



Applying prediction-based portfolio optimization model using CNN neural network and MSAD criterion in Tehran Stock Exchange

Amirreza Dodangeh¹ | Hassanali Sinaei^{2*} | Rahim Ghasemieh^{3*}

Abstract

Portfolio optimization as a popular research field has received many attention from researchers in recent decades. Quality of portfolio optimization helps investors generate more sustainable returns. In this research, Convolutional Neural Network (CNN) is used to build a portfolio optimization model based on prediction. This model not only benefits from deep learning technology, but also benefits from modern portfolio theory.

In this approach, CNN is first used to predict the future return of each stock. Then, the prediction error of CNN is used as the risk measure of each stock. Integrating the predicted return with the semi-absolute deviation of the prediction error leads to the construction of the portfolio optimization model. This model is compared with an equally weighted portfolio whose stocks are selected with CNN. Also, two prediction based portfolio models with support vector regression (SVR) are used as benchmark portfolios. The empirical data of this research includes the companies in the index of 50 most active companies of Tehran Stock Exchange. The experimental results show that the prediction-based portfolio model with CNN shows a superior performance compared to SVR in the conditions of different returns. Also, the increase in the expected return can improve the performance of this model. This research clearly states the positive role of deep neural networks (DNNs) in creating portfolio optimization models.

Keywords: Portfolio optimization, Machine learning, deep learning, Neural networks, CNN.

Research Paper

Received:
12 June 2024
Revised:
22 July 2024
Accepted:
22 July 2024
Published:
8 October 2024

ISSN: 2717-1809
E-ISSN: 2717-199x



DOR: 20.1001.1.27171809.1403.5.3.1.2

1. Master's student in financial management, Faculty of Economics and Social Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
2. Professor, Department of Management, Faculty of Economics and Social Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
3. Corresponding Author: Associate Professor, Department of Management, Faculty of Economics and Social Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran. r.ghasemiyeh@scu.ac.ir

This article is an open-access article distributed under the terms and conditions of the

Creative Commons Attribution Non-Commercial (CC-BY-NC) license.





پروہشگاہ علوم انسانی و مطالعات فرہنگی
پرتال جامع علوم انسانی

به کارگیری مدل بهینه‌سازی پورتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی CNN و معیار MSAD در بورس اوراق بهادار تهران

امیررضا دودانگه^۱ | حسنعلی سینایی^۲ | رحیم قاسمی^۳

چکیده

در دهه‌های اخیر، بهینه‌سازی پورتفوی به‌عنوان یک حوزه تحقیقاتی پرطرفدار، مورد توجه زیادی از سوی پژوهشگران قرار گرفته است. کیفیت بهینه‌سازی پورتفوی به سرمایه‌گذاران کمک می‌کند تا سودهای پایدارتری ایجاد کنند. در این پژوهش از شبکه عصبی کانواشنال (CNN) برای ساخت مدل بهینه‌سازی پورتفوی بر پایه پیش‌بینی استفاده شده است. این مدل، نه تنها از مزایای تکنولوژی یادگیری عمیق بهره‌مند می‌باشد، بلکه از مزایای تئوری مدرن پورتفوی نیز برخوردار است. در این رویکرد، ابتدا از CNN برای پیش‌بینی بازده آتی هر سهم استفاده می‌شود. سپس، خطای پیش‌بینی CNN به عنوان معیار ریسک هر سهم به کار گرفته می‌شود. ادغام بازدهی پیش‌بینی شده با انحراف نیمه مطلق خطای پیش‌بینی (MSAD)، منجر به ساخت مدل بهینه‌سازی پورتفوی می‌شود. این مدل با پورتفوی هم وزن که سهام آن با CNN انتخاب شده است، مقایسه می‌شود. همچنین، دو مدل پورتفوی مبتنی بر پیش‌بینی از طریق رگرسیون بردار پشتیبان (SVR) به عنوان پورتفوی معیار مورد استفاده قرار می‌گیرند. داده‌های تجربی این پژوهش، شامل شرکت‌های حاضر در شاخص ۵۰ شرکت فعال‌تر بورس اوراق بهادار تهران می‌باشد. نتایج تجربی نشان می‌دهند که مدل پورتفوی مبتنی بر پیش‌بینی با CNN، عملکرد برتری در مقایسه با SVR در شرایط بازده‌های متفاوت از خود نشان می‌دهد. همچنین، افزایش بازده مورد انتظار می‌تواند منجر به بهبود عملکرد این مدل شود. این پژوهش به وضوح نقش مثبت شبکه‌های عصبی عمیق (DNNها) در ایجاد مدل‌های بهینه‌سازی پورتفوی را نشان می‌دهد.

کلیدواژه‌ها: بهینه‌سازی پورتفوی، یادگیری ماشین، یادگیری عمیق، شبکه‌های عصبی، CNN

۲

سال پنجم
پاییز ۱۴۰۳
صص: ۳۰-۱۱

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۳/۰۳/۲۳

تاریخ بازنگری:

۱۴۰۳/۰۵/۰۱

تاریخ پذیرش:

۱۴۰۳/۰۵/۰۱

تاریخ انتشار:

۱۴۰۳/۰۷/۱۷

شاپا چاپی: ۹-۱۸۰۹-۲۷۱۷
الکترونیکی: x-۱۹۹-۲۷۱۷



DOR: 20.1001.1.27171809.1403.5.3.1.2

۱. دانشجوی کارشناسی ارشد مدیریت مالی، دانشکده اقتصاد و علوم اجتماعی، دانشگاه شهید چمران اهواز، اهواز، ایران.

۲. استاد، گروه مدیریت، دانشکده اقتصاد و علوم اجتماعی، دانشگاه شهید چمران اهواز، اهواز، ایران.

۳. نویسنده مسئول: دانشیار، گروه مدیریت، دانشکده اقتصاد و علوم اجتماعی، دانشگاه شهید چمران اهواز، اهواز، ایران.

r.ghasemiyeh@scu.ac.ir



مقدمه و بیان مسئله

بهینه‌سازی پورتفوی چالش مهمی در سرمایه‌گذاری است که توجه پژوهشگران و سرمایه‌گذاران را جلب کرده است. در مدل‌های کلاسیک، میانگین بازده تاریخی سهام به‌عنوان بازده مورد انتظار در نظر گرفته می‌شود که برای سرمایه‌گذاری بلندمدت مناسب است. اما در سرمایه‌گذاری کوتاه‌مدت، این مدل‌ها به دلیل نوسانات بازار و تأثیر احساسات، مناسب نیستند. استفاده از میانگین بازده تاریخی می‌تواند به پیش‌بینی‌های نادرست منجر شود و عملکرد مدل‌ها را در کوتاه‌مدت کاهش دهد (فریتاس و همکاران، ۲۰۰۹: ۱۰).

توسعه هوش مصنوعی و تکنیک‌های یادگیری ماشین، مدیران صندوق‌های سرمایه‌گذاری را قادر ساخته تا با پیش‌بینی قیمت سهام، از فرصت‌های بازار بهره‌مند شوند. این تکنیک‌ها بهبود قابل توجهی در عملکرد سرمایه‌گذاری ایجاد کرده‌اند (نافیا و همکاران، ۲۰۲۳: ۲).

اخیراً، مدل‌های یادگیری ماشین برای پیش‌بینی کوتاه‌مدت بازار مالی استفاده شده و نتایج خوبی ارائه داده‌اند. ترکیب این تکنیک‌ها با مدل‌های بهینه‌سازی پورتفوی، به‌ویژه در سرمایه‌گذاری کوتاه‌مدت، موفقیت‌آمیز بوده است. شبکه‌های عصبی عمیق (DNN) عملکرد بهتری نسبت به روش‌های سنتی نشان داده‌اند.

مقاله حاضر به‌ضرورت و اولویت استفاده از شبکه‌های عصبی عمیق (DNN) برای بهینه‌سازی پورتفوی مبتنی بر پیش‌بینی در بازار بورس اوراق بهادار ایران می‌پردازد. مدل‌های سنتی پورتفوی به علت نوسانات کوتاه‌مدت و پیش‌بینی‌های نادرست، برای سرمایه‌گذاری کوتاه‌مدت مناسب نیستند. در مقابل، تحقیقات اخیر نشان داده‌اند که خطاهای پیش‌بینی مدل‌های شبکه عصبی مصنوعی (ANN) نسبت به بازده‌های تاریخی دقیق‌تر هستند. هدف این تحقیق، بررسی عملکرد شبکه عصبی عمیق CNN در فرمول‌بندی مدل بهینه‌سازی پورتفوی مبتنی بر پیش‌بینی، استفاده از انحراف نیمه مطلق به‌جای واریانس به‌عنوان شاخص ریسک و مقایسه این مدل با مدل‌های سنتی است. سؤالات تحقیق شامل چگونگی پیش‌بینی بازده آتی سهام با مدل‌های یادگیری عمیق، به‌حداقل رساندن ریسک نزولی پورتفوی با معیار MSAD، و ارائه مدلی بهینه‌سازی پورتفوی با

استفاده از DNN و MSAD است که عملکرد بهتری نسبت به مدل‌های سنتی داشته باشد. همچنین در این مقاله تلاش شده است تا به سؤالات زیر پاسخ داده شود:

چگونه می‌توان با استفاده از مدل‌های یادگیری عمیق، بازده آتی سهام را پیش‌بینی کرد؟

چگونه می‌توان با استفاده از معیار MSAD، ریسک نزولی پورتنفوی را به حداقل رساند؟

آیا می‌توان با استفاده از مدل‌های یادگیری عمیق و معیار MSAD، مدلی جهت بهینه‌سازی پورتنفوی ارائه نمود که نسبت به مدل‌های سنتی عملکرد بهتری داشته باشد؟

بنابراین، این مقاله بر ساخت مدل بهینه‌سازی پورتنفوی مبتنی بر پیش‌بینی با استفاده از نتایج شبکه عصبی عمیق CNN تمرکز دارد. ابتدا از شبکه عصبی CNN برای پیش‌بینی بازده آتی سهام استفاده شده و بازده مورد انتظار پورتنفوی با ترکیب خطی بازده پیش‌بینی شده هر سهام محاسبه می‌شود. سپس، از متریک انحراف نیمه مطلق برای اندازه‌گیری ریسک هر سهم بر اساس خطاهای پیش‌بینی استفاده می‌شود. در نهایت، با تعمیم چارچوب مدل پورتنفوی میانگین انحراف نیمه مطلق^۱ (MSAD)، مدل بهینه‌سازی پورتنفوی مبتنی بر پیش‌بینی ساخته می‌شود. برای مقایسه، از پورتنفوی با وزن برابر (EW) که سهام آن با استفاده از شبکه عصبی CNN انتخاب شده، استفاده شده است. همچنین، دو مدل پورتنفوی مبتنی بر پیش‌بینی بر اساس رگرسیون بردار پشتیبان (SVR) نیز به‌عنوان معیار استفاده می‌شوند.

مبانی نظری پژوهش

استفاده از هوش مصنوعی در بهینه‌سازی پورتنفوی، ابزارهای جدیدی را برای مدیران سرمایه‌گذاری فراهم کرده است. الگوریتم‌های هوش مصنوعی، از جمله یادگیری ماشین و یادگیری عمیق، قادر به تحلیل داده‌های بزرگ و شناسایی الگوهای پیچیده در بازارهای مالی هستند. این روش‌ها امکان پیش‌بینی تغییرات بازار، شناسایی ریسک و بهبود عملکرد پورتنفوی را فراهم می‌کنند. مدیران سرمایه‌گذاری می‌توانند با استفاده از تکنیک‌های یادگیری ماشین و یادگیری عمیق، الگوها و روندهای نهان در داده‌ها را کشف کرده و از آنها بهره‌مند شوند. الگوریتم‌های یادگیری ماشین می‌توانند پیش‌بینی بازده دارایی‌ها را بهبود داده و با تغییرات بازار سریع‌تر تطبیق یابند.

1. Mean Semi-Absolute Deviation

مفهوم پیش‌بینی

پیش‌بینی به معنای ایجاد تصویری از آینده با استفاده از داده‌های موجود است و برای تصمیم‌گیری در بازار سهام ضروری است. بازار سهام به دلیل عوامل مختلف پیچیده و ناپایدار است (دبوئک، ۱۹۹۴: ۳۹؛ وانگ و وانگ، ۲۰۱۱: ۱۱). ابزارهای پیش‌بینی به سرمایه‌گذاران کمک می‌کنند قیمت سهام را پیش‌بینی کنند. الگوریتم‌های شبکه‌های عصبی مصنوعی به‌عنوان ابزارهای قدرتمند برای پیش‌بینی و تحلیل داده‌های بورس شناخته شده‌اند.

مفهوم بهینه‌سازی پورتفوی

بهینه‌سازی پورتفوی فرایندی است که در آن پول بین دارایی‌های مختلف توزیع می‌شود تا بازدهی حداکثر و ریسک حداقل شود. شبکه‌های عصبی به توسعه فرایندهای پیش‌بینی سری‌های زمانی، معاملات الگوریتمی و مدل‌سازی ریسک کمک می‌کنند. با توجه به عملکرد برتر شبکه‌های عصبی عمیق (DNN) در پیش‌بینی بازار مالی (سامارا و ویکراما، ۲۰۱۷: ۱-۶؛ لی و کو، ۲۰۱۹)، بررسی کاربرد آن‌ها در مدل‌های بهینه‌سازی پورتفوی اهمیت زیادی دارد.

پیشینه پژوهش

مطالعات خارجی

فیشر و کراوس (۲۰۱۸) با استفاده از شبکه عصبی LSTM، جنگل تصادفی، MLP و رگرسیون لجستیک، بازده آتی سهام را پیش‌بینی کردند. نتایج نشان داد که LSTM عملکرد بهتری دارد. آن‌ها پورتفوی مبتنی بر پیش‌بینی‌های LSTM ساختند که در دوره ۱۹۹۲ تا ۲۰۰۹ عملکرد بهتری داشت، اما در سال ۲۰۱۰ ضعیف‌تر بود.

پایوا و همکاران (۲۰۱۹) با استفاده از ماشین بردار پشتیبان (SVM) برای پیش‌بینی قیمت سهام و مدل MV برای بهینه‌سازی پورتفوی، مدل SVMCMV را ارائه کردند که در بازار برزیل عملکرد خوبی داشت.

وانگ و همکاران (۲۰۲۰) با استفاده از LSTM و مدل MV، مدلی برای انتخاب سهام و بهینه‌سازی پورتفوی ساختند که نتایج بهتری نسبت به SVM، RF و ARIMA داشت.

تا و همکاران (۲۰۲۰) با استفاده از LSTM و سه تکنیک بهینه‌سازی، شامل روش وزنی برابر، شیبه‌سازی مونت کارلو و مدل MV، پورتنفوی‌هایی با عملکرد بهتر نسبت به سایرین ایجاد کردند. لی و یو (۲۰۲۰) عملکرد شبکه عصبی بازگشتی، GRU و LSTM را مقایسه کرده و نشان دادند که LSTM عملکرد بهتری دارد و پورتنفوی‌های مبتنی بر آستانه پیشنهاد کردند. یانگ و همکاران (۲۰۲۲) عملکرد شبکه عصبی BiLSTM را با ARIMA، SVR و LSTM مقایسه کردند و نشان دادند که BiLSTM در پیش‌بینی سری‌های زمانی مالی نويزدار بهتر عمل می‌کند.

مطالعات داخلی

علیزاده و همکاران (۲۰۱۱) از سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) برای پیش‌بینی پورتنفوی استفاده کردند و نشان دادند که ANFIS با ویژگی‌های ورودی متنوع، عملکرد بهتری نسبت به مدل کلاسیک میانگین-واریانس دارد.

سرچشمی و همکاران (۲۰۲۰) از دو نوع شبکه عصبی عمیق برای پیش‌بینی بازده سهام استفاده کردند و نشان دادند که مدل شبکه عصبی پیچشی عملکرد بهتری دارد.

شریف فر و همکاران (۲۰۲۱) کارایی معماری‌های LSTM را برای پیش‌بینی قیمت سهام بررسی کردند و نشان دادند که LSTM با لایه Dropout عملکرد بهتری نسبت به مدل ساده LSTM و RNN دارد.

حیدری و امیری (۲۰۲۲) مدل‌های مختلف یادگیری ماشین را در پیش‌بینی روند قیمت سهام مقایسه کردند و دریافتند که شبکه عصبی همراه با LSTM دقت بیشتری دارد.

ذوقی و راعی (۲۰۲۲) چارچوب جدیدی از یادگیری عمیق را با استفاده از تبدیل موجک، خودرمن‌نگار انباشته و LSTM برای پیش‌بینی جهت بازار در قراردادهای آتی سکه طلا ارائه کردند که نتایج بهتری داشت.

مطابق با ادبیات پیشین می‌توان این گونه بیان کرد که هوش مصنوعی و به‌ویژه شبکه‌های عصبی عمیق، توانایی پیش‌بینی دقیق‌تری نسبت به روش‌های سنتی دارند و می‌توانند در ساخت مدل‌های بهینه‌سازی پورتنفوی مبتنی بر پیش‌بینی، دقت بالاتری به مدیران سرمایه‌گذاری و سرمایه‌گذاران خرد ارائه دهند. نوآوری این تحقیق در استفاده از شبکه‌های عصبی عمیق (DNN) و به‌ویژه شبکه

عصبی CNN برای پیش‌بینی بازده آتی سهام و بهینه‌سازی پورتنفوی است که به جای استفاده از بازده‌های تاریخی، از خطاهای پیش‌بینی برای کاهش ریسک استفاده می‌کند و در بازار بورس اوراق بهادار ایران پیاده‌سازی شده است.

روش‌شناسی پژوهش

در این مقاله، اطلاعات مالی از طریق روش کتابخانه‌ای و وبسایت‌های رسمی سازمان بورس و اوراق بهادار تهران جمع‌آوری شده است. جامعه آماری شامل شاخص ۵۰ شرکت فعال تر بورس تهران در بازه زمانی فروردین ۱۳۹۲ تا اسفند ۱۴۰۱ می‌باشد. داده‌های ورودی شامل قیمت باز شدن، قیمت بسته شدن، حداکثر و حداقل قیمت، و حجم معاملات روزانه است. برای تجزیه و تحلیل داده‌ها، از مدل‌سازی یادگیری عمیق در Python3 با کتابخانه Keras و مدل‌سازی یادگیری ماشین با scikit-learn استفاده شده است. داده‌ها به دسته‌های آموزش، اعتبارسنجی و تست تقسیم شده و مقیاس‌بندی شدند. سپس مدل با لایه‌های مختلف ایجاد و آموزش داده می‌شود.

معیارهای ارزیابی مدل شامل خطاهای MAE^1 و MSE^2 ، دقت پیش‌بینی مثبت (HR_+) و منفی (HR_-)، متوسط بازده روزانه، واریانس بازده روزانه، بازده مورد انتظار و تعداد داده‌های پرت برای هر ۵۰ سهم محاسبه می‌شود. داده‌های پرت بر اساس بازده روزانه شناسایی و حذف می‌شوند. پنج پورتنفوی تشکیل می‌گردد و به هر پورتنفوی ۱۰ سهم تخصیص داده می‌شود. جهت ساخت این پورتنفوی، ابتدا کلیه ۵۰ سهم، به ترتیب بیشترین بازدهی به کمترین بازدهی، مرتب می‌شوند. سپس ۱۰ سهمی که در ابتدای لیست قرار می‌گیرند و دارای بیشترین بازدهی هستند به پورتنفوی ۱ تخصیص داده می‌شوند. بنابراین پورتنفوی ۱ دارای بیشترین بازده مورد انتظار و بیشترین ریسک می‌باشد که برای سرمایه‌گذاران ریسک‌پذیر است. به همین ترتیب ۱۰ سهم بعدی به پورتنفوی ۲ اختصاص داده می‌شوند تا ۱۰ سهم آخر که مربوط به پورتنفوی ۵ هستند و دارای کمترین بازدهی می‌باشند. سپس با روش میانگین انحرافات نیمه مطلق (MSAD)، درصد وزن هر

1. Mean Absolute Error
2. Mean Squared Error

سهم در پورتفوی تعیین می‌گردد. میانگین بازده روزانه، بازده کل و ریسک هر پورتفوی محاسبه شده و با سه مدل سبب دارای وزن برابر و دو مدل مبتنی بر SVR مقایسه می‌شود.

پیاده‌سازی عملیاتی مدل MSAD

در این مقاله، برای بهینه‌سازی پورتفوی مبتنی بر پیش‌بینی، ابتدا از شبکه عصبی CNN و همچنین از مدل یادگیری ماشین SVR برای پیش‌بینی بازده آتی هر سهم استفاده می‌گردد و سپس انحراف نیمه مطلق به عنوان شاخص ریسک برای ساخت مدل پرتفوی مبتنی بر پیش‌بینی مورد استفاده قرار می‌گیرد. این نوع معیار ریسک، فقط ریسک نزولی هر پرتفوی را در نظر می‌گیرد که در سرمایه‌گذاری واقعی، عملی‌تر است. همچنین محاسبه انحراف معیار، آسان‌تر از شاخص واریانس است که برای مسائل بهینه‌سازی پرتفوی در مقیاس بزرگ مناسب‌تر است. در ادامه این مدل به تفصیل نمایش داده شده است. (ما و وانگ، ۲۰۲۰: ۳)

مدل بهینه‌سازی پرتفوی معادل زیر است:

$$\text{Min } \frac{1}{T} \sum_{t=1}^T d_t$$

$$\text{subject to: } d_t \geq 0, \quad t = 1, 2, 3 \dots T$$

$$d_t \geq \sum_{i=1}^n (r_i - r_{it}) x_i, \quad t = 1, 2, 3 \dots T$$

$$\sum_{i=1}^n r_i x_i \geq R_p$$

$$\sum_{i=1}^n x_i = 1$$

$$0 \leq x_i \leq 1, i = 1, 2, 3 \dots n$$

که در اینجا:

$$d_t = w_t(X) = \frac{\sum_{i=1}^n (r_i - r_{it})x_i + |\sum_{i=1}^n (r_i - r_{it})x_i|}{2}, \quad t = 1, 2, 3 \dots T$$

که $w_t(X)$ ریسک پرتفوی X در زمان t یعنی انحراف نیمه مطلق نزولی می‌باشد. r_i نشان دهنده بازده مورد انتظار دارایی i ، R_p بازده مورد انتظار پرتفوی و x_i نشان دهنده وزن هر دارایی است. T افق زمانی در نظر گرفته شده (در اینجا ۱۰ سال) است. با حل این مدل بهینه‌سازی پرتفوی، مقادیر بهینه x_1 ؛ x_2 ؛ ...؛ x_n به دست می‌آید.

مدل‌ها

در این بخش مدل‌های مختلف مورد استفاده در این پژوهش در دو بخش اصلی نشان داده شده است، یعنی مدل بهینه‌سازی پرتفوی مبتنی بر پیش‌بینی بر اساس شبکه عصبی CNN و SVR.

الف. مدل بهینه‌سازی پورتفوی بر اساس شبکه عصبی CNN

شبکه عصبی کانولوشنی^۱ یا CNN یک نوع از شبکه‌های عصبی عمیق است که برای تشخیص الگوها و ویژگی‌های مختلف در تصاویر مورد استفاده قرار می‌گیرد. این نوع از شبکه‌ها به خوبی در وظایف پردازش تصویر، تشخیص اشیا، ترجمه ماشینی تصویر، و بسیاری دیگر از وظایف بینایی ماشین موفق بوده‌اند.

در این مقاله از CNN یک‌بعدی (1D) برای پیش‌بینی بازده استفاده شده است. ابر پارامترهای مورد نظر CNN در جدول ۱ ارائه شده است. روش گرادینان کاهش تصادفی برای آموزش CNN پیشنهادی و روش توقف اولیه برای کاهش مشکل بیش برزش مورد استفاده قرار گرفته است. پس از آزمون و خطای متعدد، توپولوژی CNN به دست می‌آید.

جدول ۱. ابرپارامترهای CNN.

Parameter	Value
Filter numbers	64
Convolutional layers	1
Maxpooling layers	1 (pool_size=2)
Fully connected layers	2
Fully connected layer nodes	32, 64
Patient	10
batch size	32
Activation function	relu
Loss function	Mean Absolute Error
Optimizer	adam

مدل بهینه‌سازی پرتفوی مبتنی بر پیش‌بینی با CNN و MSAD (CNN+MSAD)

در مدل CNN+MSAD ابتدا CNN برای پیش‌بینی بازده آتی هر سهم استفاده می‌گردد و سپس انحراف نیمه مطلق به‌عنوان شاخص ریسک برای ساخت مدل پرتفوی مبتنی بر پیش‌بینی مورد استفاده قرار می‌گیرد.

پرتفوی هموزن مبتنی بر CNN (CNN+EW)

در این مقاله از CNN+EW به‌عنوان مدل مقایسه‌ای استفاده شده است که پرتفوی را با وزن-دهی برابر به سهام انتخاب شده توسط CNN، می‌سازد. در این مدل ابتدا بازده مورد انتظار تک‌تک سهام توسط CNN پیش‌بینی می‌شود، سپس سهامی که بازده مورد انتظار آنها مثبت است برای ساخت پرتفوی با روش هموزن انتخاب می‌شوند.

ب. مدل بهینه‌سازی پورتفوی بر اساس SVR

SVR یک روش رگرسیون غیرخطی مبتنی بر کرنل است که سعی می‌کند یک ابر صفحه رگرسیونی با ریسک کوچک را در فضای ویژگی با ابعاد بالا بیابد. این روش دارای قابلیت‌های خوبی در تقریب و تعمیم تابع است. در این مقاله از تابع پایه شعاعی^۱ (RBF) به‌عنوان تابع کرنل SVR استفاده شده است که به‌صورت زیر تعریف می‌شود:

1. Radial Basis Function

$$K(v_i, v_j) = \exp(-\gamma \|v_i - v_j\|^2)$$

که γ پارامتر تابع پایه شعاعی و v_i به معنای ویژگی‌های نمونه آموزشی آن است. ابرپارامترهای SVR عمدتاً حاوی C و γ هستند که در جدول ۴ ارائه شده است. C نشان دهنده پارامتر تنظیم SVR است.

جدول ۲. ابرپارامترهای SVR.

Parameter	Value
C	100
γ	0.1
epsilon	0.1

مدل بهینه‌سازی پورتفوی مبتنی بر پیش‌بینی با SVR و MSAD (SVR+MSAD)

به منظور نشان دادن مزیت انحراف نیمه مطلق در ساخت مدل پورتفولیوی مبتنی بر پیش‌بینی، در این مقاله مدل SVR+MSAD با جایگزینی SVR در CNN+MSAD به جای CNN فرموله شده است.

پرتفوی هموزن مبتنی بر SVR (SVR+EW)

در SVR+EW ابتدا از SVR برای پیش‌بینی بازده سهام استفاده شده است، سپس سهامی که بازده مورد انتظار آنها مثبت است برای ساخت پرتفوی با روش هموزن انتخاب می‌شوند.

معیارهای ارزیابی مدل‌ها

در این مقاله از میانگین مربعات خطا (MSE) و میانگین خطای مطلق (MAE) برای اندازه‌گیری خطاهای پیش‌بینی مدل‌های مختلف استفاده می‌گردد. این دو معیار به صورت زیر تعریف شده‌اند

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - \hat{P}_i)^2$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - \hat{P}_i|$$

همچنین برای اندازه‌گیری عملکرد پیش‌بینی مدل‌های مختلف، از نرخ‌های، H_{R-} ؛ H_{R+} ؛ H_R استفاده می‌شود که به صورت زیر تعریف می‌شوند.

$$H_R = \frac{\text{Count}_{t=1}^n (r_t \hat{r}_t > 0)}{\text{Count}_{t=1}^n (r_t \hat{r}_t \neq 0)}$$

$$H_{R+} = \frac{\text{Count}_{t=1}^n (r_t > 0 \text{ AND } \hat{r}_t > 0)}{\text{Count}_{t=1}^n (\hat{r}_t > 0)}$$

$$H_{R-} = \frac{\text{Count}_{t=1}^n (r_t < 0 \text{ AND } \hat{r}_t < 0)}{\text{Count}_{t=1}^n (\hat{r}_t < 0)}$$

که H_R نشان‌دهنده نرخ موفقیت پیش‌بینی مدل است، H_{R+} ؛ نشان‌دهنده دقت پیش‌بینی مثبت و H_{R-} نشان‌دهنده دقت پیش‌بینی منفی است.

یافته‌های پژوهش

در این قسمت، داده‌های مربوط به ۵۰ شرکت منتخب، مورد تجزیه و تحلیل قرار گرفته و نتایج حاصل از پیش‌بینی قیمت و ساخت پورتفوی بهینه با استفاده از مدل‌های بهینه‌سازی پورتفوی ارائه می‌گردد. قلمرو زمانی ای مقاله، بازه ۱۰ ساله از ۱ فروردین سال ۱۳۹۲ تا ۲۹ اسفند سال ۱۴۰۱ است. داده‌ها در این پژوهش به سه بخش اصلی تقسیم می‌شوند که عبارتند از: داده‌های آموزش، داده‌های اعتبارسنجی و داده‌های تست. از داده‌های آموزشی، اعتبارسنجی و تست برای سه مرحله مختلف (آموزش، اعتبارسنجی، تست) داده‌های ورودی و خروجی تولید می‌شود. داده‌های آموزش به مدل داده می‌شوند تا بتواند الگوهای مختلف موجود در داده‌ها را یاد بگیرد. سپس داده‌های اعتبارسنجی مورد استفاده قرار می‌گیرند تا عملکرد مدل در زمان‌های آتی که با داده‌های آموزش مشاهده نشده‌اند، ارزیابی شود. سپس داده‌های تست برای ارزیابی نهایی مدل بر روی داده‌هایی استفاده می‌شوند که تاکنون به مدل نمایش داده نشده‌اند.

تجزیه و تحلیل داده‌ها و ساخت مدل

همان‌طور که در جدول ۳ مشاهده می‌شود، میانگین خطاهای پیش‌بینی بازده CNN که با معیار MAE و MSE اندازه‌گیری شده است، کمتر از مدل SVR در سال ۱۴۰۱ است، و انحراف معیار آنها نیز کمترین مقدار را دارد. همچنین، میانگین HR_+ و HR_- و در مدل CNN بیشتر است و انحراف معیار آن کم است. با این حال میانگین معیار HR_- در مدل CNN اندکی کمتر از مدل SVR می‌باشد. بر اساس تحلیل فوق، عملکرد پیش‌بینی CNN از مدل SVR بهتر است. بنابراین، CNN مدل بهتری نسبت به SVR در پیش‌بینی بازده سهام است. این نتیجه با نتیجه‌گیری ما و هان (۲۰۲۰) سازگار است.

جدول ۳. عملکرد پیش‌بینی مدل‌های SVR و CNN در سال ۱۴۰۱.

مدل		MAE	MSE	HR	HR+	HR-
CNN	میانگین	0.0199	0.0014	0.5139	0.4937	0.5514
	انحراف معیار	0.0078	0.0014	0.0246	0.0363	0.0484
SVR	میانگین	0.0902	0.025	0.508	0.506	0.529
	انحراف معیار	0.1115	0.0562	0.04	0.07	0.08

ساخت پورتفوی بهینه با استفاده از نتایج پیش‌بینی مدل‌ها

در این بخش عملکرد پورتفوی‌های بهینه مختلف که بر اساس مدل‌های پیش‌بینی قیمت ساخته شده‌اند، مورد ارزیابی قرار می‌گیرد. روش ساخت پورتفوی در این مقاله، بر اساس بازده مورد انتظار پورتفوی است. در اینجا ابتدا ۵۰ سهم منتخب از نظر بازده مورد انتظار (پیش‌بینی شده) سالانه به ترتیب نزولی مرتب می‌شوند. یعنی سهامی که بیشترین بازدهی مورد انتظار سالانه را دارند، در ابتدای این فهرست قرار می‌گیرند و سهامی که کمترین بازده مورد انتظار سالانه را دارند، به انتهای فهرست منتقل می‌شوند. سپس این ۵۰ سهم، در ۵ پورتفوی ۱۰ سهمی قرار می‌گیرند. بنابراین پورتفوهایی که دارای بازده بالاتر و ریسک بالاتری هستند، برای سرمایه‌گذاران ریسک‌پذیر در نظر گرفته شده‌اند و پورتفوهایی با ریسک پایین و بازدهی پایین، برای سرمایه‌گذاران ریسک‌گریز می‌باشند.

در مرحله بعد، با استفاده از معیار MSAD و حل مسئله برنامه‌ریزی خطی، وزن بهینه سهام در هر پورتفوی به دست می‌آید. از آنجایی که مدل پورتفوی مبتنی بر پیش‌بینی، به یک بازده مطلوب

پرتفوی نیاز دارد و بازده روزانه دارایی‌ها بین $-0,6$ و $+0,7$ است، در این مقاله، بازده مطلوب روزانه پورتفوی $R_p = 0.12$ و برای یک سرمایه‌گذار ریسک‌پذیر در نظر گرفته شده است. این سرمایه‌گذار قصد دارد از بین ۵۰ سهم مختلف، سهامی را انتخاب کند که بیشترین بازده را داشته باشند.

علاوه بر این، به منظور نشان دادن مزایای مدل‌های بهینه‌سازی پورتفوی مبتنی بر معیار انحراف نیمه مطلق (MSAD)، این مقاله به بررسی عملکرد مدل‌های سبد دارای وزن برابر، یعنی SVR+EW، CNN+EW می‌پردازد.

نتایج حاصل از مدل CNN+MSAD

همان‌طور که از جدول ۴ مشخص است، بازدهی روزانه و بازدهی کل پورتفوهای ۲، ۳، ۴ و ۵ که وزن بهینه سهام آنها توسط مدل CNN + MSAD بدست آمده است، بسیار بهتر از معادل هم‌وزن آنها می‌باشد. فقط در مورد پورتفوی ۱ می‌توان گفت که عملکرد پورتفوی هم‌وزن، اندکی بهتر از مدل CNN + MSAD است.

اختلاف بازده کل به دست آمده از مدل CNN + MSAD نسبت به مدل هم‌وزن برای ۵ پورتفوی، به ترتیب برابر است با $-0,6$ ، $1,57$ ، $5,8$ ، $4,8$ ، 34 درصد. بر این اساس می‌توان نتیجه گرفت که مدل CNN + MSAD عملکرد بهتری نسبت به مدل هم‌وزن دارد.

جدول ۴. مقایسه بازدهی و ریسک پورتفوی‌های بهینه با پورتفوی‌های هم‌وزن

CNN+EW	CNN+MSAD	معیارهای ارزیابی	
0.17	0.17	بازدهی روزانه پورتفوی	پورتفوی ۱
29.46	28.87	بازدهی کل پورتفوی	
0.18	0.54	ریسک پورتفوی	
0.08	0.09	بازدهی روزانه پورتفوی	پورتفوی ۲
13.94	15.51	بازدهی کل پورتفوی	
0.15	0.44	ریسک پورتفوی	
0.05	0.09	بازدهی روزانه پورتفوی	پورتفوی ۳
8.50	14.30	بازدهی کل پورتفوی	
0.17	0.36	ریسک پورتفوی	

جدول ۴. مقایسه بازدهی و ریسک پورتفوی‌های بهینه با پورتفوی‌های هم‌وزن

CNN+EW	CNN+MSAD	معیارهای ارزیابی	
-0.04	-0.01	بازدهی روزانه پورتفوی	پورتفوی ۴
-7.04	-2.23	بازدهی کل پورتفوی	
0.17	0.43	ریسک پورتفوی	
-0.18	0.04	بازدهی روزانه پورتفوی	پورتفوی ۵
-28.68	5.56	بازدهی کل پورتفوی	
0.19	1.17	ریسک پورتفوی	

نتایج حاصل از مدل SVR+MSAD

در این بخش ابتدا نتایج حاصل از مدل SVR و معیار MSAD در تشکیل پورتفوی مورد ارزیابی قرار می‌گیرد.

پس از اعمال مدل بر روی پورتفوی‌ها، به مقایسه نتایج حاصل از آنها و پورتفوی‌های هم‌وزن پرداخته شده که در جدول ۵ نشان داده شده است.

جدول ۵. مقایسه بازدهی و ریسک پورتفوی‌های بهینه با پورتفوی‌های هم‌وزن

SVR+EW	SVR+MSAD	معیارهای ارزیابی	
0.21	0.20	بازدهی روزانه پورتفوی	پورتفوی ۱
36.71	34.49	بازدهی کل پورتفوی	
0.24	0.76	ریسک پورتفوی	
0.14	0.12	بازدهی روزانه پورتفوی	پورتفوی ۲
24.86	21.56	بازدهی کل پورتفوی	
0.21	0.62	ریسک پورتفوی	
0.05	0.08	بازدهی روزانه پورتفوی	پورتفوی ۳
8.04	12.13	بازدهی کل پورتفوی	
0.23	0.60	ریسک پورتفوی	
0.00	0.00	بازدهی روزانه پورتفوی	پورتفوی ۴
-0.83	0.29	بازدهی کل پورتفوی	
0.21	0.70	ریسک پورتفوی	
-0.12	-0.03	بازدهی روزانه پورتفوی	پورتفوی ۵

جدول ۵. مقایسه بازدهی و ریسک پورتفوی‌های بهینه با پورتفوی‌های هم‌وزن

SVR+EW	SVR+MSAD	معیارهای ارزیابی	
-19.18	-4.29	بازدهی کل پورتفوی	
0.23	1.03	ریسک پورتفوی	

همان‌طور که از جدول فوق مشخص است، بازدهی روزانه و بازدهی کل پورتفوی‌های ۳، ۴ و ۵ که وزن بهینه سهام آنها توسط مدل SVR + MSAD بدست آمده است، بهتر از معادل هم‌وزن آنها می‌باشد. در مورد پورتفوی ۱ و ۲ می‌توان گفت که عملکرد پورتفوی هم‌وزن، بهتر از مدل SVR + MSAD است.

اختلاف بازده کل به‌دست‌آمده از مدل SVR + MSAD نسبت به مدل هم‌وزن برای ۵ پورتفوی، به ترتیب برابر است با ۲،۲۲، -۳،۳۱، ۳،۸۵، ۴،۰۹، ۱۴،۸۹ درصد. بر این اساس می‌توان نتیجه گرفت که مدل SVR + MSAD عملکرد بهتری نسبت به مدل هم‌وزن دارد.

مقایسه نتایج پورتفوی‌های بهینه

در بخش قبل، این نتیجه حاصل شد که عملکرد مدل‌های مبتنی بر میانگین انحراف نیمه مطلق (MSAD) بهتر از معادل هم‌وزن آنهاست. در این بخش، عملکرد این مدل‌ها با یکدیگر مقایسه می‌شود. معیارهای ارزیابی عملکرد عبارت‌اند از بازدهی روزانه پورتفوی، بازدهی کل پورتفوی، ریسک (انحراف معیار) پورتفوی، اختلاف بازده کل پورتفوی بهینه از بازده کل پورتفوی هم‌وزن و نسبت بازدهی روزانه به ریسک پورتفوی. نتایج حاصل از مقایسه در جدول ۶ ارائه شده است.

جدول ۶. مقایسه مدل‌های مختلف بهینه‌سازی پورتفوی

SVR+MSAD	CNN+MSAD	معیارهای ارزیابی	
0.2	0.17	بازدهی روزانه پورتفوی	پورتفوی ۱
34.49	28.87	بازدهی کل پورتفوی	
0.76	0.54	ریسک پورتفوی	
-2.22	-0.6	اختلاف بازده با پورتفوی هم‌وزن	
0.26	0.31	نسبت بازدهی روزانه به ریسک	
0.12	0.09	بازدهی روزانه پورتفوی	پورتفوی ۲
21.56	15.51	بازدهی کل پورتفوی	

جدول ۶. مقایسه مدل‌های مختلف بهینه‌سازی پورتفوی

SVR+MSAD	CNN+MSAD	معیارهای ارزیابی	
0.62	0.44	ریسک پورتفوی	
-3.31	1.57	اختلاف بازده با پورتفوی هموزن	
0.19	0.20	نسبت بازدهی روزانه به ریسک	
0.08	0.09	بازدهی روزانه پورتفوی	پورتفوی ۳
12.13	14.3	بازدهی کل پورتفوی	
0.6	0.36	ریسک پورتفوی	
3.85	5.8	اختلاف بازده با پورتفوی هموزن	
0.13	0.25	نسبت بازدهی روزانه به ریسک	
0	-0.01	بازدهی روزانه پورتفوی	پورتفوی ۴
0.29	-2.23	بازدهی کل پورتفوی	
0.7	0.43	ریسک پورتفوی	
4.09	4.8	اختلاف بازده با پورتفوی هموزن	
0.00	-0.02	نسبت بازدهی روزانه به ریسک	
-0.03	0.04	بازدهی روزانه پورتفوی	پورتفوی ۵
-4.29	5.56	بازدهی کل پورتفوی	
1.03	1.17	ریسک پورتفوی	
14.89	34	اختلاف بازده با پورتفوی هموزن	
-0.03	0.03	نسبت بازدهی روزانه به ریسک	

ارزیابی عملکرد مدل‌ها روی پورتفوی‌ها

از جدول ۶ می‌توان دریافت که معیار بازدهی پورتفوی مطابق مدل SVR+MSAD، در پورتفوی‌های ۱ و ۲ نسبت به CNN+MSAD بهتر است. معیار بازدهی کل پورتفوی مطابق با مدل SVR+MSAD نیز در پورتفوی‌های ۱، ۲ و ۴ از CNN+MSAD بهتر می‌باشد. معیار ریسک پورتفوی بر مبنای مدل CNN+MSAD، در همه پورتفوی‌ها بجز پورتفوی ۵، بهتر از SVR+MSAD است. اختلاف بازده پورتفوی بهینه با پورتفوی هم‌وزن بر اساس مدل CNN+MSAD در همه پورتفوی‌ها، بهتر از مدل SVR+MSAD می‌باشد. در نهایت، نسبت

بازدهی روزانه به ریسک پورتنفوی در مدل CNN+MSAD در همه پورتنفوی‌ها بهتر از مدل SVR+MSAD می‌باشد.

باتوجه به تجزیه و تحلیل‌های فوق، این نتیجه حاصل می‌شود که مدل CNN+MSAD عملکرد بهتری نسبت به SVR+MSAD دارد.

نتیجه‌گیری و پیشنهادها

در این پژوهش از شبکه عصبی کانولوشنال (CNN) برای ساخت مدل بهینه‌سازی پورتنفوی مبتنی بر پیش‌بینی استفاده شده است که هم دارای مزایای تکنولوژی یادگیری عمیق بوده و هم از مزایای تئوری مدرن پورتنفوی برخوردار است.

این پژوهش به بررسی و بهینه‌سازی پورتنفوی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌پردازد. جمعیت آماری شامل ۵۰ شرکت برتر بورس تهران است که به روش غیر احتمالی و قضاوتی انتخاب شده‌اند. داده‌های مورد استفاده شامل اطلاعات کلیدی نظیر قیمت باز و بسته شدن، قیمت بالا و پایین و حجم معاملات است. داده‌ها پس از پیش‌پردازش و نرمال‌سازی، برای آموزش و تست مدل‌های یادگیری عمیق شبکه‌ی CNN در نرم‌افزار Python3 و با استفاده از بسته Keras آماده می‌شود. معیارهای ارزیابی مدل‌ها شامل MSE، MAE و نرخ‌های HR+، HR- هستند. قلمرو مکانی این تحقیق شرکت‌های بورس تهران و قلمرو زمانی آن بازه ۱۰ ساله از ۱ فروردین سال ۱۳۹۲ تا ۲۹ اسفند سال ۱۴۰۱ است.

پس از آموزش مدل روی داده‌های آموزش (از سال ۱۳۹۲ تا ۱۳۹۹) و اعتبارسنجی مدل روی داده‌های سال ۱۴۰۰، عملکرد مدل روی داده‌های تست که مربوط به سال ۱۴۰۱ می‌باشد و مدل آنها را قبلاً ندیده بود، مورد ارزیابی قرار گرفت. نتایج حاصل از این پژوهش، نشان دهنده عملکرد بهتر مدل CNN+MSAD نسبت به مدل SVR+MSAD می‌باشد که حاکی از دقت بالای مدل‌های یادگیری عمیق نسبت به مدل‌های سنتی یادگیری ماشین می‌باشد.

این مقاله، حوزه ادبیات مربوط به مدل‌های بهینه‌سازی پورتنفوی مبتنی بر پیش‌بینی را با استفاده از DNN برای پیش‌بینی بازده، گسترش می‌دهد. همچنین، در مدل‌های پیشنهادی بهینه‌سازی پورتنفوی مبتنی بر پیش‌بینی، از انحراف نیمه مطلق به‌عنوان معیار ریسک استفاده می‌شود که کاربرد

آن‌ها را در مسائل بهینه‌سازی پورتفوی در مقیاس بزرگ ممکن می‌سازد. در نتیجه، این مقاله، توانایی امیدوارکننده شبکه‌های عصبی عمیق در ساخت پورتفوی مبتنی بر پیش‌بینی را ارائه می‌کند و سرمایه‌گذاران را تشویق می‌کند تا از این مدل‌ها برای سرمایه‌گذاری عملی استفاده کنند.

این مقاله همچنین دارای محدودیت‌هایی است؛ چون تنها از داده‌های تاریخی ساده به‌عنوان ویژگی‌های ورودی در فرایند پیش‌بینی سهام استفاده می‌کند. شاخص‌های تکنیکال، شاخص‌های مالی، شاخص‌های اقتصادی می‌توانند عملکرد DNN‌ها را در پیش‌بینی سهام بهبود بخشند.

همچنین، می‌توان از معیارهای ریسک دیگری مانند نسبت شارپ، نسبت اومگا، ارزش در معرض ریسک شرطی (CVaR) در ساخت مدل‌های بهینه‌سازی پورتفوی استفاده نمود. در مطالعات آتی می‌توان از ویژگی‌های ورودی بیشتر و معیار ریسک بهتر و همچنین شبکه‌های عصبی دیگری همچون LSTM، MLP و یا ترکیبی از این شبکه‌ها در ساخت مدل‌های پورتفوی مبتنی بر پیش‌بینی استفاده کرد و عملکرد آنها بهبود بخشید. همچنین جهت چینه‌سازی پورتفوی‌ها نیز می‌توان از معیارهایی همچون ارزش بازار، P/E یا سایر نسبت‌های مالی شرکت‌ها استفاده نمود.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

فهرست منابع

- Freitas, F. D., De Souza, A. F., & De Almeida, A. R. (2009). Prediction-based portfolio optimization model using neural networks. *Neurocomputing*, 72(10-12), 2155-2170. Doi: 10.1016/j.neucom.2008.08.019
- Nafia, A., Yousfi, A., & Echaoui, A. (2023). Equity-Market-Neutral Strategy Portfolio Construction Using LSTM-Based Stock Prediction and Selection: An Application to S&P500 Consumer Staples Stocks. *International Journal of Financial Studies*, 11(2), 57. Doi: 10.3390/ijfs11020057
- de Freitas, F. D., De Souza, A. F., & de Almeida, A. R. (2006). A prediction-based portfolio optimization model. In *Proc. 5th Int. Symp. Robot. Automat.* (pp. 520-525).
- Hao, C., Wang, J., Xu, W., & Xiao, Y. (2013, November). Prediction-based portfolio selection model using support vector machines. In *2013 Sixth International Conference on Business Intelligence and Financial Engineering* (pp. 567-571). IEEE.
- Wang, J. Z., Wang, J. J., Zhang, Z. G., & Guo, S. P. (2011). Forecasting stock indices with back propagation neural network. *Expert Systems with Applications*, 38(11), 14346-14355. Doi: 10.1016/j.eswa.2011.04.222
- Lin, C. M., Huang, J. J., Gen, M., & Tzeng, G. H. (2006). Recurrent neural network for dynamic portfolio selection. *Applied Mathematics and Computation*, 175(2), 1139-1146.
- Samarawickrama, A. J. P., & Fernando, T. G. I. (2017, December). A recurrent neural network approach in predicting daily stock prices an application to the Sri Lankan stock market. In *2017 IEEE International Conference on Industrial and Information Systems (ICIIS)* (pp. 1-6). IEEE.
- Lee, H. C., & Ko, B. (2019). Fund price analysis using convolutional neural networks for multiple variables. *IEEE Access*, 7, 183626-183633.
- Ma, Y., Han, R., & Wang, W. (2020). Prediction-based portfolio optimization models using deep neural networks. *Ieee Access*, 8, 115393-115405. Doi: 10.1109/ACCESS.2020.3003819
- Lee, S. I., & Yoo, S. J. (2020). Threshold-based portfolio: the role of the threshold and its applications. *The journal of supercomputing*, 76(10), 8040-8057.
- Alizadeh, M., Rada, R., Jolai, F., & Fotoohi, E. (2011). An adaptive neuro-fuzzy system for stock portfolio analysis. *International Journal of Intelligent Systems*, 26(2), 99-114.
- Sharif Far, A., Khaliliaraghi, M., Raeesi Vanani, I., & Fallahshams, M. (2022). Application of Deep Learning Architectures in Stock Price Forecasting: A Convolutional Neural Network Approach. *Journal of Asset Management and Financing*, 10(3), 1-20. [In Persian] doi: 10.22108/AMF.2022.129205.1673
- Heidari, M., & Amiri, H. (2022). Inspecting the Predictive Power of Artificial Intelligence Models in Predicting the Stock Price Trend in Tehran Stock Exchange. *Financial Research Journal*, 24(4), 602-623. [In Persian] doi: 10.22059/FRJ.2022.320064.1007149
- Zoghi, S., Raei, R., & Falahpor, S. (2022). Presenting a market direction prediction model for gold coin trades in Iran's Commodity Exchange market using Long Short-Term Memory (LSTM) algorithm. *Financial Engineering and Portfolio Management*, 13(53), 34-53. [In Persian]
- Sarchami, M., Khodamipour, A., Mohammadi, M., & Zeinali, H. (2020). Applying machine learning models in creation of share optimum portfolio and their comparison. *Financial Engineering and Portfolio Management*, 11(45), 147-176. [In Persian] doi: 20.1001.1.22519165.1399.11.45.7.4

- 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. Doi: 10.1016/j.eswa.2018.08.003
- 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. Doi: 10.1016/j.ejor.2017.11.054
- 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. Doi: 10.1016/j.eswa.2019.113042
- 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. Doi: 10.3390/app10020437
- Chaweewanchon, A., & Chaysiri, R. (2022). Markowitz mean-variance portfolio optimization with predictive stock selection using machine learning. *International Journal of Financial Studies*, 10(3), 64. Doi: doi.org/10.3390/ijfs10030064
- Yang, M., & Wang, J. (2022). Adaptability of financial time series prediction based on BiLSTM. *Procedia Computer Science*, 199, 18-25. Doi: 10.1016/j.procs.2022.01.003
- Books
- Deboeck, G. J. (Ed.). (1994). *Trading on the edge: neural, genetic, and fuzzy systems for chaotic financial markets* (Vol. 39). John Wiley & Sons. ISBN: 978-0-471-31100-3

