

Paper Type: Original Article



Portfolio Selection for Neural Network Using Energy Networks in Tehran Stock Exchange

Seyyed Mohammad Hadji Molana*

Department of Industrial Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran;
Molana.m@gmail.com.

Citation:



Hadji Molana, S. M. (2024). Portfolio selection for neural network using energy networks in Tehran Stock Exchange. *Financial and banking strategic studies*, 2(3), 220-231.

Received: 10/05/2024

Reviewed: 27/07/2024

Revised: 08/09/2024

Accepted: 30/10/2024

Abstract

Purpose: Optimization problems are one of the most interesting, important, and popular fields of financial mathematics. A better portfolio optimization model can help investors earn more sustainable profits. The existing literature shows that traditional mean-variance portfolio strategies are not suitable. To address this issue, this study uses a multilayer perceptron neural network and a convolutional neural network to predict future stock price movements.

Methodology: We compare the prediction accuracy of these two methods and use the outputs from the higher-accuracy method in the proposed model. Then, given the future direction of stock prices, we propose an efficient stock selection scheme for investors. We also test the proposed stock selection scheme and investment strategies using the components of the Tehran Stock Exchange index as test cases.

Findings: The experimental results show that the proposed stock selection scheme can effectively improve the performance of all investment strategies. In addition, the proposed investment strategy outperforms the traditional minimum global variance investment strategy.

Originality/Value: This research provides an innovative framework for portfolio selection based on deep learning networks. These networks are key to improving investment efficiency, risk management, and decision-making in the Iranian capital market and serve as an advanced model for similar markets.

Keywords: Artificial neural network, Portfolio selection, Deep learning.



Corresponding Author: molana.m@gmail.com



10.22105/fbs.2024.214339



Licensee. **Financial and Banking Strategic Studies**. 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>).



انتخاب پرتفوی مبتنی بر شبکه‌عصبی مصنوعی با استفاده از شبکه یادگیری عمیق در بورس اوراق بهادار تهران

سید محمد حاجی مولانا*

گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده

هدف: مسایل بهینه‌سازی یکی از زمینه‌های جالب، مهم و پرطرفدار در ریاضیات مالی هستند. مدل بهتر بهینه‌سازی سبد سهام می‌تواند به سرمایه‌گذاران کمک کند تا سود پایدارتری کسب کنند. ادبیات موجود نشان می‌دهد که عملکرد استراتژی‌های سنتی پرتفوی میانگین-واریانس مناسب نیست. برای پرداختن به این موضوع، در این مطالعه از شبکه‌عصبی پرسپترون چندلایه و شبکه‌عصبی کانولوشن برای پیش‌بینی جهت آتی قیمت سهام استفاده شده است.

روش‌شناسی پژوهش: دقت پیش‌بینی این دو روش با یکدیگر مقایسه می‌شود و خروجی‌های هر روشی که دارای دقت بالاتری بود، وارد مدل پیشنهادی می‌گردند. سپس با در اختیار داشتن جهت آتی قیمت سهام، یک طرح انتخاب سهام کارآمد برای سرمایه‌گذاران پیشنهاد می‌دهیم. همچنین یک آزمون بر روی طرح انتخاب سهام پیشنهادی و استراتژی‌های سرمایه‌گذاری انجام می‌دهیم که در آن اجزای شاخص بورس اوراق بهادار تهران به‌عنوان نمونه‌های آزمایشی انتخاب می‌شوند.

یافته‌ها: نتایج تجربی نشان می‌دهد که طرح انتخاب سهام پیشنهادی می‌تواند به‌طور موثر عملکرد همه استراتژی‌های سرمایه‌گذاری را بهبود بخشد. علاوه بر این، استراتژی سرمایه‌گذاری پیشنهادی در مقایسه با استراتژی سرمایه‌گذاری حداقل واریانس سراسری سنتی عملکرد بهتری دارد.

اصالت/ارزش افزوده علمی: این پژوهش با ارایه چارچوبی نوآورانه برای انتخاب پرتفوی مبتنی بر شبکه‌های یادگیری عمیق، نقشی کلیدی در افزایش کارایی سرمایه‌گذاری، مدیریت ریسک و بهبود تصمیم‌گیری در بازار سرمایه ایران ایفا می‌کند و الگویی پیشرفته برای سایر بازارهای مشابه فراهم می‌نماید.

کلیدواژه‌ها: شبکه‌عصبی مصنوعی، انتخاب پرتفوی، یادگیری عمیق.

۱- مقدمه

از زمان نظریه کلاسیک پرتفوی میانگین-واریانس ارابه شده توسط مارکوویتز [1]، بهینه‌سازی پرتفوی یکی از کانون‌های تحقیقاتی مهم در زمینه مالی بوده است. این پژوهش بر چگونگی تخصیص ثروت سرمایه‌گذاران بین دارایی‌های مختلف و توسعه یک استراتژی سرمایه‌گذاری موثر برای سرمایه‌گذاران متمرکز است. به بیان دقیق، یک مساله سرمایه‌گذاری کامل شامل دو فرآیند است: ۱- انتخاب سهام و ۲- وزن‌دهی سرمایه‌گذاری. اولین فرآیند شامل تجزیه و تحلیل عملکرد جامع دارایی‌های جایگزین (مانند چشم‌انداز صنعت، وضعیت مالی شرکت، عملکرد تاریخی، شرایط بازار و...) سپس شناسایی دارایی‌های سرمایه‌گذاری به‌عنوان زیربنای پرتفوی‌ها است. فرآیند دوم را می‌توان به‌عنوان یک مساله بهینه‌سازی (به‌عنوان مثال، به حداقل رساندن ریسک پرتفوی برای یک بازده مورد انتظار معین یا به حداکثر رساندن بازده مورد انتظار برای یک ریسک پرتفوی معین) که

هدف آن تامین سرمایه‌گذاران با وزن سرمایه‌گذاری موثر است، در نظر گرفت. مدل مارکوویتز به‌عنوان آغاز نظریه مدرن پرتفوی، ابتدا یک راه حل کارآمد برای تبادل بین پیشینه‌سازی بازده مورد انتظار و کمینه‌سازی ریسک ارائه می‌دهد. این مدل‌های کلاسیک پرتفوی معمولاً از میانگین بازده سهام تاریخی به‌عنوان بازده مورد انتظار استفاده می‌کنند که برای سرمایه‌گذاری بلندمدت در بازار سهام مناسب است؛ اما برای سرمایه‌گذاری کوتاه‌مدت، این مدل‌ها ممکن است مناسب نباشند.

با این حال، مطالعات موجود عمدتاً عملکرد گذشته سهام را در نظر می‌گیرند و روند آتی قیمت سهام را در نظر نمی‌گیرند. شبکه‌های عصبی مصنوعی به‌عنوان رویکردی که ایده اصلی آن‌ها تا حدودی الهام گرفته از شیوه کارکرد سیستم عصبی زیستی برای پردازش داده‌ها و اطلاعات است، توسط ورودی‌ها آموزش داده می‌شوند و شامل سه لایه ورودی، لایه پنهان و لایه خروجی هستند و هر کدام از عصب‌ها دارای مقدار آستانه و تابع فعال‌سازی می‌باشند که به ما خروجی می‌دهند. شبکه‌های عصبی مصنوعی^۱ در واقع دسته‌ای الگوریتم هستند که برای شناسایی و تشخیص الگوها به کار می‌روند. یادگیری عمیق در واقع یادگیری به‌وسیله شبکه‌های عصبی است که دارای لایه‌های پنهانی زیاد می‌باشند. الگوریتم یادگیری عمیق درست مانند مغز انسان با هر بار تکرار یک کار تجربه کسب می‌کند. ایده ساخت این مفهوم مشابه ساختارهایی است که توسط مغز انسان استفاده می‌شوند. این الگوریتم‌ها از انواع دیگر الگوریتم‌های یادگیری ماشین پیشی می‌گیرند. هرچه تعداد لایه‌ها و عصب‌ها در هر لایه پنهان بیشتر باشند مدل پیچیده‌تر می‌شود.

این شبکه‌های عصبی که شامل بیشتر از سه لایه از عصب‌های لایه‌های ورودی و خروجی اند، به آن‌ها شبکه‌عصبی عمیق گفته می‌شود و به یادگیری آن‌ها یادگیری عمیق گفته می‌شود که به‌وسیله این شبکه‌های عصبی عمیق، مسایل بسیار پیچیده در زمینه پیش‌بینی و دسته‌بندی به مسایل ساده تبدیل و حل می‌شوند. با توجه به تعداد بالای سهامداران و حجم بالای نقدینگی در بازار سرمایه، آگاهی نسبت به وضعیت آینده سهام به‌منظور دانستن بهترین زمان انجام معامله، چگونگی شناسایی سهام قابل سرمایه‌گذاری در بازار سرمایه با تعداد زیادی دارایی و چگونگی ایجاد یک پرتفوی موثر برای سرمایه‌گذاران از موضوعات کلیدی هستند که باید به آن‌ها پرداخته شود.

با توجه به موارد فوق هدف اصلی این تحقیق، انتخاب پرتفوی مبتنی بر شبکه‌عصبی مصنوعی با استفاده از شبکه یادگیری عمیق خواهد بود. به‌منظور رسیدن به هدف مطرح شده ابتدا از شبکه‌عصبی عمیق برای پیش‌بینی جهت آتی قیمت تعدادی سهام از بازار بورس اوراق بهادار تهران استفاده می‌کنیم. سپس طرح انتخاب سهام پیشنهادی و حرکات قیمت سهام به‌دست آمده را برای ساخت مدل بهینه‌سازی پرتفوی ترکیب می‌کنیم و سپس یک استراتژی سرمایه‌گذاری موثر برای سرمایه‌گذاران ارائه می‌کنیم.

۲- مبانی نظری و پیشینه پژوهش

مارکوویتز [1] پیشنهاد کرد که تخم‌مغ‌های خود را در یک سبد قرار ندهید، یعنی سرمایه‌گذاران باید سرمایه‌گذاری‌های خود را تا حد امکان متنوع کنند تا ریسک سرمایه‌گذاری را کاهش دهند. با این حال، در فرآیند سرمایه‌گذاری واقعی، اگر پرتفوی بیش‌ازحد متنوع باشد، سرمایه‌گذاران باید هزینه‌های تراکنش بیشتری را بپردازند و استراتژی سرمایه‌گذاری پیشنهادی نیز لزوماً در عمل بهینه نیست. برای حل این مشکل، کینز و همکاران [2] استدلال کردند که سرمایه‌گذاران باید ثروت خود را در تعداد کمی از سهام با ارزش سرمایه‌گذاری، متمرکز کنند و در نتیجه تنوع پرتفوی‌ها را کاهش دهند. این استراتژی سرمایه‌گذاری به‌عنوان استراتژی کم‌تنوع نیز نامیده می‌شود. از آن زمان، مساله عدم تنوع پرتفوی‌ها به‌طور گسترده مورد مطالعه قرار گرفته است [3-9].

با این حال، مطالعات فوق عملکرد گذشته سهام را در نظر می‌گیرند و روند آتی قیمت سهام را در نظر نمی‌گیرند؛ بنابراین، چگونگی شناسایی سهام قابل سرمایه‌گذاری در بازار اوراق بهادار با تعداد زیادی دارایی و چگونگی ایجاد یک پرتفوی موثر برای سرمایه‌گذاران نیز موضوعات کلیدی هستند که در این مقاله باید به آن‌ها پرداخته شود. فکر استفاده از شبکه‌های عصبی در پیش‌بینی‌های اقتصادی اولین بار در سال توسط هالبرت وایت [10] مطرح شد. این تحقیق سعی در کشف نظم نهفته در قیمت‌های تاریخی دارایی‌های سرمایه‌ای داشت. به این منظور بازده روزانه سهام شرکت آبی

¹ Artificial Neural Networks (ANNs)

ام به‌عنوان یک مورد خاص مورد استفاده قرار گرفت و نقش روش‌های استنباط آماری و روش‌های یادگیری در شبکه‌های عصبی به‌عنوان دو عنصر مکمل یکدیگر مطرح گردید. در تحقیق دیگر، تاکاهو یودا، آساکاوا و کیموتو [11] سیستم پیش‌بینی بازار سهامی را ارائه نمودند که در آن از استفاده شده بود. در این مطالعه ضمن شبکه‌عصبی مقایسه سیستم‌های خبره و سیستم‌های شبکه‌عصبی یادگیری غیرخطی شبکه‌های عصبی به‌عنوان توانایی بالای این شبکه‌ها برشمرده شده است. در زمینه پیش‌بینی قیمت و شاخص سهام در بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی تحقیقات ذیل انجام شده است که به اختصار به آن‌ها اشاره می‌شود. در رساله‌ای تحت عنوان مدل‌سازی غیرخطی و پیش‌بینی رفتار قیمت سهام در بازار بورس ایران یک مطالعه منظم بر مقوله پیش‌بینی و پیش‌بینی‌پذیری انجام شده است.

در بخش پیش‌بینی ابتدا از یک شبکه‌عصبی سه لایه با طرح ۱-۱۵-۵ برای پیش‌بینی قیمت روز بعد، بازده و شاخص کل قیمت بورس در سری زمانی‌های مربوطه استفاده شده است و برای سنجش عملکرد شبکه از معیار R^2 در مجموعه آزمایش استفاده شده است. این عدد برای سری قیمت روز بعد ۰/۹۹۷۹، بازده روز بعد ۰/۶۰۱۱ و شاخص قیمت بورس تهران ۰/۹۹۶۹ است. علاوه بر این برای پیش‌بینی سری زمانی قیمت در ۳۰ روز بعد از یک شبکه‌عصبی سه لایه با اتصالات برگشتی استفاده شده است که نتیجه $R^2 = 0.7876$ به‌دست آمده است. در تحقیقی دیگر تحت عنوان استفاده از شبکه‌های عصبی برای پیش‌بینی روند شاخص قیمت سهام در بورس اوراق بهادار تهران از یک شبکه پرسپترون با سه لایه به‌منظور پیش‌بینی شاخص کل بورس اوراق بهادار تهران استفاده شده است.

متغیرهای ورودی شامل متغیرهای برون‌زا یعنی قیمت طلا و قیمت دلار و متغیرهای درون‌زا یعنی حجم کل معاملات و خود شاخص بورس می‌باشند. در تحقیقی دیگر با عنوان پیش‌بینی بازده سهام در بورس اوراق بهادار تهران مدل شبکه‌های عصبی و مدل چندعاملی به پیش‌بینی‌پذیری رفتار بازده سهام در بورس اوراق بهادار تهران به‌وسیله مدل خطی عاملی شبکه‌های عصبی مصنوعی پرداخته شده که برای آزمون این مساله قیمت روزانه سهام شرکت توسعه صنایع بهشهر به‌عنوان نمونه انتخاب شده و متغیرهای مستقل ورودی پنج متغیر کلان اقتصادی یعنی شاخص کل قیمت و بورس تهران، نرخ ارز دلار در بازار آزاد و قیمت نفت قیمت طلا می‌باشد. در این تحقیق برای حل مدل خطی از نرم‌افزار *SPSS* و برای حل مدل شبکه‌های عصبی از نرم‌افزار *MATLAB* استفاده شده است که به مراتب شبکه خطای کمتری نسبت به مدل چند عملی در عصبی پیش‌بینی نمونه داشته است.

همچنین در تحقیق دیگری با عنوان مدل‌سازی پیش‌بینی قیمت سهام با استفاده از شبکه‌عصبی و مقایسه آن با روش‌های پیش‌بینی ریاضی محقق برای پیش‌بینی قیمت روزانه سهام متغیرهای ورودی مدل را آخرین قیمت، تعداد معاملات، میانگین قیمت، تعداد نفر، جمع معاملات پایین‌ترین و بالاترین قیمت روزانه و قیمت قبل در نظر گرفته است که در این تحقیق روش رگرسیون از خطای کمتری نسبت به شبکه‌عصبی و میانگین متحرک برخوردار بوده است.

۳- روش‌شناسی پژوهش

۳-۱- گردآوری منابع داده

در فرآیند انتخاب پرتفوی، روش موثر انتخاب سهام تا حد زیادی تعیین‌کننده موفقیت استراتژی سرمایه‌گذاری خواهد بود. در عمل، سرمایه‌گذاران معمولاً سهام را بر اساس عملکرد تاریخی آن‌ها بررسی می‌کنند. با این حال، برخی از پژوهشگران معتقدند که یک اوراق‌بهادار که در گذشته خوب عمل می‌کند لزوماً عملکرد خوب آن را در آینده تضمین نمی‌کند. در واقع، همبستگی بین عملکرد گذشته یک دارایی و عملکرد آتی آن به اثربخشی بازارهای مالی بستگی دارد. واضح است که داده‌های تاریخی معاملات سهام نمی‌توانند به‌طور کامل ارزش سرمایه‌گذاری آتی سهام را منعکس کنند. به این دلایل، برای ارزیابی ارزش سرمایه‌گذاری سهام، داده‌های چندگانه از سهام، از جمله داده‌های معاملاتی تاریخی و شاخص فنی را جمع‌آوری خواهیم کرد.

۳-۱-۱- داده‌های تاریخی معاملات

این مقاله داده‌های معاملات تاریخی روزانه سهام را جمع‌آوری می‌کند. اطلاعات جمع‌آوری شده شامل قیمت افتتاحیه، بالاترین قیمت، پایین‌ترین قیمت، قیمت بسته شدن و حجم معاملات می‌باشد. داده‌های معاملات تاریخی فوق می‌توانند عملکرد تاریخی سهام را منعکس کنند. همچنین می‌توانند راهنمایی استراتژیک متناظری را برای انتخاب سهام سرمایه‌گذاران تا حد معینی ارائه دهند.

۳-۱-۲- شاخص‌های فنی

علاوه بر داده‌های تاریخی معاملات، داده‌های شاخص فنی سهام نیز می‌تواند مرجعی برای انتخاب سهام باشد. با اشاره به کار [12]، [13] ما شاخص تصادفی KDJ ، شاخص قدرت نسبی^۱ و میانگین متحرک همگرایی و واگرایی^۲ را به‌عنوان شاخص‌های ارزیابی فنی انتخاب می‌کنیم. از فرمول محاسبه شاخص‌های فنی [14] می‌توانیم ارزش شاخص‌های فنی را بر اساس داده‌های معاملات تاریخی به‌دست آوریم. فرمول‌های محاسباتی به شرح زیر است.

میانگین متحرک همگرا-واگرا

این شاخص ارتباط بین دو EMA قیمت‌ها را نشان می‌دهد. این شاخص از تفاوت میانگین متحرک نمایی ۲۶ روزه سهم از میانگین متحرک نمایی ۱۲ روزه قیمت آن برآورد می‌شود. خط سیگنال که همان EMA ۹ روزه است، معیاری است که از مقایسه آن با $MACD$ فرصت‌های خرید و فروش شناسایی می‌گردند. بر این اساس حالت فروش زمانی است که $MACD$ زیر خط سیگنال قرار می‌گیرد. به‌طور مشابه، یک سیگنال خرید زمانی روی می‌دهد که $MACD$ بالای خط سیگنال قرار بگیرد. رابطه آن به شرح معادله (۱) است.

$$MACD = EMA [Stock Prices, 12] - EMA [Stock Prices, 26]. \quad (1)$$

شاخص قدرت نسبی

شاخص RSI مقدار بازده‌های اخیر سهام با زیان‌های اخیر آن را مورد مقایسه قرار می‌دهد و این اطلاعات را به عددی بین ۰ تا ۱۰۰ تبدیل می‌کند. این شاخص را می‌توان از معادله (۲) محاسبه نمود. اگر RSI از ۳۰ بیشتر شود سیگنال فروش و اگر از ۷۰ کمتر شود سیگنال خرید صادر می‌شود.

$$RSI = 100 - \frac{100}{1 + RS}. \quad (2)$$

$$RS = \frac{\text{متوسط بازده‌ها در } n \text{ روزی که قیمت پایانی بیشتر از قیمت پایانی روز قبل بوده است.}}{\text{متوسط زیان‌ها در } n \text{ روزی که قیمت پایانی کمتر از قیمت پایانی روز قبل بوده است.}}. \quad (3)$$

شاخص تصادفی KDJ

معمولاً برای تجزیه و تحلیل روندهای کوتاه‌مدت یا میان‌مدت بازار سهام استفاده می‌شود. از طریق تجزیه و تحلیل شاخص KDJ ، پژوهشگران می‌توانند روند قیمت سهام را پیش‌بینی کنند و از قدرت بازار احتیاط کنند. برای پیش‌بینی حرکت قیمت سهام، شاخص سریع K را در شاخص KDJ انتخاب می‌کنیم. شاخص KDJ دارای مقداری بین ۰ تا ۱۰۰ است. به‌طور کلی، مقدار بالای ۹۰ بیش‌ازحد خرید و زیر ۱۰ بیش‌ازحد فروخته می‌شود. فرمول محاسبه به شرح معادله (۴) است:

$$\%K = \left[\frac{\left(\text{کمترین قیمت} - \text{قیمت بسته شدن} \right)}{\left(\text{کمترین قیمت} - \text{بالاترین قیمت} \right)} \right] \times 100. \quad (4)$$

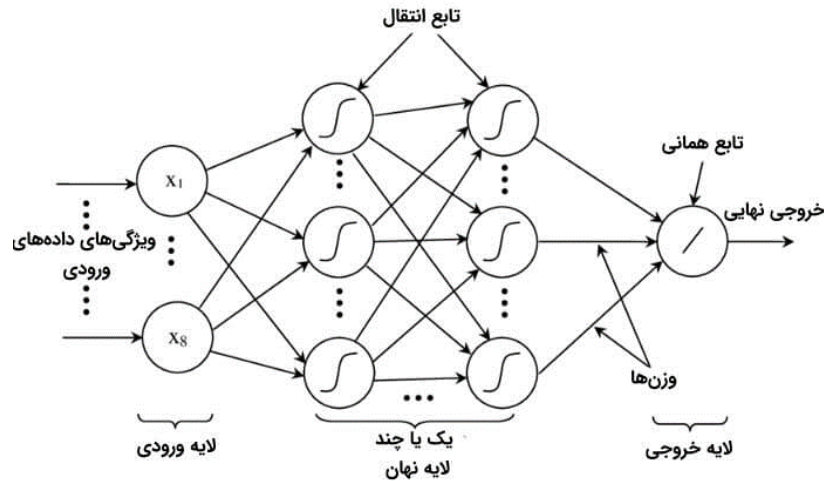
۳-۱-۳- پیش‌بینی حرکات آتی قیمت سهام

شبکه‌های عصبی پرسپترون، به‌ویژه پرسپترون چندلایه، در زمره کاربردی‌ترین شبکه‌های عصبی می‌باشند. شبکه عصبی چندلایه پرسپترون، ساختاری مشابه با ساختار مدل پرسپترون دارد اما تعداد لایه‌های پنهان آن بیش از یک لایه است. همچنین، این مدل نوعی شبکه پیش‌خور محسوب می‌شود.

¹ Relative Strength Index (RSI)

² Moving Average Convergence and Divergence (MACD)

تابع فعال‌ساز برای شبکه عصبی پرسپترون چندلایه که در این پژوهش مورد استفاده قرار می‌گیرد، برای سه لایه‌ی اول، تابع واحد یک‌سو شده خطی^۱ و برای لایه‌ی آخر، تابع سیگموئید می‌باشد. توابع فعال‌ساز در واقع مانند گیتی هستند که در هر نورون وجود دارد. ورودی این گیت همان ورودی‌های هر نورون در هر لایه است و خروجی آن به لایه‌ی بعدی منتقل می‌شود. تابع فعال‌ساز تصمیم می‌گیرد که هر نورون فعال شود یا خیر.



شکل ۱- شبکه عصبی پرسپترون چندلایه.
Figure 1- Multilayer perceptron neural network.

در این نوع از شبکه عصبی مصنوعی، از خروجی‌های لایه اول (ورودی)، به عنوان ورودی‌های لایه بعدی (پنهان) استفاده می‌شود؛ این کار به همین شکل ادامه پیدا می‌کند تا زمانی که پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه پنهان به عنوان ورودی‌های لایه خروجی مورد استفاده قرار می‌گیرد. همه لایه‌هایی که بین لایه ورودی و لایه خروجی قرار می‌گیرند، لایه‌های پنهان نامیده می‌شوند. شبکه‌های پرسپترون چندلایه، مانند شبکه‌های عصبی پرسپترون تک لایه، حاوی مجموعه‌ای از وزن‌ها نیز هستند که باید برای آموزش و یادگیری شبکه عصبی تنظیم شوند.

تعداد لایه‌های مطلوب برای شبکه عصبی پرسپترون چندلایه که در این تحقیق مورد استفاده قرار گرفته است، چهار لایه (یک لایه ورودی، دو لایه پنهان، یک لایه خروجی) با تعداد نرون‌های (۸-۲۰-۸-۱) می‌باشد. همچنین ساختار شبکه عصبی کانولوشن شامل ۸ نرون در لایه اول، ۴ نرون در لایه دوم ۱۵ نرون در لایه سوم، ۲۰ نرون در لایه چهارم، ۸ نرون در لایه پنجم و ۱ نرون در لایه آخر است. در این پژوهش، ما طرح انتخاب سهام پیشنهادی و حرکات قیمت سهام به دست آمده را برای ساخت مدل بهینه‌سازی پرتفوی ترکیب می‌کنیم و سپس یک استراتژی سرمایه‌گذاری موثر برای سرمایه‌گذاران ارائه می‌نماییم. به طور خاص، مدل بهینه‌سازی پرتفوی پیشنهادی را می‌توان به صورت مدل (۱۵) بیان کرد.

$$\begin{aligned} \min_x \quad & x' \Omega_n x - \phi \times x' f_n^i, \\ \text{s. t.} \quad & \sum_{i=1}^n z_i = k, \\ & \sum_{i=1}^n x_i = 1, \\ & l_i z_i \leq x_i \leq u_i z_i, \quad (i = 1, 2, \dots, n), \\ & z_i \in [0, 1], \quad (i = 1, 2, \dots, n), \\ & x_i \geq 0 \quad (i = 1, 2, \dots, n). \end{aligned} \quad (5)$$

در اینجا، $f_n^i = (f_n^1, f_n^2, \dots, f_n^n)'$ بردار پیش‌بینی شده قیمت سهام را نشان می‌دهد. علاوه بر این، f_n^i یک متغیر $1-0$ است، که در آن $f_n^i = 1$ نشان می‌دهد که قیمت سهام در آینده کاهش نخواهد یافت و $f_n^i = 0$ نشان می‌دهد که قیمت سهام در آینده کاهش می‌یابد، $i = 1, 2, \dots, n$. ضریب ϕ

¹ Rectified Linear Unit (ReLU)

² Hidden layers

یک پارامتر از پیش تعیین شده است که می‌تواند به‌عنوان پارامتر معاوضه بین به حداکثر رساندن شاخص پیش‌بینی قیمت سهام و به حداقل رساندن واریانس بازده پرتفوی در نظر گرفته شود. عدد k تعداد سهام موجود در پرتفوی می‌باشد که بیانگر محدودیت کاردینال است. پارامترهای l_i و u_i به ترتیب کف و سقف هر سهم در پرتفوی می‌باشد.

مدل‌های بهینه‌سازی پرتفوی موجود معمولاً بر اساس بازده دارایی برای ایجاد هدف بهینه‌سازی هستند و سپس از بازده تاریخی دارایی‌های اساسی برای تخمین پارامترهای ورودی موردنیاز برای هدف بهینه‌سازی استفاده می‌کنند. با این حال، در واقع، ویژگی‌های آماری بازده‌های تاریخی دارایی ممکن است در آینده نتوانند آن‌ها را به‌دست آورند که باعث می‌شود عملکرد استراتژی سرمایه‌گذاری حاصل رضایت‌بخش نباشد [15-18]. از جمله محدودیت‌های کاربردی در بهینه‌سازی سبد سرمایه‌گذاری می‌توان به حداقل یا حداکثر کردن میزان سرمایه‌گذاری در یک دارایی اشاره نمود که توسط بیل و فارست به مدل اولیه مارکوویتز اضافه شد [19]. با توجه به تمایل سرمایه‌گذاران به در اختیار داشتن و مدیریت سبدهای سهام که تعداد محدودتری از دارایی‌ها را در خود جای داده باشد، محدودیت دیگری تحت عنوان محدودیت کاردینالیته به مدل اضافه شد.

برای نشان دادن اعتبار استراتژی سرمایه‌گذاری پیشنهادی، استراتژی حداقل واریانس سراسری کلاسیک را برای مقایسه ارایه می‌کنیم. برای این منظور، ابتدا فرض می‌کنیم که سرمایه‌گذاران شاخص‌های پیش‌بینی قیمت سهام را در نظر نمی‌گیرند و فقط نگران واریانس بازده پرتفوی هستند و سپس می‌توان مدل بهینه‌سازی پرتفوی حداقل واریانس سراسری متناظر را به‌صورت مدل (۱۶) ساخت.

$$\begin{aligned} \min_x x' \Omega_n x, \\ \text{s. t. } \sum_{i=1}^n z_i = k, \\ \sum_{i=1}^n x_i = 1, \\ l_i z_i \leq x_i \leq u_i z_i, \quad (i = 1, 2, \dots, n), \\ z_i \in [0, 1], \quad (i = 1, 2, \dots, n), \\ x_i \geq 0, \quad (i = 1, 2, \dots, n). \end{aligned} \quad (6)$$

برخی از شاخص‌های ارزیابی کلاسیک (مانند نسبت شارپ و نسبت سورتینو) را برای اندازه‌گیری بازده پرتفوی اعمال می‌کنیم و سپس تفاوت در عملکرد استراتژی‌های سرمایه‌گذاری مختلف را بررسی می‌کنیم.

اجازه دهید دنباله بازده پرتفوی به‌دست آمده از یک استراتژی سرمایه‌گذاری مشخص، یک متغیر تصادفی r_p باشد، سپس نسبت شارپ و نسبت سورتینو مربوط به بازده پرتفوی را می‌توان به ترتیب به‌صورت معادله‌های (۷) و (۸) بیان کرد.

$$\theta_{Sharpe} = \frac{\bar{E}(r_p) - r_f}{\sqrt{\text{Var}(r_p)}} \quad (7)$$

$$\theta_{Sortino} = \frac{\bar{E}(r_p) - r_f}{\sqrt{\bar{E}[(r_p - \bar{E}(r_p))^2]}} \quad (8)$$

در اینجا $\bar{E}(\cdot)$ و $\text{Var}(\cdot)$ به ترتیب میانگین نمونه و واریانس نمونه را نشان می‌دهند. توجه داشته باشید از آنجایی که افق سرمایه‌گذاری کوتاه است، نرخ بدون ریسک را صفر فرض می‌کنیم.

۴- تجزیه و تحلیل داده‌ها

در این پژوهش داده‌های جمع‌آوری شده، متعلق به ۶۰ شرکت پذیرفته‌شده در سازمان بورس و اوراق بهادار تهران از ۱۹ صنعت مختلف است که در حواصل شهریورماه ۱۴۰۰ تا آبان‌ماه ۱۴۰۱ اخذ و تحلیل شده‌اند.

برای انتخاب مجموعه سهام، معیارهای زیر اعمال شده است:

۱. شرکت قبل از سال ۱۴۰۰ در بورس اوراق بهادار تهران پذیرفته شده باشد و نام آن تا پایان آبان ماه ۱۴۰۱ از فهرست شرکت‌های یادشده حذف نشده باشد.
۲. سال مالی آن‌ها به پایان اسفندماه هر سال منتهی شود.
۳. در دوره موردبررسی توقف نماد بیش از ۲ ماه نداشته باشند.
۴. اطلاعات آن‌ها کامل و در دسترس باشد.

سیستم عامل مربوط برای اجرای نرم‌افزارها ویندوز نسخه ۱۱ بوده و محاسبات توسط پردازشگر کامپیوتر قابل حمل ۸ هسته‌ای با فرکانس ۱/۸ گیگاهرتز و حافظه موقت ۸ گیگابایت صورت گرفته است. در ابتدا اطلاعات و داده‌های (X_s) مربوط به ۲۵۰ روز گذشته هر یک از این ۶۰ سهم، شامل بیشترین قیمت، کمترین قیمت، قیمت پایانی، حجم، قیمت بازگشایی و شاخص‌های KDJ ، RSI و $MACD$ به منظور یادگیری مدل شبکه عصبی مصنوعی جمع‌آوری، محاسبه و وارد مدل می‌شوند. پس از یادگیری مدل، برای پیش‌بینی Y روز معاملاتی ۱۴۰۱/۰۸/۱۱ توسط شبکه عصبی، ۸ ویژگی (X) هر یک از ۶۰ سهم برای آن روز جمع‌آوری و محاسبه شده‌اند.

نتایج پیش‌بینی در جداول زیر آورده شده است. در جدول ۱ میزان دقت، میانگین دقت و واریانس دقت پیش‌بینی توسط شبکه عصبی پرسپترون چندلایه برای هر یک از سهم‌ها قابل مشاهده است.

جدول ۱- تحلیل دقت جامعه مطالعاتی توسط شبکه عصبی MLP.

Table 1- Accuracy analysis of the study population by MLP neural network.

Variance	Mean	Accuracy	Row	Variance	Mean	Accuracy	Row
7.2	65.6	68.4	31	8.009993	66.8	68.8	1
8.236504	57.6	64.8	32	12.059850	63.6	65.2	2
8.158431	71.2	73.6	33	11.926441	64.4	68	3
7.155417	64	70.4	34	7.889233	68.4	73.6	4
10.77032	66	72	35	9.541488	59.6	63.6	5
6.311893	64.4	72.4	36	3.224903	66	71.6	6
8.009993	61.2	66	37	6.693280	68	72	7
8.049844	62	68	38	6.196773	60	67.2	8
4.543126	87.6	90	39	7.472616	68.4	71.6	9
3.666060	65.6	68.8	40	5.932958	68	72.4	10
8.541662	63.2	70	41	9.130169	70.8	75.6	11
6.511528	74	76.4	42	11.20714	70	72.8	12
8.845337	64.4	70.8	43	11.14271	63.2	64.4	13
9.303762	66.8	69.6	44	9.329523	66.4	70	14
5.440588	62	65.6	45	7.375635	64	68.8	15
9.666436	70.4	72.8	46	10	70	76	16
6.311893	68.4	68.4	47	10.11928	64	66.8	17
7.332121	64.8	68.8	48	8.625543	66	70	18
9.329523	61.6	70.4	49	9.499473	61.6	67.2	19
7.807688	69.2	73.2	50	5.782732	63.6	65.6	20
8.988882	66	69.6	51	6.209669	69.2	70.4	21
3.487119	56.8	63.6	52	8.009993	66.8	70.4	22
9.6	71.2	75.6	53	5.727128	74	77.6	23
10.15874	66	70.8	54	10.03194	71.6	72.8	24
7.418894	69.6	70.8	55	9.541488	64.4	70	25
7.641989	66	69.2	56	7.756287	68.8	70.4	26
9.666436	70.4	71.6	57	6.705221	69.2	71.2	27
10.03194	71.6	74	58	7.472616	79.6	84	28
9.260669	63.2	68.8	59	9.838699	70	71.2	29
7.641989	82	82.8	60	6.209669	65.2	66.8	30

در جدول ۲ میزان دقت، میانگین دقت و واریانس دقت پیش‌بینی توسط شبکه عصبی کانولوشن برای هر یک از سهم‌ها قابل مشاهده است.

جدول ۲- تحلیل دقت جامعه مطالعاتی توسط شبکه عصبی CNN.

Table 2- Accuracy analysis of the study population by CNN neural network.

Variance	Mean	Accuracy	Row	Variance	Mean	Accuracy	Row
10.735455	61.5	76	31	11.191514	61.5	74	1
13.047988	56.5	66	32	8.789197	60.5	70	2
9.3407708	65.5	74	33	12.25765	61.5	72	3
9.7979589	62	72	34	8.200609	64.5	78	4
12.083045	68	76	35	10.90871	54	68	5
11.357816	61	68	36	7.228416	59.5	74	6
5.9371710	63.5	66	37	8.660254	65	76	7
10.908712	64	70	38	10.53565	53	70	8
6.344288	86.5	96	39	8.944271	65	76	9
8.6023252	66	72	40	10.012492	68.5	72	10
8.8881944	61	72	41	5.590169	67.5	82	11
8.3066238	71	80	42	9.233092	66.5	68	12
9.7467943	60	72	43	10.908712	59	62	13
9	63	84	44	9.604686	65.5	74	14
8.7891979	60.5	76	45	7.889866	64.5	70	15
9.6046863	70.5	78	46	9	73	80	16
9.165151	59	76	47	11.357816	59	72	17
9.949874	59	76	48	14.705441	57.5	78	18
7.348469	61	78	49	9.759610	58.5	70	19
7.348469	66	80	50	8.381527	56.5	72	20
7.826237	62.5	82	51	6.800735	67.5	84	21
7	54	62	52	11.789826	61	76	22
9.5	66.5	82	53	12.44989	70	76	23
9.069178	65.5	72	54	10.049875	67	72	24
14.150971	66.5	72	55	8.124038	62	72	25
9.273618	62	82	56	10.049875	67	76	26
9.810708	62.5	72	57	12.737739	65.5	76	27
11.412712	68.5	82	58	11.715374	80.5	86	28
6.726812	63.5	72	59	12.206555	66	78	29
10.295630	78	88	60	12.134661	60.5	78	30

در ادامه، اثرات پیش‌بینی مدل *MLP* و *CNN* را بر اساس شاخص‌های ارزیابی دقت، صحت، فراخوان، امتیاز *FI* ارزیابی می‌کنیم. در اینجا، دقت به نسبت نمونه‌های پیش‌بینی شده درست به همه نمونه‌ها اشاره دارد. صحت نشان‌دهنده نسبت نمونه‌های مثبت پیش‌بینی شده صحیح به نمونه‌های مثبت پیش‌بینی شده است. فراخوان نشان‌دهنده نسبت نمونه‌های مثبت پیش‌بینی شده صحیح به نمونه‌های مثبت واقعی است. امتیاز *FI* میانگین هارمونیک صحت و فراخوان است. فرمول‌های محاسباتی به شرح زیر است:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

$$F1_{score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

TP نشان‌دهنده مثبت واقعی، *FP* نشان‌دهنده مثبت کاذب، *TN* نشان‌دهنده منفی واقعی و *FN* نشان‌دهنده منفی کاذب است. جزییات *TP*، *FP*، *TN* و *FN* در جدول ۳ نشان داده شده است.

جدول ۳- ساختار ماتریس در هم ریختگی.

Table 3- The structure of the confusion matrix.

		برچسب پیش‌بینی شده	
		مثبت	منفی
برچسب شناخته شده	مثبت	TP	FP
	منفی	FN	TN

چهار شاخص ارزیابی (دقت، صحت، فراخوان و امتیاز FI) برای ارزیابی عملکرد مدل استفاده می‌شود. ارزیابی عملکرد پیش‌بینی جهت آتی قیمت سهام توسط شبکه عصبی MLP و شبکه عصبی CNN در جداول زیر قابل مشاهده است.

جدول ۴- ارزیابی عملکرد پیش‌بینی جهت آتی قیمت سهام توسط شبکه عصبی MLP .

Table 4- Evaluation of the prediction performance of the future direction of the stock price by the MLP neural network.

شاخص‌ها	حداکثر	حداقل	متوسط	> 0.7	> 0.6	> 0.5
Accuracy	90.0	63.6	70.9	32	60	60
Precision	90.5	62.7	70.4	28	60	60
Recall	96.8	36.6	63.9	15	35	56
Specificity	93.6	41.5	74.9	44	56	59
F1-Score	96.6	49.6	66.5	16	51	59

جدول ۵- ارزیابی عملکرد پیش‌بینی جهت آتی قیمت سهام توسط شبکه عصبی CNN .

Table 5- Evaluation of the prediction performance of the future direction of the stock price by the CNN neural network.

شاخص‌ها	حداکثر	حداقل	متوسط	> 0.7	> 0.6	> 0.5
Accuracy	96.0	62	75.1	48	60	60
Precision	95.1	50	73.7	39	56	59
Recall	100	40	68.3	26	44	56
Specificity	96.4	50	78.1	45	56	59
F1-Score	97.5	46.1	70.2	29	53	59

همان‌گونه که در جدول‌های ۴ و ۵ ملاحظه می‌کنیم، متوسط دقت پیش‌بینی در روش CNN نسبت به روش MLP به میزان حدود ۵٪ افزایش یافته است؛ به طوری که میزان متوسط $Accuracy$ در MLP برابر ۷۰/۹ و در CNN برابر ۷۵/۱ است؛ بنابراین با در اختیار داشتن نتایج پیش‌بینی جهت آتی قیمت سهام توسط روش CNN ، مدل حداقل واریانس برای بهینه‌سازی پرتفوی به کار گرفته می‌شود. نتایج پیش‌بینی حرکات قیمت سهام توسط هر دو مدل در جدول‌های ۶ و ۷ آورده شده است.

جدول ۶- نتایج پیش‌بینی جهت آتی قیمت سهام توسط شبکه عصبی MLP .

Table 6- The results of predicting the future direction of stock prices by the MLP neural network.

پیش‌بینی	ردیف	پیش‌بینی	ردیف	پیش‌بینی	ردیف	پیش‌بینی	ردیف
1	46	1	31	1	16	1	1
1	47	1	32	1	17	1	2
1	48	1	33	1	18	0	3
0	49	1	34	1	19	1	4
1	50	0	35	1	20	1	5
0	51	1	36	1	21	1	6
0	52	1	37	1	22	1	7
1	53	0	38	1	23	1	8
0	54	1	39	1	24	1	9
1	55	0	40	1	25	0	10
1	56	1	41	0	26	1	11
1	57	1	42	0	27	1	12
1	58	0	43	0	28	1	13
1	59	0	44	1	29	1	14
0	60	1	45	1	30	1	15

جدول ۷- نتایج پیش‌بینی جهت آتی قیمت سهام توسط شبکه عصبی CNN.

Table 7- The results of predicting the future direction of stock prices by the CNN neural network.

پیش‌بینی	ردیف	پیش‌بینی	ردیف	پیش‌بینی	ردیف	پیش‌بینی	ردیف
0	46	1	31	1	16	1	1
1	47	1	32	1	17	1	2
1	48	1	33	1	18	0	3
0	49	1	34	1	19	0	4
1	50	0	35	1	20	1	5
0	51	0	36	1	21	0	6
0	52	1	37	1	22	1	7
1	53	0	38	1	23	1	8
0	54	1	39	1	24	1	9
1	55	1	40	1	25	0	10
1	56	1	41	0	26	1	11
1	57	1	42	0	27	1	12
1	58	1	43	0	28	1	13
1	59	0	44	1	29	1	14
0	60	1	45	1	30	1	15

در آخر، با در اختیار داشتن نتایج پیش‌بینی جهت آتی قیمت سهام توسط روش CNN، مدل حداقل واریانس برای بهینه‌سازی پرتفوی به کار گرفته می‌شود. اعتبارسنجی این روش با مقایسه استراژی سرمایه‌گذاری پیشنهادی نسبت به استراژی سرمایه‌گذاری حداقل واریانس جهانی سنتی انجام می‌شود. نتایج حاصل از اجرای استراژی‌های سرمایه‌گذاری (۱) و (۲) در جدول ۸ آورده شده است.

جدول ۸- سبد سهام بهینه استراژی‌های مختلف سرمایه‌گذاری.

Table 8- Optimal stock portfolio of different investment strategies.

استراژی سرمایه‌گذاری پیشنهادی						
4	6	24	30	36	39	42
0.299906	0.164527	0.100300	0.100047	0.100668	0.101272	0.133272
استراژی سرمایه‌گذاری حداقل واریانس سراسری						
4	6	16	30	36	39	42
0.299784	0.142537	0.100580	0.100174	0.101183	0.106212	0.149532

در انتها شاخص‌های ارزیابی نسبت شارپ و نسبت سورتینو را برای اندازه‌گیری بازده پرتفوی اعمال می‌کنیم و سپس تفاوت در عملکرد استراژی‌های سرمایه‌گذاری مختلف را بررسی می‌کنیم.

جدول ۹- مقایسه عملکرد استراژی‌های مختلف سرمایه‌گذاری.

Table 9- Performance comparison of different investment strategies.

نسبت شارپ بازده پرتفوی	استراژی سرمایه‌گذاری
0.188528	پیشنهادی
0.082406	حداقل واریانس سراسری
نسبت سورتینو بازده پرتفوی	استراژی سرمایه‌گذاری
0.203634	پیشنهادی
0.089009	حداقل واریانس سراسری

همان‌گونه که در جدول ۹ مشاهده می‌کنیم، نسبت شارپ و سورتینو بازده پرتفوی استراژی سرمایه‌گذاری پیشنهادی در مقایسه با نسبت شارپ و سورتینو بازده پرتفوی استراژی سرمایه‌گذاری حداقل واریانس سراسری عملکرد بهتری را ارائه می‌دهد.

۵- نتیجه‌گیری

یکی از چالش‌های اساسی که سرمایه‌گذاران بازار سرمایه با آن روبرو هستند، چگونگی شناسایی سهام قابل سرمایه‌گذاری در بازار بورس اوراق بهادار با تعداد زیادی دارایی و چگونگی ایجاد یک پرتفوی موثر می‌باشد. برای حل این مشکل، مدل‌های مختلف سرمایه‌گذاری به کمک سرمایه‌گذاران شتافتند. ابتدا پیشنهاد شد که افراد باید پرتفوی خود را تا حد امکان متنوع کنند تا ریسک سرمایه‌گذاری را کاهش دهند؛ اما در فرآیند سرمایه‌گذاری واقعی، اگر سبد سهام بیش از حد متنوع باشد، سرمایه‌گذاران باید هزینه‌های تراکنش بیشتری را بپردازند و مشخص شد که این استراژی

در عمل بهینه نیست. سپس مساله عدم تنوع پرتفوی ها و استراتژی های کم تنوع به طور گسترده مورد مطالعه قرار گرفت و محققین استدلال کردند که افراد باید ثروت خود را در تعداد کمی از سهام با ارزش سرمایه گذاری متمرکز کنند و در نتیجه تنوع پرتفوی ها را کاهش دهند. با این حال، فقط در نظر گرفتن عملکرد گذشته ی سهام و در مقابل، نادیده گرفتن روند آتی قیمت سهام توسط مطالعات بالا، عاملی است که بر عملکرد سبد سرمایه گذاران تاثیر به سزایی می گذارد. لذا طراحی مدلی کارا برای حل این مشکل، امری ضروری برای ذینفعان بازار سرمایه به شمار می آید. بدین منظور در این پژوهش به دنبال بهینه سازی پرتفوی مبتنی بر شبکه عصبی مصنوعی با استفاده از شبکه یادگیری عمیق بوده ایم. شبکه عصبی به صورت عمومی ابزار مناسبی برای بهینه سازی نیست؛ کار شبکه عصبی بیشتر مدل سازی و پیش بینی است.

به منظور دستیابی به هدف مذکور، از شبکه عصبی عمیق برای پیش بینی جهت آتی قیمت سهام های مورد ارزیابی پژوهش استفاده نمودیم؛ به این صورت که ابتدا اطلاعات و داده های مربوط به سهام های مورد نظر را به منظور یادگیری مدل شبکه عصبی مصنوعی جمع آوری، محاسبه و در مدل قرار دادیم. پس از طی فرآیند مربوط به شبکه عصبی که جزئیات نحوه کار و جداول حاصل از نتایج آن در فصول قبل تشریح شد، نتایج پیش بینی حرکات قیمت سهام را به دست آوردیم. سپس با در اختیار داشتن این نتایج، مدل حداقل واریانس برای بهینه سازی پرتفوی به کار گرفته شد. اعتبارسنجی این روش نیز با مقایسه استراژی سرمایه گذاری پیشنهادی نسبت به استراژی سرمایه گذاری حداقل واریانس جهانی سنتی انجام گردید و طبق نتایج به دست آمده مشاهده شد که نسبت شارپ و سورتینو بازده پرتفوی استراتژی سرمایه گذاری پیشنهادی در مقایسه با نسبت شارپ و سورتینو بازده پرتفوی استراتژی سرمایه گذاری حداقل واریانس سراسری عملکرد به مراتب بهتری را ارائه می دهد.

با توجه به مطالب بالا، در این پژوهش نشان دادیم که به کارگیری شبکه های عصبی می تواند در گزینش پرتفوی ثمربخش واقع شود. این نتایج نشان داد که سرمایه گذاران باید یک استراتژی سرمایه گذاری کم تنوع را به جای استراتژی سنتی کاملاً متنوع اتخاذ کنند. در پایان و به عنوان پیشنهادها جهت پژوهش های آتی، گفتنی است که به کارگیری سنجه های ریسک دیگری غیر از سنجه واریانس، مانند ارزش در معرض خطر، ارزش در معرض خطر شرطی، نیم انحراف معیار و یا نیم واریانس و نیز استفاده از مدل های توسعه یافته تر شبکه عصبی چندلایه مانند شبکه عصبی چندلایه فازی جهت تعیین وضعیت آتی سهام؛ می تواند عملکرد استراتژی سرمایه گذاری را بهتر نماید.

تشکر و قدردانی

از دست اندرکاران و داوران نشریه مهندسی و مدیریت کیفیت که در بهبود کیفی این پژوهش به نویسندگان مقاله کمک نمودند، قدردانی می شود.

منابع مالی

هیچ گونه حمایت مالی برای این پژوهش دریافت نشده است.

تعارض با منافع

نویسندگان اعلام می دارند که هیچ تعارض منافی در مورد انتشار این نسخه وجود ندارد.

منابع

- [1] Markowitz, H. (1952). Portfolio Selection. *The journal of finance*, 7(1), 77–91. <https://doi.org/10.2307/2975974>
- [2] Keynes, J. M. (1983). Keynes as an investor. *The collected works of john maynard keynes*, 12, 1–113. <https://tontinecoffeehouse.com/2019/12/02/keynes-the-investor/>
- [3] Uppal, R., & Wang, T. (2003). Model misspecification and underdiversification. *The journal of finance*, 58(6), 2465–2486. <https://doi.org/10.1046/j.1540-6261.2003.00612.x>
- [4] Boyle, P., Garlappi, L., Uppal, R., & Wang, T. (2012). Keynes meets Markowitz: The trade-off between familiarity and diversification. *Management science*, 58(2), 253–272. <https://doi.org/10.1287/mnsc.1110.1349>
- [5] Liu, H. (2014). Solvency constraint, underdiversification, and idiosyncratic risks. *Journal of financial and quantitative analysis*, 49(2), 409–430. <https://doi.org/10.1017/S0022109014000271>
- [6] Guidolin, M., & Liu, H. (2016). Ambiguity aversion and underdiversification. *Journal of financial and quantitative analysis*, 51(4), 1297–1323. <https://www.jstor.org/stable/44157614>

- [7] Florentsen, B., Nielsson, U., Raahauge, P., & Rangvid, J. (2019). The aggregate cost of equity underdiversification. *Financial review*, 54(4), 833–856. <https://doi.org/10.1111/fire.12212>
- [8] Najafi, S. E., & Alem-Tabriz, A. (2024). Working capital efficiency and true performance of companies in Iran's capital market. *Accounting and auditing with applications*, 1(4), 205–214. <https://doi.org/10.22105/aaa.v1i4.51>
- [9] Bao, Z., & Pouresmaeil Motlagh, B. (2024). How Investment Efficiency Affects Firms Performance? *Accounting and auditing with applications*, 1(1), 17–26. <https://doi.org/10.22105/aaa.v1i1.19>
- [10] White, H. (1989). Learning in artificial neural networks: A statistical perspective. *Neural computation*, 1(4), 425–464. <https://doi.org/10.1162/neco.1989.1.4.425>
- [11] Kimoto, T., Asakawa, K., Yoda, M., & Takeoka, M. (1990). Stock market prediction system with modular neural networks. *1990 ijcn international joint conference on neural networks* (pp. 1–6). IEEE. <https://doi.org/10.1109/IJCNN.1990.137535>
- [12] Weng, B., Ahmed, M. A., & Megahed, F. M. (2017). Stock market one-day ahead movement prediction using disparate data sources. *Expert systems with applications*, 79, 153–163. <https://doi.org/10.1016/j.eswa.2017.02.041>
- [13] Basak, S., Kar, S., Saha, S., Khaidem, L., & Dey, S. R. (2019). Predicting the direction of stock market prices using tree-based classifiers. *The north american journal of economics and finance*, 47, 552–567. <https://doi.org/10.1016/j.najef.2018.06.013>
- [14] Mohammadi, S. (2004). Technical analysis in Tehran Stock Exchange. *Financial research journal*, 6(1), 97–129. (In Persian). <https://dor.isc.ac/dor/20.1001.1.10248153.1383.6.1.5.5>
- [15] Michaud, R. O. (1989). The markowitz optimization enigma: Is optimized optimal? *Financial analysts journal*, 45(1), 31–42. <https://doi.org/10.2469/faj.v45.n1.31>
- [16] DeMiguel, V., Garlappi, L., & Uppal, R. (2009). Optimal versus naive diversification: How inefficient is the 1/N portfolio strategy? *The review of financial studies*, 22(5), 1915–1953. <https://doi.org/10.1093/rfs/hhm075>
- [17] Tu, J., & Zhou, G. (2011). Markowitz meets Talmud: A combination of sophisticated and naive diversification strategies. *Journal of financial economics*, 99(1), 204–215. <https://doi.org/10.1016/j.jfineco.2010.08.013>
- [18] Heidari Haratemeh, M. (2021). Portfolio optimization and random matrix theory in stock exchange. *Innovation management and operational strategies*, 2(3), 257–267. (In Persian). <https://doi.org/10.22105/imos.2021.289758.1109>
- [19] Beale, E. M. L., & Forrest, J. J. H. (1976). Global optimization using special ordered sets. *Mathematical programming*, 10, 52–69. <https://doi.org/10.1007/BF01580653>