

Prediction-Based Portfolio Optimization in Tehran Stock Exchange; NARX and LSTM Neural Networks Approach¹

Razieh Sahrai², Ali Akbar Gholizadeh³, Hamid Sepehrdoust⁴,
Seyed Ehsan Hosseinidoust⁵

Received: 2024/05/03
Accepted: 2025/01/05

Research Paper

Abstract

The purpose of present study is to implement prediction-based portfolio optimization in Tehran Stock Exchange using nonlinear autoregressive with exogenous variables (NARX) neural network as main approach and long short term memory (LSTM) neural network as competing approach and comparing its performance with Markowitz mean-variance portfolio optimization method. For this purpose, firstly, ranking and identifying stocks of the companies that are profitable to invest in was done by using Sharpe's single-index model, then in order to estimate expected return index and portfolio risk, prediction of the return of companies' stocks and variance of prediction errors were used based on mentioned approaches, and then portfolio optimization is done based on Markowitz's mean-variance general method. Companies included in the index of 50 most active stock companies related to end of 1400 are considered as the sample, and estimates were made using daily data related to the time period from 1/2/1399 to 29/12/1400. Results show that NARX neural network approach is more accurate than LSTM neural network approach in predicting returns of companies' stocks and defeats it in optimization stage. Prediction-based portfolio optimization using NARX and LSTM neural networks provides lower risk and higher maximum Sharpe ratio compared to mean-variance Markowitz portfolio optimization.

Key Words: Portfolio Optimization, Prediction, NARX Neural Network, LSTM Neural Network, Markowitz.

JEL Classification: G11, G17, C53, C58.

1. doi: 10.22034/JSE.2024.12328.2202


2. Ph.D Student, Department of Economics, Faculty of Economic and Social Sciences, Bu-Ali Sina University, Hamedan, Iran. (razieh.sahrai@gmail.com)

3. Associate Professor, Department of Economics, Faculty of Economic and Social Sciences, Bu-Ali Sina University, Hamedan, Iran. (Corresponding Author). (a.gholizadeh@basu.ac.ir).

4. Professor, Department of Economics, Faculty of Economic and Social Sciences, Bu-Ali Sina University, Hamedan, Iran. (h.sepehrdoust@basu.ac.ir).

5. Assistant Professor, Department of Economics, Faculty of Economic and Social Sciences, Bu-Ali Sina University, Hamedan, Iran. (hosseinidoust@basu.ac.ir).





سازمان بورس و اوراق بهادار، مرکز پژوهش، توسعه و مطالعات اسلامی

فصلنامه بورس اوراق بهادار، سال هجدهم، شماره ۷۰، تابستان ۱۴۰۴، صص ۱۳۴-۱۰۵

بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی در بورس اوراق بهادار تهران؛ رویکرد شبکه‌های عصبی LSTM و NARX^۱

راضیه صحرایی^۲، علی اکبر قلی‌زاده^۳، حمید سپهردوست^۴، سید احسان حسینی دوست^۵

تاریخ دریافت: ۱۴۰۳/۰۲/۱۴

تاریخ پذیرش: ۱۴۰۳/۱۰/۱۶

مقاله پژوهشی

چکیده

هدف از مطالعه حاضر پیاده‌سازی بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی در بورس اوراق بهادار تهران با استفاده از شبکه عصبی خودبازگشتی غیرخطی با متغیرهای برونزا (NARX) به‌عنوان رویکرد اصلی و شبکه عصبی حافظه کوتاه‌مدت طولانی (LSTM) به‌عنوان رویکرد رقیب و نیز مقایسه عملکرد آن با روش بهینه‌یابی پرتفوی میانگین-واریانس مارکوفیتز است. بدین منظور ابتدا رتبه‌بندی و تشخیص سهام شرکت‌هایی که سرمایه‌گذاری روی آن‌ها به‌صرفه‌است با بهره‌گیری از مدل تک عامله شارپ صورت گرفته، سپس در راستای برآورد شاخص بازده مورد انتظار و ریسک پرتفوی از پیش‌بینی بازدهی سهام شرکت‌ها و واریانس خطاهای پیش‌بینی برپایه رویکردهای یادشده استفاده و پس از آن بهینه‌یابی پرتفوی براساس روش کلی میانگین-واریانس مارکوفیتز انجام شده‌است. شرکت‌های موجود در شاخص ۵۰ شرکت فعال تر بورسی مربوط به پایان سال ۱۴۰۰ به عنوان نمونه در نظر گرفته شدند و برآوردها با استفاده از داده‌های روزانه مربوط به دوره زمانی ۱۳۹۹/۲/۱ تا ۱۴۰۰/۱۲/۲۹ انجام شد. نتایج نشان می‌دهد رویکرد شبکه عصبی NARX نسبت به رویکرد شبکه عصبی LSTM دقت بالاتری در پیش‌بینی بازدهی سهام شرکت‌ها دارد و در مرحله بهینه‌یابی نیز آن را مغلوب می‌کند. بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه‌های عصبی LSTM و NARX در مقایسه با بهینه‌یابی پرتفوی میانگین-واریانس مارکوفیتز ریسک کمتر و حداکثر نرخ شارپ بالاتری را فراهم می‌آورد.

واژه‌های کلیدی: بهینه‌یابی پرتفوی، پیش‌بینی، شبکه عصبی NARX، شبکه عصبی LSTM، مارکوفیتز.

طبقه‌بندی موضوعی: G11, G17, C53, C58.

doi: 10.22034/JSE.2024.12328.2202

۲. دانشجوی دکتری، گروه اقتصاد، دانشکده اقتصاد و علوم اجتماعی، دانشگاه بوعلی سینا، همدان، ایران. (razieh.sahrai@gmail.com).

۳. دانشیار، گروه اقتصاد، دانشکده علوم اقتصادی و اجتماعی، دانشگاه بوعلی سینا، همدان، ایران. (نویسنده مسئول). (a.gholizadeh@basu.ac.ir).

۴. استاد، گروه اقتصاد، دانشکده علوم اقتصادی و اجتماعی، دانشگاه بوعلی سینا، همدان، ایران. (h.sepehrdoust@basu.ac.ir).

۵. استادیار، گروه اقتصاد، دانشکده علوم اقتصادی و اجتماعی، دانشگاه بوعلی سینا، همدان، ایران. (hosseinidoust@basu.ac.ir).

حق انتشار این مستند، متعلق به نویسندگان آن است. ۱۴۰۴. ©. ناشر این مقاله، سازمان بورس و اوراق بهادار است.

این مقاله تحت گواهی زیر منتشرشده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است.



Creative Commons Attribution-NonCommercial 4.0 International license
(<https://creativecommons.org/licenses/by-nc/4.0/>)

مقدمه

مسئله بهینه‌یابی پرتفوی یکی از مهم‌ترین زمینه‌های پژوهشی در مدیریت ریسک است. در سال ۱۹۵۲، مارکوویتز^۱ مسئله چگونگی تعیین سبد سرمایه‌گذاری بهینه در روبرویی با ریسک را با عنوان تئوری پرتفوی مدرن (MPT)^۲ تبیین کرد. در مدل میانگین-واریانس مارکوویتز با در نظر گرفتن یک فرض اساسی مبنی بر نرمال بودن توزیع بازدهی‌های گذشته هر سهم، از میانگین سری زمانی بازدهی‌های گذشته سهام به عنوان شاخص بازدهی انتظاری سهام استفاده شده است. همچنین با اتکا بر همین فرض واریانس بازدهی‌های گذشته سهام به عنوان معیار ریسک پرتفوی معرفی شده است. توزیع سری‌های زمانی بازدهی سهام اغلب با نشان دادن کشیدگی و چولگی از فرض نرمال بودن عدول می‌کنند و این فرض در دنیای واقعی به سختی برقرار است (ما، هان و وانگ^۳، ۲۰۲۰ و فریتاس، دی سوزا و آلمدیا^۴، ۲۰۰۹). استفاده از میانگین بازدهی‌های گذشته سهام به عنوان بازدهی انتظاری، تنها برای سرمایه‌گذاری بلندمدت در بازار سهام مناسب است و برای سرمایه‌گذاری کوتاه مدت، از جمله سفته‌بازی‌های کوتاه‌مدت، مناسب نیست (ما و همکاران، ۲۰۲۰، ما، هان و وانگ^۵، ۲۰۲۱، کارابی، حیدری و یوسف زاده^۶، ۲۰۲۲). همچنین تصمیمات سرمایه‌گذاری مربوط به آینده است و استفاده از معیارهایی که تنها مبتنی بر بازدهی‌های تحقق یافته است، مناسب نیست (اوستون و کاسمبلی^۷، ۲۰۱۲ و کارابی و همکاران، ۲۰۲۲). این موضوع سبب می‌شود شاخص‌های استفاده شده برای بازدهی انتظاری و ریسک پرتفوی در مدل‌های کلاسیک بهینه‌یابی پرتفوی تبدیل به شاخص‌های نامناسب شوند. بازدهی انتظاری و ریسک دو بعد اصلی در بهینه‌یابی پرتفوی هستند (آدینه‌وند، رازینی، خدام، اوحدی و هاشمی زاده، ۱۴۰۲: ۱۶۱). استفاده از شاخص‌های نامناسب منجر به تصمیم‌گیری‌های نادرست می‌شود که تبعات جبران‌ناپذیر از بین رفتن منابع سرمایه‌گذاران را در پی خواهد داشت. این مسائل توسعه مدل‌های بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی را به عنوان راهی برای پشتیبانی از نیازهای سرمایه‌گذاری در دوره‌های زمانی کوتاه مدت، تشویق و ترغیب کرده است (فریتاس،

1 . Markowitz (1952)

2 . Modern Portfolio Theory

3 . Ma, Y; Han, R. & Wang, W.

4 . & Freitas, F.D; De Souza, A.F. & Almeida, A.R.

5 . Ma, Y; Han, R. & Wang, W.

6 . Karabi, A; Heydari, A. & Yousefzade, H.R.

7 . Ustun, O. & Kasimbeyli, R.

دی سوزا و المديا، ۲۰۰۶). پژوهش‌های نشان می‌دهد مدل‌های بهینه‌یابی پرتفوی مبتنی بر پیش-بینی برای استراتژی‌های سرمایه‌گذاری کوتاه‌مدت مناسب‌تر هستند (هاو، وانگ، خو و شیائو^۱، ۲۰۱۴).

مدل‌های مبتنی بر پیش‌بینی^۲ به طور کلی در دو مجموعه طبقه‌بندی می‌شوند: مدل‌های آماری^۳ و مدل‌های مبتنی بر هوش مصنوعی^۴ (AI). مدل‌های آماری به عنوان روش‌های خطی یا سنتی نیز شناخته می‌شوند. روش‌های خطی یک محدودیت جدی دارند چرا که نمی‌توانند هیچ رابطه غیرخطی را در داده‌ها الگوسازی کنند (رادر، ساستری و آگاروال^۵، ۲۰۱۷؛ رادر^۶، ۲۰۱۹). به طور کلی داده‌های مربوط به بازارهای مالی دارای مشخصه‌های مهمی هستند به شکلی که غیرخطی، غیرپارامتریک، غیرایستا، دارای تلاطم^۷، همراه با نویز بالا^۸ و به طور قطع دارای سیستم بی‌نظم^۹ در ذات خود هستند (پای و ایلانگو^{۱۰}، ۲۰۲۰ و راسل، سلطانا و میساد^{۱۱}، ۲۰۱۵). پژوهشگران برای اینکه بر محدودیت‌های مدل‌های آماری فائق آیند، مدل‌های مبتنی بر هوش مصنوعی را توسعه دادند که پیش از این در بسیاری از مطالعات برای تحلیل روند بازارهای مالی به منظور توضیح و درک الگوی روند قیمت و بازدهی سهام مورد استفاده قرار گرفته است (رادر و همکاران، ۲۰۱۷ و راسل و همکاران، ۲۰۱۵). در بین مدل‌های مبتنی بر هوش مصنوعی، شبکه عصبی مصنوعی در رشته سیستم‌های مبتنی بر پیش‌بینی بسیار مشهور است و برای پیش‌بینی داده‌های غیرایستا معمول‌ترین استفاده را دارد (کیانی زاده، باغانی و حمیدیان، ۱۴۰۲: ۸۲ و رادر، ۲۰۱۹). در این بین شبکه‌های عصبی بازگشتی^{۱۲} (RNNs) با توجه به استفاده از سیگنال‌های خودبازگشتی در فرآیند شبیه‌سازی برای پیش‌بینی داده‌های سری زمانی بسیار مناسب هستند و زیر مجموعه یادگیری عمیق^{۱۳} قرار دارند. یکی از انواع شبکه‌های عصبی بازگشتی، شبکه عصبی

1. Hao, C; Wang, J; Xu, W. & Xiao, Y.

2. Prediction-Based

3. Statistical

4. Artificial Intelligence

5. Rather, A.M; Sastry, V.N. & Agarwal, A.

6. Rather, A.M.

7. volatile

8. high noise

9. chaotic

10. Pai, N. & Ilango, V.

11. Rasel, R. I; Sultana, N. & Meesad, P.

12. Recurrent Neural Networks

13. Deep Learning

خودبازگشتی غیرخطی با متغیرهای برونزا (NARX)^۱ است که برای پیش‌بینی داده‌های سری زمانی غیرخطی که دارای سیستم بی‌نظم در ذات خود هستند (مانند بازدهی سهام) بسیار مناسب است (شیو و ژانگ^۲، ۲۰۱۷). در مطالعات خارجی از رویکرد یادشده برای پیش‌بینی انواع متغیرها در بازارهای مالی استفاده شده است و برتری آن در مقایسه با انواع دیگر شبکه‌های عصبی به اثبات رسیده است (بوسی^۳، ۲۰۲۰؛ دیوین^۴، ۲۰۱۷ و گریگوریان^۵، ۲۰۱۵). هرچند استفاده از رویکرد یادشده در زمینه بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی، با توجه به پیچیدگی پیاده‌سازی الگوریتم آن، در مطالعات خارجی و داخلی مغفول واقع شده است. همچنین شبکه عصبی حافظه کوتاه‌مدت طولانی (LSTM)^۶ نیز یکی از انواع شبکه‌های عصبی بازگشتی است که در زمینه پیش‌بینی بازدهی سهام و بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی به کار گرفته شده (ما و همکاران، ۲۰۲۰ و ۲۰۲۱، تا، لیو و تادس^۷، ۲۰۲۰، بوسی، ۲۰۲۰)، هر چند از رویکرد یادشده تا به حال در زمینه بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی در بورس اوراق بهادار تهران استفاده نشده است. بر این اساس مطالعه حاضر به منظور بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی در بورس اوراق بهادار تهران از شبکه عصبی NARX به عنوان رویکرد اصلی و از شبکه عصبی LSTM به عنوان رویکرد رقیب استفاده می‌کند.

برخی مطالعات انجام شده در زمینه بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی در کنار استفاده از انواع رویکردها به منظور پیش‌بینی بازدهی سهام، از خطاهای پیش‌بینی در راستای برآورد شاخص ریسک پرتفوی بهره بردند و به نتایج امیدوارکننده‌ای دست یافتند (فریتاس و همکاران، ۲۰۰۶ و ۲۰۰۹، هاو و همکاران، ۲۰۱۴، اوستون و کاسمبیلی^۸، ۲۰۱۲ و ما و همکاران، ۲۰۲۰). مطالعه حاضر نیز در کنار استفاده از شبکه‌های عصبی NARX و LSTM به منظور پیش‌بینی بازدهی سهام، از خطاهای پیش‌بینی رویکردهای یادشده به منظور برآورد شاخص ریسک پرتفوی استفاده می‌کند. در بین مطالعات داخلی تا به حال از شاخص خطاهای پیش‌بینی به عنوان شاخص ریسک در بحث بهینه‌یابی پرتفوی استفاده نشده است.

1. Nonlinear Autoregressive neural network with exogenous inputs (NARX)
2. Xiu, Y. & Zhang, W.
3. Bucci
4. Divine
5. Garigoryan
6. Long Short Term Memory
7. Ta, V-D; Liu C-M & Tadesse, DA.
8. Ustun, O. & Kasimbeyli, R.

یکی دیگر از معایب مدل بهینه‌یابی پرتفوی مارکوویتز عدم ارائه روشی برای انتخاب سهام شرکت‌ها پیش از ورود به مرحله بهینه‌یابی پرتفوی است. بر این اساس با افزایش تعداد شرکت‌های ورودی، تعداد ضرایب همبستگی که می‌بایست محاسبه شود افزایش می‌یابد که زمان‌بر و پرهزینه خواهد بود. از طرفی مدیریت یک پرتفوی با تعداد زیاد شرکت‌ها کاری دشوار است. برای رفع این مشکل ویلیام شارپ^۱ مدلی را تحت عنوان مدل تک عامله^۲ ارائه داده است که بر اساس آن سهام شرکت‌ها رتبه‌بندی شده و بر مبنای معیاری به نام نرخ کات اف^۳ تنها سهام شرکت‌هایی که از لحاظ اقتصادی سرمایه‌گذاری روی آن‌ها به صرفه است وارد مرحله بهینه‌یابی پرتفوی می‌شوند. در مطالعه حاضر نیز از مدل تک عامله شارپ به منظور حل مشکل یادشده استفاده شده است.

در بخش دوم از مطالعه حاضر به بحث و بررسی پیرامون مبانی نظری و توسعه فرضیه‌ها پرداخته می‌شود. در بخش سوم روش انجام پژوهش مورد بررسی قرار می‌گیرد. در بخش چهارم یافته‌ها و در بخش پنجم بحث و نتیجه‌گیری نهایی پیرامون مطالعه حاضر ارائه می‌شود.

مبانی نظری و توسعه فرضیه‌ها

در مبانی نظری مطالعه حاضر ابتدا مدل بهینه‌یابی پرتفوی میانگین-واریانس مارکوویتز و مدل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی مطرح می‌شود، سپس فرضیه‌های پژوهش و مطالعات پیشین مورد بحث و بررسی قرار خواهد گرفت.

مارکوویتز مسئله چگونگی تعیین سبد سرمایه‌گذاری بهینه سرمایه‌گذاران در روبرویی با ریسک را به گونه‌ای تبیین کرد که جزء کلیدی آن تنوع‌بخشی است. هدف از تنوع‌بخشی انتخاب صحیح یک مجموعه وزن‌دار از دارایی‌های سرمایه‌ای است که به طور کلی ریسک کمتری نسبت به سرمایه‌گذاری در هر دارایی منفرد نشان می‌دهد. میزان کاهش ریسک پرتفوی با استفاده از تنوع‌بخشی به ارتباط بین دارایی‌های ترکیب شده وابسته است، هر چقدر همبستگی منفی بین دارایی‌ها بیشتر باشد ریسک پرتفوی کمتر خواهد بود. در مدل میانگین-واریانس مارکوویتز از میانگین سری زمانی بازدهی‌های گذشته سهام به عنوان شاخص بازدهی انتظاری پرتفوی استفاده شده است:

1 . William F. Sharpe
2 . single – index model
3 . cut off rate

معادله (۱) بازدهی سهام شرکت i در زمان t را نشان می‌دهد:

$$r_{it} = \frac{p_t - p_{t-1}}{p_{t-1}} \times 100 \quad (۱)$$

که در آن p_t قیمت سهام شرکت i در زمان t و p_{t-1} قیمت سهام شرکت i در زمان $t-1$ است. معادله (۲) بازدهی انتظاری مربوط به سهام شرکت i ($\bar{r}_i$) را نشان می‌دهد که میانگین وزنی بازدهی‌های گذشته سهام شرکت i طی N دوره زمانی گذشته است:

$$\bar{r}_i = \frac{1}{N} \sum_{t=1}^N r_{it} \quad (۱)$$

برپایه معادله (۳) معیار ریسک که توسط مارکوویتز پیشنهاد شده، واریانس سری زمانی بازدهی‌های گذشته سهام، σ_i^2 ، است:

$$\sigma_i^2 = \frac{1}{N-1} \sum_{t=1}^N (r_{it} - \bar{r}_i)^2 \quad (۲)$$

بر این اساس مدل بهینه‌یابی پرتفوی مارکوویتز به شکل زیر است:

Minimize

$$\sigma_p^2 = \sum_{i=1}^M W_i^2 \sigma_i^2 + \sum_{i=1}^M \sum_{j=1, j \neq i}^M W_i W_j \gamma_{ij} \quad (۴)$$

Subject to

$$\bar{r}_p = \sum_{i=1}^M W_i \bar{r}_i \geq R \quad (۵)$$

$$\sum_{i=1}^M W_i = 1 \quad (۶)$$

$$W_i \geq 0, i = 1, \dots, M \quad (۷)$$

در معادلات بالا تابع هدف ریسک پرتفوی می‌باشد که کمینه شده است. ریسک پرتفوی بر اساس ترکیب خطی واریانس بازدهی سهام شرکت‌ها معرفی می‌شود. W_i میزان مشارکت سهام شرکت i در پرتفوی است. معادله (۵) قید بازدهی است که یک حداقل میزان بازدهی را

برای پرتفوی تضمین می‌کند. $\bar{r}_p$ بازدهی انتظاری پرتفوی است که از جمع وزنی میانگین بازدهی‌های گذشته سهام شرکت‌ها به دست می‌آید. معادله (۶) تخصیص تمام منابع را تضمین می‌کند و قید بودجه سرمایه‌گذار است. معادله (۷) مدل را تنها به مبادلات خرید محدود می‌کند و اجازه فروش استقراضی^۱ را به سرمایه‌گذار نمی‌دهد.

ریسک میزان اختلاف میان بازده واقعی و بازده مورد انتظار سرمایه‌گذار است. در صورتی که برای برآورد شاخص بازدهی انتظاری از رویکردهای پیش‌بینی بازدهی استفاده شود، بهره بردن از خطاهای پیش‌بینی به منظور برآورد شاخص ریسک منطقی است. در ادامه یک مدل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی معرفی می‌شود که در آن به منظور برآورد شاخص ریسک پرتفوی از واریانس خطاهای پیش‌بینی، استفاده شده است:

$$r_{it} = \hat{r}_{it} + \epsilon_{it} \quad (۸)$$

$$\epsilon_{it} = r_{it} - \hat{r}_{it} \quad (۹)$$

$$\sigma_{\epsilon i}^2 = \frac{1}{n-1} \sum_{t=1}^n \epsilon_{it}^2 \quad (۱۰)$$

$$\hat{\sigma}_p^2 = \sum_{i=1}^M W_i^2 \sigma_{\epsilon i}^2 + \sum_{i=1}^M \sum_{j=1, j \neq i}^M W_i W_j \gamma_{\epsilon ij} \quad (۳)$$

بازدهی واقعی سهام شرکت i در زمان t ، r_{it} ، است و $\hat{r}_{it}$ بازدهی پیش‌بینی شده سهام شرکت i در زمان t است. ϵ_{it} خطای پیش‌بینی بازدهی سهام شرکت i در زمان t است. واریانس خطاهای پیش‌بینی به صورت معادله (۱۰) تعریف می‌شود. معادله (۱۱) ریسک پرتفوی را نشان می‌دهد که نخستین بخش آن ریسک فردی برای سهام هر یک از شرکت‌های موجود در پرتفوی بهینه است و بخش دوم آن ریسک مشترک هر زوج از سهام شرکت‌هاست که از کوواریانس خطاهای پیش‌بینی بازدهی سهام شرکت‌های i و j حاصل شده است:

$$\gamma_{\epsilon ij} = \frac{1}{n-1} \sum_{t=1}^n \epsilon_{it} \epsilon_{jt} \quad (۱۲)$$

مدل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی بر اساس روش کلی بهینه‌یابی میانگین-واریانس مارکوویتز به شکل زیر تعریف می‌شود:

Minimize

$$\hat{\sigma}_p^2 = \sum_{i=1}^M W_i^2 \sigma_{\epsilon i}^2 + \sum_{i=1}^M \sum_{j=1, j \neq i}^M W_i W_j \gamma_{\epsilon ij} \quad (13)$$

Subject to

$$\hat{r}_p = \sum_{i=1}^M W_i \hat{r}_{it} \geq R \quad (14)$$

بر اساس معادله (۱۴) بازدهی پرتفوی، $\hat{r}_p$ ، مجموع وزنی بازدهی‌های پیش‌بینی شده سهام شرکت‌هاست. نتیجه بهینه‌یابی مقید بالا یافتن وزن بهینه مربوط به سهام هر یک از شرکت‌های موجود در پرتفوی بهینه است. قیود (۶) و (۷) در بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی نیز برقرار است (فریتاس و همکاران، ۲۰۰۶ و ۲۰۰۹ و ما و همکاران، ۲۰۲۰).

فرضیه‌های مطالعه حاضر به صورت زیر است:

۱. عملکرد شبکه عصبی غیرخطی خود بازگشتی با متغیرهای برون‌زا (NARX) در خصوص پیش‌بینی بازدهی سهام شرکت‌های بورس اوراق بهادار تهران در مقایسه با شبکه عصبی حافظه کوتاه مدت طولانی (LSTM) بهتر است.
۲. عملکرد روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی NARX، در مقایسه با روش بهینه‌یابی پرتفوی میانگین-واریانس مارکوویتز در بورس اوراق بهادار تهران بهتر است.
۳. عملکرد روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی LSTM، در مقایسه با روش بهینه‌یابی پرتفوی میانگین-واریانس مارکوویتز در بورس اوراق بهادار تهران بهتر است.
۴. عملکرد روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی NARX، در مقایسه با روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی LSTM در بورس اوراق بهادار تهران بهتر است.

در ادامه تعدادی از مطالعات پیشین انجام شده در زمینه بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی، استفاده از شبکه‌های عصبی NARX و LSTM به عنوان رویکردهای پیش‌بینی و نیز استفاده از خطاهای پیش‌بینی به منظور برآورد شاخص ریسک پرتفوی آورده شده است:

کارابی و همکاران در سال ۲۰۲۲ یک مدل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی دو مرحله‌ای در بورس اوراق بهادار تهران ارائه دادند که در مرحله اول از توان هرست^۱ به عنوان یک فیلتر برای شناسایی سهام شرکت‌هایی که پایدار^۲ هستند، استفاده کرده و سپس از مدل رگرسیون بردار پشتیبان (SVR)^۳ به منظور پیش‌بینی روند قیمت سهام شرکت‌های پایدار بهره بردند. در مرحله دوم بر اساس روند قیمت پیش‌بینی شده، سهام شرکت‌هایی که دارای بازدهی مثبت هستند انتخاب شدند و بهینه‌یابی پرتفوی با استفاده از الگوریتم ازدحام ذرات چند هدفه صورت گرفته و وزن بهینه مربوط به سهام هر یک از شرکت‌ها استخراج شده است. نتایج بیانگر آن است که رویکرد پیشنهادی عملکرد بهتری نسبت به رویکردهای گذشته‌نگر در تقریب مرز کارا دارد.

ذولفقاری، سحابی و بختیاری در سال ۱۳۹۹ یک رویکرد ترکیبی از شبکه عصبی یادگیری عمیق و رویکردهای منتخب خانواده GARCH به منظور پیش‌بینی کوتاه‌مدت بازدهی روزانه شاخص کل بورس اوراق بهادار تهران معرفی کردند. در این پژوهش از میان رویکردهای یادگیری عمیق، شبکه بازگشتی مبتنی بر حافظه کوتاه مدت طولانی^۴ (RNN-LSTM) انتخاب و از میان رویکردهای دارای حافظه کوتاه مدت GARCH و EGARCH^۵ انتخاب شدند. در این مطالعه به منظور دریافت پیش‌بینی از رویکرد ترکیبی یادشده به صورت گام به گام از رویکردهای ARIMA^۶، GARCH و LSTM استفاده شده است. نتایج نشان می‌دهد رویکرد ترکیبی RNN-LSTM-EGARCH^۷ دارای خطای پیش‌بینی کمتری نسبت به ۲۳ رویکرد تخمینی دیگر که شامل رویکردهای خانواده ARMA^۸ و رویکردهای خانواده GARCH و نیز رویکردهای ترکیبی حاصل از آن‌ها است.

1. Hurst exponent

2. stable stocks

3. Support Vector Regression

4. Recurrent Neural Network - Long Short Term Memory

5. Exponential Generalized Autoregressive Conditional Heteroskedasticity

6. Autoregressive Integrated Moving Average

7. Recurrent Neural Network -Long Short Term Memory- Exponential Generalized Autoregressive Conditional Heteroskedasticity

8. Autoregressive Moving Average

ما و همکاران در سال ۲۰۲۱ به منظور بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی مربوط به ۴۹ سهم از شاخص ۱۰۰ اوراق بهادار چین، ابتدا عملکرد دو متد پیش‌بینی یادگیری ماشین (مدل جنگل تصادفی (RF)^۱ و مدل رگرسیون بردار پشتیبان (SVR)) و متد یادگیری عمیق (شبکه عصبی LSTM، شبکه عصبی پرسپترون چند لایه DMLP^۲ و شبکه عصبی کانولوشنی CNN^۳) را در پیش‌بینی بازدهی سهم‌ها مورد بررسی قرار دادند و از متد پیش‌بینی ARIMA^۴ نیز به عنوان یک متد شاخص استفاده کردند. مرحله بهینه‌یابی پرتفوی با استفاده از دو متد بهینه‌یابی میانگین واریانس مارکوفیتز بر اساس پیش‌بینی (MVF)^۵ و مدل امگا بر اساس پیش‌بینی (OF)^۶ انجام شده است. نتایج بیانگر آن است که مدل جنگل تصادفی عملکرد بهتری نسبت به سایر مدل‌های پیش‌بینی دارد. مقایسه پرتفوی‌های ایجاد شده بر اساس هر دو متد نشان می‌دهد، متد بهینه‌یابی پرتفوی میانگین واریانس بر اساس پیش‌بینی با مدل جنگل تصادفی (RF+MVF)^۷ عملکرد بهتری نسبت به سایر متدها داشته است.

تا، لیو و تادس^۸ در سال ۲۰۲۰ شبکه عصبی بازگشتی LSTM را برای پیش‌بینی قیمت سهام و بهینه‌یابی پرتفوی پیشنهاد کردند. بر این اساس ابتدا مقایسه‌ای بین عملکرد پیش‌بینی توسط شبکه عصبی LSTM، شبکه عصبی واحد بازگشتی گیتی (GRU)^۹، رگرسیون خطی (LR)^{۱۰} و رگرسیون بردار پشتیبان (SVR) صورت گرفته است و شبکه عصبی LSTM عملکرد بهتری را نشان می‌دهد. به منظور بهینه‌یابی پرتفوی از سه تکنیک متفاوت استفاده شده است که شامل انتخاب سهم‌ها با وزن‌های برابر (EW)^{۱۱}، شبیه سازی مونت کارلو (MCS)^{۱۲} و بهینه‌یابی میانگین واریانس (MVO)^{۱۳} است. داده‌ها مربوط به بورس اوراق بهادار آمریکا شاخص

- 1 . Random Forest
- 2 .Deep Multilayer Perceptron
- 3 . Convolutional Neural Network
- 4 . Auto Regressive Integrated Moving Average
- 5 . Mean Variance with Forecasting model
- 6 . Omega with Forecasting model
- 7 . Random Forest + Mean Variance with Forecasting model
- 8 . Ta, V-D; Liu C-M. & Tadesse, DA.
- 9 . Gated Recurrent Unit
- 10 . Linear regression
- 11 . Equal Weight
- 12 . Monte Carlo Simulation
- 13 . Mean-Variance Optimization

S&P500 هستند. پرتفوی های ایجاد شده بر اساس معیارهای نرخ شارپ (^۱SR) و بازدهی با هم مقایسه شدند. نتایج نشان می دهد روش پیش بینی LSTM در مرحله پیش بینی و در مرحله بهینه یابی پرتفوی دارای عملکرد بهتری نسبت به سایر روش ها است.

ما و همکاران در سال ۲۰۲۰ تلاش کردند عملکرد امیدوار کننده شبکه های عصبی عمیق (DNNs)^۲ در ساخت مدل های بهینه یابی پرتفوی مبتنی بر پیش بینی را نشان دهند. در این مطالعه از سه نوع شبکه عصبی عمیق با نام های پرسپترون چند لایه عمیق (DMLP)^۳، شبکه عصبی LSTM و شبکه عصبی کانولوشنی (CNN)^۴ برای پیش بینی بازدهی سهام و بهینه یابی پرتفوی مبتنی بر پیش بینی استفاده شده است، همچنین از شاخص نیم انحراف مطلق خطاهای پیش بینی رویکردهای مذکور به عنوان شاخص ریسک پرتفوی بهره بردند. داده ها مربوط به ۴۹ سهم از شاخص ۱۰۰ اوراق بهادار چین، می باشد. مدل های بهینه یابی پرتفوی مبتنی بر پیش بینی با تعمیم چارچوب تئوری پرتفوی مدرن مارکوویتز به شکل میانگین-نیم انحراف مطلق (MSAD)^۵ ساخته شدند. نتایج حاکی از برتری متد DMLP نسبت به دیگر متدها در مرحله پیش بینی و بهینه یابی پرتفوی می باشد. همچنین بهره گیری از خطاهای پیش بینی به منظور برآورد شاخص ریسک در مقابل عدم استفاده از آن آزمون شده و برتری رویکرد یادشده مشخص شده است. افزون بر مطالعه یادشده در رابطه با استفاده از خطاهای پیش بینی به منظور برآورد شاخص ریسک پرتفوی می توان به هاو و همکاران (۲۰۱۴) اشاره کرد که در یک مدل بهینه یابی پرتفوی مبتنی بر پیش بینی ابتدا از ماشین های بردار پشتیبان و نیز یکی از انواع شبکه های عصبی به عنوان رویکردی برای پیش بینی بازدهی سهام بهره بردند و از خطاهای پیش بینی، برای تدوین شاخص ریسک و بهینه یابی پرتفوی استفاده کردند. همچنین اوستون و کاسمبیلی^۶ (۲۰۱۲) به منظور بهینه یابی پرتفوی ابتدا از سه رویکرد متفاوت در جهت پیش بینی بازدهی سهام استفاده کردند سپس با استفاده از خطاهای پیش بینی آن ها شاخص ریسک پرتفوی را برآورد کردند و از نتایج آن به منظور بهینه یابی پرتفوی مبتنی بر پیش بینی بهره بردند. فریتاس و همکاران در سال های ۲۰۰۶ و ۲۰۰۹ یک مدل بهینه یابی پرتفوی مبتنی بر پیش بینی طراحی کردند که در آن ابتدا با

1 . Sharpe Ratio

2. Deep Neural Networks

3. Deep Multi-Layer Perceptron

4. Convolutional Neural Network

5 . Mean Semi Absolute Deviation

6 . Ustun, O. & Kasimbeyli, R.

استفاده از نوعی شبکه عصبی خودبازگشتی بازدهی سهام شرکت‌ها پیش‌بینی شده و سپس با استفاده از واریانس خطاهای پیش‌بینی شبکه عصبی به عنوان شاخص ریسک، بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی انجام شده است.

بوسی^۱ در سال ۲۰۲۰ به مقایسه عملکرد شبکه‌های عصبی پیش‌خور و انواع شبکه‌های عصبی بازگشتی شامل شبکه عصبی المان (ENN)^۲، شبکه عصبی جردن (JNN)^۳، شبکه عصبی LSTM و شبکه عصبی NARX و نیز رویکردهای اقتصادسنجی از جمله ARFIMAX^۴ و LSTARX^۵ در خصوص پیش‌بینی تلاطم تحقق یافته^۶ بر اساس بازدهی‌های روزانه مربوط به شاخص S&P 500 می‌پردازد. نتایج نشان می‌دهد شبکه‌های عصبی بازگشتی (RNNs) رویکردهای اقتصادسنجی را مغلوب می‌کنند. همچنین رویکردهای LSTM و NARX با توانایی کشف وابستگی‌های بلندمدت حتی در یک دوره با تلاطم بالا، دقت پیش‌بینی را بهبود می‌بخشند.

دیوین^۷ در سال ۲۰۱۷ برتری شبکه عصبی NARX را به عنوان یک تحلیل‌گر سری زمانی مالی و ابزاری برای پیش‌بینی قیمت بسته سهام و مسیر شاخص بازار سهام نشان داده است. در این مطالعه از دو مدل شبکه عصبی NARX و مدل GBM^۸ به عنوان یک ابزار پیش‌بینی مقایسه‌ای استفاده شده است. داده‌ها مربوط به شاخص بورس اوراق بهادار زیمباوه^۹ (JSE) و جوهانسبورگ^{۱۰} (JSE) در سال‌های ۲۰۱۴ تا ۲۰۱۷ است. نتایج نشان می‌دهد شبکه عصبی مصنوعی NARX در هر دو مرحله پیش‌بینی قیمت بسته و پیش‌بینی مسیر حرکت بازار سهام نسبت به روش پیش‌بینی GBM عملکرد بهتری دارد.

گریگوریان^{۱۱} در سال ۲۰۱۵ یک مدل ترکیبی پیش‌بینی بازار سهام با استفاده از شبکه عصبی NARX و روش انتخاب ویژگی تحلیل مؤلفه اصلی (PCA)^{۱۲} ارائه کرده است. مطالعه روی

1 . Bucci

2 . Elman Neural Network

3 . Jordan Neural Network

4 . Autoregressive Fractionally Integrated Moving Average with exogenous variables

5 . Logistic Fractionally Autoregressive model with exogenous variables

6 . realized volatility(RV_t)

7 . Divine

8 . Geometric Brownian Motion

9 . Zimbabwe Stock Exchange Index

10 . Johannesburg Stock Exchange Index

11 . Garigoryan

12 . Principal Component Analysis

سهام تالینک گروپ آس^۱ (نماد TAL1T) از بازار بورس اوراق بهادار ناسداک OMX بالتیک^۲ طی سال های ۲۰۱۲ تا ۲۰۱۴ انجام شده است. نتایج نشان می دهد مدل ترکیبی پیشنهادی PCA-NARX می تواند به عنوان یک متد جایگزین تکنیک های آماری استاندارد برای پیش بینی سری های زمانی مالی استفاده شود.

بررسی مطالعات پیشین نشان می دهد هرچند از رویکرد شبکه عصبی NARX به منظور پیش بینی انواع متغیرها در بازارهای مالی استفاده شده و برتری آن در مقایسه با انواع دیگر شبکه های عصبی به اثبات رسیده است ولی در زمینه بهینه یابی پرتفوی مبتنی بر پیش بینی، به دلیل پیچیدگی پیاده سازی الگوریتم آن مغفول واقع شده است. همچنین شبکه عصبی LSTM نیز در مطالعات پیشین در زمینه پیش بینی بازدهی سهام و بهینه یابی پرتفوی مبتنی بر پیش بینی به کار گرفته شده، ولی با توجه به پیچیدگی پیاده سازی الگوریتم آن تا به حال در زمینه بهینه یابی پرتفوی مبتنی بر پیش بینی در بورس اوراق بهادار تهران استفاده نشده است. از طرفی در بین مطالعات داخلی تا به حال از شاخص خطاهای پیش بینی به عنوان شاخص ریسک در بحث بهینه یابی پرتفوی استفاده نشده است. بر این اساس مطالعه حاضر به منظور بهینه یابی پرتفوی مبتنی بر پیش بینی در بورس اوراق بهادار تهران از شبکه عصبی NARX به عنوان رویکرد اصلی و از شبکه عصبی LSTM به عنوان رویکرد رقیب استفاده می کند و از خطاهای پیش بینی رویکردهای مذکور به منظور برآورد شاخص ریسک پرتفوی بهره می برد.

روش انجام پژوهش

مطالعه حاضر از روش کتابخانه ای و اسنادی برای گردآوری اطلاعات در جهت تحلیل و توصیف پژوهش استفاده کرده و به منظور برنامه نویسی از زبان برنامه نویسی پایتون نسخه ۳.۸^۳ و نرم افزار پایچارم^۴ بهره برده است. داده های آماری مورد نظر از طریق سایت کدال^۵، سامانه شرکت مدیریت فناوری بورس تهران^۶ و نیز سامانه ره آورد^۷ جمع آوری شدند. جامعه

-
- 1 . Tallink Grupp As shares
 - 2 . Nasdaq OMX Baltic stock Exchange
 - 3 . Python 8/3
 - 4 . Pycharm
 - 5 . www.codal.ir
 - 6 . <http://www.tsetmc.com>
 - 7 . www.rahavard365.com

آماري شامل شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. شاخص ۵۰ شرکت فعال‌تر، نمایانگر تغییرات قیمت سهام ۵۰ شرکت منتخب از صنایع مختلف بورسی است که معمولاً هر سه ماه یک بار در هر سال، توسط شرکت مدیریت فناوری بورس تهران، منتشر می‌شود. در مطالعه حاضر بر مبنای اطلاعات منتشر شده در پایان سال ۱۴۰۰، شرکت‌های فعال‌تر بورسی به عنوان یک نمونه از جامعه آماری در نظر گرفته شدند. بازه زمانی مورد مطالعه ۱۳۹۹/۲/۱ تا ۱۴۰۰/۱۲/۲۹ (یک دوره زمانی ۲۳ ماهه^۱) است و داده‌ها روزانه هستند. شرکت‌هایی که تاریخ ورود آن‌ها به بورس اوراق بهادار تهران بعد از تاریخ ۱۳۹۹/۲/۱ است، از مطالعه حذف شدند. در مطالعه حاضر بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی در بورس اوراق بهادار تهران در سه مرحله انجام شد. در مرحله اول سهام شرکت‌ها بر مبنای مدل تک عامله شارپ رتبه‌بندی شده و تنها سهام شرکت‌هایی که از دیدگاه اقتصادی سرمایه‌گذاری روی آن‌ها به صرفه است، وارد مرحله بهینه‌یابی پرتفوی شدند. در مرحله دوم به منظور برآورد شاخص بازدهی انتظاری پرتفوی، بازدهی سهام شرکت‌ها با استفاده از شبکه‌های عصبی NARX و LSTM، پیش‌بینی شد و به منظور برآورد شاخص ریسک از خطاهای پیش‌بینی شبکه‌های عصبی یادشده استفاده شد. در مرحله سوم بهینه‌یابی پرتفوی بر اساس روش کلی میانگین-واریانس مارکویتز انجام شد. همچنین مدل بهینه‌یابی پرتفوی میانگین-واریانس مارکویتز در شکل سنتی آن به عنوان رویکرد رقیب در نظر گرفته شد. در ادامه هر یک از مراحل انجام پژوهش مورد بررسی قرار می‌گیرد:

مرحله اول: رتبه‌بندی سهام شرکت‌ها و محاسبه نرخ کات اف^۲

به منظور تشکیل پرتفوی بهینه با استفاده از مدل میانگین - واریانس مارکویتز، اگر N تعداد شرکت‌هایی باشد که قرار است بهینه‌یابی پرتفوی برای آن‌ها صورت گیرد، می‌بایست تعداد $N(N-1)/2$ ضریب همبستگی محاسبه شود که با افزایش N ، کاری زمان بر و پرهزینه خواهد بود. برای رفع این مشکل ویلیام شارپ^۳ مدلی را تحت عنوان مدل تک عامله^۴ ارائه داده

۱. با توجه به اینکه تاریخ ورود شرکت سرمایه‌گذاری تأمین اجتماعی (شستا) به بورس اوراق بهادار تهران ۱۳۹۹/۱/۲۷ می‌باشد، به منظور حفظ بیشترین تعداد شرکت‌های موجود در نمونه در مطالعه حاضر، دوره زمانی ۲۳ ماهه در نظر گرفته شده است.

2. cut off rate

3 . William F. Sharpe

4 . single - index model

است که بر اساس آن سهام شرکت‌ها رتبه‌بندی می‌شوند و بر مبنای معیاری به نام نرخ کات اف تنها سهام شرکت‌هایی که از نظر اقتصادی سرمایه‌گذاری روی آن‌ها به صرفه است وارد مرحله بهینه‌یابی پرتفوی می‌شوند. به منظور محاسبه نرخ کات اف ابتدا نسبت بازدهی اضافه سهام هر شرکت (پاداش)^۱ به بتای آن، محاسبه می‌شود:

$$\frac{\bar{R}_i - R_F}{\beta_i} \quad (۱۵)$$

که در آن $\bar{R}_i$ میانگین بازدهی سهام شرکت i و R_F بازدهی دارایی بدون ریسک است. نسبت بیان شده بازدهی اضافه به ازای هر واحد از ریسک سیستماتیک یا ریسک غیرقابل حذف از طریق تنوع بخشی را نشان می‌دهد و یک ارتباط بین پاداش و ریسک به ازای سهام هر شرکت ایجاد می‌کند. شرکت‌ها بر اساس اندازه نسبت یادشده از بیشترین به کمترین مرتب می‌شوند. پس از آن نرخ C_i بر اساس رابطه زیر به ترتیب برای سهام شرکت‌هایی که در مرحله قبل مرتب شدند، محاسبه خواهد شد:

$$C_i = \frac{\sigma_m^2 \sum_{j=1}^i \frac{(\bar{R}_j - R_F)\beta_j}{\sigma_{ej}^2}}{1 + \sigma_m^2 \sum_{j=1}^i \left(\frac{\beta_j^2}{\sigma_{ej}^2}\right)} \quad (۱۶)$$

که در آن $\bar{R}_j$ میانگین بازدهی سهام شرکت j ، σ_{ei}^2 واریانس بازدهی سهام شرکت i ، σ_m^2 واریانس بازدهی شاخص بازار، σ_{ej}^2 و σ_{ei}^2 واریانس بخش تصادفی بازدهی سهام شرکت i ^۲ و j است. محاسبه نرخ C_i برای شرکت‌های مرتب شده بر اساس نسبت $\frac{\bar{R}_i - R_F}{\beta_i}$ ادامه می‌یابد تا جایی که برای سهام یک شرکت $C_i < \frac{\bar{R}_i - R_F}{\beta_i}$ شود. نرخ C_i برای این شرکت به عنوان نرخ C^* شناخته می‌شود که به عنوان نرخ معناداری اقتصادی^۳ تفسیر می‌شود، بدین معنی که از لحاظ اقتصادی ورود سهام این شرکت و شرکت‌هایی که بعد از آن قرار دارند، به پرتفوی بهینه، به صرفه نیست. بر این اساس تنها سهام شرکت‌هایی که دارای $C^* > \frac{\bar{R}_i - R_F}{\beta_i}$ هستند وارد مرحله

۱ . reward

۲. بازدهی سهام یک شرکت را می‌توان به شکل $R_i = \alpha_i + \beta_i R_m + e_i$ نوشت که در آن e_i بخش تصادفی بازدهی سهام شرکت i است

۳ . economic significance

بهینه‌یابی پرتفوی می‌شوند (التون، گروبر، برون و گودسمان^۱، ۲۰۱۴). به منظور محاسبه بازدهی سهام شرکت‌ها از قیمت‌های بسته‌تعدیلی سهام به روش عملکردی استفاده شده است. با توجه به اینکه دوره زمانی مطالعه حاضر یک دوره زمانی تقریباً دو ساله را شامل می‌شود، نرخ بهره بدون ریسک^۲، نرخ سود علی الحساب سپرده‌های بانک‌های دولتی برای سپرده‌های سرمایه‌گذاری دو ساله در نظر گرفته شده که مقدار آن در پایان سال ۱۴۰۰ توسط بانک مرکزی ۱۸ درصد اعلام شده است. همچنین به منظور محاسبه بازدهی شاخص بازار از شاخص کل بورس اوراق بهادار در دوره زمانی مربوطه استفاده شده است.

مرحله دوم: پیش‌بینی بازدهی سهام شرکت‌ها با استفاده از شبکه‌های عصبی NARX و LSTM

بررسی مطالعات انجام شده در زمینه پیش‌بینی بازدهی سهام شرکت‌های بورسی نشان می‌دهد پژوهشگران از انواع متغیرها به عنوان متغیرهای پیش بین استفاده نمودند. بعضی محققان از قیمت‌های گذشته باز، بسته، بالا و پایین سهام (یا نرخ رشد آن‌ها) و نیز حجم معاملات گذشته سهام، برای پیش‌بینی بازدهی آینده سهام شرکت‌های بورسی بهره بردند (ما و همکاران، ۲۰۲۱؛ پای و ایلانگو^۳، ۲۰۲۰؛ تا و همکاران، ۲۰۲۰ و هاو و همکاران، ۲۰۱۴) و یا از روند بازدهی‌های گذشته سهام بدین منظور استفاده کردند (ما و همکاران، ۲۰۲۱؛ نایک و موهان^۴، ۲۰۱۹؛ فریتاس و همکاران، ۲۰۰۶ و ۲۰۰۹؛ هاو و همکاران، ۲۰۱۴ و استون و کاسمبلی، ۲۰۱۲). برخی پژوهشگران نیز از متغیرهای مربوط به شرایط شرکت برای پیش‌بینی بازدهی سهام شرکت‌ها استفاده کردند (سانتوسو، سیدهارتا و واردینی^۵، ۲۰۲۰، ستایش و کاظم نژاد، ۱۳۹۸). مطالعه حاضر نیز به منظور پیش‌بینی بازدهی سهام در جهت بهینه‌یابی پرتفوی، از متغیرهای حجم معاملات گذشته سهام، نرخ رشد قیمت‌های گذشته بالا، پایین و باز سهام مربوط به هر شرکت و نیز متغیرهای مربوط به شرایط شرکت (شامل نسبت‌های P/E (نسبت قیمت به سود شرکت به ازای هر سهم) (برای تمام شرکت‌ها) و P/S (نسبت قیمت به فروش شرکت به ازای هر سهم) (فقط برای شرکت‌های تولیدی) و P/NAV^۶ (نسبت قیمت به خالص ارزش دارایی‌ها به ازای

1 . Elton, E; Gruber, M; Brown, S. & Goetzmann, W.

2. risk free rate

3 . Pai, N. & Ilango, V.

4 . Naik, N. & Mohan, B.

5 . Santoso, B; Sidharta, E.A. & Wardini, A.K.

6 . Net Asset Value

هر سهم) (فقط برای شرکت‌های سرمایه‌گذاری)) استفاده کرده است.^۱ با توجه به ذات خودبازگشتی بودن شبکه عصبی NARX متغیر بازدهی‌های گذشته سهام نیز به عنوان ورودی شبکه عصبی یادشده در نظر گرفته شد.

شبکه عصبی مصنوعی اتورگرسیو غیر خطی با متغیرهای برون زا (NARX) از انواع شبکه‌های عصبی بازگشتی است و می‌تواند یک نگاشت ورودی-خروجی را توسط پرسپترون چندلایه که واحد تأخیر زمانی^۲ و بازخورد خروجی^۳ را در لایه ورودی ترکیب می‌کند، تحقق بخشد (لیو، چن، هو، زو و زی^۴، ۲۰۲۰). شبکه عصبی NARX با اجازه دادن به شکل‌گیری تأخیرها و ایجاد ارتباطات مستقیم از گذشته، مشکل محو شدگی گرادیان^۵ را بهبود می‌بخشد و بنابراین نسبت به دیگر شبکه‌های عصبی همگرایی در NARX دقیق‌تر و سریع‌تر است (ایرکان^۶، ۲۰۱۷). معادله زیر مربوط به شبکه عصبی NARX است:

$$\hat{y}(t) = f[u(t), u(t-1), \dots, u(t-n_u), y(t-1), \dots, y(t-n_y)] + e(t) \quad (17)$$

که در آن $\hat{y}(t)$ مقدار متغیر خروجی پیش‌بینی شده است؛ $y(t)$ مقدار متغیر خروجی واقعی یا در واقع متغیر هدف^۷ است. $u(t)$ متغیر ورودی شبکه است، n_u و n_y تأخیرهای زمانی از متغیرهای ورودی و خروجی است و $e(t)$ خطای مدل است که اختلاف بین مقدار واقعی متغیر خروجی و مقدار پیش‌بینی شده آن است (لیو و همکاران، ۲۰۲۰).

در شبکه عصبی حافظه کوتاه‌مدت طولانی (LSTM) که از انواع شبکه‌های عصبی بازگشتی (RNN) است، سعی شده با مدیریت حافظه، مشکل محو شدگی گرادیان حل شود. ایجاد حافظه در شبکه عصبی LSTM از طریق سه مکانیزم اصلی به نام درگاه‌ها^۸ انجام می‌شود:

۱. مطالعه حاضر در کنار استفاده از متغیرهای پیش بین فوق الذکر از گروه دیگری از متغیرهای پیش بین شامل متغیرهای مربوط به شرایط اقتصاد کلان کشور (شامل نرخ رشد قیمت طلا، نرخ رشد قیمت نفت، نرخ رشد قیمت ارز، میانگین نرخ بازده مؤثر تا سررسید (YTM) اسناد خزانه اسلامی) و متغیرهای مربوط به شرایط شرکت (شامل نسبت های P/E، P/S و P/NAV) نیز بهره برده است. نتایج نشان از برتری به کارگیری متغیرهای پیش بین شامل حجم معاملات گذشته سهام، نرخ رشد قیمت‌های گذشته بالا، پایین و باز سهام و نیز متغیرهای مربوط به شرایط شرکت (شامل نسبت های P/E، P/S و P/NAV) دارد.

2. Time delay unit

3. Output feedback

4. Liu, Q; Chen, W; Zhu, Q. & Xie, Z.

5. Gradient Vanishing

6. Ercan, H.

7. Target

8. Gates

درگاه ورودی^۱ (i_t)، درگاه فراموشی^۲ (f_t) و درگاه خروجی^۳ (o_t). معادلات مربوط به شبکه عصبی LSTM به شکل زیر است:

$$i_t = \sigma(W_{x_i}x_t + W_{h_i}h_{t-1} + b_i) \quad (۱۸)$$

$$f_t = \sigma(W_{x_f}x_t + W_{h_f}h_{t-1} + b_f) \quad (۱۹)$$

$$o_t = \sigma(W_{x_o}x_t + W_{h_o}h_{t-1} + b_o) \quad (۲۰)$$

$$g_t = \tanh(W_{x_g}x_t + W_{h_g}h_{t-1} + b_g) \quad (۲۱)$$

$$c_t = f_t c_{t-1} + i_t g_t \quad (۲۲)$$

$$y_t = h_t = o_t \tanh c_t \quad (۴)$$

در تمام درگاه‌های ورودی، فراموشی، خروجی و نیز واحد بازگشتی، از وزن‌ها (W_i, W_f, W_o, W_g) و نیز بایاس‌ها (b_i, b_f, b_o, b_g) برای یادگیری شبکه استفاده می‌شود (تا و همکاران، ۲۰۲۰). به منظور انجام برآوردهای مربوط به پیش‌بینی بازدهی سهام شرکت‌ها با استفاده از شبکه‌های عصبی، ۷۰ درصد داده‌ها برای آموزش (Train)، ۱۵ درصد داده‌ها برای اعتبارسنجی (Validation) و ۱۵ درصد داده‌ها نیز برای آزمایش (Test) مورد استفاده قرار گرفتند. داده‌های مربوط به آزمایش داده‌هایی هستند که پیش‌بینی روی آن‌ها صورت گرفته است. با توجه به اینکه کل داده‌ها مربوط به یک دوره ۲۳ ماهه هستند، داده‌های مربوط به سه ماه پایانی سال ۱۴۰۰ داده‌های آزمایش را شامل می‌شوند. به منظور بررسی و مقایسه دقت پیش‌بینی رویکردهای یادشده، معیارهای میانگین مربع خطاها (fMSE) و جذر میانگین مربع خطاها (dRMSE) برای داده‌های آزمایش گزارش می‌شود:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (۵)$$

-
- 1 . Input gate
 - 2 . Forget gate
 - 3 . Output gate
 - 4 . Mean Squared Errors
 - 5 . Root Mean Squared Errors

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2} \quad (25)$$

که در آن N تعداد مشاهدات، Y_i بازدهی واقعی سهام برای مشاهده i ام و $\hat{Y}_i$ بازدهی پیش‌بینی شده سهام برای مشاهده i ام است.

مرحله سوم: بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی

پس از انجام مرحله پیش‌بینی بازدهی سهام شرکت‌ها توسط شبکه‌های عصبی NARX و LSTM، مرحله بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی بر اساس مدل کلی بهینه‌یابی پرتفوی میانگین-واریانس مارکowitz انجام شد به شکلی که مطالعه حاضر به منظور برآورد شاخص بازدهی مورد انتظار به جای میانگین بازدهی‌های گذشته سهام شرکت‌ها از پیش‌بینی بازدهی سهام شرکت‌ها استفاده کرده و به منظور برآورد شاخص ریسک پرتفوی به جای استفاده از واریانس بازدهی‌های گذشته سهام شرکت‌ها از واریانس خطاهای پیش‌بینی بهره می‌برد. بدین منظور تعداد ۲۰۰۰۰ پرتفوی تصادفی در نظر گرفته شده است و پرتفوی با بالاترین نرخ شارپ بر اساس هر یک از روش‌های بهینه‌یابی پرتفوی، به عنوان معیاری جهت مقایسه روش‌ها مورد استفاده قرار می‌گیرد. نرخ شارپ S_R به شکل معادله (۲۶) محاسبه می‌شود:

$$S_R = \frac{R_p - R_f}{\sigma_p} \quad (26)$$

که در آن R_p بازدهی پرتفوی، R_f بازدهی دارایی بدون ریسک و σ_p انحراف معیار پرتفوی است. روش‌های بهینه‌یابی پرتفوی شامل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی NARX، بهینه‌یابی پرتفوی استوار بر پیش‌بینی با استفاده از شبکه عصبی LSTM و بهینه‌یابی پرتفوی میانگین-واریانس مارکowitz در شکل سنتی آن است.

یافته‌های پژوهش

در مرحله اول از مطالعه حاضر پس از بررسی تاریخ ورود شرکت‌های موجود در نمونه مشخص شد تاریخ ورود دو شرکت به بورس اوراق بهادار تهران پس از ۱۳۹۹/۲/۱ است که با

توجه به کمبود داده برای دوره زمانی مورد نظر از مطالعه حاضر حذف شدند^۱. نتایج مربوط به رتبه‌بندی سهام شرکت‌ها و محاسبه نرخ کات اف در جدول (۱) خلاصه شده است:

جدول ۱. نتایج مربوط به رتبه‌بندی سهام شرکت‌ها و محاسبه نرخ کات اف

رتبه‌بندی شرکت‌ها	نام و نماد شرکت‌ها	شاخص مرتب شده	نرخ کات اف
۱	توسعه معادن خاورمیانه (میدکو)	۰/۶۲۳۷۵	۰/۰۲۳۹۶
۲	ایران خودرو (خودرو)	۰/۲۸۳۲۵	۰/۰۲۶۵
۳	توسعه معدنی و صنعتی صابونر (کنور)	۰/۲۴۴۰۷	۰/۰۴۰۱۶
۴	گروه بهمن (خبهمن)	۰/۲۲۰۲۹	۰/۰۴۵۸۹
۵	بانک پاسارگاد (وپاسار)	۰/۲۰۴۵۱	۰/۰۵۶۳۷
۶	گروه مدیریت سرمایه گذاری امید (وامید)	۰/۱۸۸۶۹	۰/۰۶۱۹۸
۷	پتروشیمی نوری (نوری)	۰/۱۸۲۳۳	۰/۰۷۰۲۳
۸	سایا (خسپا)	۰/۱۷۴۴۹	۰/۰۷۱۳۲
۹	چادرملو (کچاد)	۰/۱۶۱۰۸	۰/۰۷۴۳۸
۱۰	معدنی و صنعتی گل گهر (کگل)	۰/۱۴۱۸۳	۰/۰۷۷۸۷
۱۱	پتروشیمی پردیس (شپدیس)	۰/۱۳۵۰۲	۰/۰۸۲۲۱
۱۲	پالایش نفت بندرعباس (شبندر)	۰/۱۳۳۴۳	۰/۰۸۴۷۱
۱۳	پتروشیمی فن آوران (شفن)	۰/۱۲۸۴۸	۰/۰۸۶۱
۱۴	ملی صنایع مس ایران (فملی)	۰/۱۰۶۵۱	۰/۰۸۶۸۸
۱۵	گسترش نفت و گاز پارسیان (پارسان)	۰/۱۰۱۶۶	۰/۰۸۷۵۴
۱۶	پتروشیمی کرمانشاه (کرماشا)	۰/۱۰۰۴۹	۰/۰۸۷۹۹
۱۷	سرمایه گذاری تأمین اجتماعی (شستا)	۰/۰۹۸۶	۰/۰۸۸۴۶
۱۸	پالایش نفت اصفهان (شپنا)	۰/۰۹۳۵۹	۰/۰۸۸۷۷
۱۹	پتروشیمی جم (جم)	۰/۰۸۸۰۳	۰/۰۸۸۷۳
۲۰	پلی پروپیلن جم (جم پیلن)	۰/۰۸۷۲۵	۰/۰۸۸۶۹
۲۱	گسترش سرمایه گذاری ایران خودرو (خگستر)	۰/۰۸۰۳۶	۰/۰۸۸۶۳
۲۲	توسعه معادن و فلزات (ومعادن)	۰/۰۷۶۶	۰/۰۸۷۹۲
۲۳	پتروشیمی پارس (پارس)	۰/۰۷۱۵۳	۰/۰۸۷۶
۲۴	پتروشیمی سازند (شاراک)	۰/۰۶۶۷۱	۰/۰۸۶۷۲
۲۵	پالایش نفت تبریز (شبریز)	۰/۰۶۱۶۸	۰/۰۸۵۷
۲۶	فولاد مبارکه اصفهان (فولاد)	۰/۰۵۸۶۵	۰/۰۸۴۷۳

۱. شرکت پتروشیمی بوعلی سینا (با نماد بوعلی) و شرکت فراوری معدنی اپال کانی پارس (با نماد اپال) از مطالعه حاضر حذف شدند.

رتبه‌بندی شرکت‌ها	نام و نماد شرکت‌ها	شاخص مرتب شده	نرخ کات اف
۲۷	پالایش نفت تهران (شتران)	۰/۰۵۷۶۱	۰/۰۸۳۶۸
۲۸	سرمایه‌گذاری صندوق بازتنستگي (وصندوق)	۰/۰۵۶۰۴	۰/۰۸۲۵۸
۲۹	فولاد خوزستان (فخوز)	۰/۰۴۷۹۲	۰/۰۸۱۹۸
۳۰	نفت و گاز و پتروشیمی تأمین (تاپیکو)	۰/۰۲۸۴۳	۰/۰۷۹۴۲
۳۱	سرمایه‌گذاری غدیر (وغدیر)	۰/۰۲۷۸۲	۰/۰۷۵۹۲
۳۲	صنایع پتروشیمی خلیج فارس (فارس)	۰/۰۲۷۳۱	۰/۰۷۵۱۸
۳۳	پتروشیمی شیراز (شیراز)	۰/۰۲۴۷۵	۰/۰۷۴۱۱
۳۴	گروه صنعتی پاکشو (پاکشو)	۰/۰۱۳۹۷	۰/۰۷۳۹۶
۳۵	بانک صادرات ایران (وبصادر)	۰/۰۱۲۵۷	۰/۰۷۱۸۳
۳۶	بانک تجارت (وتجارت)	۰/۰۰۵۵۴	۰/۰۶۹۷۵
۳۷	مبین انرژی خلیج فارس (مبین)	-۰/۰۰۶۶۸	۰/۰۶۸۰۱
۳۸	پتروشیمی خارک (شخارک)	-۰/۰۰۷۱۹	۰/۰۶۶۸۶
۳۹	سرمایه‌گذاری صدر تأمین (تاصیکو)	-۰/۰۱۳۰۴	۰/۰۶۳۸
۴۰	فجر انرژی خلیج فارس (بفجر)	-۰/۰۲۰۱	۰/۰۶۲۹۲
۴۱	بانک ملت (وبملت)	-۰/۰۲۸۶۵	۰/۰۶۰۸۶
۴۲	سرمایه‌گذاری گروه توسعه ملی (ویانک)	-۰/۰۵۴۴۷	۰/۰۵۶۸۴
۴۳	بانک پارسیان (وپارس)	-۰/۰۶۴۹۱	۰/۰۵۵۳۷
۴۴	گروه مپنا (رمپنا)	-۰/۱۱۳۸۴	۰/۰۵۱۶۸
۴۵	کشتیرانی جمهوری اسلامی ایران (حکشتی)	-۰/۱۶۰۸۴	۰/۰۴۹۰۳
۴۶	بورس کالای ایران (کالا)	-۰/۱۶۷۶۴	۰/۰۴۸۱
۴۷	مخابرات ایران (اخابر)	-۰/۱۷۴	۰/۰۴۷۳۹
۴۸	ارتباطات سیار ایران (همراه)	-۰/۲۱۷۲۴	۰/۰۴۳۷۱

به منظور محاسبه نرخ کات اف ابتدا نسبت بازدهی اضافه سهام هر شرکت به بتای آن $\frac{\bar{R}_i - R_F}{\beta_i}$ محاسبه شده است. سپس سهام شرکت‌ها بر اساس اندازه شاخص یادشده از بیشترین به کمترین مرتب شدند. این معیار تحت عنوان شاخص مرتب شده در جدول (۱) آمده است. همچنین نرخ G_i برای سهام تمام شرکت‌ها محاسبه شده که در جدول (۱) تحت عنوان نرخ کات اف است. برای سهام شرکت ۱۹ ام (با نماد جم) $G_i < \frac{\bar{R}_i - R_F}{\beta_i}$ شده است. نرخ G_i برای این شرکت، نرخ G^* است که به عنوان نرخ معناداری اقتصادی^۱ تفسیر می‌شود و مقدار آن برابر

1 . Economic significance


با $0/08873$ است. از لحاظ اقتصادی ورود سهام این شرکت و شرکت‌هایی که بعد از آن قرار دارند، به پرتفوی بهینه، به صرفه نیست. بر این اساس سهام ۱۸ شرکت وارد مرحله بهینه‌یابی پرتفوی می‌شود. مرحله بعدی مربوط به گزارش عملکرد پیش‌بینی بازدهی سهام شرکت‌ها با استفاده از شبکه‌های عصبی NARX و LSTM است که بر اساس شاخص میانگین مربع خطاها (MSE) و جذر میانگین مربع خطاها (RMSE) در جدول ۲ بیان شده است:

جدول ۲. نتایج مربوط به گزارش عملکرد شبکه‌های عصبی NARX و LSTM

نماد شرکت‌ها	MSE-NARX	MSE-LSTM	RMSE-NARX	RMSE-LSTM
میدکو	0/000016	0/001612	0/004	0/04015
خودرو	0/000068	0/000089	0/008246	0/009434
کنور	0/000006	0/00304	0/002449	0/055136
خیمن	0/000192	0/000412	0/013856	0/020298
وپاسار	0/000095	0/000252	0/009747	0/015875
وامید	0/000632	0/000964	0/02514	0/031048
نوری	0/000173	0/000677	0/013153	0/026019
خسپا	0/000024	0/00032	0/004899	0/017889
کچاد	0/000062	0/00026	0/007874	0/016125
کگل	0/000069	0/000149	0/008307	0/012207
شیدیس	0/000101	0/002941	0/01005	0/054231
شبندر	0/000053	0/001004	0/00728	0/031686
شفن	0/000561	0/001309	0/023685	0/03618
فعلی	0/000192	0/001076	0/013856	0/032802
پارسان	0/000089	0/000119	0/009434	0/01909
کرماشا	0/000158	0/003255	0/01257	0/057053
شستا	0/00001	0/000113	0/01	0/01063
شپنا	0/000171	0/000235	0/013077	0/01533

نتایج بیانگر آن است که هر دو رویکرد شبکه عصبی NARX و LSTM در رابطه با پیش‌بینی بازدهی سهام شرکت‌ها در بورس اوراق بهادار تهران عملکرد رضایت بخشی دارند. از طرفی مقایسه عملکرد دو شبکه عصبی NARX و LSTM بیانگر آن است که به طور کلی عملکرد شبکه عصبی NARX بهتر و دارای قدرت پیش‌بینی بالاتری است. بنابراین فرضیه اول

مطالعه حاضر مبتنی بر بهتر بودن عملکرد شبکه عصبی NARX در خصوص پیش‌بینی بازدهی سهام شرکت‌های منتخب بورس اوراق بهادار تهران در مقایسه با شبکه عصبی LSTM قابل پذیرش است. ما و همکاران (۲۰۲۰ و ۲۰۲۱) به بررسی عملکرد شبکه عصبی LSTM در مقایسه با انواع رویکردهای یادگیری ماشین و یادگیری عمیق در پیش‌بینی بازدهی سهام شرکت‌ها پرداختند و مغلوب شدن شبکه عصبی LSTM را نشان دادند. نمودار پیش‌بینی بازدهی سهام شرکت پتروشیمی نوری با استفاده از شبکه‌های عصبی NARX و LSTM به عنوان نمونه در نمودار زیر آورده شده است:



نمودار ۱. نتایج شبکه عصبی NARX و LSTM در رابطه با پیش‌بینی بازدهی سهام شرکت پتروشیمی نوری با استفاده از نرم افزار پایچارم

در نمودار ۱ پیش‌بینی بازدهی سهام شرکت پتروشیمی نوری برای داده‌های آزمایش با استفاده از شبکه عصبی NARX (تصویر سمت چپ) و شبکه عصبی LSTM (تصویر سمت راست) به تصویر کشیده شده است که نشان دهنده عملکرد بهتر شبکه عصبی NARX نسبت به شبکه عصبی LSTM در پیش‌بینی بازدهی سهام شرکت یادشده است.

در مرحله سوم از مطالعه حاضر بهینه‌یابی پرتفوی میانگین-واریانس مارکویتز (MV) با استفاده از بازدهی‌های گذشته سهام انجام شده است. همچنین بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه‌های عصبی NARX و LSTM بر اساس روش کلی بهینه‌یابی پرتفوی مارکویتز (MV-NARX و MV-LSTM) انجام شده است، به شکلی که به جای میانگین بازدهی‌های گذشته سهام از میانگین بازدهی‌های پیش‌بینی شده سهام و به جای واریانس

بازدهی‌های گذشته سهام از واریانس خطاهای پیش‌بینی استفاده شده است. نتایج بر اساس بازدهی و ریسک پرتفوی (انحراف معیار) در پرتفوی حداکثر نرخ شارپ ارائه شده است. همچنین نقطه حداکثر نرخ شارپ بر اساس معادله (۲۶) و با در نظر گرفتن نرخ بهره بدون ریسک برابر با ۱۸ درصد برای هر یک از روش‌های بهینه‌یابی پرتفوی محاسبه و در ردیف آخر ارائه شده است:

جدول ۳. نتایج مربوط به حداکثر نرخ شارپ در مرحله بهینه‌یابی پرتفوی

MV-LSTM	MV-NARX	MV	
۰/۲۴۴۲۹	۰/۲۲۰۸۷	۰/۳۵۶۸۶	بازدهی پرتفوی
۰/۲۱۹۹۶	۰/۱۲۶۸۸	۱/۸۲۹۰۹	ریسک پرتفوی
۰/۲۹۲۲۸	۰/۳۲۲۱۱۵	۰/۰۹۶۶۹۳	حداکثر نرخ شارپ

بر اساس نتایج جدول ۳، بهینه‌یابی پرتفوی با استفاده از روش بهینه‌یابی پرتفوی میانگین-واریانس مارکویتز، در نقطه حداکثر نرخ شارپ بازدهی بالاتر و همچنین ریسک بسیار بالاتری را نسبت به دو روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی ارائه می‌دهد. بالاتر بودن ریسک پرتفوی سبب کاهش مقدار حداکثر نرخ شارپ شده است و مقدار بسیار کمتری (۰/۰۹۶۶۹۳) را نسبت به دو روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی ارائه می‌دهد. بنابراین روش‌های بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه‌های عصبی NARX و LSTM روش بهینه‌یابی پرتفوی میانگین-واریانس مارکویتز را مغلوب می‌کنند و بر این اساس نتایج مطالعه حاضر با نتایج مطالعات پیشین در این زمینه سازگاری دارد (کارابی و همکاران، ۲۰۲۲، ما و همکاران، ۲۰۲۰ و ۲۰۲۱، پای و ایلانگو، ۲۰۲۰، تا و همکاران، ۲۰۲۰، فریتاس و همکاران، ۲۰۰۶ و ۲۰۰۹، استون و کاسمبلی، ۲۰۱۲، هاو و همکاران، ۲۰۱۴). بنابراین فرضیه‌های دوم و سوم مبنی بر بهتر بودن عملکرد روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه‌های عصبی NARX و LSTM، در مقایسه با روش بهینه‌یابی پرتفوی میانگین-واریانس مارکویتز در بورس اوراق بهادار تهران قابل پذیرش است. روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی مورد استفاده در مطالعه حاضر در کنار استفاده از پیش‌بینی بازدهی سهام شرکت‌ها به منظور برآورد شاخص بازده انتظاری پرتفوی از خطاهای پیش‌بینی برای برآورد شاخص ریسک پرتفوی بهره می‌برد. بنابراین در صورتی که یک رویکرد پیش‌بینی بازدهی‌ها را بالاتر از بازدهی واقعی ارائه دهد معیار ریسک که در مطالعه حاضر واریانس خطاهای پیش‌بینی است، افزایش

خواهد یافت و در نتیجه حداکثر نرخ شارپ پایین تری را ارائه می دهد. روش بهینه یابی پرتفوی مبتنی بر پیش بینی با استفاده از شبکه عصبی NARX ریسک کمتر و حداکثر نرخ شارپ بالاتری را نسبت به روش بهینه یابی پرتفوی مبتنی بر پیش بینی با استفاده از شبکه عصبی LSTM نشان می دهد و بنابراین فرضیه چهارم مبنی بر بهتر بودن عملکرد روش بهینه یابی پرتفوی مبتنی بر پیش بینی با استفاده از شبکه عصبی NARX، در مقایسه با روش بهینه یابی پرتفوی مبتنی بر پیش بینی با استفاده از شبکه عصبی LSTM در بورس اوراق بهادار تهران قابل پذیرش است. در بین مطالعات پیشین مقایسه ای بین عملکرد شبکه های عصبی NARX و LSTM به منظور بهینه یابی پرتفوی مبتنی بر پیش بینی صورت نگرفته است. با توجه به توانایی رویکرد پیش بینی شبکه عصبی NARX در پیش بینی سری های زمانی غیر خطی که دارای سیستم های پیچیده در ذات خود هستند (شیو و ژانگ، ۲۰۱۷)، نتایج مطالعه حاضر دور از انتظار نیست. رویکرد پیش بینی NARX از نوع خودبازگشتی است و بنابراین بازدهی های پیشین به عنوان یک متغیر پیش بین وارد شبکه عصبی شده است که می تواند در پیش بینی بازدهی آینده سهام کمک کننده باشد. فریتاس و همکاران (۲۰۰۶ و ۲۰۰۹) از نوعی شبکه عصبی خودبازگشتی (AR-MRNN)^۲ به منظور بهینه یابی پرتفوی مبتنی بر پیش بینی استفاده کردند و به نتایج مطلوبی رسیدند. به طور کلی سیستم های خودبازگشتی در رابطه با پیش بینی سری های زمانی عملکرد مناسبی نشان داده اند (چاو و پوتر، ۲۰۱۳).

وزن اختصاص یافته به سهام هر شرکت برای نقطه حداکثر نرخ شارپ و میانگین بازدهی سهام هر شرکت بر اساس هر یک از روش های بهینه یابی پرتفوی در جدول زیر آمده است:

جدول ۴. نتایج مربوط به مرحله بهینه یابی پرتفوی

نماد شرکت ها	میانگین بازدهی سهام شرکت ها (MV)	وزن سهام شرکت ها (MV)	میانگین بازدهی سهام شرکت ها (MV-NARX)	وزن سهام شرکت ها (MV-NARX)	میانگین بازدهی سهام شرکت ها (MV-LSTM)	وزن سهام شرکت ها (MV-LSTM)
میدکو	۰/۴۸۱۶	۰/۱۰۳۹۱۵	-۰/۰۱۵۲	۰/۰۰۴۲۱	۰/۵۲۷۹	۰/۱۰۹۶۵۸
خودرو	۰/۴۲۸۳	۰/۰۵۲۵۱۵	۰/۵۶۶۲	۰/۰۸۸۵۱	۰/۲۳۹۹	۰/۰۷۹۲۹
کنور	۰/۳۸۸۷	۰/۱۱۸۰۱۳	۰/۱۲۳۳	۰/۰۲۴۴۶۶	-۱/۲۷۸۶	۰/۰۱۹۱۶۷

1. Xiu, Y. & Zhang, W.
2. Auto Regressive-Moving Average Neural Network
3. Chauvet, M. & Potter, S.

نماد شرکت‌ها	میانگین بازدهی سهام شرکت‌ها (MV)	وزن سهام شرکت‌ها (MV)	میانگین بازدهی سهام شرکت‌ها (MV-NARX)	وزن سهام شرکت‌ها (MV)	میانگین بازدهی سهام شرکت‌ها (MV-LSTM)	وزن سهام شرکت‌ها (MV-LSTM)
خهمن	۰/۳۷۰۵	۰/۱۳۲۶۴۹	-۰/۲۲۰۶	۰/۳۶۳۹۷	-۰/۵۲۵۹	۰/۰۳۳۶۹۷
وپاسار	۰/۳۱۲۵	۰/۰۷۲۸۰۹	۰/۴۷۶۸	۰/۱۶۱۷۷۲	۰/۲۸۸۹	۰/۰۵۰۸۵۶
وامید	۰/۲۸۵۵	۰/۰۰۲۵۲	۰/۱۸۸۷	۰/۰۳۶۴۱	-۰/۰۹۹۳	۰/۰۵۱۹۴۵
نوری	۰/۳۸۳۴	۰/۱۱۴۷۹	-۰/۰۰۶۶	۰/۰۲۳۵۷۴	-۰/۷۸۶۲	۰/۰۰۶۸۴۲
خسپا	۰/۳۵۱۷	۰/۰۰۱۶۶۳	-۰/۲۵۷۵	۰/۰۰۷۹۳۴	-۱/۶۶۳۱	۰/۰۰۱۹۸
کچاد	۰/۳۳۶۱	۰/۱۱۹۱۴۸	۰/۲۰۱	۰/۰۰۹۶۸۵	۰/۸۸۲۵	۰/۱۱۱۳۷۵
کگل	۰/۳۱۵۹	۰/۰۵۰۹۲۸	۰/۳۴۹۴	۰/۱۴۷۶	۰/۶۱۸۸	۰/۱۰۴۵۳۳
شپدیس	۰/۳۳۸۲	۰/۰۲۱۲۵۶	-۰/۰۰۶۲	۰/۰۲۵۴۶۱	-۰/۸۹۴۲	۰/۰۰۱۹۸۶
شبندر	۰/۳۱۶۵	۰/۰۱۱۵۳۶	۰/۱۲۸	۰/۱۵۸۸۳۶	-۰/۸۳۵	۰/۰۴۵۸۳۹
شفن	۰/۲۸۴۹	۰/۰۷۱۷۷۲	-۰/۴۵۰۲	۰/۰۱۸۷۵۵	-۰/۴۸۶۹	۰/۰۱۴۴۸۶
فملی	۰/۲۸۷۹	۰/۰۰۴۵۶۶	-۰/۱۶۴۵	۰/۰۱۹۷۱۹	۱/۰۷۱۷	۰/۱۲۰۵۸۴
پارسان	۰/۲۹۲۵	۰/۰۱۱۰۷۲	۰/۰۹۷۳	۰/۰۶۱۹۵۲	۰/۰۹۵۵	۰/۰۵۸۷۰۶
کرماشا	۰/۲۷۲۲	۰/۰۳۴۸۱	۰/۱۵۵۲	۰/۰۴۵۲۷۲	-۰/۹۷۱۶	۰/۰۶۶۹۷۳
شستا	۰/۲۳۴۴	۰/۰۴۴۷۱۴	۰/۱۱۷۲	۰/۱۰۳۶۸۵	۰/۱۸۱۴	۰/۱۱۱۲۸۵
شپنا	۰/۲۹۶۹	۰/۰۳۱۳۲۵	۰/۲۴۶۶	۰/۰۵۸۵۳۳	۰/۲۷۱۵	۰/۰۱۰۸

در روش بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی که در مطالعه حاضر مورد استفاده قرار گرفته است از واریانس خطاهای پیش‌بینی به عنوان معیار ریسک پرتفوی استفاده شده است، بنابراین در صورتی که خطای شبکه عصبی در رابطه با پیش‌بینی بازدهی سهام یک شرکت خاص بالا باشد، ریسک خرید سهام آن شرکت خاص افزایش می‌یابد. به طور مثال در مورد سهام شرکت بورسی با نماد وامید، خطای پیش‌بینی بر اساس معیار RMSE با استفاده از شبکه عصبی NARX به مقدار (۰/۰۲۵۱۴) رسیده است که بالاترین مقدار خطا در بین سهام شرکت‌های دیگر است. از طرفی میانگین بازدهی سهام شرکت یادشده بر اساس روش بهینه‌یابی پرتفوی (MV-NARX) به مقدار (۰/۱۸۸۷) رسیده است که بالاتر از شرکت‌های بورسی با نمادهای میدکو، کنور، خهمن، نوری، خسپا، شپدیس، شبندر، شفن، فملی، پارسان، کرماشا و شستا است ولی وزن اختصاص یافته به سهام شرکت یادشده (۰/۰۰۳۶۴۱) از تمام این شرکت‌ها کمتر است. بنابراین برتری استفاده از خطاهای پیش‌بینی به منظور تدوین شاخص ریسک در روش بهینه‌یابی

پرتفوی مبتنی بر پیش‌بینی این است که اگر خطای پیش‌بینی بازدهی سهام یک شرکت خاص افزایش یابد، وزن اختصاص یافته به آن کاهش خواهد یافت.

بحث و نتیجه‌گیری

مدل بهینه‌یابی پرتفوی مارکویتز از میانگین بازدهی‌های گذشته سهام به عنوان شاخص بازدهی انتظاری پرتفوی و از واریانس بازدهی‌های گذشته سهام به عنوان شاخص ریسک پرتفوی استفاده می‌کند. با توجه به اینکه تصمیمات سرمایه‌گذاری مربوط به آینده است، استفاده از معیارهایی که تنها مبتنی بر بازدهی‌های تحقق یافته هستند، مناسب نیست. همچنین مدل بهینه‌یابی پرتفوی مارکویتز روشی برای انتخاب سهام شرکت‌ها برای ورود به مرحله بهینه‌یابی پرتفوی ارائه نمی‌دهد. هدف از مطالعه حاضر ارائه مدلی در جهت ارتقای نتایج حاصل از مسئله بهینه‌یابی پرتفوی است و در این راستا یک مدل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی ارائه کرده است که در سه مرحله انجام شد. در مرحله نخست سهام شرکت‌ها با استفاده از مدل تک عامله شارپ رتبه‌بندی شدند و تنها سهام شرکت‌هایی که از نظر اقتصادی سرمایه‌گذاری روی آن‌ها به صرفه است وارد مرحله بهینه‌یابی پرتفوی شد. در مرحله دوم به جای استفاده از میانگین بازدهی‌های گذشته سهام از پیش‌بینی بازدهی سهام شرکت‌ها از طریق شبکه عصبی خودبازگشتی غیرخطی با متغیرهای برون‌زا (NARX) به عنوان رویکرد اصلی و نیز از شبکه عصبی حافظه کوتاه‌مدت طولانی (LSTM) به عنوان رویکرد رقیب استفاده شده است. همچنین مطالعه حاضر به منظور برآورد شاخص ریسک به جای استفاده از واریانس بازدهی‌های گذشته سهام از واریانس خطاهای پیش‌بینی شبکه‌های عصبی یادشده بهره برده است. در مرحله سوم، بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی بر اساس روش کلی میانگین-واریانس مارکویتز انجام شده است.

نتایج بیانگر آن است که در مرحله پیش‌بینی بر اساس معیارهای میانگین مربع خطاها (MSE) و جذر میانگین مربع خطاها (RMSE) رویکرد شبکه عصبی NARX، رویکرد شبکه عصبی LSTM را مغلوب می‌کند. مطالعات پیشین نتایج مطالعه حاضر را در مورد مغلوب شدن شبکه عصبی LSTM، در خصوص پیش‌بینی بازدهی سهام شرکت‌ها، در مقابل انواع رویکردهای پیش‌بینی یادگیری ماشین و یادگیری عمیق تأیید می‌کند. همچنین نتایج مطالعه حاضر در خصوص اهمیت و برتری شبکه عصبی NARX در خصوص پیش‌بینی در بازارهای

مالی مورد تأیید مطالعات پیشین است. در مرحله بهینه‌یابی پرتفوی نیز رویکرد بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی NARX ریسک کم‌تر و حداکثر نرخ شارپ بالاتری را نسبت به رویکرد بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه عصبی LSTM ارائه می‌دهد که با توجه به نتایج مرحله پیش‌بینی، دور از انتظار نیست. همچنین بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از شبکه‌های عصبی NARX و LSTM نسبت به روش بهینه‌یابی پرتفوی میانگین-واریانس مارکوویتز ریسک کمتر و حداکثر نرخ شارپ بالاتری را برای سرمایه‌گذاران فراهم می‌آورد. نتایج مطالعه حاضر در خصوص حصول نتایج بهتر از بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی نسبت به بهینه‌یابی پرتفوی میانگین-واریانس مارکوویتز یافته‌های مطالعات پیشین را تأیید می‌کند. یافته‌های مطالعه حاضر مبنی بر به کارگیری شبکه عصبی NARX در زمینه پیش‌بینی بازدهی سهام شرکت‌ها در بورس اوراق بهادار تهران و نیز استفاده از مدل بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از رویکرد شبکه عصبی NARX به جای استفاده از روش بهینه‌یابی پرتفوی میانگین-واریانس مارکوویتز در شکل سنتی آن به سرمایه‌گذاران، تحلیل‌گران و کارشناسان حرفه‌ای حوزه مدیریت پرتفوی پیشنهاد می‌شود. مطالعات بیشتر روی مسئله بهینه‌یابی پرتفوی مبتنی بر پیش‌بینی با استفاده از انواع رویکردهای بهینه‌یابی پرتفوی و نیز انواع رویکردهای پیش‌بینی و ارائه راهکارهای عملی در خصوص سرمایه‌گذاری به فعالان بازار سرمایه می‌تواند موضوع پژوهش‌های آتی قرار گیرد.

References

- Adinehvand, D; Razini, E.A; khoddam, M; Ohadi, F. & hashemizadeh, E. (2023). Examining the Efficiency Models, Markowitz Mean-Semi Variance, VaR and multi-objective Genetic Algorithm (NSGAI) under MSV and CVAR risk criterion in Selection Optimal Portfolio Shares Listed Firms on Stock Exchange. *Journal of Securities Exchange*, 16(61):101-120, 22034/10/JSE.11826/1876/2022. (In Persian)
- Bucci, A. (2020). Realized Volatility Forecasting with Neural Networks. *Journal of Financial Econometrics*, 18(3), 502-531. <https://doi.org/1093/10/jjfinec/nbaa008>.
- Chauvet, M. & Potter, S. (2013). Forecasting output, Chapter 3 in handbook of economic forecasting. *Elsevier*, 2, 141-194. DOI: 1016/10/B978-0-444-53683-00003/9-7.
- Divine, J. (2017). Predicting the Closing Price and Direction of Stock Market Index using NARX Neural Networks. *Research Gate*, 1-21. <https://www.researchgate.net/publication/330888102>. DOI:13140/10/RG.2/44486/2/28730.
- Elton, E; Gruber, M; Brown, S. & Goetzmann, W. (2014). Modern Portfolio Theory and Investment Analysis, 9th Edition. New York: Wiley, 1-754.
- Ercan, H. (2017). Baltic stock market prediction by using NARX. *2017 12th International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT)*, 464-467. DOI: 1109/10/STC-CSIT.8098829/2017.
- Freitas, F.D, De Souza, A.F, & Almeida, A.R (2006). A prediction-based portfolio optimization model. *5th International Symposium on Robotics and Automation 2006*, 520-525. <https://scholar.google.com/citations?user=s51oG68AAAAJ&hl=ja>.
- Freitas, F.D, De Souza, A.F, & Almeida, A.R (2009). Prediction-based portfolio optimization model using neural networks. *Neuro computing*, 72 (10-12). DOI:1016/10/j.neucom.08/019/2008.
- Garigoryan, H. (2015). Stock Market Prediction using Artificial Neural Networks. Case Study of TAL1T, Nasdaq OMX Baltic Stock. *Database Systems Journal, Academy of Economic Studies - Bucharest, Romania*, 6(2), 14-23. <https://ideas.repec.org/a/aes/dbjour/v6y2015i2p14-23.html>.
- Hao, C; Wang, J; Xu, W. & Xiao, Y. (2014). Prediction-Based Portfolio Selection Model Using Support Vector Machines. *Proceedings - 2013 6th International Conference on Business Intelligence and Financial Engineering, BIFE 2013*, 567-571. DOI:1109/10/BIFE.118/2013.
- Karrabi, A; Heydari, A. & Yousefzade, H.R. (2022). A new two-phase approach to the portfolio optimization problem based on the prediction of stock price trends. *Advances in Mathematical Finance & Applications*. 7(4), 849-865. DOI: 22034/10/AMFA.1937022/1622/2021.
- Kianizadeh, H; Baghani, A. & Hamidian, M. (2023). Comparing the accuracy of selected Machin learning models for stock price prediction in stock exchange market. *Journal of Securities Exchange*, 16(62): 75-102, 22034/10/jse.11636/1733/2021. (In Persian)
- Liu, Q; Chen, W; Hu,H; Zhu, Q. & Xie, Z. (2020). An optimal NARX neural network identification model for a magnetorheological damper with force distortion behavior. *Frontiers in materials*, 7, 1-12. DOI: <https://doi.org/3389/10/fmats.00010/2020>.

- Ma, Y; & Han, R; & Wang, W. (2020). Prediction-Based Portfolio Optimization Models Using Deep Neural Networks. *IEEE Access*, 8, 115393-115405. DOI:1109/10/ACCESS.3003819/2020.
- Ma, Y; Han, R. & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, (165), 1-15. DOI:1016/10/j.eswa.113973/2020.
- Naik, N; & Mohan, B. (2019). Study of Stock Return Predictions Using Recurrent Neural Networks with LSTM. *International Conference on Engineering Applications of Neural Networks, EANN 2019, Communications in Computer and Information Science*, 1000, 453-459. DOI:1007/10/978-3-030-20257-6_39.
- Pai, N; & Ilango, V. (2020). Neural Network Model for Efficient portfolio Management and Time Series Forecasting. *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 150-155. DOI:1109/10/ICICCS2020/9121049/48265.
- Rasel, R. I; Sultana, N; & Meesad, P. (2015). An efficient modelling approach for forecasting financial time series data using support vector regression and windowing operators. *International Journal of Computational Intelligence Studies (IJCISTUDIES)*, 4 (2), 134-150. DOI:1504/10/IJCISTUDIES.071180/2015.
- Rather, A.M. (2019). Integration of Vector Autoregression and Artificial Neural Networks: A Robust Model for Prediction of Nonstationary Data. *Proceedings of the Second International Conference on SCI 2018, Smart Intelligent Computing and Applications*, 2. DOI:1007/10/978-981-13-1927-3_57.
- Rather, A.M; Sastry, V.N. & Agarwal, A. (2017). Stock market prediction and Portfolio selection models: a survey. *OPSEARCH*. 54(3). 558-579. DOI:1007/10/s12597-016-0289-y.
- Santoso, B. , Sidharta, E.A. & Wardini, A.K. (2020) .The impact of Fundamental Factors on Stock Return of Engineering and Construction Services Companies. *Jurnal Organisasi dan Manajemen*, 16(2), 158-170. DOI: 33830/10/jom.v16i818/2020/2.
- Setayesh, M.H. & Kazemnezhad, M. (2018). The Usefulness of Variables (Dimension) Reduction Methods in Stock Returns of the Companies Listed on Tehran Stock Exchange. *Empirical studies in financial accounting*, 16(63): 83-107. <https://doi.org/22054/10/qjma.10647/2019>. (In Persian)
- Ta, V-D; Liu C-M; & Tadesse, DA. (2020). Portfolio Optimization-Based Stock Prediction Using Long-Short Term Memory Network in Quantitative Trading. *Applied Sciences*, 10(2), 1-20. <https://doi.org/3390/10/app10020437>.
- Ustun, O. & Kasimbeyli, R. (2012). Combined forecasts in portfolio optimization: A generalized approach. *Computers & Operations Research*, (39), 805-819. DOI:1016/10/j.cor.09/008/2010.
- Xiu, Y. & Zhang, W. (2017). Multivariate chaotic time series prediction based on NARX neural networks. *2th International Conference on Electrical, Automation and Mechanical Engineering (EAME 2017)*, 86, 164-167. DOI:2991/10/eame-2017/40/17.
- Zolfaghari, M; Sahabi, B; & Bakhtyaran, M. J. (2020). Designing a Model for Forecasting the Stock Exchange Total Index Returns (Emphasizing on Combined Deep Learning Network Models and GARCH Family Models). *Financial Engineering and Portfolio Management*, 11(42): 138-171. <https://dorl.net/dor/1001/22519165/20/11/1/6/1399/7/42>. (In Persian)