

Proposing a Model for Feasibility Assessment of Utilizing Artificial Neural Networks Optimized by Metaheuristic Algorithms for Predicting Stock Prices of Companies during Crises in the Tehran Stock Exchange

Masud Darabi*¹, Mohsen Golsorkh Hagh², Asghar Asgharzadeh³, Aidin Aboutalebi⁴

1. Assist. Prof. Faculty of Passive Defense, Malek Ashtar University of Technology, Tehran, Iran. (Corresponding Author) masud.darabi@gmail.com
2. PhD. in Strategic Defense Management, Supreme National Defense University, Tehran, Iran.
3. Assist. Prof. Social Capital Research Institute, Commandery University and AJA Headquarters, Tehran, Iran.
4. PhD. Student, Monetary Economics, Faculty of Economic, Islamic Azad university, Science and Research Branch, Tehran, Iran.



<https://dor.isc.ac/dor/20.1001.1.23453915.1404.14.1.1.9>

Original Paper

Currently, investing in the stock market constitutes a significant portion of the country's economy. Securities are considered a reliable tool for gaining the trust of investors and are associated with various levels of risk. This approach can gather small and dispersed investments that, on their own, cannot be effectively utilized and transform them into substantial financial resources for economic development. In stock markets, price fluctuations are highly sensitive, leading to regular analysis and monitoring of these changes. As a result, stock price prediction has gained significant importance for investors, enabling them to maximize their returns and assisting them in making informed investment decisions. In recent years, modern time-series prediction methods based on artificial intelligence and machine learning have advanced rapidly. Given the high value of this data for investment and stock price prediction, traditional data analysis methods face limitations in effectively learning from it. With technological advancements and the introduction of new techniques, such as neural networks and metaheuristic algorithms, the use of these methods for stock price prediction has seen significant growth. In this study, the capability of various models based on neural networks optimized by two algorithms, Harris Hawk Optimization (HHO) and Honey Badger Algorithm (HBA), in predicting the stock price trends of two companies, Iran Khodro and Isfahan Oil Refinery, in the Tehran Stock Exchange over the next 10 days, is examined. The results of these two algorithms are compared using metrics such as MSE, RMSE, MAE, RSE, and EVS. The findings of this research indicate that the HBA algorithm outperforms the HHO algorithm, with accuracies of 75% and 76% in predicting the stock prices of Iran Khodro and Isfahan Oil Refinery, respectively, compared to the HHO algorithm's accuracies of 73% and 67%.

Keywords:
Stock Price Prediction, Artificial Neural Network, Stock Market, Metaheuristic Optimization Algorithms, Crisis.



Received: Nov. 10, 2024
Revised: Dec. 6, 2024
Accepted: Jan. 25, 2025



Use your device to scan and read the article online

To cite this article:

Darabi, M., Golsorkh Hagh, M., Asgharzadeh, A. and Aboutalebi, A. 2025. Proposing a Model for Feasibility Assessment of Utilizing Artificial Neural Networks Optimized by Metaheuristic Algorithms for Predicting Stock Prices of Companies during Crises in the Tehran Stock Exchange, *Emergency Management*, 14(1), 1-36.
<https://dor.isc.ac/dor/20.1001.1.23453915.1404.14.1.1.9>

© The Author(s).

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)





ارائه مدلی برای امکان‌سنجی استفاده از شبکه عصبی مصنوعی بهینه‌سازی شده توسط الگوریتم‌های بهینه‌سازی فرا ابتکاری برای پیش‌بینی قیمت سهام شرکت‌ها در بحران‌های بورس اوراق بهادار تهران

مسعود دارابی^{۱*}، محسن گل سرخ حق^۲، اصغر اصغرزاده^۳، آیدین ابوطالبی^۴

۱- استادیار، مجتمع دانشگاهی پدافند غیرعامل، دانشگاه مالک اشتر، تهران، ایران (نویسنده مسئول) masuod.darabi@gmail.com

۲- دکترای مدیریت راهبردی دفاعی، دانشگاه عالی دفاع ملی، تهران، ایران

۳- استادیار، مدیریت مالی، پژوهشکده سرمایه اجتماعی، دانشگاه فرماندهی و ستاد آجا، تهران، ایران

۴- دانشجوی دکترای اقتصاد، بخش اقتصاد، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم تحقیقات، تهران، ایران



<https://dor.isc.ac/dor/20.1001.1.23453915.1404.14.1.1.9>

مقاله پژوهشی

چکیده

در حال حاضر، سرمایه‌گذاری در بورس بخش قابل توجهی از اقتصاد کشور را شامل می‌شود. اوراق بهادار ابزاری مطمئن برای جذب اعتماد سرمایه‌گذاران به شمار می‌رود و با ریسک‌های متفاوتی همراه است. این بازار قادر است سرمایه‌های کوچک و پراکنده‌ای را که به تنهایی قابلیت بهره‌برداری ندارند، جمع‌آوری کرده و از آن‌ها منابع مالی قابل توجهی برای توسعه اقتصادی ایجاد کند. در بازارهای بورس، نوسانات قیمت از حساسیت بالایی برخوردار است و این موضوع موجب شده که تغییرات مربوط به این نوسانات به‌طور منظم مورد بررسی و تحلیل قرار گیرد. به همین دلیل، پیش‌بینی قیمت سهام در زمان بحران، برای سرمایه‌گذاران اهمیت زیادی پیدا کرده تا بتوانند بیشترین سود ممکن را از سرمایه‌گذاری‌های خود به دست آورند. در سال‌های اخیر و بحران‌های اقتصادی مانند تحریم و سایر موارد، قیمت سهام با نوساناتی همراه بوده است و به دلیل پیش‌بینی دقیق توسط سرمایه‌گذاران در این زمان‌ها، عملکرد کم خطای الگوریتم‌های فرا ابتکاری جدید به‌عنوان روشی نوین مطرح می‌شود. امروزه روش‌های نوین پیش‌بینی سری‌های زمانی بر اساس هوش مصنوعی و یادگیری ماشین به سرعت پیشرفت کرده‌اند، به طوری که این داده‌ها برای سرمایه‌گذاری و پیش‌بینی قیمت سهام ارزش زیادی دارند ولی شیوه‌های سنتی تحلیل داده در یادگیری مؤثر از آن‌ها محدودیت دارند. با توسعه فناوری و ورود تکنیک‌های جدید مانند شبکه‌های عصبی و الگوریتم‌های فرا ابتکاری، استفاده از این روش‌ها در پیش‌بینی قیمت سهام به شکل چشم‌گیری افزایش یافته است. در این تحقیق، امکان‌سنجی توانایی مدل‌های مختلف مبتنی بر شبکه‌های عصبی بهینه‌سازی شده توسط دو الگوریتم شاهین هریس (HHO) و الگوریتم گورکن عسل خوار (HBA) در پیش‌بینی روند قیمت سهام در دو شرکت ایران خودرو و پالایش نفت اصفهان در بحران‌های بازار بورس اوراق بهادار تهران در بازه زمانی ۱۰ روز آینده مورد بررسی قرار گرفته است و با معیارهای R^2 ، $RMSE$ ، MAE ، RSE و EVS نتایج این دو الگوریتم مقایسه شده است. نتایج این تحقیق نشان می‌دهد که الگوریتم HBA در پیش‌بینی قیمت سهام ایران خودرو و پالایش نفت اصفهان در طول زمان و بحران‌ها با دقت‌های به ترتیب ۷۵٪ و ۷۶٪ نسبت به الگوریتم HHO با دقت‌های ۷۳٪ و ۶۷٪ برتری دارد.

واژه‌های کلیدی:
پیش‌بینی قیمت سهام،
شبکه عصبی مصنوعی،
بورس، الگوریتم‌های
بهینه‌سازی فرا ابتکاری،
بحران

دریافت: ۱۴۰۳/۸/۲۰

اصلاح: ۱۴۰۳/۹/۱۶

پذیرش: ۱۴۰۳/۱۱/۶



از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید

برای ارجاع به این مقاله به صورت زیر اقدام فرمایید:

دارابی، م.، گل سرخ حق، م.، اصغرزاده، ا.، ابوطالبی، ا.، ۱۴۰۴، ارائه مدلی برای امکان‌سنجی استفاده از شبکه عصبی مصنوعی بهینه‌سازی شده توسط الگوریتم‌های بهینه‌سازی فرا ابتکاری برای پیش‌بینی قیمت سهام شرکت‌ها در

بحران‌های بورس اوراق بهادار تهران. مدیریت بحران، ۱۴(۱)، ۳۶-۱

<https://dor.isc.ac/dor/20.1001.1.23453915.1404.14.1.1.9>



© The Author(s).

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)

در این پژوهش امکان‌سنجی استفاده از شبکه عصبی مصنوعی بهینه‌سازی شده توسط الگوریتم‌های بهینه‌سازی فرا ابتکاری برای پیش‌بینی قیمت سهام شرکت‌ها در بحران‌های بورس اوراق بهادار تهران مورد مطالعه قرار گرفته است و با مقایسه کارایی الگوریتم‌ها در نوسانات قیمتی سالیان اخیر و بحران‌های بورس در تلاش برای معرفی کاراترین الگوریتم برای پیش‌بینی قیمت است. پیش‌بینی قیمت سهام در بورس یکی از فعالیت‌های کلیدی در بازارهای مالی است که برای سرمایه‌گذاران، تحلیل‌گران و کارگزاران اهمیت زیادی دارد. با پیش‌بینی قیمت سهام، سرمایه‌گذاران می‌توانند تصمیم‌های خود را بهتر مدیریت کنند و از ضررهای احتمالی جلوگیری نمایند [۱]. با تحلیل اطلاعات و داده‌های گذشته، پیش‌بینی‌ها به سرمایه‌گذار کمک می‌کنند تا ریسک‌های سرمایه‌گذاری خود را کاهش دهد [۱]. اگر یک سرمایه‌گذار یا معامله‌گر بتواند روند قیمت‌ها را پیش‌بینی کند، می‌تواند در زمان مناسب وارد بازار شود و با خرید سهام در قیمت‌های پایین‌تر و فروش آن در قیمت‌های بالاتر، سود کسب کند [۱]. این پیش‌بینی‌ها می‌توانند در بهره‌برداری از فرصت‌های سودآور بازار بسیار مؤثر باشند. پیش‌بینی قیمت سهام به تحلیل‌گران و مدیران صندوق‌ها کمک می‌کند تا تصمیمات بهتری در تخصیص منابع مالی بگیرند. این امر باعث می‌شود که منابع مالی به شرکت‌ها یا صنایعی اختصاص یابند که بیشترین بازدهی را داشته باشند [۲]. پیش‌بینی قیمت سهام اغلب شامل تحلیل وضعیت مالی و عملکرد شرکت‌ها نیز می‌شود. این امر به تحلیل‌گران و سرمایه‌گذاران امکان می‌دهد تا وضعیت مالی شرکت‌ها را بهتر درک کنند و بر اساس آن تصمیم‌گیری کنند [۲]. با دسترسی به پیش‌بینی‌های قوی‌تر و شفاف‌تر، سرمایه‌گذاران

به اطلاعات بیشتری دسترسی پیدا می‌کنند. این امر باعث می‌شود که بازارها شفاف‌تر و منصفانه‌تر باشند و احتمال تقلب و نوسانات ناشی از اطلاعات ناقص کاهش یابد [۳]. در مجموع، پیش‌بینی قیمت سهام با استفاده از مدل‌های هوش مصنوعی (AI) و شبکه‌های عصبی مصنوعی (ANNs) یکی از روش‌های پیشرفته و پرکاربرد در تحلیل بازارهای مالی است و این روش‌ها به دلیل توانایی در تحلیل الگوهای پیچیده، استخراج روابط پنهان و پردازش حجم بالای داده‌ها بسیار محبوب شده‌اند، نقش این روش‌ها در دانش‌افزایی و بهبود روش‌های تحلیل، باعث افزایش دقت پیش‌بینی‌ها نسبت به روش‌های سنتی مانند تحلیل تکنیکال و تحلیل بنیادی می‌شود. شرکت‌های مالی از ابزارهای هوشمند برای ارائه پیشنهادها، سرمایه‌گذاری دقیق‌تر به مشتریان استفاده می‌کنند. در رابطه با آموزش و تحقیق توسعه‌دهندگان و پژوهشگران می‌توانند از این روش‌ها برای طراحی مدل‌های جدیدتر و دقیق‌تر استفاده کنند. پیش‌بینی قیمت سهام می‌تواند به افزایش اعتماد و کارایی بازار کمک کند و باعث تصمیم‌گیری بهتر و هوشمندانه‌تر سرمایه‌گذاران و تحلیل‌گران شود. پیش‌بینی قیمت سهام به‌عنوان یک فعالیت پیچیده در زمینه تحلیل سری‌های زمانی مالی شناخته می‌شود [۳]. پیش‌بینی دقیق قیمت سهام می‌تواند منافع قابل‌توجهی را برای سرمایه‌گذاران به ارمغان آورد. با اینکه تلاش‌های زیادی در این راستا صورت گرفته، هنوز موفقیت‌های قابل‌توجهی حاصل نشده است [۴]. به دلیل پیچیدگی داده‌های بازار بورس، ایجاد مدل‌های مؤثر برای این نوع پیش‌بینی کار آسانی نیست [۴]. روش‌های سنتی در شناسایی الگوهای پیچیده و غیرخطی بازار با محدودیت‌هایی مواجه‌اند [۴]. شبکه‌های عصبی به همراه الگوریتم‌های بهینه‌سازی فرا ابتکاری می‌توانند این محدودیت‌ها را رفع کنند و خطای

پیش‌بینی‌ها را کاهش دهند، چراکه این سیستم‌ها توانایی یادگیری و به‌روزرسانی بر اساس تغییرات جدید در داده‌ها را دارند. با توجه به موارد ذکر شده، در این تحقیق به امکان‌سنجی استفاده از شبکه عصبی مصنوعی برای پیش‌بینی قیمت دو سهام ایران خودرو و پالایش نفت اصفهان در بحران‌های بازار بورس تهران، در بازه زمانی ۱۰ روز آینده توسط دو الگوریتم بهینه‌سازی فرا ابتکاری شاهین هریس (HHO) و گورکن عسل خوار (HBA) پرداخته‌شده و نتایج آن‌ها با یکدیگر مقایسه شده است.

۲- مطالعات پیشین

به‌منظور پیش‌بینی قیمت سهام شرکت‌ها در بورس اوراق بهادار با استفاده از مدل‌های هوش مصنوعی و یادگیری ماشین، مطالعات داخلی و خارجی زیادی انجام شده است که در ادامه به برخی از آن‌ها اشاره شده است.

عادل آذر و همکاران (۱۳۸۵) با بهره‌گیری از سه رویکرد، شامل روش‌های کلاسیک، هوش مصنوعی و مدل ترکیبی، شاخص قیمت سهام را پیش‌بینی کردند. در ابتداء، عملکرد روش‌های کلاسیک مانند هموارسازی نمایی، تحلیل روند و مدل ARIMA و همچنین تکنیک‌های هوش مصنوعی از جمله شبکه‌های عصبی و شبکه‌های عصبی فازی ارزیابی شد. سپس، در مرحله سوم، مدل ترکیبی از ARIMA و شبکه‌های عصبی فازی طراحی و بررسی شد. نتایج نشان می‌دهد که مدل ترکیبی عملکرد بهتری نسبت به سایر روش‌های کلاسیک و هوش مصنوعی دارد [۵].

مرادزاده فرد و همکاران (۱۳۹۳) با استفاده از ترکیب روش‌های هوش مصنوعی شامل شبکه‌های عصبی - فازی و الگوریتم ژنتیک و مدل خطی ARIMA به پیش‌بینی قیمت سهام (بورس اوراق بهادار تهران - شرکت ایران خودرو) پرداختند. هدف آن‌ها رسیدن به این پاسخ است که آیا

می‌توان با استفاده از ترکیب روش‌های هوش مصنوعی مدلی ایجاد نمود که نسبت به سایر روش‌های خطی و غیرخطی پیش‌بینی قیمت سهام را با میزان خطای کمتری انجام دهد. نتایج تحقیق آن‌ها با توجه به معیارهای MSE, MAPE, MAE, R نشان از برتری مدل ترکیبی نسبت به سایر مدل‌های مورد بررسی دارد [۶].

صالحی و همکاران (۱۳۹۵) تغییرات شاخص قیمت سهام صنعت بانک‌ها و مؤسسات مالی بورس تهران را برای سال‌های ۱۳۸۵ تا ۱۳۹۲ با بهره‌گیری از الگوریتم‌های هوش مصنوعی بررسی کردند. در این پژوهش، با استفاده از مطالعات پیشین، ۴۸ متغیر مؤثر بر قیمت سهام شناسایی و به‌عنوان ورودی الگوریتم PSO انتخاب شد. الگوریتم PSO ترکیب بهینه‌ای از متغیرهای مؤثر را تعیین کرد و در نهایت ۱۰ متغیر به‌عنوان مهم‌ترین عوامل گزینش شدند. این متغیرها شامل نسبت‌های حسابداری به‌عنوان متغیر مستقل و قیمت سهام به‌عنوان متغیر وابسته بودند. نتایج تحقیق نشان داد که الگوریتم‌های مورد استفاده، توان بالایی در پیش‌بینی شاخص سهام بورس تهران دارند و الگوریتم ANFIS عملکرد بهتری نسبت به سایر الگوریتم‌ها از خود نشان داد [۷].

سارنج و همکاران (۱۳۹۷) به بررسی رفتار قیمت سهام پرداختند و یک مدل ترکیبی از شبکه عصبی و تبدیل موجک را پیشنهاد کردند. در این مدل، الگوریتم ژنتیک برای بهینه‌سازی تابع پایه تبدیل موجک و افزایش کارایی آن به کار گرفته شده است. داده‌های استفاده‌شده در این پژوهش شامل داده‌های روزانه از تاریخ ۱۳۹۱/۰۲/۰۲ تا ۱۳۹۶/۰۱/۳۰ است. نتایج نشان داد که این روش با یافتن تابع پایه‌ای هماهنگ با ویژگی‌های ذاتی سری زمانی، دقت پیش‌بینی را بهبود می‌بخشد و خطای پیش‌بینی را در مقایسه با مدل شبکه عصبی و مدل ترکیبی شبکه عصبی

و تبدیل موجب کاهش می‌دهد [۸].
وقفی (۱۳۹۸) به بررسی نقش الگوریتم‌های هوش مصنوعی در پیش‌بینی ورشکستگی مالی شرکت‌های پذیرفته‌شده در بورس تهران با بهره‌گیری از متغیرهای کلان اقتصادی و حسابداری پرداخت. این پژوهش با تحلیل داده‌های ۱۴۸۸ شرکت از سال ۱۳۹۰ تا ۱۳۹۵، به بومی‌سازی روشی برای شناسایی شرکت‌های دارای بحران مالی در سه سطح پرداخته است. در نهایت، با استفاده از الگوریتم‌های هوش مصنوعی مانند ماشین بردار پشتیبان با کرنل گوسی و الگوریتم چاید، ورشکستگی مالی در سال‌های آتی و دو سال آینده با استفاده از متغیرهای کلان و حسابداری پیش‌بینی شد. از جنبه‌های نوآورانه این تحقیق، بومی‌سازی مدل‌های ورشکستگی برای ایران با استفاده از ترکیبی از مدل‌های بین‌المللی و ایرانی و کاربرد هم‌زمان متغیرهای اقتصادی و حسابداری است. نتایج نشان می‌دهد که تورم و ریسک مالی تأثیر مستقیم و نسبت مدیران غیرموظف، بازده سالانه سهام و نسبت وجه نقد عملیاتی تأثیر معکوس بر ورشکستگی دارند. همچنین، الگوریتم ماشین بردار پشتیبان با کرنل گوسی دقت بیشتری نسبت به الگوریتم چاید در پیش‌بینی ورشکستگی نشان داده است [۹].

پاشایی و همکاران (۱۳۹۹) در تحقیق خود بازار سهام تهران را به‌عنوان یک بازار واقعی بررسی کردند. برای پیش‌بینی شاخص کل سهام تهران، از مدل‌های هوشمند غیرخطی مانند شبکه عصبی مصنوعی (ANN) و شبکه عصبی فازی (ANFIS) بهره بردند و عملکرد آن‌ها را با مدل‌های خطی کلاسیک (ARIMA) و (SARIMA) مقایسه کردند. علاوه بر شاخص کل، داده‌های تأثیرگذاری مانند قیمت دلار، طلا، نفت، شاخص صنعت، شاخص ارز شناور و شاخص بازار اول و دوم طی پنج سال اخیر نیز مورد بررسی

قرار گرفت. داده‌های انتخابی به‌عنوان ورودی به مدل‌های ANN و ANFIS وارد شدند، به‌طوری‌که با استفاده از معیارهای تابع اطلاعات مشترک (MI) و ضریب همبستگی خطی (CC)، ویژگی‌های مؤثر بر شاخص کل شناسایی و داده‌های نامرتب حذف شدند. مقایسه این مدل‌ها بر اساس معیارهای برازش نشان داد که انتخاب ویژگی‌ها با روش‌های MI و CC دقت پیش‌بینی شاخص را در هر دو مدل ANFIS و ANN تا ۵۵٪ بر اساس معیار ارزیابی Nash-Sutcliffe افزایش می‌دهد. همچنین، ANFIS در هر پنج معیار ارزیابی عملکرد بهتری نسبت به ANN دارد [۱۰].

رجب‌زاده و همکاران (۱۴۰۰) با استفاده از رویکرد هوش مصنوعی به تحلیل عوامل مؤثر بر نقدینگی و پیش‌بینی نقدینگی شرکت‌های پذیرفته‌شده در بورس تهران پرداختند. برای این منظور، اطلاعات مالی ۱۳۸ شرکت از سال ۱۳۹۰ تا ۱۳۹۷ برای آزمون فرضیات پژوهش گردآوری شد. در این تحقیق، نسبت وجه نقد عملیاتی به‌عنوان متغیر وابسته (نقدینگی) و شاخص‌های مالی به‌عنوان متغیرهای مستقل اولیه انتخاب شدند. نتایج نشان داد که معیارهایی مانند بازده دارایی‌ها، کیو توین، نسبت سرمایه در گردش، حاشیه سود عملیاتی و سود تقسیمی تأثیر بیشتری بر نقدینگی دارند و رویکرد هوش مصنوعی لاسو توانایی بالایی در پیش‌بینی نقدینگی شرکت‌های بورس تهران دارد [۱۱].

حیدری و همکاران (۱۴۰۱) با بهره‌گیری از مدل‌های گوناگون یادگیری ماشین به پیش‌بینی روند قیمت سهام در بورس تهران پرداختند. داده‌های مربوط به ۱۵۰ شرکت بزرگ از سال ۱۳۹۰ تا ۱۳۹۹ گردآوری شد و با تنظیم دقیق مدل‌های یادگیری ماشین برای هر سهم، پیش‌بینی قیمت‌ها و ارزیابی دقت مدل‌ها انجام و مقایسه‌ای بین آن‌ها صورت گرفت. در این

روش‌ها، داده‌ها به دو بخش یادگیری و آزمون تقسیم شدند. مدل‌های مورد استفاده شامل مدل‌های خطی، مدل‌های خود همبسته، جنگل تصادفی و شبکه‌های عصبی بودند. نتایج نشان می‌دهد که مدل‌های یادگیری عمیق، دقت بهتری در پیش‌بینی روند کوتاه‌مدت قیمت‌ها دارند (۷۰ تا ۸۰ درصد) و مدل‌های یادگیری کم‌عمق از دقت بالایی برخوردارند. همچنین، اکثر مدل‌ها در پیش‌بینی روندهای منفی عملکرد بهتری نشان دادند [۱۲].

مصری، جعفر؛ محمدرضا شهرکی (۱۴۰۱) در شناسایی و گروه‌بندی ریسک‌های احداث واحدهای صنعتی به‌وسیله روش دلفی و شبکه عصبی مصنوعی خود سازمانده، با استفاده از روش دلفی با کمک خبرگان و اساتید دانشگاه در ۳ سطح از ۴۰ ریسک مورد بررسی ۲۱ ریسک را انتخاب کردند. سپس با توجه به نظر خبرگان، اساتید و مصاحبه‌های عوامل اجرایی ساخت کارخانه تراورس تمامی عوامل ریسک در مورد احتمال وقوع و شدت تأثیر ریسک از صفر تا ۱۰ امتیازدهی کردند. سپس با بهره‌گیری از شبکه عصبی خود سازمانده کوهونن در برنامه نرم‌افزاری MATLAB، ریسک‌ها گروه‌بندی و نتایج خروجی شبکه عصبی مشخص شد و با توجه به ۵ گروه طبقه‌بندی که مشخص شده بود، ریسک‌های قرارگرفته در گروه ۴ از لحاظ میزان اهمیت بین ۶۰ تا ۸۰ درصد اهمیت را به خود اختصاص داده بودند که می‌توان با طرح و بررسی این موضوع در احداث واحدهای صنعتی تازه در کشور میزان ریسک احداث این گونه واحدهای صنعتی را در کشور به میزان زیادی کاهش داد [۱۳].

خضرلو، آرام؛ (۱۴۰۲) در تحلیل فضایی آسیب‌پذیری محلات شهر سلماس در برابر زلزله مبتنی بر روش Fuzzy WASPASS در نرم‌افزار متلب، در تحقیقی با هدف تحلیل فضایی آسیب‌پذیری محلات شهر سلماس در برابر زلزله

با رویکرد پدافند غیرعامل، برای نیل به هدف تحقیق تعداد ۱۲ شاخص انتخاب و بر اساس توابع فازی در نرم‌افزار GIS استانداردسازی انجام‌شده و برای نمایش آسیب‌پذیری در محلات ۱۳ گانه شهر سلماس نیز از روش WASPAS بهره گرفته‌شده و داده‌های آن در نرم‌افزار MATLAB تحلیل شده است. نتایج بیانگر آن بوده که ۱۶ درصد از محدوده شهر سلماس در پهنه آسیب‌پذیری خیلی کم، ۳۳ درصد در پهنه آسیب‌پذیری کم، ۲۹ درصد در پهنه آسیب‌پذیری متوسط، ۱۹ درصد در پهنه آسیب‌پذیری زیاد و ۳ درصد در پهنه آسیب‌پذیری خیلی زیاد قرارگرفته بود. همچنین کم‌ترین میزان آسیب‌پذیری مربوط به محله ۱۰ و بیش‌ترین میزان آسیب‌پذیری به محله ۱۳ مربوط بوده است [۱۴].

مزرعه، مسعود؛ محمد حقیقی و لیلیا آندرواژ (۱۴۰۳) در پژوهشی برای جذب سرمایه‌گذاری ترکیبی در راستای رونق کسب‌وکار و رشد اقتصادی در مناطق آزاد تجاری برای مقابله با بحران اقتصادی ناشی از شرایط تحریم و جنگ اقتصادی انجام‌شده است. پس از جمع‌آوری داده‌ها اقدام به آزمون مدل در نرم‌افزار لیزرل شده است. مدل پارادایمی جذب سرمایه‌گذاری ترکیبی دارای چند بعد اصلی است که هر کدام، ابعاد و مقولات خردتری را شامل می‌شوند. به‌عبارت‌دیگر نتایج حاکی از این بوده است که مقوله مرکزی «سرمایه‌گذاری ترکیبی به‌مثابه پدیده‌ای چندبعدی» بوده و در سطح اطمینان ۹۵ درصد بین مقوله مرکزی جذب سرمایه‌گذاری ترکیبی و ابعاد آن با پیامدهای احصاء‌شده به‌صورت فرایندی رابطه معنادار و مثبت وجود دارد، نتایج مدل احصا شده پژوهش در سطح اطمینان ۹۵ درصد مورد تأیید قرار می‌گیرد [۱۵].

مینتاریا و همکاران (۲۰۲۳) در پژوهش خود به پیش‌بینی بازار سهام به مدت طولانی با استفاده از روش‌های سنتی با تحلیل جنبه‌های

بنیادی و تکنیکی پرداختند. با استفاده از یادگیری ماشین، پیش‌بینی‌های بازار سهام آسان‌تر و دقیق‌تر شده‌اند. در این مطالعه، به بررسی آثار مرتبط با رویکردهای یادگیری ماشین در پیش‌بینی بازار سهام پرداخته شده است. برای این منظور، یک مرور سیستماتیک ادبیات انجام شد و ۳۰ مطالعه در زمینه رویکردها و مدل‌های یادگیری ماشین در پیش‌بینی بازار سهام بررسی شده است. رویکردهای مورد استفاده شامل شبکه‌های عصبی و ماشین‌های بردار پشتیبان بود. نتیجه این مطالعه نشان می‌دهد که شبکه‌های عصبی بیشترین کاربرد را دارند [۲].

مقبول و همکاران (۲۰۲۳) در تحقیق خود، مدلی مبتنی بر یادگیری ماشین ارائه کردند که در آن از اخبار مالی به همراه داده‌های تاریخی قیمت سهام برای پیش‌بینی قیمت‌های آتی استفاده می‌شود. سه الگوریتم برای محاسبه نمرات احساسی مختلف به کاررفته و ترکیب‌های متفاوتی از آن‌ها برای درک تأثیر اخبار مالی بر قیمت سهام بررسی شده است. آزمایش‌هایی بر روی داده‌های تاریخی قیمت سهام به مدت ده سال و اخبار مالی چهار شرکت از بخش‌های مختلف انجام شده تا روندهای روز بعد و هفته آینده پیش‌بینی شود و معیارهای دقت برای دوره‌های ۱۰، ۳۰ و ۱۰۰ روز بررسی شده است. مدل پیشنهادی توانسته دقت ۰٫۹۰ را برای هر دو روند و روندهای آینده در دوره ۱۰ روزه به دست آورد. همچنین، آزمایش‌هایی برای بررسی دشواری پیش‌بینی برخی سهام انجام شده که نشان می‌دهد پیش‌بینی سهام شرکت تاتا موتورز بالاترین MAPE را دارد و لذا بیشتر از پیش‌بینی واقعی انحراف دارد [۱۶].

سریواستاوا و همکاران (۲۰۲۳) در پژوهش خود به ارائه مدلی برای پیش‌بینی برای حرکت بازار سهام هند در آینده نزدیک پیشنهاد کرده‌اند که از داده‌های تاریخی شرکت‌های موجود در

شاخص nifty 50 و برخی شاخص‌های مالی و اجتماعی مانند اخبار مالی و توییت‌های مرتبط با سهام استفاده می‌کند. پس از پیش‌پردازش و نرمال‌سازی، الگوریتم‌های مختلف یادگیری ماشین مانند LSTM، ماشین‌های بردار پشتیبان، نزدیک‌ترین همسایگی، جنگل تصادفی و رگرسیون تقویت‌گرایان بر روی این داده‌های زمانی اعمال شده‌اند تا دقت بهتری کسب شود و خطای RMSE کاهش یابد. این مدل می‌تواند خسارات عمده را برای سرمایه‌گذارانی که در بازار سهام سرمایه‌گذاری می‌کنند، کاهش دهد. همچنین، شاخص‌های اجتماعی بینش مناسبی برای پیش‌بینی برای بازار سهام ارائه می‌دهند. شبکه LSTM از قیمت‌های پایانی تاریخی، توییت‌ها و حجم معاملات استفاده می‌کند [۱۷].

سونکاوده و همکاران (۲۰۲۳) در تحقیق خود الگوریتم‌هایی مانند الگوریتم‌های یادگیری ماشین نظارت‌شده و غیر نظارت‌شده، الگوریتم‌های تجمیع، الگوریتم‌های تحلیل سری زمانی و الگوریتم‌های یادگیری عمیق را برای پیش‌بینی قیمت سهام و حل مسائل طبقه‌بندی بررسی می‌کنند. سهم‌های این مقاله مروری به شرح زیر است: (الف) توصیف مدل‌های یادگیری ماشین و یادگیری عمیق مورد استفاده در بخش مالی؛ (ب) ارائه یک چارچوب عمومی برای پیش‌بینی قیمت سهام و طبقه‌بندی؛ و (ج) پیاده‌سازی یک مدل تجمیع—"جنگل تصادفی + XG-Boost + LSTM—برای پیش‌بینی قیمت سهام TAINIWALCHM و AGROPHOS و انجام یک تحلیل مقایسه‌ای با مدل‌های محبوب یادگیری ماشین و یادگیری عمیق. در پایان این مقاله، تأکید می‌شود که پژوهشگران باید به کاوش در زمینه‌های جدید برای حل مشکلات حرکتی قیمت با استفاده از تکنیک‌های تجمیع ادامه دهند. مدل‌های پیش‌بینی سهام باید با تنظیمات مناسب هاپر پارامترها بهبود یابند تا

به‌عنوان مدل‌های دقیق پیش‌بینی قیمت سهام عمل کنند. بازرگانان و مشاوران سرمایه‌گذاری می‌توانند از مدل‌های یادگیری ماشین و یادگیری عمیق به‌عنوان شاخص‌های تأییدی اضافی برای حمایت از تصمیمات خود استفاده کنند و نباید تصمیمات فقط به روش‌های پیش‌بینی قیمت مبتنی بر هوش مصنوعی وابسته باشند. علاوه بر تکنیک‌های پیش‌بینی سهام، پژوهشگران در آینده می‌توانند مطالعات خود را به مدیریت سبد سرمایه‌گذاری، طراحی استراتژی‌های معاملاتی و تصمیم‌گیری سرمایه‌گذاری گسترش دهند [۱۸].

آیلدیز و همکاران (۲۰۲۴) در پژوهش خود به مقایسه عملکرد الگوریتم‌های مختلف در پیش‌بینی برای حرکت شاخص‌های بازار سهام کشورهای توسعه‌یافته و تعیین بهترین الگوریتم پرداختند. شاخص‌هایی همچون NYSE 100 آمریکا (،) NIKKEI 225 ژاپن (،) FTSE 100 انگلستان (،) CAC 40 فرانسه (،) DAX 30 آلمان (،) FTSE MIB ایتالیا (و) TSX کانادا) با الگوریتم‌هایی مانند درخت تصمیم، جنگل تصادفی، نزدیک‌ترین همسایه، بیز ساده، رگرسیون لجستیک، ماشین بردار پشتیبان و شبکه عصبی مصنوعی پیش‌بینی شدند. نتایج نشان داد که شبکه عصبی مصنوعی برای شاخص‌های NYSE 100، FTSE 100، DAX 30 و FTSE MIB و رگرسیون لجستیک برای شاخص‌های CAC 40، NIKKEI 225 و TSX بهترین عملکرد را داشتند. همچنین، شبکه عصبی مصنوعی به‌عنوان بهترین الگوریتم با دقت پیش‌بینی بالاتر از ۷۰ درصد برای تمامی شاخص‌ها شناخته شد [۱].

آجیگا و همکاران (۲۰۲۴) به‌مرور تکنیک‌های یادگیری ماشین (ML) برای پیش‌بینی بازار سهام پرداختند. این مقاله مروری جامع بر مدل‌های مختلف ML در پیش‌بینی بازار سهام ارائه می‌دهد و به بررسی روش‌ها و دقت آن‌ها در پیش‌بینی

روندهای بازار می‌پردازد. ابتدا مدل‌های سنتی سری زمانی مانند ARIMA و MACD و محدودیت‌های آن‌ها در شناسایی الگوهای پیچیده مالی بررسی می‌شوند. سپس، مدل‌های پیشرفته‌تری چون ماشین بردار پشتیبان (SVM)، شبکه‌های عصبی مصنوعی (ANN) و روش‌های ترکیبی مثل جنگل تصادفی و تقویت گرادیانی مورد بحث قرار می‌گیرند. مقاله به اهمیت انتخاب ویژگی و مهندسی آن در بهبود دقت پیش‌بینی ML پرداخته و تأثیر مجموعه ویژگی‌هایی مانند شاخص‌های مالی، متغیرهای اقتصادی کلان، تحلیل احساسات، اخبار و داده‌های شبکه‌های اجتماعی را تحلیل می‌کند. همچنین، به بررسی استفاده از شاخص‌های فنی و منابع داده جایگزین به‌منظور تقویت مدل پرداخته‌شده و دقت مدل‌ها با معیارهایی چون خطای مطلق میانگین (MAE)، خطای میانگین مربعات (MSE) و نرخ دقت مقایسه می‌شود. این مقاله مروری، چالش‌ها و فرصت‌های پیش‌رو برای بهبود دقت در پیش‌بینی‌های بازار را به‌طور جامع بررسی کرده و بینش‌های ارزشمندی برای محققان، فعالان و سرمایه‌گذاران ارائه می‌دهد [۱۹].

فوک و همکاران (۲۰۲۴) در پژوهش خود به پیش‌بینی روند قیمت سهام در ویتنام با استفاده از الگوریتم حافظه طولانی کوتاه‌مدت (LSTM) و شاخص‌های تحلیل تکنیکال شامل میانگین متحرک ساده (SMA)، میانگین متحرک همگرایی-واگرایی (MACD) و شاخص قدرت نسبی (RSI) بر اساس داده‌های VN-Index و VN-30 پرداختند. نتایج نشان داد مدل پیش‌بینی برای بیشتر داده‌های سهام با دقت بالای ۹۳٪ عمل می‌کند. این یافته‌ها مناسب بودن مدل LSTM را در تحلیل و پیش‌بینی حرکات قیمت سهام نشان می‌دهد [۲۰].

چین و همکاران (۲۰۲۴) در پژوهش خود یک تحلیل جامع از روندها و جهت‌گیری‌های آینده

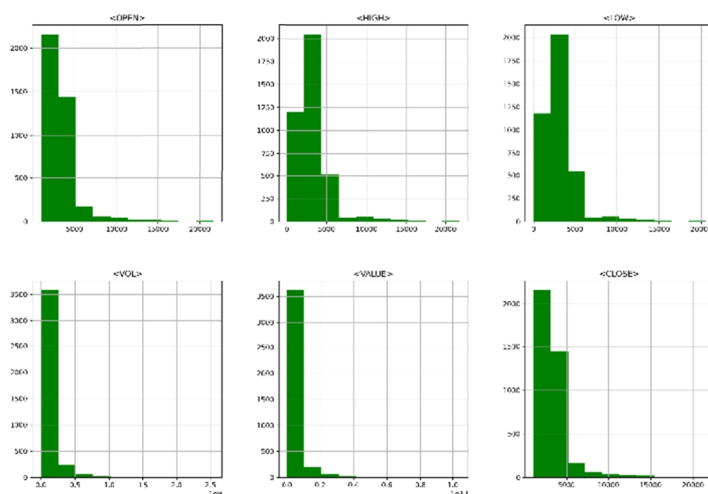
نشان می‌دهند که یادگیری ماشین چگونه پیش‌بینی بازار سهام را متحول کرده است. این مقاله پژوهش‌های ۲۰ سال اخیر در مورد کاربردهای یادگیری ماشین در پیش‌بینی بازار سهام را به‌طور منظم مرور کرده و مقالات را به چهار دسته شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان، الگوریتم‌های ژنتیک به همراه سایر روش‌ها و روش‌های ترکیبی یا جایگزین تقسیم‌بندی کرده است. هر دسته برای شناسایی روندها، دیدگاه‌های مختلف، محدودیت‌ها و نیازهای تحقیقاتی بیشتر بررسی شده است. نتایج این بررسی تحلیل‌های ارزشمندی ارائه داده و پیشنهادهایی برای پژوهش‌های آینده در این حوزه رو به رشد مطرح می‌کند [۴].

سوی و همکاران (۲۰۲۴) در مطالعه خود بر

بهبود پیش‌بینی قیمت سهام برای سرمایه‌گذاران خرد با استفاده از تکنیک‌های پیشرفته یادگیری ماشین بر اساس داده‌های بازار بورس پرداختند. آن‌ها از یک روش جامع شامل پیش‌پردازش داده‌ها برای مدیریت مقادیر گمشده و داده‌های پرت، مهندسی ویژگی، اعتبارسنجی متقابل و تنظیم پارامترها استفاده کردند. تکنیک‌های به‌کاررفته شامل شبکه‌های عصبی عمیق Keras، LSTM، LightGBM، GRU و رگرسیون خطی بوده است. مدل ترکیبی پیشنهادی آن‌ها که مدل‌های سری زمانی و یادگیری عمیق را ترکیب می‌کند، عملکرد بهتری نسبت به مدل‌های فردی نشان می‌دهد. این ادغام روش‌ها منجر به بهبود قابل توجهی در دقت پیش‌بینی می‌شود و راه‌حلی قوی برای سرمایه‌گذاران خرد فراهم می‌کند [۲۱].

جدول ۱- مقادیر آمار توصیفی ویژگی‌های مجموعه داده قیمت سهام ایران خودرو

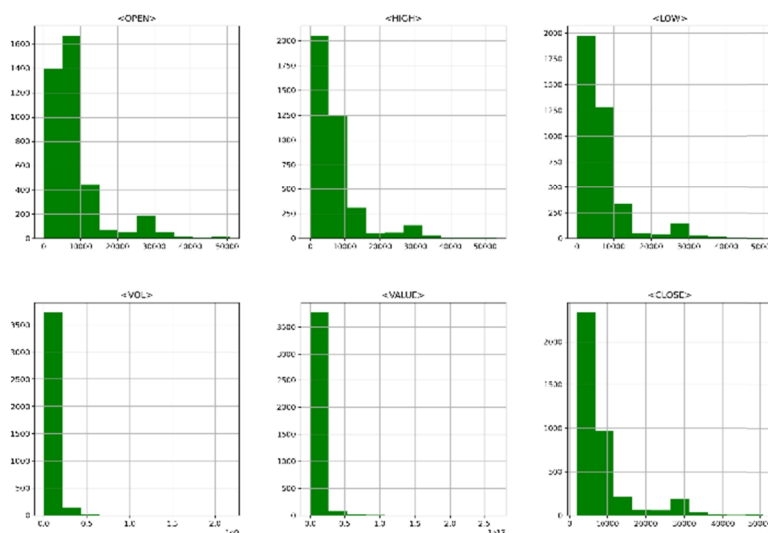
variables	Open	High	Low	Volume	Value	Close
count	3938	3938	3938	3938	3938	3938
mean	3327.37	3106.36	2981.56	67455584.07	281272841104.41	3333.11
std	2185.17	2364.09	2249.55	162416451.78	741677191465.65	2204.04
min	1040.00	0.00	0.00	0.00	0.00	1040.00
25%	2064.00	1798.25	1750.00	436748.50	847586400.25	2064.00
50%	2914.00	2819.50	2720.00	2571860.00	7620094484.50	2914.00
75%	3975.00	3996.50	3833.00	30536023.50	186750000000.00	3976.50
max	21582.00	21750.00	20600.00	2540260831.00	1040000000000.00	21582.00



شکل ۱- هیستوگرام متغیرهای موجود در مجموعه داده قیمت سهام ایران خودرو

جدول ۲- مقادیر آمار توصیفی ویژگی‌های مجموعه داده قیمت سهام پالایش نفت اصفهان

variables	Open	High	Low	Volume	Value	Close
count	3899	3899	3899	3899	3899	3899
mean	8433.80	6644.67	6421.02	40651581.41	448725371147.83	8443.92
std	7304.50	7498.25	7196.23	88911415.82	1454619139061.31	7307.13
min	0.00	0.00	0.00	0.00	0.00	1911.00
25%	4517.00	2621.50	2530.50	121064.00	567397383.00	4518.50
50%	5790.00	5073.00	4942.00	4199784.00	21912883652.00	5800.00
75%	9751.00	7844.00	7590.00	43253519.00	315719500000.00	9751.00
max	50680.00	53210.00	49990.00	2171454496.00	2676040000000.00	50680.00



شکل ۲- هیستوگرام متغیرهای موجود در مجموعه داده قیمت سهام پالایش نفت اصفهان

ساله از ۲۳ دسامبر ۲۰۰۶ تا ۳۰ اکتبر ۲۰۲۴ جمع‌آوری و مورد استفاده قرار گرفته است. این مجموعه داده شامل ۳۹۳۸ نمونه و ۶ متغیر است. متغیرهای قیمت سهام ایران خودرو در هنگام باز شدن^۱، قیمت بالایی^۲، قیمت پایینی^۳، حجم معاملات^۴ و ارزش بازار^۵ به‌عنوان متغیرهای ورودی و متغیر قیمت نهایی سهام ایران خودرو^۶ به‌عنوان متغیر خروجی در نظر گرفته شده است. مقادیر آمار توصیفی متغیرهای مجموعه داده‌های قیمت سهام ایران خودرو در جدول ۱ نمایش داده شده است. همچنین شکل ۱ هیستوگرام نحوه پراکندگی متغیرهای موجود در این مجموعه داده را نمایش می‌دهد.

1 Open
2 High
3 Low
4 Volume
5 Value
6 Close

۳- مواد و روش‌ها

در این بخش ابتدا به معرفی مجموعه داده‌های مورد استفاده در این پژوهش پرداخته می‌شود، سپس روش یادگیری ماشین شبکه عصبی مصنوعی و دو الگوریتم بهینه‌سازی فرا ابتکاری شاهین هریس (HHO) و گورکن عسل خوار (HBA) به‌منظور بهینه‌سازی شبکه‌های عصبی مصنوعی مورد استفاده در این مطالعه شرح داده می‌شود.

۳-۱- مجموعه داده‌های مورد استفاده و آماده‌سازی داده‌ها

در این تحقیق از دو مجموعه داده مربوط به شرکت‌های ایران خودرو و پالایش نفت اصفهان که در بورس ارائه شده استفاده شده است. مجموعه داده‌ی قیمت سهام شرکت ایران خودرو مورد استفاده در این تحقیق مربوط به یک دوره‌ی ۱۷


مجموعه داده‌ی قیمت سهام پالایش نفت اصفهان مورد استفاده در این تحقیق مربوط به یک دوره‌ی ۱۶ ساله از ۲۹ ژوئن ۲۰۰۸ تا ۳۰ اکتبر ۲۰۲۴ جمع‌آوری و مورد استفاده قرار گرفته است. این مجموعه داده شامل ۳۸۹۹ نمونه و ۶ متغیر می‌باشند. متغیرهای قیمت سهام پالایش نفت اصفهان در هنگام باز شدن، قیمت بالایی سهام، قیمت پایینی سهام، حجم معاملات و ارزش بازار به‌عنوان متغیرهای ورودی و متغیر قیمت نهایی سهام پالایش نفت اصفهان به‌عنوان متغیر خروجی در نظر گرفته شده است.

مقادیر آمار توصیفی متغیرهای مجموعه داده‌های قیمت سهام پالایش نفت اصفهان در جدول ۲ نمایش داده شده است. همچنین شکل ۲ هیستوگرام نحوه پراکندگی متغیرهای موجود در این مجموعه داده را نمایش می‌دهد. مقادیر آمار توصیفی متغیرهای مجموعه داده‌های قیمت سهام پالایش نفت اصفهان در جدول ۲ نمایش داده شده است. همچنین شکل ۲ هیستوگرام نحوه پراکندگی متغیرهای موجود در این مجموعه داده را نمایش می‌دهد.

۳-۲- شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی از تعداد زیادی واحد پردازشی متصل به هم تشکیل شده‌اند که به آنها نورون می‌گویند و همانند نورون‌های مغز انسان به‌صورت هماهنگ برای حل مسائل عمل می‌کنند. این نورون‌ها با هم ارتباط دارند و این ارتباط، عملکرد شبکه را تعیین می‌کند. در شبکه‌های عصبی با بهره‌گیری از دانش برنامه‌نویسی، ساختاری ایجاد می‌شود که می‌تواند نقش نورون را ایفا کند و سپس با اتصال گره‌ها به یکدیگر و اعمال الگوریتم‌های یادگیری، آموزش داده می‌شود. این شبکه‌ها با استفاده از مثال‌ها به‌طور مشابه با انسان آموزش می‌بینند [۲۲]. به‌طور کلی، شبکه‌های عصبی سه لایه دارند:

[۲۳]. لایه ورودی که داده‌های اولیه را دریافت می‌کند، لایه‌های پنهان که با ورودی‌ها و وزن‌های ارتباطی کار می‌کنند و مشخص می‌کنند کدام واحد فعال شود و لایه خروجی که عملکرد آن به فعالیت واحدهای پنهان و وزن‌های ارتباطی وابسته است. [۲۳].




شکل ۳- ویژگی‌های اصلی یک نورون زیستی [۲۴]

در یک شبکه عصبی مصنوعی، نورون m اطلاعات ورودی خود را از طریق گره‌های ورودی I_i دریافت می‌کند. پیش از اینکه این اطلاعات به هسته اصلی نورون برسند، به هر ورودی وزنی اعمال می‌شود، به این معنا که مقدار هر ورودی در W_{im} ضرب می‌شود. سپس این مقادیر با هم جمع شده و به‌عنوان ورودی کل به نورون انتقال داده می‌شود. در برخی موارد، مقدار ثابتی به نام بایاس نیز به این ورودی‌ها افزوده می‌شود که میزان آن برابر با b_m است. با در نظر گرفتن وزن بایاس، مقدار نهایی ورودی به نورون طبق رابطه زیر محاسبه می‌شود [۲۵].

$$U_m = \sum_{i=1}^n I_i W_{i,m} + b_m \quad (1)$$

در گام بعدی، یک تابع به نام تابع فعال‌سازی که اغلب غیرخطی است، بر روی مقدار حاصل از مجموع در مرحله قبل اعمال می‌شود و مقدار خروجی نورون با استفاده از این تابع به‌دست می‌آید [۲۵].

$$O_m = f\left(\sum_{i=1}^n I_i W_{i,m} + b_m\right) \quad (3)$$



شکل ۵- فازهای مختلف الگوریتم HHO [۲۶]

۳-۱- فاز اکتشاف


شاهین‌های هریس با تکیه بر دید قوی خود طعمه را جستجو می‌کنند، اما گاهی نیاز به انتظار و نظارت بر محیط دارند. در الگوریتم HHO، شاهین‌ها به‌عنوان راه‌حل‌های کاندید قرار می‌گیرند و بهترین راه‌حل در هر مرحله به‌عنوان طعمه یا جواب تقریبی بهینه انتخاب می‌شود. شاهین‌ها به‌صورت تصادفی در مناطق مختلف پراکنده شده و با دو استراتژی طعمه را شناسایی می‌کنند: در استراتژی اول موقعیت خود را بر اساس موقعیت اعضای گروه و طعمه تنظیم می‌کنند که در رابطه (۳)، با شرط نمایش داده‌شده و در استراتژی دوم، به‌صورت تصادفی روی درختان نزدیک گروه مستقر می‌شوند که در رابطه (۳) با شرط $q \geq 0.5$ نمایش داده‌شده است [۲۶].

(۳)

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3 (LB + r_4 (UB - LB)) & q < 0.5 \end{cases}$$

در رابطه مذکور، $X(t+1)$ به‌عنوان موقعیت شاهین در تکرار بعدی t و $X_{rabbit}(t)$ موقعیت خرگوش را نمایش می‌دهد. همچنین موقعیت فعلی شاهین‌ها و ضرایب r_1, r_2, r_3, r_4 و q اعداد تصادفی در بازه (۰، ۱) هستند که در هر تکرار به‌روز می‌شوند. LB و UB به ترتیب حد

هدف از استفاده از این تابع، محدود کردن خروجی به یک دامنه مشخص است. به‌بیان دیگر، باوجود این تابع، خروجی نوروں در برابر ورودی‌های با مقادیر بسیار کوچک یا بسیار بزرگ از محدوده تعیین‌شده فراتر نمی‌رود [۲۵]. شکل ۴ ساختار و نحوه عملکرد یک شبکه عصبی مصنوعی را نشان می‌دهد.




شکل ۴- ساختار کلی یک شبکه عصبی سه لایه و شیوه پردازش اطلاعات در نوروں [۲۴]

۳-۳- الگوریتم شاهین هریس

الگوریتم شاهین هریس^۱ (HHO) یکی از الگوریتم‌های بهینه‌سازی مبتنی بر جمعیت و الهام گرفته از طبیعت است که در سال ۲۰۱۹ توسط حیدری و همکاران معرفی شد [۲۶]. این الگوریتم رفتار گروهی و شیوه شکار شاهین‌های هریس که به نام یورش غافلگیرانه شناخته می‌شود را شبیه‌سازی می‌کند، جایی که شاهین‌ها با هماهنگی، طعمه خود را از جهات مختلف غافلگیر می‌کنند. HHO با توجه به رفتار پویا و متنوع شاهین‌ها در شکار، الگوهای متنوعی از تعقیب و حمله را ارائه می‌دهد که به آن‌ها امکان می‌دهد در شرایط مختلف، راه‌حل‌های بهینه را پیدا کنند. در این بخش، مراحل اکتشاف و بهره‌برداری در الگوریتم HHO با استفاده از روش‌های گوناگون برای شناسایی طعمه، حمله ناگهانی و استراتژی‌های شکار مدل‌سازی می‌شود [۲۶]. شکل ۵، تمامی گام‌های موجود در الگوریتم HHO را به تصویر می‌کشد.

¹ Harris Hawks Optimization (HHO)

در شکل ۶ نشان داده شده است [۲۶].



شکل ۶- نمودار وابسته به زمان E در طی ۵۰۰ تکرار [۲۶]

۳-۳-۲- فاز بهره‌برداری

در این مرحله، شاهین‌ها به طعمه‌ای که قبلاً شناسایی شده، حمله می‌کنند. باین‌حال، طعمه‌ها معمولاً تلاش می‌کنند از موقعیت‌های خطرناک فرار کنند که این امر منجر به بروز رفتارهای تعقیب متنوعی می‌شود. برای مدل‌سازی فرآیند حمله، چهار استراتژی در HHO پیشنهاد شده است که بر اساس رفتارهای فرار طعمه و استراتژی‌های تعقیب شاهین‌ها طراحی شده‌اند. طعمه‌ها همیشه سعی دارند از تهدیدها بگریزند. فرض کنید شانس موفقیت ($r < 0.5$) یا عدم موفقیت طعمه ($r \geq 0.5$) در فرار قبل از حمله غافلگیرانه باشد. برای مدل‌سازی استراتژی‌های حمله و سوئیچ بین محاصره نرم و سخت در الگوریتم HHO، از پارامتر E استفاده می‌شود. در این صورت، محاصره نرم زمانی رخ می‌دهد که $|E| \geq 0.5$ است و محاصره سخت در زمانی که $|E| < 0.5$ است اتفاق می‌افتد [۲۶].

۳-۳-۳- محاصره نرم

زمانی که $|E| \geq 0.5$ و $r \geq 0.5$ خرگوش انرژی کافی دارد، سعی می‌کند با حرکات گمراه‌کننده فرار کند، اما در نهایت موفق نمی‌شود. در این وضعیت، شاهین‌ها به‌طور نرم او را محاصره می‌کنند تا خستگی‌اش را افزایش دهند و سپس

پایین و بالای متغیرها را نشان می‌دهند. $X_{rand}(t)$ به شاهینی که به‌طور تصادفی از جمعیت انتخاب شده اشاره دارد و $X_m(t)$ میانگین موقعیت شاهین‌ها است که با استفاده از موقعیت هر شاهین در تکرار t و تعداد کل شاهین‌ها N محاسبه می‌شود [۲۶].

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (۴)$$

- انتقال از فاز اکتشاف به فاز بهره‌برداری

الگوریتم HHO قادر است از فاز اکتشاف به فاز بهره‌برداری منتقل شود و در ادامه، بسته به میزان انرژی باقی‌مانده طعمه، به انواع مختلفی از رفتارهای بهره‌برداری تغییر وضعیت دهد. در طول رفتار فرار، انرژی طعمه به تدریج کاهش می‌یابد [۲۶].

$$E = 2E_0 \left(1 - \frac{t}{T} \right) \quad (۵)$$

که E انرژی فرار طعمه و حداکثر تعداد تکرار الگوریتم و E_0 مقدار اولیه انرژی است. در HHO مقدار E_0 در هر تکرار به‌صورت تصادفی در بازه ۱- و ۱ انتخاب می‌شود. زمانی که مقدار E_0 از ۰ به ۱- کاهش می‌یابد، خرگوش ضعیف می‌شود و زمانی که مقدار E_0 از ۰ به سمت ۱ افزایش می‌یابد، خرگوش قوی‌تر می‌شود. انرژی فرار دینامیک E به‌طور پیوسته در طول تکرارها کاهش می‌یابد. زمانی که انرژی فرار $|E| \geq 1$ باشد، شاهین‌ها برای یافتن خرگوش جستجو می‌کنند و الگوریتم در فاز اکتشاف قرار دارد و زمانی که $|E| < 1$ باشد الگوریتم به بهره‌برداری از راه‌حل‌های همسایه می‌پردازد. به‌طور خلاصه زمانی که $|E| \geq 1$ باشد اکتشاف رخ می‌دهد و زمانی که $|E| < 1$ است بهره‌برداری اتفاق می‌افتد. نمودار وابسته به زمان

حمله غافلگیرانه‌ای انجام می‌دهند [۲۶].

(۶)

$$X(t+1) = \Delta X(t) - E | JX_{rabbit}(t) - X(t) |$$


$$\Delta X(t) = X_{rabbit}(t) - X(t) \quad (۷)$$

که $\Delta X(t)$ اختلاف بین موقعیت خرگوش و موقعیت فعلی در تکرار t است و r به‌عنوان عددی تصادفی در بازه (۰ و ۱) معرفی می‌شود که قدرت پرش تصادفی خرگوش در حین فرار را نشان می‌دهد. مقدار J در هر تکرار به‌صورت تصادفی تغییر می‌کند تا رفتار حرکت خرگوش را شبیه‌سازی کند [۲۶].

۳-۳-۴- محاصره سخت

زمانی که $|r| \geq 0.5$ و $|E| \leq 1$ شکار به‌اندازه کافی خسته شده و انرژی فرار آن کاهش یافته است، شاهین‌ها طعمه را با شدت بیشتری محاصره می‌کنند تا نهایتاً حمله غافلگیرانه‌ای انجام دهند. در این وضعیت، موقعیت فعلی طبق رابطه زیر به‌روزرسانی می‌شود [۲۶].

$$X(t+1) = X_{rabbit}(t) - E |\Delta X(t)| \quad (۸)$$



شکل ۷- محاصره سخت [۲۶]

۳-۳-۵- محاصره نرم با یورش‌های سریع روبه‌جلو

زمانی که هنوز $|E| \geq 0.5$ است اما $r < 0.5$ ، خرگوش انرژی کافی برای فرار دارد و محاصره نرم همچنان برقرار است، این فرایند از مرحله

قبلی هوشمندانه‌تر عمل می‌کند. برای مدل‌سازی ریاضی الگوهای فرار طعمه و حرکات جهشی، مفهوم پرواز لوی یا LF در الگوریتم HHO به کار گرفته می‌شود. LF برای تقلید حرکات فریبنده و زیگزاگی طعمه (به‌ویژه خرگوش) در حین فرار و حرکات نامنظم و سریع شاهین‌ها در اطراف طعمه استفاده می‌شود؛ بنابراین، به‌منظور انجام یک محاصره نرم، فرض می‌شود که شاهین‌ها می‌توانند حرکت بعدی خود را بر اساس رابطه زیر ارزیابی کنند [۲۶]:

$$Y = X_{rabbit}(t) - E | JX_{rabbit}(t) - X(t) | \quad (۹)$$

در این مرحله، آن‌ها به مقایسه نتایج احتمالی حرکت خود با شیرجه قبلی می‌پردازند تا ارزیابی کنند که آیا این شیرجه مناسب است یا خیر. اگر این حرکت معقول نباشد (به‌خصوص زمانی که طعمه حرکات فریبنده‌تری را از خود نشان می‌دهد)، آن‌ها به‌تدریج شروع به انجام شیرجه‌های نامنظم و ناگهانی می‌کنند. فرض بر این است که آن‌ها بر اساس الگوهای مرتبط با LF، از رابطه زیر برای انجام شیرجه استفاده می‌کنند [۲۶]:

$$Z = Y + S \times LF(D) \quad (۱۰)$$

که D ابعاد مسئله و S یک بردار تصادفی به‌اندازه D مؤلفه است و LF تابع پروازی Levy است که با رابطه زیر محاسبه می‌شود [۲۶].

(۱۱)

$$LF(x) = 0.01 \times \frac{\mu \times \sigma}{|\nu|^{\frac{1}{\beta}}}, \sigma = \left(\frac{\Gamma(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{\frac{1}{\beta}}$$

که در آن μ و ν اعداد تصادفی در بازه (۰، ۱)


می‌باشند و β یک مقدار ثابت مساوی ۱,۵ است. از این‌رو، استراتژی نهایی برای به‌روزرسانی موقعیت‌های شاهین‌ها در مرحله محاصره نرم توسط رابطه زیر می‌تواند انجام شود [۲۶].

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (12)$$

که در آن Y و Z توسط روابط زیر محاسبه می‌شوند. یک نمای ساده از این مرحله برای یک شاهین در شکل ۸ نشان داده شده است. لازم به ذکر است که تاریخچه موقعیت الگوهای حرکتی مبتنی بر LF در برخی از تکرارها نیز در این تصویر ثبت شده است. نقاط رنگی نشان‌دهنده مکان‌های الگوهای مبتنی بر LF در یک آزمایش هستند و سپس HHO به نقطه Z می‌رسد. در هر مرحله، تنها بهترین موقعیت بین Y یا Z به‌عنوان مکان بعدی انتخاب می‌شود. این استراتژی به تمامی عوامل جستجو تعمیم داده می‌شود [۲۶].

$$Y = X_{rabbit}(t) - E |JX_{rabbit}(t) - X(t)| \quad (13)$$

$$Z = Y + S \times LF(D) \quad (14)$$



شکل ۸- محاصره نرم با یورش‌های سریع روبه‌جلو

[۲۶]

۳-۳-۶- محاصره سخت با یورش‌های سریع روبه‌جلو

زمانی که $|E| < 0.5$ و $r < 0.5$ ، خرگوش توانایی کافی برای فرار را ندارد و در این حالت، محاصره سخت پیش از یورش غافلگیرانه به‌منظور گرفتن و کشتن طعمه شکل می‌گیرد. وضعیت این مرحله در نزدیکی طعمه مشابه شرایط محاصره نرم است، با این تفاوت که شاهین‌ها تلاش می‌کنند فاصله میانگین خود را با طعمه در حال فرار کاهش دهند؛ بنابراین، قانون زیر در شرایط محاصره سخت اجرا می‌شود [۲۶].

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (15)$$

که در آن Y و Z توسط روابط زیر محاسبه می‌شوند [۲۶].

$$Y = X_{rabbit}(t) - E |JX_{rabbit}(t) - X_m(t)| \quad (16)$$

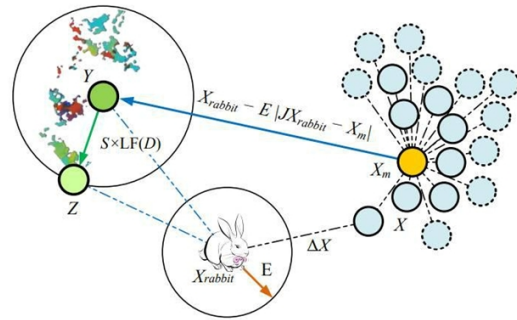
$$Z = Y + S \times LF(D) \quad (17)$$

که در آن $X_m(t)$ با استفاده از رابطه (۴) محاسبه می‌شود. یک مثال ساده از این مرحله در شکل‌های زیر ارائه شده است. توجه داشته باشید که نقاط رنگی نمایانگر موقعیت الگوهای مبتنی بر LF در یک آزمایش هستند و فقط Y یا Z به‌عنوان مکان بعدی برای تکرار جدید انتخاب خواهد شد [۲۶].


۳-۴- الگوریتم گورکن عسل خوار

الگوریتم گورکن عسل خوار^۱ یک الگوریتم بهینه‌سازی فرا ابتکاری است که در سال ۲۰۲۲ توسط هاشم و همکاران ابداع شد [۲۷]؛ که بر اساس رفتار شکار و جستجوی غذا توسط گورکن

¹ Honey Badger Algorithm (HBA)



شکل ۹- محاصره سخت با یورش‌های سریع روبه‌جلو در فضای ۲ بعدی [۲۶]



شکل ۹- محاصره سخت با یورش‌های سریع روبه‌جلو در فضای ۳ بعدی [۲۶]

عسل خوار مدل‌سازی شده است. این الگوریتم از ویژگی‌های خاص و هوشمندانه گورکن‌های عسل خوار، مانند صبر، جستجوی غافلگیرانه و توانایی کشف منابع مخفی غذا الهام گرفته شده است. این الگوریتم در حل مسائل بهینه‌سازی پیوسته و گسسته عملکرد خوبی دارد [۲۷].

۳-۴-۱- زیست‌شناسی گورکن عسل خوار

گورکن عسل خوار جانوری پستاندار و جسور است که توانایی مقابله با حیواناتی بزرگ‌تر مانند شیر و ببر را دارد و می‌تواند ساعت‌ها با آن‌ها مبارزه کند. این حیوان از لحاظ ساختار بدنی به سگ شبیه است و وزنش بین ۷ تا ۱۳ کیلوگرم و طول آن از ۶۶ تا ۷۷ سانتی‌متر متغیر است. زیستگاه اصلی گورکن عسل خوار در نواحی نیمه بیابانی، جنگل‌های بارانی آفریقا، شمال شرق آسیا و هند است. این جانور زندگی انفرادی را ترجیح داده و

بیشتر در حفره‌ها و گودال‌ها سکونت دارد. تا به حال ۱۲ زیرگونه از گورکن شناسایی شده است. این حیوان به دلیل شجاعت بالای خود، در مواجهه با شکارچیان بزرگ‌تر، اگر قادر به فرار نباشد، بدون تردید به آن‌ها حمله می‌کند. تحقیقات نشان می‌دهد که گورکن قادر است تا ۶۰ گونه از مارهای خطرناک را شکار کند. همچنین، همان‌طور که در شکل ۱۱ مشاهده می‌شود، این جانور به راحتی برای رسیدن به لانه پرندگان یا یافتن عسل از درختان بالا می‌رود و از آن‌ها تغذیه می‌کند [۲۸-۳۰].

۳-۴-۲- رفتار گورکن عسل خوار

گورکن عسل خوار با حرکت پیوسته و آرام، از حس بویایی قوی خود برای تعقیب و شکار طعمه استفاده می‌کند (مرحله اکتشاف). در طول روز، این حیوان قادر است تا حدود ۵۰ چاله در شعاع ۴۰ کیلومتری حفر کند. علاقه زیاد گورکن به عسل اما سختی در یافتن آن، منجر به همکاری با نوعی پرنده به‌عنوان راهنما شده است. این پرنده در پیدا کردن عسل ماهر است اما به خود عسل دسترسی ندارد. در نتیجه، پرنده عسل را شناسایی می‌کند و گورکن به دنبال آن می‌رود تا هر دو به غذا دست یابند [۲۷].

الگوریتم گورکن عسل خوار شامل دو حالت اصلی است. در حالت اول، گورکن به تنهایی و با استفاده از حس بویایی و حفر چاله به دنبال طعمه می‌شود که این مرحله به‌عنوان حالت حفاری^۱ شناخته می‌شود. در حالت دوم، با کمک پرنده راهنما به جستجوی عسل می‌پردازد که به آن حالت عسل^۲ گفته می‌شود [۲۷].

۳-۴-۳- مدل ریاضی الگوریتم HBA

در ادامه به تشریح دو فاز حفاری و عسل

¹ Digging mode

² Honey mode

می پردازیم.

$$I_i = r_2 \times \frac{S}{4\pi d_i^2}$$

$$S = (x_i - x_{i+1})^2 \quad (20)$$

$$d_i = x_{prev} - x_i$$

که S منبع تولید بو است (محل طعمه را نمایش می دهد Di). (فاصله بین طعمه و i امین گورکن است. r_2 یک عدد تصادفی بین 0 و 1 است.

گام 3: به روزرسانی ضریب چگالی (α) برای کنترل زمان و حالات تصادفی برای رسیدن از فاز اکتشاف به بهره برداری از فرم ول (3) استفاده نمایید [10].

$$\alpha = C \times \exp\left(\frac{-t}{t_{max}}\right) \quad (21)$$

که C یک عدد ثابت بزرگ تر از 1 است (حالت پیش فرض برابر است با 2). t_{max} حداکثر تعداد تکرارهای الگوریتم است.

گام 4: رهایی از بهینه های محلی: الگوریتم برای رهای از بهینه های محلی از یک تابع F برای جستجو کردن فضای جستجو استفاده می کند [10]. این مرحله و دو مرحله بعدی برای خروج از نواحی بهینه محلی استفاده می شوند. در این راستا، الگوریتم پیشنهادی از یک علامت (F) استفاده می کند که جهت جستجو را تغییر داده و فرصت های بیشتری برای اعضای جمعیت فراهم می آورد تا فضای جستجو را به طور دقیق تری بررسی کنند.

در این بخش مباحث ریاضیاتی و محاسباتی مربوط به تئوری گورکن عسل خوار و مراحل الگوریتم شرح داده می شود همچنین شبه کد الگوریتم آمده است که شامل سه مرحله ایجاد جمعیت اولیه ارزیابی جمعیت و به روزرسانی پارامترها است [10].

$$\begin{bmatrix} X_{11} & X_{12} & X_{13} & \dots & X_{1D} \\ X_{21} & X_{22} & X_{23} & \dots & X_{2D} \\ \dots & \dots & \dots & \dots & \dots \\ X_{n1} & X_{n2} & X_{n3} & \dots & X_{nD} \end{bmatrix} \quad (18)$$

i امین جایگاه گورکن $[X_i^1, X_i^2, \dots, X_i^D] = x_i$
گام 1: فاز مقداردهی اولیه: مطابق فرمول (1) قرار دادن تعدادی گورکن (N) در فضای مسئله [10].

$$x_i = lb_i + r_1 \times (ub_i - lb_i) \quad (19)$$

که i امین گورکن انتخاب شده از جمعیت N و lb_i و ub_i حد بالا و پایین فضای جستجو مسئله اند. r_1 یک عدد تصادفی بین 0 و 1 است.
گام 2: تعریف شدت بو طعمه: مطابق فرمول (2): همان طور که در شکل 4 مشاهده می کنید گورکن با توجه به حس بویایی قوی که دارد با استفاده از شدت بوی طعمه فاصله خود را تا طعمه محاسبه می کند I شدت بوی طعمه 12 است [10].



شکل 10- (a) حمله گورکن عسل خوار به یک شیر (b) بالا رفتن گورکن از شاخ و برگ درختان [27]

۱۷
شماره ۲۹
بهار ۱۴۰۴
فصلنامه علمی و پژوهشی



ارائه مدلی برای امکان سنجی استفاده از شبکه عصبی مصنوعی بهینه سازی شده توسط الگوریتم های بهینه سازی فرا ابتکاری برای پیش بینی قیمت سهام شرکت ها در بحران های بورس اوراق بهادار تهران / مسعود دارابی، محسن گل سرخ، حق، اصغر امغرزاده، آیدین یوطلبی

(۲۲)

$$X_{new} = X_{prey} + F \times \beta \times X_{prey} + F \times r_3 \times \alpha \times d_i \times \left| \cos(2\pi r_4) \times [1 - \cos(2\pi r_5)] \right|$$

$$F = \begin{cases} 1 & \text{if } r_6 \leq 0.5 \\ -1 & \text{else} \end{cases} \quad (۲۳)$$

r_6 یک عدد تصادفی بین ۰ و ۱ است. در فاز حفاری گورکن به دنبال شدت بوی (I) طعمه (I) می تواند با استفاده از F اختلالها را متوجه شده و طعمه بهتری پیدا کند.


فاز عسل: این مرحله زمانی رخ می دهد که گورکن برای یافتن عسل پرنده راهنما را دنبال می کند. این فاز طبق رابطه (۲۴) شبیه سازی می شود.

$$X_{new} = X_{prey} + F \times r_7 \times \alpha \times d_i \quad (۲۴)$$


r_7 یک عدد تصادفی بین ۰ و ۱ است. X_{new} موقعیت جدید گورکن و X_{prey} موقعیت طعمه است.

۴- پیش بینی قیمت سهام توسط مدل پیشنهادی

این پژوهش، یک مطالعه کاربردی با هدف ایجاد چارچوبی برای پیش بینی قیمت سهام^۱ در بازه زمانی ۱۰ روز آینده با استفاده از روش یادگیری ماشین به نام شبکه عصبی مصنوعی^۲ که توسط دو الگوریتم فرا ابتکاری بهینه سازی شده است: الگوریتم شاهین هریس (HHO) و الگوریتم گورکن عسل خوار (HBA) ارائه می دهد. روند کار به این صورت است که ابتدا داده ها در نرم افزار MATLAB پیش پردازش می شوند. پس از نرمال سازی داده ها و رفع مقادیر گمشده، مجموعه



شکل ۱۱- قانون مربع معکوس: I شدت بوی تولیدشده از طعمه، S موقعیت طعمه و r یک عدد تصادفی بین ۰ و ۱ است [۲۷]



شکل ۱۲- فاز حفاری: خط آبی شدت بوی طعمه و خط مشکی موقعیت آن را نمایش می دهد [۲۷]

گام ۵: بروز رسانی موقعیت اعضای جمعیت: فرآیند به روز رسانی موقعیت گورکن () از دو بخش تشکیل می شود. بخش حفاری و عسل که در ادامه توضیح داده شده است.

فاز حفاری: در این فاز گورکن طبق شکل ۱۳ مشابه یک میکروفون کاردیوئید عمل می کند. حرکت گورکن در این فاز را می توان مطابق رابطه شبیه سازی نمود.

که X_{prey} بهترین موقعیت گورکن است و $\beta \geq 1$ (پیش فرض = ۱) که توانایی هر گورکن در یافتن غذا است. d_i فاصله بین i امین گورکن با طعمه است. r_3, r_4, r_5 اعداد تصادفی بین ۰ و ۱ اند و تابع F مطابق با رابطه (۲۳) کار می کند.

۱۸

شماره ۲۹

بهار ۱۴۰۴

فصلنامه علمی

و پژوهشی



ارائه مدلی برای امکان سنجی استفاده از شبکه عصبی مصنوعی بهینه سازی شده توسط الگوریتم های بهینه سازی فرا ابتکاری برای پیش بینی قیمت سهام شرکت ها در بحران های بورس اوراق بهادار تهران / مسعود دارابی، محسن گل سرخ حق، اصغر اصغرزاده، آیدین بوعلالی

¹ Stock

² Artificial Neural Network (ANN)

داده آماده ارائه به شبکه عصبی مصنوعی می‌شود. سپس شبکه عصبی مصنوعی برای پیش‌بینی قیمت سهام شرکت‌های ایران خودرو و پالایش نفت اصفهان، به کمک الگوریتم‌های فوق بهینه‌سازی می‌شود. در پایان، عملکرد هر الگوریتم در بهینه‌سازی شبکه عصبی و دقت پیش‌بینی قیمت سهام با استفاده از معیارهای ارزیابی و اعتبارسنجی بررسی خواهد شد.

۴-۱- پیش‌پردازش داده‌ها

پیش‌پردازش^۱ داده‌ها، مرحله‌ای است که طی آن داده‌های خام برای تحلیل آماده می‌شوند. این فرآیند به معنای تبدیل داده‌های خام به داده‌های قابل درک و بخش اساسی حل مسائل یادگیری ماشین به شمار می‌آید. در کاربردهای واقعی، داده‌ها اغلب ناقص، ناسازگار و دارای الگوهای نامشخص یا خطاهای متعدد هستند. پیش‌پردازش، روشی کارآمد برای رفع این مشکلات است. بسیاری از مجموعه داده‌ها نیازمند پردازش و قالب‌بندی هستند تا بتوان از آن‌ها برای آموزش الگوریتم‌های یادگیری ماشین استفاده کرد. در این مرحله، نکات کلیدی شامل بررسی داده‌های گمشده، حذف داده‌های پرت^۲، نرمال‌سازی^۳ و تقسیم‌بندی داده‌ها^۴ می‌باشند.

۴-۱-۱- داده‌های ناموجود

گاهی برخی ویژگی‌های یک یا چند نمونه ممکن است مقدار معتبری نداشته باشند که این مشکل می‌تواند به دلیل نویزی بودن^۵ داده، عدم ثبت صحیح یا نامعتبر بودن مقدار رخ دهد. به این‌گونه داده‌ها، داده‌های ناموجود گفته می‌شود. برای پردازش مجموعه داده‌هایی با این مشکل، باید

¹ Preprocess
² Outliers
³ Normalization
⁴ Data Splitting
⁵ Noise

روشی برای جایگزینی مقادیر ناموجود انتخاب شود. روش‌های مختلفی برای مدیریت این داده‌ها وجود دارند که از جمله آن‌ها می‌توان به حذف نمونه، جایگذاری دستی، استفاده از مقدار ثابت یا میانگین ویژگی اشاره کرد.

۴-۱-۲- داده‌های پرت


در برخی مواقع، مقادیری در مجموعه داده‌ها مشاهده می‌شوند که اختلاف زیادی با سایر مقادیر دارند و از الگوی کلی داده‌ها پیروی نمی‌کنند؛ به این مقادیر داده‌های پرت گفته می‌شود. این داده‌ها که با رفتار عمومی مجموعه متفاوت هستند، می‌توانند موجب اختلال در عملکرد الگوریتم‌ها و دسته‌بندی‌های^۶ یادگیری ماشین شوند. به همین دلیل، شناسایی و کاهش اثر آن‌ها در مرحله پیش‌پردازش داده اهمیت زیادی دارد. برای مدیریت داده‌های پرت، روش‌های متعددی مانند حذف داده‌ها یا جایگزینی با مقدار میانگین استفاده می‌شود.

۴-۱-۳- نرمال‌سازی داده‌ها

برای بهبود دقت نتایج، لازم است که محدوده مقادیر ویژگی‌های مختلف به هم نزدیک‌تر یا هم‌تراز شود. این کار از طریق نرمال‌سازی انجام می‌شود. روش‌های مختلفی برای نرمال‌سازی وجود دارند که در پژوهش‌های علمی به کار گرفته می‌شوند. از رایج‌ترین آن‌ها می‌توان به نرمال‌سازی مین-مکس^۷، نرمال‌سازی Z-Score^۸ و مقیاس‌گذاری اعشاری^۹ اشاره کرد. در این مطالعه، داده‌ها به محدوده ۰ تا ۱ نرمال‌سازی شدند تا تأثیر مقیاس‌ها در نتایج مدل کاهش یابد. قبل از مدل‌سازی، نرمال‌سازی ورودی‌ها و در برخی موارد خروجی‌ها نیز ضروری است، زیرا

⁶ Classifier
⁷ Min-Max
⁸ Z-Score
⁹ Decimal Scaling

پیشرفته در مدل‌سازی و پیش‌بینی فرآیندها و توابع غیرخطی که روابط ریاضی مشخصی برای تحلیل دقیق آن‌ها در دسترس نیست، کارایی بالایی دارد. این مدل‌ها پس از آموزش، می‌توانند بدون نیاز به روابط ریاضی واضح، رفتار سیستم را شبیه‌سازی و پیش‌بینی کنند. همچنین، عملکرد شبکه‌های عصبی مصنوعی به میزان قابل توجهی به نحوه تنظیم وزن‌ها^۱ و بایاس‌های^۲ آن‌ها وابسته است. در شکل ۱۴ وزن‌های اتصالات نورون‌ها در یک شبکه عصبی سه لایه فرضی با نماد ω و بایاس‌های آن با نماد β نمایش داده شده‌اند.



شکل ۱۴- مقادیر وزن‌ها و بایاس‌های اتصالات

نورونی در یک شبکه عصبی سه لایه

شبکه‌های عصبی مصنوعی، مدل‌هایی الهام گرفته از ساختار یادگیری مغز انسان هستند که توانایی ایجاد ارتباط پیچیده و غیرخطی میان داده‌های ورودی و خروجی را فراهم می‌کنند و می‌توانند حجم زیادی از ورودی‌ها را پردازش کنند. با این وجود، این شبکه‌ها محدودیت‌هایی دارند، از جمله:

۱- شبکه‌های عصبی مصنوعی مانند جعبه سیاه عمل می‌کنند، یعنی امکان تفسیر و اصلاح رفتار آن‌ها به صورت دستی وجود ندارد و رفتار آن‌ها به سادگی قابل درک نیست.

۲- آموزش این شبکه‌ها نیاز به حجم عظیمی از محاسبات دارد که این مسئله به مانعی برای تولید

استفاده از داده‌های خام می‌تواند دقت و سرعت مدل را کاهش دهد. برای نرمال‌سازی داده‌ها، از رابطه (۲۵) استفاده شده که داده‌ها را به محدوده a و b می‌برد. در این رابطه، به ترتیب نمایانگر کمینه، بیشینه و مقدار نرمال‌شده داده ورودی است و a و b حد پایین و بالای محدوده نرمال‌سازی هستند که در اینجا 0 و 1 در نظر گرفته شده‌اند.

$$XN = a + \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (b - a) \quad (25)$$

۴-۱-۴- تقسیم‌بندی داده‌ها

در یادگیری ماشین، معمولاً داده‌ها به دو بخش تقسیم می‌شوند: داده‌های آموزش و داده‌های آزمایش. در این پژوهش، ۸۰ درصد ابتدایی داده‌های قیمت سهام شرکت‌های ایران خودرو و پالایش نفت اصفهان به عنوان داده‌های آموزش و ۲۰ درصد پایانی آن‌ها به عنوان داده‌های آزمایش در نظر گرفته شده است.

داده‌های آموزش (Training set): این بخش برای ایجاد، آموزش و تنظیم پارامترهای مدل‌های یادگیری ماشین به کار می‌رود و مدل‌ها از این داده‌ها برای یادگیری استفاده می‌کنند.

داده‌های آزمایش (Test set): این بخش به منظور ارزیابی عملکرد مدل‌ها مورد استفاده قرار می‌گیرد. داده‌های آزمایش شامل مقادیر ورودی و پاسخ‌های واقعی است که در فرآیند آموزش شرکت نداشته‌اند اما امکان مقایسه پیش‌بینی مدل‌ها را با مقادیر واقعی فراهم می‌کنند. داده‌های آزمایش مدل را تغییر نمی‌دهند و تنها برای ارزیابی دقت مدل‌ها کاربرد دارند.

۴-۱-۵- مدل پیشنهادی پیش‌بینی قیمت سهام

شبکه عصبی مصنوعی به‌عنوان یک روش

¹ Weight
² Bias

گسترده محصولات مبتنی بر این فناوری تبدیل می‌شود.


۳- تنظیم ساختار مناسب و تعیین پارامترهای وزن و بایاس نورون‌ها نیاز به بررسی و تجربه‌ی فراوان دارد و قانون مشخصی برای این کار موجود نیست.

۴- شبکه‌های عصبی مصنوعی در صورت آموزش بیش‌ازحد^۱، دچار کاهش توانایی تعمیم می‌شوند و در مواجهه با داده‌های جدید، خروجی دقیقی ارائه نمی‌دهند.

روش‌های جستجوی گرادیانی یکی از تکنیک‌های مورد استفاده برای به‌روزرسانی وزن‌ها و بایاس‌های شبکه‌های عصبی است؛ اما به دلیل برخی محدودیت‌های این روش‌ها در آموزش شبکه‌های عصبی مصنوعی (ANN)، پژوهشگران به سمت الگوریتم‌های بهینه‌سازی فرا ابتکاری گرایش پیدا کرده‌اند. از جمله ضعف‌های روش‌های گرادیانی می‌توان به وابستگی به نرخ یادگیری، از کارافتادگی شبکه^۲، کاهش سرعت با افزودن لایه‌های پنهان، وجود فضای خطای پیچیده^۳ و احتمال گیر افتادن در نقاط بهینه محلی اشاره کرد. عملکرد این الگوریتم‌ها به شدت به مقدار اولیه وابسته است که احتمال گیر افتادن در بهینه‌های محلی را افزایش می‌دهد. در مقابل، الگوریتم‌های بهینه‌سازی فرا ابتکاری مانند HHO و HBA با رویکرد تصادفی خود، می‌توانند این محدودیت‌ها را کاهش دهند.

این الگوریتم‌ها برای انواع شبکه‌های عصبی مصنوعی با توابع فعال‌ساز مختلف در مسائل پیچیده کاربردی هستند. به‌طور کلی، آموزش ANN شامل تنظیم وزن‌ها و بایاس‌های آن است که به صورت اولیه و تصادفی مقداردهی شده‌اند. این مقادیر در هر تکرار تغییر می‌کنند تا اختلاف

خروجی پیش‌بینی شده با مقدار واقعی به سطح مطلوب برسد. به همین دلیل، به‌روزرسانی وزن‌ها و بایاس‌ها یک مسئله بهینه‌سازی به حساب می‌آید. الگوریتم‌های فرا ابتکاری مانند HHO و HBA می‌توانند به‌عنوان ابزارهایی کارآمد برای تنظیم وزن‌ها و بایاس‌ها در ANN مورد استفاده قرار گیرند. شکل ۱۵ مراحل کلی الگوریتم پیشنهادی را به تصویر می‌کشد.



شکل ۱۴- فرآیند کلی بهینه‌سازی شبکه عصبی توسط الگوریتم‌های HHO، HBA

بنابراین، با توجه به دلایل ذکر شده، بهینه‌سازی شبکه‌های عصبی مصنوعی با استفاده از الگوریتم‌های بهینه‌سازی فرا ابتکاری ضروری به نظر می‌رسد. به همین منظور، در این تحقیق به بررسی بهینه‌سازی شبکه‌های عصبی مصنوعی با بهره‌گیری از الگوریتم‌های فرا ابتکاری نظیر HHO و HBA پرداخته خواهد شد تا قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان پیش‌بینی شود. در این روش، فرآیند آموزش شبکه عصبی که معمولاً زمان‌بر، پرهزینه و مستعد خطاهای آموزشی است، با استفاده از الگوریتم‌های فرا ابتکاری به گونه‌ای انجام می‌شود که نیازی به دخالت مستقیم نباشد. به این ترتیب، مراحل تکراری و خسته‌کننده آزمون و خطا برای دستیابی به خطای مورد نظر حذف می‌شود. این روش آموزشی با افزایش پیچیدگی شبکه، به‌طور بهتری عملکرد خود را نشان می‌دهد.

روش کار به این صورت است که در ابتدا یک

¹ Overtraining
² Paralysis
³ Multimodal

شبکه عصبی مشخص تعریف می‌شود. در این شبکه، تعداد نورون‌های ورودی برابر با تعداد متغیرهای مستقل است. برای لایه پنهان، تعدادی ثابت از نورون‌ها تعیین می‌شود و در لایه نهایی نیز تعداد نورون‌های خروجی با توجه به خروجی‌های مورد نظر مشخص می‌شود. پس از ساخت شبکه عصبی، وزن‌ها و بایاس‌ها به صورت تصادفی مقداره‌ی می‌شوند. به منظور بهره‌گیری از الگوریتم‌های فرا ابتکاری برای آموزش و به‌روزرسانی وزن‌ها و بایاس‌ها، باید آموزش شبکه عصبی را به‌عنوان یک تابع (اختلاف بین خروجی‌های واقعی و خروجی‌های شبکه عصبی) تعریف کرد و هدف بهینه‌سازی (کاهش) این تابع در فضایی با ابعاد M است که M برابر با مجموع وزن‌ها و بایاس‌های شبکه عصبی ایجاد شده است.


سپس، مسئله بهینه‌سازی به‌دست آمده می‌تواند با استفاده از الگوریتم‌های بهینه‌سازی فرا ابتکاری حل شود و این الگوریتم‌ها برای بهینه‌سازی وزن‌ها و بایاس‌های شبکه عصبی فراخوانی می‌شوند. در هر مرحله از الگوریتم، بهترین وزن‌ها و بایاس‌ها انتخاب می‌شوند و در نهایت بهترین نتیجه در میان تمامی پاسخ‌ها به‌عنوان جواب بهینه الگوریتم ارائه می‌شود.

این مقادیر به‌عنوان وزن‌ها و بایاس‌های شبکه عصبی در نظر گرفته می‌شوند و وزن‌ها به‌روزرسانی می‌شوند. در نهایت، شرط پایان مورد بررسی قرار می‌گیرد و در صورت برقراری این شرط، الگوریتم خاتمه می‌یابد. شرایط پایانی معمولاً به دو صورت تعریف می‌شود: ۱- خطای حداقل مربعات شبکه (RMSE) از یک آستانه مشخص کمتر باشد ۲- تعداد تکرارهای از پیش تعیین شده. در نهایت، با تحقق این شرایط، به شبکه عصبی با وزن‌ها و بایاس‌های بهینه دست می‌یابیم.

برای آموزش شبکه عصبی مصنوعی با بهره‌گیری از الگوریتم‌های بهینه‌سازی فرا ابتکاری

مانند HHO و HBA، وزن‌ها و بایاس‌های هر نورون مصنوعی در شبکه در بردارهای تصادفی تولید می‌شوند به‌گونه‌ای که شبکه عصبی مصنوعی کمترین خطا را بر روی داده‌های آموزشی داشته باشد. طول این بردار برابر با مجموع وزن‌ها و بایاس‌های لازم برای ایجاد شبکه عصبی است. به‌طور کلی، به ازای هر عضو جمعیت تولید شده در الگوریتم‌های بهینه‌سازی فرا ابتکاری HHO و HBA، بردارهای تصادفی حاوی مقادیر وزن‌ها و بایاس‌ها ایجاد شده و سپس با استفاده از تابع هدف (RMSE) کیفیت این شبکه‌های عصبی از لحاظ خطای بین مقادیر واقعی و پیش‌بینی شده ارزیابی می‌شود. در انتهای الگوریتم‌های بهینه‌سازی، شبکه عصبی بهینه با کمترین میزان خطا به‌دست می‌آید. شکل ۱۶ نمونه‌ای از بردارهای تصادفی وزن‌ها و بایاس‌های تولید شده توسط الگوریتم‌های HHO و HBA را نشان می‌دهد.

تابع هدفی که در شبکه‌های عصبی مصنوعی به کار می‌رود، در رابطه (۲۶) نشان داده شده است. در این تابع، z نمایانگر مقدار واقعی قیمت سهام Z ، بیانگر قیمت پیش‌بینی شده قیمت سهام توسط شبکه عصبی و n نشان‌دهنده تعداد کل داده‌ها است. در فرایند بهینه‌سازی وزن‌های شبکه‌های عصبی مصنوعی، هدف به‌دست آوردن



شکل ۱۶- بردار وزن‌ها و بایاس‌های تولید شده توسط الگوریتم‌های HHO ، HBA

مجموعه‌ای از وزن‌هاست که با استفاده از آن‌ها در شبکه عصبی، تفاوت بین خروجی‌های واقعی و خروجی‌های تولیدشده توسط شبکه بر روی داده‌های موجود به حداقل ممکن برسد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_i - \bar{z}_i)^2} \quad (26)$$

فلوچارت روش پیشنهادی برای بهینه‌سازی شبکه عصبی با استفاده از الگوریتم‌های فرا ابتکاری HHO و HBA در شکل ۱۷ ارائه شده است.



شکل ۱۷- فلوچارت بهینه‌سازی شبکه عصبی مصنوعی با استفاده از الگوریتم‌های HHO، HBA

۵- اجرای مدل و بررسی نتایج

هدف از این مطالعه پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان در بازه زمانی ده روز آینده با استفاده از شبکه عصبی مصنوعی (ANN) بهینه‌شده توسط الگوریتم‌های شاهین هریس (HHO) و گورکن عسل خوار (HBA) است. با توجه به این که داده‌های قیمت سهام این دو شرکت تشکیل‌دهنده یک سری زمانی هستند، برای پیش‌بینی قیمت‌های آینده، متغیرهای ورودی به الگوریتم‌های یادگیری ماشین، شامل مقادیر قیمت‌های سهام در روزهای گذشته خواهند بود. به عبارت دیگر، ورودی‌های مدل‌های یادگیری ماشین شامل قیمت‌های سهام در روزهای پیشین است که این فرآیند به‌عنوان ایجاد تأخیر زمانی در پارامترهای ورودی شناخته می‌شود.

به‌منظور پیش‌بینی قیمت سهام این دو شرکت، تأخیر زمانی بر روی متغیرهای قیمت سهام در زمان باز شدن^۱، بالاترین^۲ و پایین‌ترین^۳ قیمت سهام، حجم معاملات^۴ و ارزش سهام^۵

در نظر گرفته می‌شود که به‌صورت $X-a$ مشخص می‌شود که X پارامتر ورودی و a تعداد روز تأخیر است. در این پژوهش، ورودی‌های مدل‌های یادگیری ماشین شامل قیمت‌های سهام در زمان باز شدن، بالاترین و پایین‌ترین قیمت‌ها، حجم معاملات و ارزش سهام در ۱، ۲، ۳، ۴ و ۵ روز گذشته یعنی $(X-1, X-2, X-3, X-4, X-5)$ است. به‌عبارت‌دیگر، تأخیرها به‌صورت ۱، ۲، ۳، ۴ و ۵ روز در نظر گرفته‌شده و متغیر خروجی نیز قیمت نهایی سهام^۱ در ۱۰ روز آینده است که هدف پیش‌بینی آن است. لذا، قیمت سهام در ۱۰ روز آینده به‌عنوان تابعی از ورودی‌های متغیر در ۱، ۲، ۳، ۴ و ۵ روز گذشته تعریف می‌شود. با

¹ Open

² High

³ Low

⁴ Volume

⁵ Value


⁶ Close

احتساب ۵ متغیر ورودی و تأخیر ۵ روزه برای هرکدام، در مجموع ۲۵ متغیر ورودی و یک متغیر خروجی در این پژوهش خواهیم داشت.

شبکه عصبی مصنوعی استفاده شده است که جزئیات آن در جدول ۳ و ساختار شماتیک آن در شکل ۱۸ به نمایش گذاشته شده است.

(۲۷)

$$X+10 = f(X-1, X-2, X-3, X-4, X-5)$$



شکل ۱۸- ساختار کلی شبکه عصبی مصنوعی به کاررفته در پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان

برای مدل‌سازی و پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان، از

۵-۱- معیارهای ارزیابی و اعتبارسنجی

در این پژوهش، به منظور ارزیابی و مقایسه کارایی الگوریتم‌های بهینه‌سازی شاهین هریس (HHO) و گورکن عسل خوار (HBA) در بهینه‌سازی شبکه عصبی مصنوعی و پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان، از معیارهای معتبر به شرح موارد زیر استفاده شده است. در این روابط، n ، \bar{x} ، x_{ipred} ، x_{imeas} به ترتیب برابر با تعداد متغیر اندازه‌گیری شده، مقدار میانگین متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده است.

جدول ۳- مشخصات شبکه عصبی مصنوعی به کاررفته برای پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان

مقدار	پارامتر
MLP	نوع شبکه عصبی
۲۵×۵×۱	ساختار شبکه عصبی
۲۵	تعداد ورودی‌های شبکه عصبی
۵	تعداد نورون‌های لایه پنهان
۱	تعداد خروجی‌های شبکه عصبی
۲۵	تعداد نورون‌های لایه ورودی
۵	تعداد نورون‌های لایه پنهان
۱	تعداد نورون‌های لایه خروجی
Tansig (تانزانگ سیگموئید)	تابع محرک لایه اول
Purelin (خطی)	تابع محرک لایه دوم
۸۰ درصد	داده‌های آموزش
۲۰ درصد	داده‌های آزمون
.GPC, .SPO, .HBO, .PO .FOX, .FHO	الگوریتم آموزش
۱۰۰	تعداد تکرارها

۵-۱-۱- ضریب تعیین

ضریب تعیین^۱ که به صورت R^2 نمایش داده می‌شود، نمایانگر توانایی مدل در توضیح تغییرات متغیر وابسته است. این ضریب مشخص می‌کند که چه میزان از نوسانات متغیر وابسته به وسیله متغیرهای مستقل قابل توضیح است. به بیان دیگر، ضریب تعیین درصدی از کل واریانس مقادیر مشاهده شده را که توسط مقادیر شبیه‌سازی شده توجیه می‌شود، نشان می‌دهد. مقدار این ضریب بین صفر و یک تغییر می‌کند؛ به طوری که مقدار یک به معنای شبیه‌سازی دقیق مقادیر مشاهده شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_{imeas} - x_{ipred})^2}{\sum_{i=1}^n (x_{imeas} - \bar{x})^2} \quad (28)$$

۵-۱-۲- میانگین مربعات خطا

میانگین مربعات خطا (MSE) ابزاری برای اندازه‌گیری دقت پیش‌بینی‌ها است که در واقع اختلاف میان مقادیر پیش‌بینی شده و مقادیر واقعی را نشان می‌دهد. این معیار که همواره غیر منفی است، هر چه به صفر نزدیک‌تر شود، بیانگر خطای کمتر است. مقدار این شاخص به شکل زیر تعریف می‌شود:

$$MSE = \frac{1}{n} \times \sum_{i=1}^n [(x_{imeas} - x_{ipred})^2] \quad (29)$$

۵-۱-۳- مجذور میانگین مربعات خطا

ریشه مربع میانگین خطا (RMSE) در واقع مجذور مقدار میانگین مربعات خطا است. این معیار به عنوان سنجی از خطای کلی بین مقادیر پیش‌بینی شده و مقادیر واقعی به کار می‌رود. دامنه‌ی مقادیر این شاخص از صفر تا بی‌نهایت

متغیر است. هرچه مقدار RMSE کمتر باشد، به معنای دقت بیشتر مدل در شبیه‌سازی داده‌ها است و در صورتی که این مقدار صفر باشد، نشان‌دهنده‌ی بهترین عملکرد است.

(۳۰)

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n [(x_{imeas} - x_{ipred})^2]}$$

۵-۱-۴- میانگین قدر مطلق خطا

میانگین قدر مطلق خطا^۲ (MAE) نشان‌دهنده‌ی میانگین تفاوت بین مقادیر پیش‌بینی شده و مقادیر واقعی در تمامی نمونه‌ها است. این شاخص به عنوان نمایانگر خطای متوسط در پیش‌بینی عمل می‌کند. هرچه مقدار این معیار کمتر باشد، نشان‌دهنده‌ی دقت بالاتر مدل در شبیه‌سازی داده‌ها است و در صورتی که این مقدار صفر باشد، بهترین عملکرد ممکن است.

$$MAE = \frac{1}{n} \times \sum_{i=1}^n |x_{imeas} - x_{ipred}| \quad (31)$$

۵-۱-۵- مربع خطای نسبی

مربع خطای نسبی^۳ (RSE) معیاری برای سنجش میزان انطباق مدل با داده‌های موجود است. به طور ساده، هرچه مقدار RSE به صفر نزدیک‌تر باشد، نشان‌دهنده‌ی این است که مدل به خوبی با داده‌ها سازگار است؛ اما اگر این مقدار بیشتر از صفر باشد، به معنای عدم انطباق مناسب مدل با داده‌ها خواهد بود.

$$RSE = \frac{\sum_{i=1}^n (x_{ipred} - x_{imeas})^2}{\sum_{i=1}^n (\bar{x}_{meas} - x_{imeas})^2} \quad (32)$$

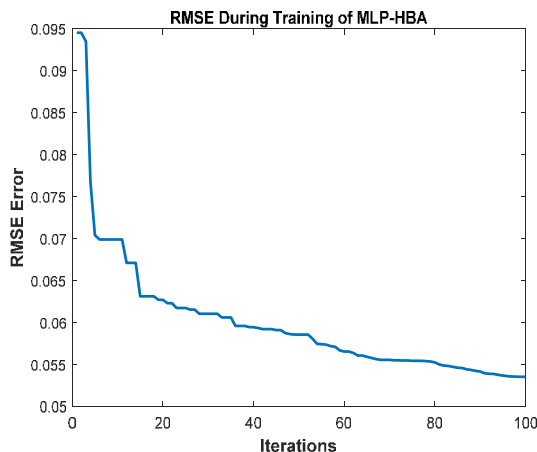
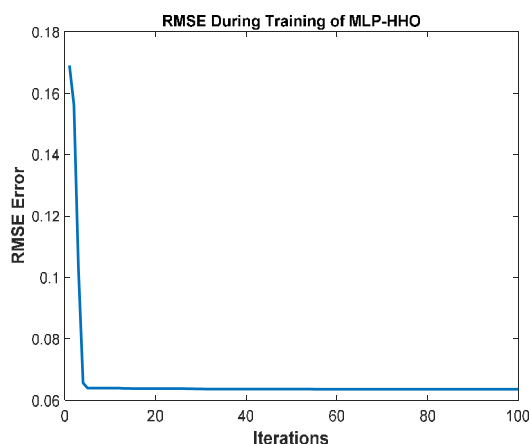
² Mean Absolute Error (MAE)

³ Relative Squared Error (RSE)

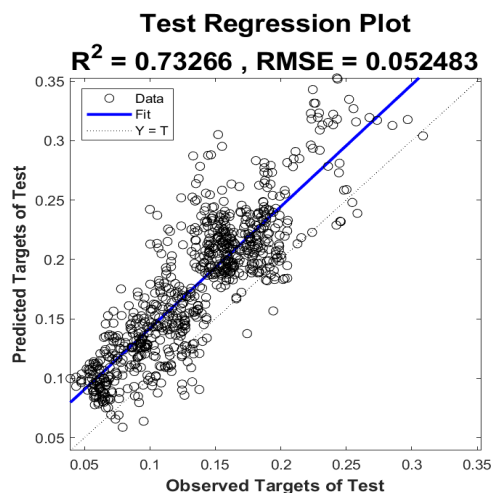
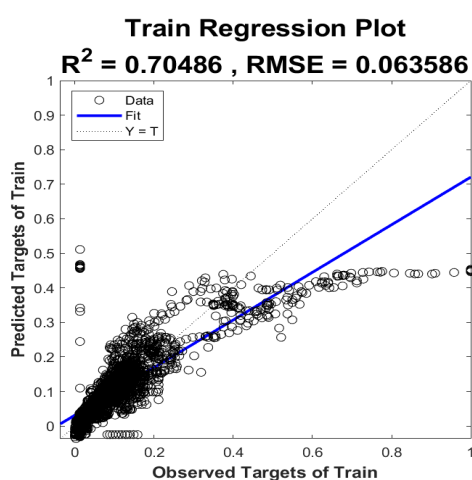
¹ Determination Coefficient

جدول ۴- نتایج پیش‌بینی قیمت سهام شرکت ایران خودرو

پارامتر	مرحله	R ²	MSE	RMSE	MAE	RSE	EVS
ANN-HHO	Train	0.70486	0.0040432	0.063586	0.034087	0.29566	0.45642
	Test	0.73266	0.0027545	0.052483	0.044741	0.5518	0.37988
ANN-HBA	Train	0.79075	0.0028692	0.053565	0.026754	0.20981	0.54209
	Test	0.74984	0.001018	0.031906	0.024975	0.42567	0.42038



شکل ۱۵- نمودار همگرایی الگوریتم‌های HHO, HBA برای بهینه‌سازی شبکه عصبی مصنوعی در پیش‌بینی قیمت سهام شرکت ایران خودرو



شکل ۱۶- نمودار پراکنش مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت ایران خودرو توسط مدل ANN+HHO

می‌پردازد. مقدار ایدئال برای این شاخص برابر با ۱ است و هر چه این مقدار کمتر باشد، نشان‌دهنده‌ی عملکرد ضعیف‌تری است.

۵-۱-۶- واریانس تبیین شده

واریانس تبیین شده^۱ (EVS) در آمار، به ارزیابی میزان تناسب یک مدل ریاضی برای توضیح تغییرات (پراکنده‌گی) در یک مجموعه داده خاص


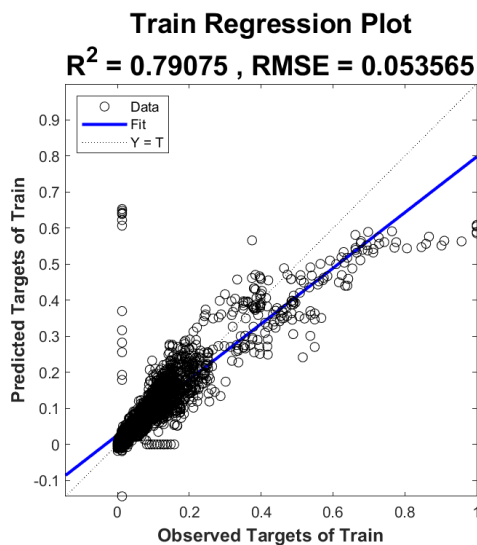
^۱ Explained Variance Score

$$EVS = 1 - \frac{Var\{x_{imeas} - x_{ipred}\}}{Var\{x_{imeas}\}} \quad (33)$$

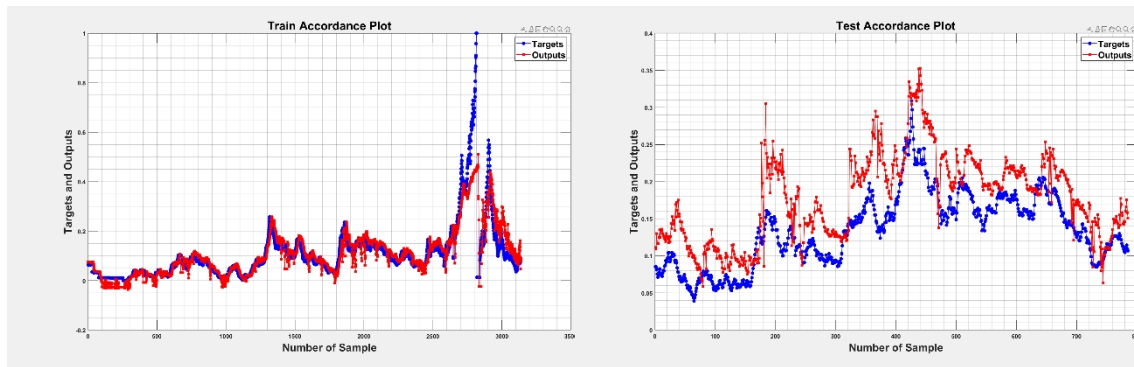
۲-۵- پیش‌بینی قیمت سهام شرکت ایران خودرو

پیش‌بینی قیمت سهام شرکت ایران خودرو با استفاده از یک شبکه عصبی مصنوعی که به وسیله الگوریتم‌های بهینه‌سازی HHO و HBA بهینه‌سازی شده بود، در بازه زمانی ۱۰ روز آینده در نرم‌افزار MATLAB انجام شد. نتایج و شاخص‌های ارزیابی در دو وضعیت آموزش و آزمایش به شرح زیر ارائه شده است. شکل ۱۹ نمودار همگرایی الگوریتم‌های HHO و HBA را در ۱۰۰ تکرار برای بهینه‌سازی شبکه عصبی مصنوعی به منظور پیش‌بینی قیمت سهام شرکت

ایران خودرو در ۱۰ روز آینده و کاهش مقادیر تابع هدف (رابطه (۲۶)) نشان می‌دهد. نمودارهای پراکنش مربوط به پیش‌بینی قیمت سهام شرکت ایران خودرو در مدل‌های شبکه عصبی بهینه‌سازی شده با این دو الگوریتم در بازه زمانی ۱۰ روز آینده در فازهای آموزش و آزمایش در شکل ۲۰ و شکل ۲۱ ارائه شده‌اند. همان‌طور که از این نمودارها مشخص است، خط مشکی، نیمساز ربع اول را در محورهای عمودی و افقی ترسیم می‌کند. مقادیر واقعی قیمت سهام شرکت ایران خودرو بر روی محور X و مقادیر پیش‌بینی شده بر روی محور Y قرار داده شده‌اند. هر چه این مقادیر به نیمساز ربع اول نزدیک‌تر باشند، نشان‌دهنده‌ی برازش عالی و پیش‌بینی



شکل ۲۱- نمودار پراکنش مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت ایران خودرو توسط مدل ANN+HBA

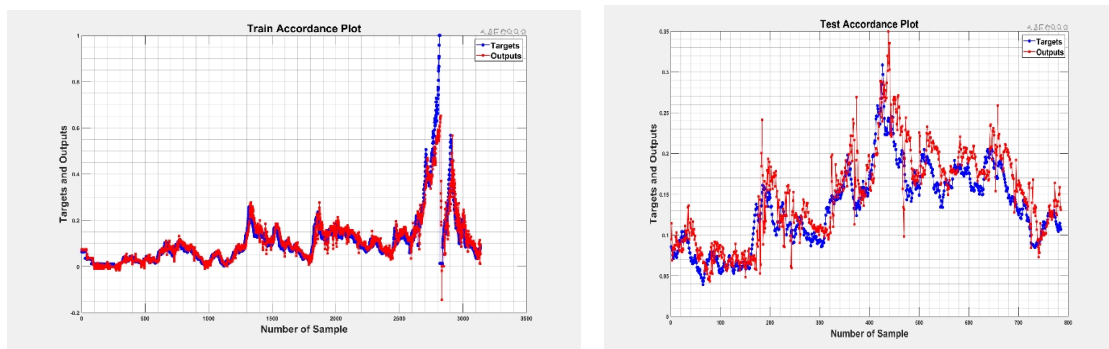


شکل ۲۲- نمودار مقایسه مقادیر واقعی و پیش‌بینی‌شده قیمت سهام شرکت ایران خودرو توسط مدل ANN+HHO

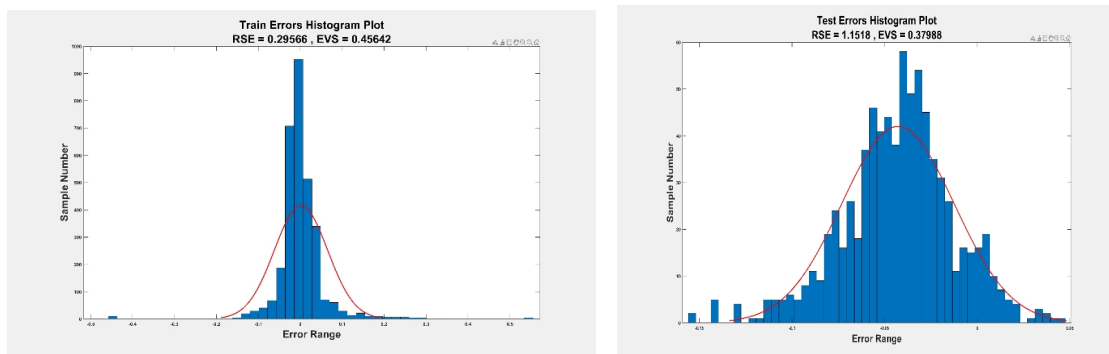
نشان‌دهنده‌ی عملکرد دقیق‌تر این مدل‌ها در تخمین مقادیر قیمت سهام شرکت ایران خودرو است.

در شکل ۲۴ و شکل ۲۵، هیستوگرام خطاهای ناشی از پیش‌بینی قیمت سهام شرکت ایران خودرو با استفاده از مدل‌های شبکه عصبی که توسط الگوریتم‌های HHO و HBA بهینه‌سازی شده‌اند، در بازه ۱۰ روز آینده نمایش

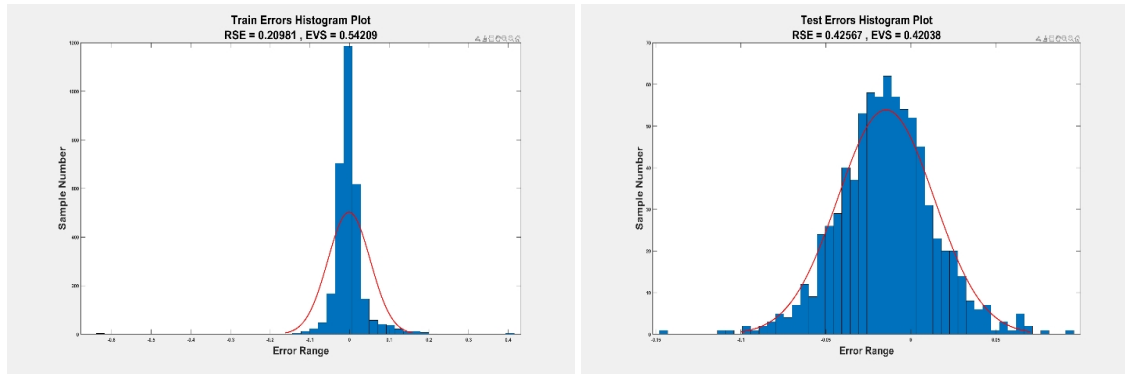
دقیق‌تری از قیمت سهام شرکت ایران خودرو خواهد بود. شکل ۲۲ و شکل ۲۳ نیز میزان انطباق و هماهنگی بین مقادیر واقعی (آبی) و پیش‌بینی‌شده (قرمز) قیمت سهام شرکت ایران خودرو در مدل‌های شبکه عصبی بهینه‌سازی شده با الگوریتم‌های HHO و HBA در دوره ۱۰ روز آینده در فازهای آموزش و آزمایش را نمایش می‌دهد. نزدیکی این دو نمودار به یکدیگر



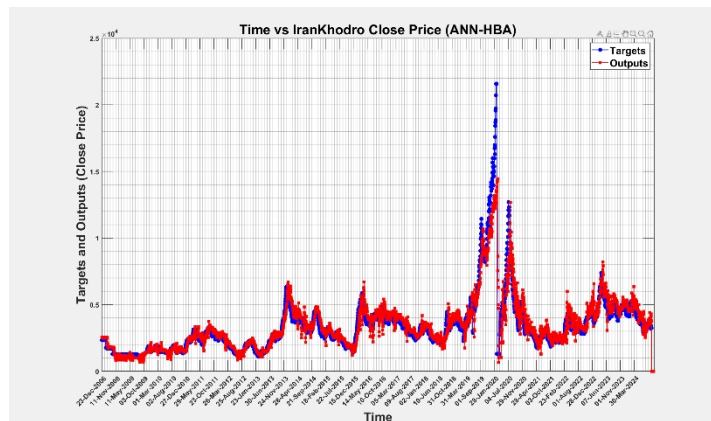
شکل ۱۷- نمودار مقایسه مقادیر واقعی و پیش‌بینی‌شده قیمت سهام شرکت ایران خودرو توسط مدل ANN+HBA



شکل ۲۴- نمودار هیستوگرام خطای مقادیر واقعی و پیش‌بینی‌شده قیمت سهام شرکت ایران خودرو توسط مدل ANN+HHO



شکل ۲۵- نمودار هیستوگرام خطای مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت ایران خودرو توسط مدل ANN+HBA



شکل ۲۶- نمودار مقایسه قیمت واقعی و پیش‌بینی شده‌ی سهام شرکت ایران خودرو

که به وسیله الگوریتم‌های بهینه‌سازی HHO و HBA بهینه‌سازی شده بود، در بازه زمانی ۱۰ روز آینده در نرم‌افزار MATLAB انجام شد. نتایج و شاخص‌های ارزیابی در دو وضعیت آموزش و آزمایش به شرح زیر ارائه شده است. شکل ۲۷ نمودار همگرایی الگوریتم‌های HHO و HBA را در ۱۰۰ تکرار برای بهینه‌سازی شبکه عصبی مصنوعی به منظور پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان در ۱۰ روز آینده و کاهش مقادیر تابع هدف (رابطه (۲۶)) نشان می‌دهد.

نمودارهای پراکنش مربوط به پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان در مدل‌های شبکه عصبی بهینه‌سازی شده با این دو الگوریتم در بازه زمانی ۱۰ روز آینده در فازهای آموزش و آزمایش در شکل ۲۸ و شکل ۲۹ ارائه شده‌اند. همان‌طور که از این نمودارها مشخص

داده شده است. در این نمودار، بازه‌های خطای پیش‌بینی بر روی محور X و تعداد نمونه‌های هر خطا بر روی محور Y قرار دارند. همچنین، شکل ۲۶ نمودار مقایسه‌ای را بین قیمت واقعی (آبی) سهام ایران خودرو و قیمت پیش‌بینی شده (قرمز) آن توسط مدل‌های شبکه عصبی بهینه‌سازی شده با الگوریتم‌های HHO و HBA در همان بازه زمانی ۱۰ روزه به تصویر کشیده است. نزدیکی این دو نمودار به یکدیگر نشان‌دهنده دقت بالاتر این مدل‌ها در برآورد قیمت سهام شرکت ایران خودرو است.

۳-۵- پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان

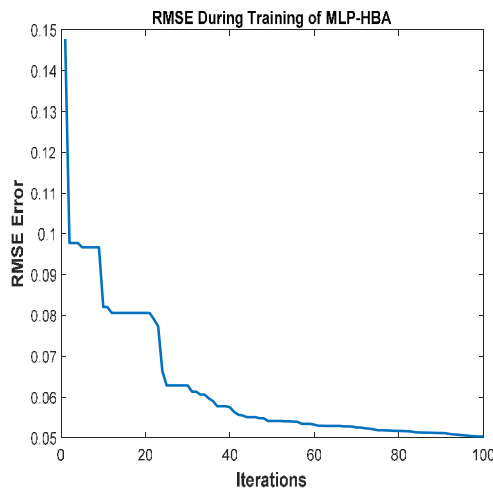
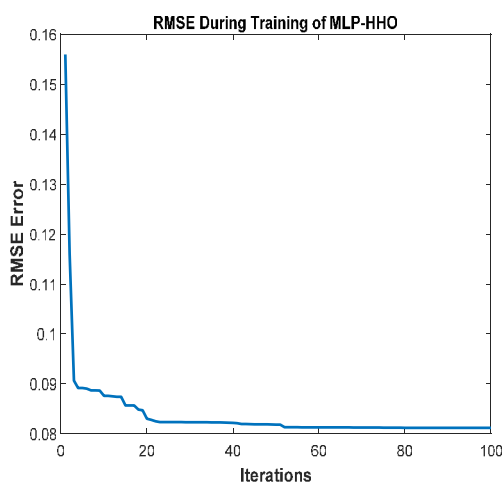
پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان با استفاده از یک شبکه عصبی مصنوعی

است، خط مشکی، نیمساز ربع اول را در محورهای عمودی و افقی ترسیم می‌کند. مقادیر واقعی قیمت سهام شرکت پالایش نفت اصفهان بر روی محور X و مقادیر پیش‌بینی‌شده بر روی محور Y قرار داده شده‌اند. هر چه این مقادیر به نیمساز ربع اول نزدیک‌تر باشند، نشان‌دهنده‌ی برازش عالی و پیش‌بینی دقیق‌تری از قیمت سهام شرکت پالایش نفت اصفهان خواهد بود. شکل ۳۰ و شکل ۳۱ نیز میزان انطباق و هماهنگی بین مقادیر واقعی (آبی) و پیش‌بینی‌شده (قرمز) قیمت

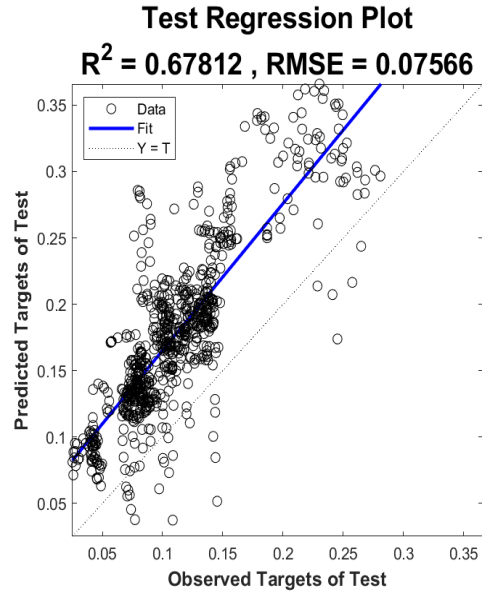
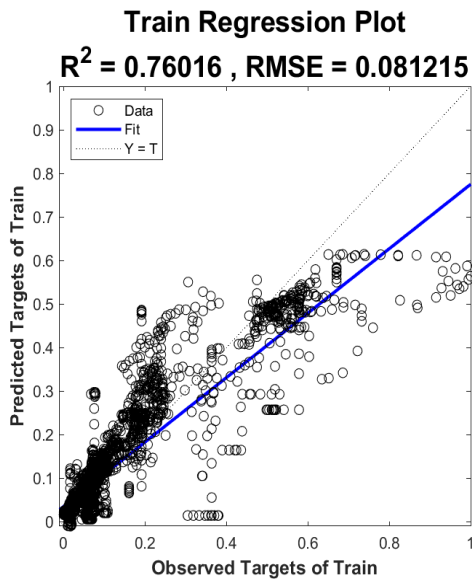
سهام شرکت پالایش نفت اصفهان در مدل‌های شبکه عصبی بهینه‌سازی شده با الگوریتم‌های HHO و HBA در دوره ۱۰ روز آینده در فازهای آموزش و آزمایش را نمایش می‌دهد. نزدیکی این دو نمودار به یکدیگر نشان‌دهنده‌ی عملکرد دقیق‌تر این مدل‌ها در تخمین مقادیر قیمت سهام شرکت پالایش نفت اصفهان است. در شکل ۳۲ و شکل ۳۳، هیستوگرام خطاهای ناشی از پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان با استفاده از مدل‌های شبکه عصبی

جدول ۵- نتایج پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان

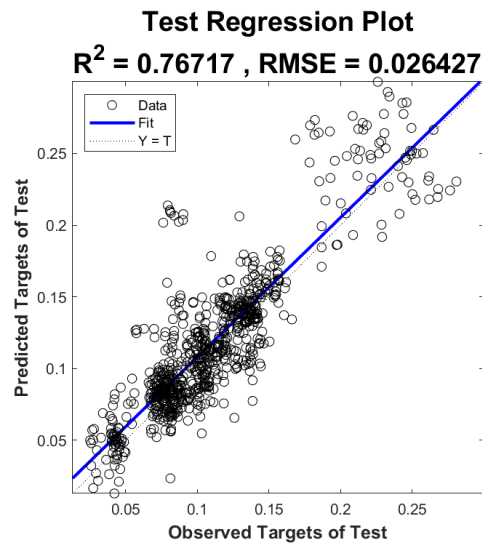

پارامتر	مرحله	R ²	MSE	RMSE	MAE	RSE	EVS
ANN-HHO	Train	0.76016	0.0065958	0.081215	0.054411	0.24043	0.5097
	Test	0.67812	0.0057244	0.07566	0.068357	0.5816	0.23009
ANN-HBA	Train	0.90776	0.0025335	0.050334	0.021967	0.09235	0.69613
	Test	0.76717	0.0006984	0.026427	0.018029	0.31496	0.4639




شکل ۱۸- نمودار همگرایی الگوریتم‌های HHO، HBA برای بهینه‌سازی شبکه عصبی مصنوعی در پیش‌بینی قیمت سهام شرکت پالایش نفت اصفهان



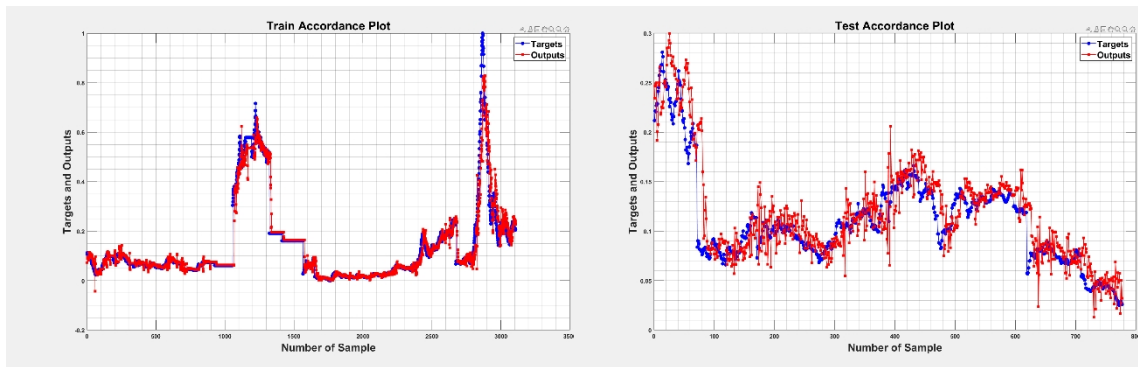
شکل ۲۸- نمودار پراکنش مقادیر واقعی و پیش‌بینی‌شده قیمت سهام شرکت پالایش نفت اصفهان توسط مدل ANN+HHO




شکل ۲۹- نمودار پراکنش مقادیر واقعی و پیش‌بینی‌شده قیمت سهام شرکت پالایش نفت اصفهان توسط مدل ANN+HBA




شکل ۱۹- نمودار مقایسه مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت پالایش نفت اصفهان توسط مدل ANN+HHO




شکل ۲۰- نمودار مقایسه مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت پالایش نفت اصفهان توسط مدل ANN+HBA




شکل ۲۱- نمودار هیستوگرام خطای مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت پالایش نفت اصفهان توسط مدل ANN+HHO



شکل ۲۲- نمودار هیستوگرام خطای مقادیر واقعی و پیش‌بینی شده قیمت سهام شرکت پالایش نفت اصفهان توسط مدل ANN+HBA




ANN+HHO




ANN+HBA


شکل ۲۳- نمودار مقایسه قیمت واقعی و پیش‌بینی شده قیمت سهام شرکت پالایش نفت اصفهان




شکل ۲۴- مقایسه پارامترهای R2، RSE و EVS مدل‌های شبکه عصبی مصنوعی پیش‌بینی‌کننده قیمت سهام شرکت ایران خودرو



شکل ۲۵- مقایسه پارامترهای RMSE، MSE و MAE مدل‌های شبکه عصبی مصنوعی پیش‌بینی‌کننده قیمت سهام شرکت ایران خودرو



شکل ۲۶- مقایسه پارامترهای R2، RSE و EVS مدل‌های شبکه عصبی مصنوعی پیش‌بینی‌کننده قیمت سهام شرکت پالایش نفت اصفهان



شکل ۲۷- مقایسه پارامترهای RMSE، MSE و MAE مدل‌های شبکه عصبی مصنوعی پیش‌بینی‌کننده قیمت سهام شرکت پالایش نفت اصفهان

شکل مؤثرتری می‌توانند روابط موجود در داده‌ها را تحلیل کنند. روش‌های سنتی پیش‌بینی قیمت سهام ممکن است خطاهای زیادی داشته باشند. شبکه‌های عصبی با استفاده از الگوریتم‌های بهینه‌سازی و ساختارهای چندلایه، می‌توانند با تنظیم و اصلاح وزن‌ها به صورت پیوسته، دقت پیش‌بینی را بهبود بخشند و خطاها را کاهش دهند. با توجه به توانایی شبکه‌های عصبی در پردازش حجم زیادی از داده‌های ورودی، می‌توانند هم برای پیش‌بینی‌های کوتاه‌مدت و هم بلندمدت مورد استفاده قرار گیرند و نتایج مطلوبی ارائه دهند.

با استفاده از شبکه‌های عصبی، پیش‌بینی‌ها می‌توانند به صورت خودکار و در زمان‌های مختلف به روزرسانی شوند. این خودکارسازی می‌تواند در تصمیم‌گیری‌های سریع و صحیح نقش مهمی ایفا کند. پیش‌بینی دقیق‌تر قیمت سهام به سرمایه‌گذاران کمک می‌کند تا ریسک‌های موجود را کاهش داده و تصمیمات هوشمندانه‌تری اتخاذ کنند. این امر می‌تواند در ایجاد بازدهی مطلوب و مدیریت بهتر سبد سرمایه‌گذاری نیز مؤثر باشد؛ بنابراین، شبکه‌های عصبی مصنوعی به‌عنوان ابزاری هوشمند و پویا، می‌توانند به سرمایه‌گذاران

که توسط الگوریتم‌های HHO و HBA بهینه‌سازی شده‌اند، در بازه ۱۰ روز آینده نمایش داده شده است. در این نمودار، بازه‌های خطای پیش‌بینی بر روی محور X و تعداد نمونه‌های هر خطا بر روی محور Y قرار دارند. همچنین، شکل ۳۴ نمودار مقایسه‌ای را بین قیمت واقعی (آبی) سهام پالایش نفت اصفهان و قیمت پیش‌بینی‌شده (قرمز) آن توسط مدل‌های شبکه عصبی بهینه‌سازی شده با الگوریتم‌های HHO و HBA در همان بازه زمانی ۱۰ روزه به تصویر کشیده است. نزدیکی این دو نمودار به یکدیگر نشان‌دهنده دقت بالاتر این مدل‌ها در برآورد قیمت سهام شرکت پالایش نفت اصفهان است.

۶- نتیجه‌گیری

پیش‌بینی قیمت سهام در بورس یکی از ابزارهای مهم برای تصمیم‌گیری بهتر سرمایه‌گذاران و مدیران مالی در زمان‌های بحران است. قیمت سهام معمولاً تحت تأثیر عوامل متعدد و پیچیده‌ای مانند اخبار اقتصادی، روان‌شناسی بازار، روندهای تاریخی و سایر بحران‌ها قرار دارد. شبکه‌های عصبی مصنوعی به خاطر توانایی‌شان در یادگیری الگوهای پیچیده و غیرخطی، به

و تحلیل‌گران کمک کنند تا پیش‌بینی‌های دقیقی از روندهای آینده داشته و از این طریق، بازدهی سرمایه‌گذاری خود را بهبود بخشند.

در مطالعات پیشین انجام‌شده، استفاده از هوش مصنوعی و شبکه عصبی درصد خطای پیش‌بینی را کاهش داده و برتری مدل ترکیبی به سایر مدل‌ها مشهود بوده است و با استفاده از مطالعات پیشین و بهبود روش‌های استفاده‌شده، در این پژوهش به منظور پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان در بحران‌های بورس و بازه‌ی زمانی ۱۰ روز آینده، از مدل‌های شبکه عصبی مصنوعی بهینه‌سازی شده توسط الگوریتم‌های بهینه‌سازی شاهین هریس (HHO) و گورکن عسل‌خوار (HBA) استفاده‌شده است.

ابتدا داده‌های مورد نیاز برای مدل‌سازی را پیش‌پردازش کرده و مقادیر خالی و ناموجود آن را حذف می‌کنیم. سپس به منظور کاهش اثرات مقیاس داده‌ها بر روی نتایج مدل به نرمال‌سازی داده‌ها در بازه ۰ تا ۱ می‌پردازیم زیرا وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت مدل‌ها می‌شود. سپس با تقسیم‌بندی داده‌ها از ۸۰ درصد از ابتدای مجموعه داده‌های قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان به عنوان داده‌های آموزش و ۲۰ درصد باقی‌مانده از انتهای داده‌ها، به عنوان داده‌های آزمایش اقدام به تولید مجموعه داده‌های آموزش و آزمایش می‌کنیم. سپس در مرحله بعد با استفاده از دیتاست آموزش، به آموزش شبکه عصبی مصنوعی (ANN) با الگوریتم‌های بهینه‌سازی فرا ابتکاری HBA و HHO می‌پردازیم. سپس در مرحله بعد با استفاده از دیتاست آزمایش، به آزمایش مدل‌های شبکه عصبی مصنوعی که در مرحله قبل توسط الگوریتم‌های بهینه‌سازی ذکرشده، بهینه‌سازی شده است، می‌پردازیم. در مرحله آخر نیز به

مقایسه نتایج و میزان دقت و کارایی مدل‌های مختلف شبکه عصبی مصنوعی در پیش‌بینی قیمت سهام دو شرکت ایران خودرو و پالایش نفت اصفهان در حالت آموزش و آزمایش می‌پردازیم.

معیارهای ارزیابی و اعتبارسنجی مدل‌ها شامل ضریب تعیین (R^2)، میانگین مربعات خطا (MSE)، ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، مربع خطای نسبی (RSE) و واریانس تبیین شده (EVS) می‌باشند. تمام مراحل مدل‌سازی در نرم‌افزار MATLAB R2023b صورت گرفته است. نتایج این تحقیق نشان می‌دهد که در بازه زمانی ۱۰ روز آینده، الگوریتم HBA و HHO قیمت سهام ایران خودرو را به ترتیب با دقت‌های ۷۵٪ و ۷۳٪ و قیمت سهام پالایش نفت اصفهان را با دقت‌های ۷۶٪ و ۶۷٪ پیش‌بینی کرده‌اند. نتایج این تحقیق حاکی از برتری الگوریتم HBA نسبت به الگوریتم HHO است.

۸- قدردانی

در پایان از پژوهشکده سرمایه اجتماعی، سازمان اقتصاد مقاومتی آجا برای راهنمایی و همکاری لازم در این تحقیق تقدیر و تشکر می‌شود.

۹- منابع

1. Ayyildiz, N. and O.J.H. Iskenderoglu, How effective is machine learning in stock market predictions? 2024. 10(2).
2. Mintarya, L.N. et al. Machine learning approaches in stock market prediction: A systematic literature review. 2023. 216: p. 96-102.
3. Pahwa, N. et al. Stock prediction using machine learning a review paper. 2017. 163(5): p. 36-43.
4. Jain, S. et al. Exploring the Future of Stock Market Prediction through Machine Learning: An Extensive Review and Outlook. 2024. 12(4): p. 1-10.
- ۵- عادل، آ.ا.ا. امیر و ا. پرویز، مقایسه روش‌های کلاسیک و هوش مصنوعی در پیش‌بینی شاخص قیمت سهام و طراحی مدل ترکیبی. ۲۰۰۶.

market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications. 2023. 11(3): p. 94.

19. Ajiga, D.I. et al. Machine learning for stock market forecasting: a review of models and accuracy. 2024. 6(2): p. 112-124.

20. Phuoc, T. et al. Applying machine learning algorithms to predict the stock price trend in the stock market-The case of Vietnam. 2024. 11(1): p. 1-18.

21. Sui, M. et al. An ensemble approach to stock price prediction using deep learning and time series models. 2024.

22. Smith, M. Neural networks for statistical modeling. 1993: Thomson Learning.

23. Hornik, K. M. Stinchcombe, and H.J.N.n. White, Multilayer feedforward networks are universal approximators. 1989. 2(5): p. 359-366.

24. Engelbrecht, A.P. Computational intelligence: an introduction. 2007: John Wiley & Sons.

۲۵- محمدباقر، م. مبانی شبکه‌های عصبی هوش محاسباتی Vol. 0. 1381. دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، واحد تفرش، مرکز نشر پروفسور.

26. Heidari, A.A. et al. Harris hawks optimization: Algorithm and applications. 2019. 97: p. 849-872.

27. Hashim, F.A. et al. Honey Badger Algorithm: New metaheuristic algorithm for solving optimization problems. 2022. 192: p. 84-110.

28. Heptner, V.G. and S. Robert, Mammals of the Soviet Union: Vol. II. Part 1b Carnivora (weasels; additional species). 2001: Smithsonian Institution Libraries and the National Science Foundation.

29. Begg, C. et al. Life-history variables of an atypical mustelid, the honey badger *Mellivora capensis*. 2005. 265(1): p. 17-22.

30. Begg, C. et al. Scent-marking behaviour of the honey badger, *Mellivora capensis* (Mustelidae), in the southern Kalahari. 2003. 66(5): p. 917-929.

۶- مهدی مرادزاده، ف. د. رؤیا و رامین شاه علی، یکپارچه‌سازی تکنیک‌های هوش مصنوعی جهت ارائه مدل پیش‌بینی قیمت سهام. پژوهش‌های حسابداری مالی و حسابداری. سال ششم. صص ۸۹-۱۰۲.

۷- مهدی، ص. ح. پ. کیانا و خ. حمید، بررسی مقایسه‌ای پیش‌بینی تغییرات شاخص قیمت سهام در نهادهای پولی با استفاده از هوش مصنوعی. ۲۰۱۶.

۸- علیرضا، س. ق. مجید و ت. رضا، پیش‌بینی شاخص کل بورس اوراق بهادار تهران با استفاده از رویکرد ترکیبی الگوریتم‌های فرا ابتکاری، هوش مصنوعی و معادله پارامتریک موجک. ۲۰۱۸.

۹- سید حسام و. کاربرد الگوریتم هوش مصنوعی در پیش‌بینی ورشکستگی با استفاده از متغیرهای کلان اقتصادی و حسابداری در شرکت‌های پذیرفته‌شده بورس اوراق بهادار تهران. ۲۰۱۹.

۱۰- زهرا، پ. و د. رحیم، مدل‌سازی بازار سهام با استفاده از مدل‌های هوش مصنوعی و مقایسه با مدل‌های کلاسیک خطی. ۲۰۲۱.

۱۱- حامد، ر. ز. و همکاران. رویکرد هوش مصنوعی انقباضی لاسو در پیش‌بینی نقدینگی شرکت‌های پذیرفته‌شده بورس اوراق بهادار تهران. ۲۰۲۲.

۱۲- مهدی، ح. و ا. حمیدرضا، بررسی قدرت مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی روند قیمت سهام بورس اوراق بهادار تهران. ۲۰۲۲.

۱۳- جعفر، م؛ و ش. محمدرضا، شناسایی و گروه‌بندی ریسک‌های احداث واحدهای صنعتی به‌وسیله روش دلفی و شبکه عصبی مصنوعی خودسازمان‌ده (مطالعه موردی: احداث کارخانه تراورس). فصلنامه مدیریت بحران، ۱۴۰۱. ۱۱(۱): p. 141-148.

۱۴- آرام، خ. تحلیل فضایی آسیب‌پذیری محلات شهر سلماس در برابر زلزله مبتنی بر روش Fuzzy WASPAS. فصلنامه مدیریت بحران، ۱۴۰۲. ۱۲(۲): p. 116-130.

۱۵- مزرعه، م. م. حقیقی و ل. آندرواژ، طراحی مدل جذب سرمایه‌گذاری ترکیبی در راستای رونق کسب‌وکار و رشد اقتصادی (مورد مطالعه: مناطق آزاد تجاری). فصلنامه مدیریت بحران، ۱۴۰۳. ۱۳(۲)

16. Maqbool, J. et al. Stock prediction by integrating sentiment scores of financial news and MLP-regressor: A machine learning approach. 2023. 218: p. 1067-1078.

17. Srivastava, S. et al. Analysis and prediction of Indian stock market: a machine-learning approach. 2023. 14(4): p. 1567-1585.

18. Sonkavde, G. et al. Forecasting stock