

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 to earn more sustainable profits. The existing literature shows that the performance of traditional mean-variance portfolio strategies is not suitable. To address this issue, this study uses a multilayer perceptron neural network and a convolutional neural network to predict the future direction of stock prices.

Methodology: We compare the prediction accuracy of these two methods and enter the outputs of each method with higher accuracy into 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 Tehran Stock Exchange index components 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 increasing investment efficiency, risk management, and decision-making in the Iranian capital market and provide 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>).



نوع مقاله: پژوهشی

انتخاب پرتفوی مبتنی بر شبکه عصبی 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 سید 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 شبکه عصبی پرسپترون چندلایه و شبکه عصبی 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: شبکه عصبی مصنوعی، انتخاب پرتفوی، یادگیری عمیق.

۱- مقدمه

از زمان نظریه کلاسیک پرتفوی میانگین-واریانس ارایه شده توسط مارکویتز [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 آی بی

¹ Artificial Neural Networks (ANNs)

ام به عنوان یک مورد خاص مورد استفاده قرار گرفت و نقش روش های استنباط آماری و روش های یادگیری در شبکه های عصبی به عنوان دو عنصر مکمل یکدیگر مطرح گردید. در تحقیق دیگر، تاکاهو یودا، آساکاوا و کیموتو [11] سیستم پیش بینی بازار سهامی را ارائه نمودند که در آن از استفاده شده بود. در این مطالعه ضمن شبکه عصبی مقایسه سیستم های خبره و سیستم های شبکه عصبی یادگیری غیر خطی شبکه های عصبی به عنوان توانایی بالای این شبکه ها بر شمرده شده است. در زمینه پیش بینی قیمت و شاخص سهام در بورس اوراق بهادار تهران با استفاده از شبکه های عصبی تحقیقات ذیل انجام شده است که به اختصار به آن ها اشاره می شود. در رساله ای تحت عنوان مدل سازی غیر خطی و پیش بینی رفتار قیمت سهام در بازار بورس ایران یک مطالعه منظم بر مقوله پیش بینی و پیش بینی پذیری انجام شده است.

در بخش پیش بینی ابتدا از یک شبکه عصبی سه لایه با طرح ۱-۱۵-۵ برای پیش بینی قیمت روز بعد، بازده و شاخص کل قیمت بورس در سری زمانی های 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 پیش بینی سری زمانی قیمت در ۳۰ روز بعد از یک شبکه عصبی سه لایه با اتصالات برگشتی استفاده شده است که نتیجه $R^2 = 0.7876$ به دست آمده است. در تحقیقی دیگر تحت عنوان استفاده از شبکه های عصبی برای پیش بینی روند شاخص قیمت سهام در بورس اوراق بهادار تهران از یک شبکه پرسپترون با سه لایه به منظور پیش بینی 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 می باشند. در تحقیقی دیگر با عنوان پیش بینی بازده سهام در بورس اوراق بهادار تهران مدل شبکه های عصبی و مدل چندعاملی به پیش بینی پذیری رفتار بازده سهام در بورس اوراق بهادار تهران به وسیله مدل خطی عاملی شبکه های عصبی مصنوعی پرداخته شده که برای آزمون این مساله قیمت روزانه سهام شرکت توسعه صنایع بهشهر به عنوان 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 می باشد. در این تحقیق برای حل مدل خطی از نرم افزار SPSS و برای حل مدل شبکه های عصبی از نرم افزار MATLAB استفاده شده است که به مراتب شبکه خطای کمتری نسبت به مدل چند عاملی در عصبی پیش بینی نمونه داشته است.

همچنین در تحقیق دیگری با عنوان مدل سازی پیش بینی قیمت سهام با استفاده از شبکه عصبی و مقایسه آن با روش های پیش بینی ریاضی محقق برای پیش بینی قیمت روزانه سهام متغیرهای ورودی مدل را آخرین قیمت، تعداد معاملات، میانگین قیمت، تعداد نفر، جمع معاملات پایین ترین و بالاترین قیمت روزانه و قیمت قبل در نظر گرفته است که در این تحقیق روش رگرسیون از خطای کمتری نسبت به شبکه عصبی و میانگین متحرک برخوردار بوده است.

۳- روش شناسی پژوهش

۳-۱- گردآوری منابع داده

در فرآیند انتخاب پرتفوی، روش موثر انتخاب سهام تا حد زیادی تعیین کننده موفقیت استراتژی سرمایه گذاری خواهد بود. در عمل، سرمایه گذاران معمولاً سهام را بر اساس عملکرد تاریخی آن ها بررسی می کنند. با این حال، برخی از پژوهشگران معتقدند که یک اوراق بهادار که در گذشته خوب عمل می کند لزوماً عملکرد خوب آن را در آینده تضمین نمی کند. در واقع، همبستگی بین عملکرد گذشته یک دارایی و عملکرد آتی آن به اثربخشی بازارهای مالی بستگی دارد. واضح است که داده های تاریخی معاملات سهام نمی توانند به طور کامل ارزش سرمایه گذاری آتی سهام را منعکس کنند. به این دلایل، برای ارزیابی ارزش سرمایه گذاری سهام، داده های چندگانه از سهام، از جمله داده های معاملاتی تاریخی و شاخص فنی را جمع آوری خواهیم کرد.

۳-۱-۱- داده های تاریخی معاملات

این مقاله داده های معاملات تاریخی روزانه سهام را جمع آوری می کند. اطلاعات جمع آوری شده شامل قیمت افتتاحیه، بالاترین قیمت، پایین ترین قیمت، قیمت بسته شدن و حجم معاملات می باشد. داده های معاملات تاریخی فوق می توانند عملکرد تاریخی سهام را منعکس کنند. همچنین می توانند راهنمایی استراتژیک متناظری را برای انتخاب سهام سرمایه گذاران تا حد معینی ارائه دهند.

۳-۱-۲- شاخص های فنی

علاوه بر داده های تاریخی معاملات، داده های شاخص فنی سهام نیز می تواند 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 به عنوان شاخص های ارزیابی فنی انتخاب می کنیم. از فرمول محاسبه شاخص های فنی [14] می توانیم ارزش شاخص های فنی را بر اساس داده های معاملات تاریخی به دست آوریم. فرمول های محاسباتی به شرح زیر است.

میانگین متحرک همگرا-واگرا

این شاخص ارتباط بین دو EMA قیمت ها را نشان می دهد. این شاخص از تفاوت میانگین متحرک نمایی ۲۶ روزه سهم از میانگین متحرک نمایی ۱۲ روزه قیمت آن برآورد می شود. خط سیگنال که همان EMA ۹ روزه است، معیاری است که از مقایسه آن با $MACD$ فرصت های خرید و فروش شناسایی می گردند. بر این اساس حالت فروش زمانی است که $MACD$ زیر خط سیگنال قرار می گیرد. به طور مشابه، یک سیگنال خرید زمانی روی می دهد 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 بازده های اخیر سهام با زیان های اخیر آن را مورد مقایسه قرار می دهد و این اطلاعات را به عددی بین ۰ تا ۱۰۰ تبدیل می کند. این شاخص را می توان از معادله (۲) محاسبه نمود. اگر RSI از ۳۰ بیشتر شود سیگنال فروش و اگر از ۷۰ کمتر شود سیگنال خرید صادر می شود.

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

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

شاخص تصادفی KDJ

معمولاً برای تجزیه و تحلیل روندهای کوتاه مدت یا میان مدت بازار سهام استفاده می شود. از طریق تجزیه و تحلیل شاخص KDJ ، پژوهشگران می توانند روند قیمت سهام را پیش بینی کنند و از قدرت بازار احتیاط کنند. برای پیش بینی حرکت قیمت سهام، شاخص سریع K را در شاخص KDJ انتخاب می کنیم. شاخص KDJ دارای مقداری بین ۰ تا ۱۰۰ است. به طور کلی، مقدار بالای ۹۰ بیش از حد خرید و زیر ۱۰ بیش از حد فروخته می شود. 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- پیش بینی حرکات آتی قیمت سهام

شبکه های عصبی پرسپترون، به ویژه پرسپترون چندلایه، در زمره کاربردی ترین شبکه های عصبی می باشند. شبکه عصبی چندلایه پرسپترون، ساختاری مشابه با ساختار مدل پرسپترون دارد اما تعداد لایه های پنهان آن بیش از یک لایه است. همچنین، این مدل نوعی شبکه پیش خور محسوب می شود.

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 لایه اول، تابع واحد یک‌سو شده خطی^۱ و برای لایه 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 لایه 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^۲ 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.

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

در اینجا، 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]. ازجمله 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 سبدي از سهام که تعداد محدودتری از دارایی‌ها را در خود جای داده باشد، محدودیت دیگری تحت عنوان محدودیت کاردینالیتی 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 حدفصل شهریورماه ۱۴۰۰ تا آبان ماه 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 نرم افزارها و 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 RSI ، KDJ 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
x7.348469	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 *F1* 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 *F1* 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 پیش‌بینی‌شده			
برچسب شناخته‌شده	مثبت	TP	FP
	منفی	FN	TN

چهار شاخص ارزیابی (دقت، صحت، فراخوان و امتیاز $F1$) برای ارزیابی عملکرد مدل استفاده می‌شود. ارزیابی عملکرد پیش‌بینی جهت آتی قیمت سهام توسط شبکه‌عصبی MLP و شبکه‌عصبی CNN در جداول زیر قابل مشاهده است.

جدول ۴- ارزیابی عملکرد پیش‌بینی جهت آتی قیمت سهام توسط شبکه‌عصبی 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 شبکه‌عصبی 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؛ به‌طوری‌که 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 به‌کار 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 شبکه‌عصبی 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 به‌کار 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	124	30	p36	e39	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.

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

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 روبه‌رو 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. اعتبار سنجی این روش نیز با مقایسه استراتژی سرمایه گذاری پیشنهادی نسبت به استراتژی سرمایه گذاری حداقل واریانس جهانی سنتی انجام گردید و طبق نتایج به دست آمده مشاهده شد که نسبت شارپ و سورتنو بازده پرتفوی استراتژی سرمایه گذاری پیشنهادی در مقایسه با نسبت شارپ و سورتنو 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 سنج های ریسک دیگری غیر از سنج 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 چند لایه مانند شبکه عصبی چند لایه فازی جهت تعیین وضعیت آتی سهام؛ می تواند عملکرد استراتژی سرمایه گذاری را بهتر نماید.

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>

