌بینی‌کننده بازده سهام استفاده کردیم. به این ترتیب که هر یک مدل‌های پیش‌بینی به‌کار رفته در این ماژول، بازده ۶۰ روز پیش از روز تست هر سهم را به‌عنوان ورودی دریافت و بازده روز بعد آن سهم را پیش‌بینی می‌کنند. تمامی ابرپارامترهای این مدل‌ها طی یک فرآیند آزمون و خطا بهینه‌سازی شده‌اند.

در ادامه از داده‌های ۴۴۱ روز منتهی به مارس ۲۰۲۰ برای آموزش و تست مدل پیش‌بینی کارایی سبد استفاده شده است. با این توضیح که به ترتیب داده‌های ۱۲۰ روز برای ساخت ماتریس کوواریانس، ۱۴۹ روز برای آموزش شبکه عصبی، ۵۰ روز به‌عنوان داده اعتبارسنجی و ۱۲۲ روز برای تست مدل پیشنهادی به‌کار رفته‌اند. در این مقاله تعداد سهام‌های سبد (k) را برابر ۷ و طول بازه موردنیاز برای محاسبه خطای پیش‌بینی مدل‌ها (m) را برابر ۲۰ در نظر گرفته‌ایم.

برای آموزش شبکه *Per-Learner* به‌ازای هر روز آموزش، ۱۰۰۰ سبد شدنی تولید کردیم و براساس مقادیر بازده واقعی هر یک از این سبدها مدل را آموزش دادیم. برای تست مدل هم به‌ازای هر روز ۱۰۰۰ سبد تصادفی تولید کرده و سبد بهینه را از میان آن‌ها تعیین کردیم. در این پژوهش در تمامی مدل‌های مبتنی بر شبکه عصبی از مکانیزم *earlystopping* برای جلوگیری از بیش‌برازش مدل‌ها استفاده شده است.

۴-۱- مقایسه مدل پیشنهادی با مدل‌های موجود

برای سنجش توانایی مدل پیشنهادی در تخصیص وزن مناسب به سهام‌های سبد، کارایی وزن‌دهی مدل را علاوه بر وزن یکسان ($Eq-w$) و وزن‌دهی براساس میانگین واریانس با سبدهای تنظیم‌شده براساس وزن‌دهی میانگین واریانس بهبودیافته ($MVPE$) معرفی شده در مقاله [6] که مجموع بازده پیش‌بینی شده و متوسط خطای پیش‌بینی مدل را به‌عنوان بازده مورد انتظار هر سهم دریافت می‌کند، مقایسه کرده‌ایم. هم‌چنین مدل‌های ساخت سبد معرفی شده در مقالات [14] و [15] را نیز به‌عنوان رقبای *Per-Learner* در نظر گرفتیم.



۱. مقاله [14] یک مکانیزم تخصیص سرمایه بر اساس الگوریتم خوشه‌بندی k -medioids ارائه داده است. در این مکانیزم بسته به این که در ابتدا مراکز خوشه را به صورت تصادفی یا ابتکاری مقداردهی کند، در دو نسخه $AAPC-R$ و $AAPC-H$ در نظر گرفته شده است. در این مدل برای تقسیم سرمایه میان خوشه‌ها و سهم‌های درون هر خوشه از دوروش تخصیص فازی و تخصیص مبتنی بر کارایی ارائه شده است.
۲. مقاله [15] یک روش جدید انتخاب سبد سهام مبتنی بر الگوریتم تکاملی موسوم به $ARMOPSO$ با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات^۲ ارائه داده است که می‌تواند محدودیت‌های متعددی را در فرآیند انتخاب سبد بهینه در نظر بگیرد و باتوجه به این که در روش ما محدودیت تعداد سهام لحاظ می‌شود این الگوریتم نیز به‌عنوان یکی از رقبا برگزیده شده است.

برای اطمینان از نتایج مدل‌های مختلف، ۱۰۰ دور مدل‌های بهینه‌سازی را به‌ازای پیش‌بینی‌های هر مدل پیش‌بینی سهم اجرا کردیم. در نهایت میانگین نتایج تمام دوره‌ها به‌عنوان نتیجه‌نهایی گزارش شده است. جدول ۳ مقادیر درصد بازده تجمعی، انحراف معیار، نرخ شارپ، نرخ امگا و ماکسیمم ضرر همه مدل‌های تنظیم سبد را در ۱۰۰ تست انجام‌شده نشان می‌دهند.

۵- نتایج و یافته‌های پژوهش

همان‌طور که پیش‌تر اشاره کردیم، موفقیت یک سبد علاوه بر انتخاب سهام مناسب برای سبد به نحوه تخصیص سرمایه میان سهم‌های آن نیز بستگی دارد. به‌عنوان مثال در جدول ۱، با استفاده از مدل پیش‌بینی بازده سهم RF برای یک روز تصادفی از بازه تست، ۷ سهم TXN ، $CSCO$ ، $NFLX$ ، $AAPL$ ، ACN ، VZ و WCF را که بالاترین بازده پیش‌بینی شده را داشتند برای قرارگیری در سبد انتخاب کردیم و وزنی که هر یک از روش‌های تخصیص وزن به سهام منتخب نسبت داده‌اند را نشان دادیم. همان‌طور که مشخص است بازده سبد شامل این ۷ سهم ($Portfolio\ return$)، به‌ازای تخصیص‌های مختلف، تفاوت چشمگیری دارد. این که صرفاً براساس پیش‌بینی‌های یک مدل به هر یک از سهم‌های سبد وزن تخصیص دهیم عملاً باعث به خطر افتادن سرمایه می‌شود چراکه هر پیش‌بینی یک خطایی دارد و این خطا روی بازده نهایی اثرگذار است. براساس مدل RF ، هر ۷ سهم سبد برای روز آتی بازده مثبت خواهند داشت؛ اما بازده واقعی ($Actual\ Return$) این ۷ سهم نشان می‌دهد که عملاً پیش‌بینی RF محقق نشده است و بازده سهم اِپل منفی بوده است. به‌همین دلیل بازده روش‌های هم‌وزن ($Eq-w$) و میانگین واریانس که در تصمیم‌گیری تا حد زیادی به مقدار بازده پیش‌بینی شده متکی هستند از روش $Per-Learner$ کم‌تر است. همان‌طور که از جدول ۱ پیداست $Per-Learner$ باتوجه به سایر ویژگی‌های سهم اِپل توانسته تشخیص دهد که این سهم بایستی وزن کم‌تری در مقایسه با سایر سهم‌ها داشته باشد. جدول ۱، وزن تخصیص‌یافته به هر سهم سبد را به‌ازای سه روش تخصیص وزن مختلف نشان می‌دهد.

جدول ۱- مقایسه‌ی تغییرات بازده یک سبد معین به‌ازای روش‌های مختلف تخصیص وزن.

Table 1- Comparison of portfolio return changes for changes in weighting method.

Portfolio Stock Names	TXN	CSCO	NFLX	AAPL	VZ	ACN	WFC		
Actual Return	0.024	0.017	0.011	-0.010	0.013	0.009	0.002	Portfolio return	
Method	Per_Learner	0.147	0.484	0.122	0.013	0.055	0.088	0.092	0.014
	Eq-w	0.143	0.143	0.143	0.143	0.143	0.143	0.143	0.009
	MV	0.158	0.051	0.022	0.171	0.095	0.496	0.007	0.009

جدول ۲ میزان متوسط بازده ماهیانه سبدهای پیشنهادی چارچوب $Per-Learner$ را به‌ازای مدل‌های مختلف پیش‌بینی بازده سهم در مقایسه با سایر روش‌های تخصیص وزن نشان می‌دهد. برای هرروز تست ۷ سهمی که بالاترین بازده پیش‌بینی شده را دارا هستند برای قرارگیری در سبد انتخاب می‌شوند. همان‌طور که مشخص است این چارچوب مستقل از کیفیت مدل پیش‌بینی بازده سهم، از نظر متوسط بازدهی ماهیانه عملکرد بهتری در مقایسه با روش‌های هم‌وزن ($Eq-w$) و میانگین واریانس سنتی (MVP) و میانگین واریانس بهبودیافته دارد. هر چه مدل پیش‌بینی بازده سهم عملکرد بهتری در تشخیص سهام مناسب داشته باشد، بازده سبد تنظیم‌شده توسط $Per-Learner$ افزایش خواهد یافت. همان‌طور که مشخص است چارچوبی که از $LSTM$ برای پیش‌بینی بازده سهام استفاده می‌کند، در مقایسه با سایر مدل‌ها سودآورتر ظاهر شده است، احتمالاً $LSTM$ به‌دلیل دارا بودن حافظه در تشخیص الگوهای زمانی بازده یک سهم موفق‌تر است در نتیجه با دقت بالاتری بازده هر سهم را پیش‌بینی می‌کند؛ بنابراین، در مقایسه با سایر روش‌ها سهم‌های بهتری را برای سبد انتخاب می‌کند.

¹ Adaptive Ranking Multi-Objective Particle Swarm Optimization (ARMOPSO)

² Particle Swarm Optimization (PSO)

Table 2- Comparison of per-learner portfolios returns for different stock return prediction models.

Stock Selection Model	Stock Weighting Model			
	Eq-w	MVPE	MVP	Per-Learner
Per-learner CNN	4.018	9.441	-0.667	13.96
Per-learner LSTM	8.958	4.923	9.441	26.427
Per-learner RF	13.107	9.012	15.322	16.427
Per-learner DNN	4.093	6.066	10.404	23.536

جدول ۳ کارایی Per-Learner مبتنی بر مدل LSTM را براساس معیارهای مختلفی نظیر درصد بازده تجمعی^۱، انحراف معیار^۲، نرخ شارپ^۳، نرخ امگا^۴ و ماکسیم ضرر^۵ در مقایسه با سایر رقبا نشان می دهد. مطابق این نتایج از نظر میزان کارایی Per-Learner از مدل هایی نظیر ARMOPSO و AAPC-H که از پیش بینی بازده برای انتخاب سهام استفاده نمی کنند عملکرد بهتری دارد. مقایسه مقادیر نرخ شارپ و نرخ امگای همه مدل ها بیانگر این است که بازده بالاتر Per-Learner به دلیل سرمایه گذاری پرریسک تر نبوده است؛ یعنی پذیرش ریسک بالاتر موجب این بازده بالاتر نشده است بلکه انتخاب مناسب سهام سبد و تخصیص کارآمد سرمایه میان آن ها منجر به سود بالاتر شده است. ترکیب Per-Learner با مکانیزم انتخاب سهم LSTM نسبت شارپ ایده آلی را نشان می دهد، یعنی سرمایه گذار به ازای هر واحد ریسکی که متحمل شده، بیش از ۲/۵ برابر سود کرده است و این به معنای انتخاب مناسب سهام و تخصیص کارآمد سرمایه میان آن هاست.

جدول ۳- کارایی Per-learner و سایر روش های ساخت سبد سهام.

Table 3- Performance of per-learner and other portfolio formation methods.

Model	AR%	SD	SR	OR	MDD%
Per-Learner-Istm	26.472	0.016	2.521	1.503	4.53
AABPC 1	11.357	0.029	0.756	1.588	1.86
AABPC 2	17.362	0.031	1.064	4.195	0.571
ARMOPSO	19.028	0.012	2.545	1.368	12.421
S&P500	3.744	0.009	0.657	1.437	12.031

۶- نتیجه گیری و کارهای آتی

در این مقاله یک مدل دو مرحله ای مبتنی بر یادگیری ماشین برای انتخاب و بهینه سازی سبد سهام براساس پیش بینی بازده سهم و پیش بینی بازده سبد معرفی کردیم. نتایج به وضوح تاییدکننده اثرگذاری یادگیری روی افزایش کارایی تصمیمات سرمایه گذاری است. در واقع یادگیری ماشین امکان انطباق مدل را با شرایط فراهم می کند در نتیجه تصمیمات با هوشمندی بیش تر اتخاذ می شوند و نهایتاً کارایی بیش تری محقق می کنند و این دقیقاً همان نکته ای است که در مدل های مرسوم بهینه سازی نادیده گرفته شده است.

مشاهده شد که مدل های مختلف یادگیری می توانند نتایج مختلفی را در یک چارچوب تصمیم گیری یکسان داشته باشند؛ بنابراین، انتخاب مکانیزم یادگیری مناسب و ویژگی های موثر در تصمیم گیری اهمیت زیادی دارد و ارزش بررسی بیش تر دارد. هم چنین توسعه مدل به نحوی که بتواند تعداد سهام های سبد را براساس شرایط روز بازار تعیین کند یا تعداد معاملات را کنترل کند می تواند موضوع مطالعات آتی باشد. توسعه مدل بهینه سازی سبد به صورت یکپارچه برای کاهش اثر انتشار خطای مدل پیش بینی بازده سهم در مدل بهینه سازی وزن سبد و کاهش ریسک تصمیم گیری دیگر مسیری است که می تواند در ادامه کار پی گرفته شود.

¹ Abnormal Return (AR)

² Standard Deviation (SD)

³ Sharpe Ratio (SR)

⁴ Omega Rate (OR)

⁵ Maximum Damage (MDD)





- [1] Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural networks*, 18(5), 602–610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- [2] Wang, W., Li, W., Zhang, N., & Liu, K. (2020). Portfolio formation with preselection using deep learning from long-term financial data. *Expert systems with applications*, 143, 113042. <https://doi.org/10.1016/j.eswa.2019.113042>
- [3] 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>
- [4] Hoseinzade, E., & Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert systems with applications*, 129, 273–285. <https://doi.org/10.1016/j.eswa.2019.03.029>
- [5] Lee, S. II, & Yoo, S. J. (2020). Threshold-based portfolio: the role of the threshold and its applications. *The journal of supercomputing*, 76(10), 8040–8057. DOI:10.1007/s11227-018-2577-1
- [6] Yu, J. R., Paul Chiou, W. J., Lee, W. Y., & Lin, S. J. (2020). Portfolio models with return forecasting and transaction costs. *International review of economics and finance*, 66, 118–130. <https://doi.org/10.1016/j.iref.2019.11.002>
- [7] Chen, W., Zhang, H., Mehlawat, M. K., & Jia, L. (2021). Mean–variance portfolio optimization using machine learning-based stock price prediction. *Applied soft computing*, 100, 106943. DOI:<https://doi.org/10.1016/j.asoc.2020.106943>
- [8] Ta, V. D., Liu, C. M., & Tadesse, D. A. (2020). Portfolio optimization-based stock prediction using long-short term memory network in quantitative trading. *Applied sciences*, 10(2), 437.
- [9] Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European journal of operational research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- [10] Yang, F., Chen, Z., Li, J., & Tang, L. (2019). A novel hybrid stock selection method with stock prediction. *Applied soft computing*, 80, 820–831. DOI:<https://doi.org/10.1016/j.asoc.2019.03.028>
- [11] Markowitz, H. M., & Todd, G. P. (2000). *Mean-variance analysis in portfolio choice and capital markets* (Vol. 66). John Wiley & Sons.
- [12] Paiva, F. D., Cardoso, R. T. N., Hanaoka, G. P., & Duarte, W. M. (2019). Decision-making for financial trading: a fusion approach of machine learning and portfolio selection. *Expert systems with applications*, 115, 635–655. <https://doi.org/10.1016/j.eswa.2018.08.003>
- [13] Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert systems with applications*, 165, 113973. <https://doi.org/10.1016/j.eswa.2020.113973>
- [14] Duarte, F. G., & De Castro, L. N. (2020). A framework to perform asset allocation based on partitional clustering. *IEEE access*, 8, 110775–110788. DOI:10.1109/ACCESS.2020.3001944
- [15] Silva, Y. L. T. V, Herthel, A. B., & Subramanian, A. (2019). A multi-objective evolutionary algorithm for a class of mean-variance portfolio selection problems. *Expert systems with applications*, 133, 225–241. <https://doi.org/10.1016/j.eswa.2019.05.018>

جدول ۱ اسامی ۴۹ سهم به کاررفته در این پژوهش را در بر دارد.

جدول ۱- اسامی سهم‌های موجود در مجموعه داده این پژوهش.

Table 1- The names of the stocks in the data set of this research.

AAPL	NVDA	BAC	ABT	PFE	LLY	DHR
MSFT	V	INTC	XOM	KO	TXN	WFC
AMZN	DIS	NFLX	T	MRK	QCOM	UNP
GOOGL	PG	CMCSA	WMT	PEP	MDT	C
GOOG	UNH	VZ	TMO	CVX	MCD	MS
JPM	HD	ADBE	CSCO	NKE	NEE	HON
JNJ	MA	CRM	AVGO	ACN	COST	UPS



۵۳۹