



Deep Learning-based Modeling for Stock Price Prediction in Iran

Saleh Goltabar *

*Corresponding Author, Ph.D. Candidate, Department of Economics, Semnan University, Semnan, Iran. E-mail: saleh_goltabar@semnan.ac.ir

Esmail Abounoori

Prof., Department of Economics, Semnan University, Semnan, Iran. E-mail: esmaiel.abounoori@semnan.ac.ir

Ali Habibnia

Assistant Prof., Department of Economics, Virginia Tech, Blacksburg, USA. E-mail: habibnia@vt.edu

Abstract

Objective

This study aims to propose an innovative approach for forecasting stock closing prices using supervised deep learning techniques. The research seeks to capture temporal dependencies within stock market data and generate accurate and reliable predictions. By focusing on the Iranian stock market—a developing economy that has received limited attention in prior research—and analyzing 10 stocks over a period exceeding 10 years (2012–2023) using 21 input variables, the study investigates distinctive aspects of stock price prediction.

Methods

The methodology involves integrating Long Short-Term Memory (LSTM) networks with deep learning techniques. Identifying a research gap in high-dimensional data, the study introduces the use of a Stack Supervised Autoencoder LSTM (SLSAE) to improve prediction accuracy. The study leverages LSTM neural networks to capitalize on their strong capabilities in modeling temporal dependencies. However, when dealing with high-dimensional data, relying on a single method may not be sufficient to achieve precise predictions. Therefore, we incorporate an LSTM Autoencoder (LAE) into the process. A key

Citation: Goltabar, Saleh; Abounoori, Esmail & Habibnia, Ali (2026). Deep Learning-based Modeling for Stock Price Prediction in Iran. *Financial Research Journal*, 28(2), 424-463. <https://doi.org/10.22059/FRJ.2025.383898.1007656> (in Persian)



contribution of this paper is the use of the Supervised Autoencoder LSTM (LSAE), which significantly enhances prediction accuracy compared to previous methods. Furthermore, we utilize the Stack LSAE (SLSAE), which can identify and extract precise and valuable features from the data, ultimately leading to highly accurate predictions.

Results

To conduct a comprehensive comparison, we utilize five different prediction models: SLSAE, LSAE, LSTM, Artificial Neural Network (ANN), and ARIMA. The results show that the more complex models, particularly SLSAE and LSAE, outperform simpler models like ARIMA and ANN in terms of accuracy. Across all stocks, SLSAE achieved the best results across various metrics. This model provided the lowest RMSE, MSE, and MAE values and the highest R² scores. The superior performance is attributed to the use of a multi-layered supervised architecture, which enables the detection of complex and nonlinear patterns in the time-series data. These features make the model highly effective in capturing and predicting fine details of closing stock prices.

Conclusion

Predicting stock market prices is a significant challenge due to the inherent nonlinearity in the input data. When a wide range of variables are introduced as inputs, deep learning techniques demonstrate superior performance. To enhance the accuracy of stock market predictions, we utilized a deep learning architecture comprising SAE, LSAE, and a hybrid called SLSAE. The SLSAE method, however, stands out as it can directly learn deep features related to closing prices from raw input data. Unlike existing deep networks, which primarily focus on unsupervised feature learning to extract useful features from raw data, the SLSAE method can directly learn the deep features associated with closing prices. It employs a hierarchical structure, where high-level features related to closing prices are learned through building several SAE models from earlier low-level samples. Each SAE model ensures that the learned features significantly contribute to predicting price data in the output layer. Consequently, features associated with closing prices are gradually learned while irrelevant information is progressively reduced through the hierarchical stacking of SAE models. The results demonstrate that using this approach significantly improves the accuracy of stock price predictions and confirms the efficiency of the proposed method.

Keywords: Prediction, Stocks, Deep learning, Supervised autoencoder, Long Short-Term Memory Network (LSTM)

مدل سازی پیش بینی قیمت سهام در ایران با استفاده از یادگیری عمیق

صالح گل تبار*

* نویسنده مسئول، دانشجوی دکتری، گروه اقتصاد، دانشگاه سمنان، سمنان، ایران. رایانامه: saleh_goltabar@semnan.ac.ir

اسماعیل ابونوری

استاد، گروه اقتصاد، دانشگاه سمنان، سمنان، ایران. رایانامه: esmaiel.abounoori@semnan.ac.ir

علی حبیب نیا

استادیار، گروه اقتصاد، دانشگاه ویرجینیا تک، بلکسبورگ، آمریکا. رایانامه: habibnia@vt.edu

چکیده

هدف: این پژوهش با بهره گیری از روش های یادگیری عمیق نظارت شده، رویکردی نوآورانه برای پیش بینی قیمت پایانی در بازار سهام ارائه می دهد. هدف این پژوهش، درک وابستگی های زمانی موجود در داده های بازار سهام و ارائه پیش بینی های دقیق و قابل اطمینان است. همچنین با تمرکز بر بازار ایران، به عنوان یک کشور در حال توسعه که در مطالعات پیشین به آن کم توجهی شده است و بررسی ۱۰ سهم در بازار سهام ایران، طی دوره زمانی بیش از ۱۰ سال (از ۱۳۹۱ تا ۱۴۰۲) و در نظر گرفتن ۲۱ متغیر ورودی، این مطالعه ابعاد منحصر به فردی را بررسی می کند.

روش: به طور مشخص، روش این مطالعه ادغام شبکه حافظه طولانی کوتاه مدت با یادگیری عمیق است. با شناسایی یک شکاف تحقیقاتی در زمینه داده های با ابعاد بالا، این مطالعه استفاده از کدکننده خودکار نظارت شده شبکه حافظه طولانی کوتاه مدت پشته ای را برای بهبود دقت پیش بینی معرفی می کند. در این مقاله، از شبکه عصبی حافظه طولانی کوتاه مدت بهره برده شده است تا از توانایی های برجسته این روش در مدل سازی وابستگی های زمانی استفاده شود؛ با این حال، هنگام مواجهه با داده های با ابعاد بالا، استفاده از یک روش منفرد ممکن است برای دستیابی به پیش بینی های دقیق کافی نباشد؛ بنابراین، LSTM کدکننده خودکار وارد فرایند شده است. نکته برجسته این مقاله، استفاده از کدکننده خودکار نظارت شده (LSAE) LSTM است که در مقایسه با روش های قبلی، بهبود شایان توجهی در دقت پیش بینی ها ایجاد می کند. در ادامه، از LSAE پشته ای بهره برده شده است که قادر است ویژگی های دقیق و ارزشمند داده ها را شناسایی و استخراج کند و در نهایت به پیش بینی های بسیار دقیق تر منجر شود.

یافته ها: برای انجام مقایسه جامع، از پنج مدل پیش بینی مختلف شامل LSTM، LSAE، SLSAE، ANN و ARIMA استفاده شده است. نتایج نشان می دهد که مدل های پیچیده تر و مبتنی بر شبکه های عصبی عمیق، به ویژه SLSAE و LSAE، نسبت به مدل های ساده تر مثل ARIMA و ANN دقت بیشتری دارند. در تمام سهام ها، SLSAE بهترین نتایج را در معیارهای مختلف به دست آورده است.

استناد: گل تبار، صالح؛ ابونوری، اسماعیل و حبیب نیا، علی (۱۴۰۵). مدل سازی پیش بینی قیمت سهام در ایران با استفاده از یادگیری عمیق. *تحقیقات مالی*، ۲۸(۲) ۴۲۴-۴۶۳.

این مدل کمترین مقادیر RMSE، MSE و MAE و همچنین بالاترین مقادیر R^2 را ارائه می‌دهد. دلیل این عملکرد برتر، استفاده از معماری نظارت‌شده چندلایه است که امکان شناسایی الگوهای پیچیده و ناخطی در داده‌های سری زمانی را فراهم می‌کند. این ویژگی‌ها باعث شده است که این مدل در شناسایی و پیش‌بینی جزئیات دقیق قیمت پایانی سهام، بسیار موفق عمل کند.

نتیجه‌گیری: پیش‌بینی بازار سهام به دلیل ناخطی بودن ذاتی موجود در داده‌های ورودی، چالش مهمی را ایجاد می‌کند. هنگامی که متغیرهای متنوعی به‌عنوان ورودی ارائه می‌شوند، تکنیک‌های یادگیری عمیق عملکرد برتری را نشان می‌دهند. برای افزایش دقت پیش‌بینی بازار سهام، از معماری یادگیری عمیق متشکل از SAE، LSAE و ترکیبی به نام SLSAE استفاده شده است. برخلاف شبکه‌های عمیق موجود که بیشتر بر یادگیری ویژگی‌های نظارت‌نشده برای استخراج ویژگی‌های مفید از داده‌های ورودی خام تمرکز می‌کنند، روش SLSAE قادر است که ویژگی‌های عمیق مرتبط با قیمت پایانی را به‌طور مستقیم از داده‌های ورودی خام یاد بگیرد. این روش ساختار سلسله‌مراتبی‌ای را به‌کار می‌گیرد که در آن، ویژگی‌های مرتبط با قیمت پایانی سطح بالا از طریق ساخت چندین مدل SAE از نمونه‌های سطح پایین قبلی آموخته می‌شود. هر مدل SAE تضمین می‌کند که ویژگی‌های آموخته شده، به‌طور چشمگیری به پیش‌بینی داده‌های قیمت در لایه خروجی کمک می‌کند. در نتیجه، ویژگی‌های مرتبط با قیمت پایانی به‌تدریج آموخته می‌شوند، در حالی که اطلاعات نامربوط به‌تدریج از طریق انباشته شدن سلسله‌مراتبی مدل‌های SAE کاهش می‌یابد. نتایج نشان می‌دهد که استفاده از این روش، به‌طور چشمگیری دقت پیش‌بینی قیمت پایانی سهام را بهبود می‌بخشد و کارآمدی روش پیشنهادی را نشان می‌دهد.

کلیدواژه‌ها: پیش‌بینی، سهام، یادگیری عمیق، کدکننده خودکار نظارت‌شده، شبکه حافظه طولانی کوتاه‌مدت.

مقدمه

پیش‌بینی‌های مالی، به‌ویژه پیش‌بینی قیمت پایانی (CP)^۱ و بازده بازار سهام، همواره مورد توجه فعالان بازارهای مالی بوده است. پیش‌بینی دقیق قیمت و یا بازده سهام، به سرمایه‌گذاران، مؤسسه‌های مالی و سیاست‌گذاران کمک می‌کند تا تصمیم‌های آگاهانه‌تری بگیرند، ریسک‌ها را کاهش دهند و بازدهی سبد سرمایه‌گذاری خود را بهینه‌سازی کنند. این امر در عملکرد بازارهای مالی نقش مهمی دارد و پیامدهای گسترده‌ای برای اقتصاد به همراه دارد. نظریه بازار کارا (EMH)^۲ که توسط فاما در سال ۱۹۷۰ مطرح شد، بیان می‌کند که حرکات در بازار سهام کارا بی‌فایده است؛ چون معمولاً بسیاری از بازارها کارا نیستند، مدل‌های مالی سنتی همچنان تحلیل‌های بنیادی و تکنیکال را به‌عنوان ابزاری برای پیش‌بینی قیمت‌های آتی بازار به کار می‌گیرند. تحلیل بنیادی بر بررسی دقیق صورت‌های مالی و شاخص‌های اقتصادی مبتنی است، در حالی که تحلیل تکنیکال سعی دارد با استفاده از داده‌های تاریخی قیمت، مسیر قیمت‌های آینده را پیش‌بینی کند. علاوه بر این رویکردهای مرسوم، روش‌های آماری و اقتصادسنجی مانند ARIMA^۳ (باکس و جنکینز^۴، ۱۹۷۰)، ARCH^۵، SARIMA^۶ (انگل^۷، ۱۹۸۲)، VAR^۸، GARCH^۹ (بولرسلو^{۱۰}، ۱۹۸۶) و مدل‌های هموارسازی نمایی^{۱۱} (براون^{۱۲}، ۲۰۰۴) نیز برای پیش‌بینی در بازار سهام به کار گرفته شده‌اند. با اینکه این روش‌ها طی سالیان متمادی به‌طور گسترده‌ای مورد استفاده قرار گرفته و دیدگاه‌های ارزشمندی را درباره پویایی‌های بازار ارائه کرده‌اند؛ اما محدودیت‌هایی نیز دارند که از آن جمله، می‌توان به ناتوانی در شناسایی الگوهای پیچیده و ناخطی در سری‌های زمانی اشاره کرد. بنابراین، با افزایش ابعاد داده‌ها، نیاز به رویکردهای جایگزینی که از تکنیک‌های محاسباتی پیشرفته استفاده کنند، روزافزون شده است (شاهی، شرستا، نئوپان و گوئو^{۱۳}، ۲۰۲۰).

با ظهور نوآوری‌های اخیر، روش‌های هوش مصنوعی^{۱۴}، به‌ویژه الگوریتم‌های یادگیری ماشین^{۱۵}، به ابزارهای قدرتمندی برای تحلیل بازار سهام تبدیل شده‌اند و رویکردی عینی و مبتنی بر داده برای پیش‌بینی قیمت‌ها ارائه می‌دهند. این الگوریتم‌های پیچیده توانایی منحصر به فردی در کشف الگوهای پنهان در سری‌های زمانی دارند که روش‌های سنتی قادر به شناسایی آن‌ها نیستند. در حال حاضر، تکنیک‌های یادگیری ماشین نتایج امیدوارکننده‌ای در پیش‌بینی بازار سهام

1. Close price
2. Efficient-market hypothesis
3. AutoRegressive Integrated Moving Average
4. Box and Jenkins
5. Autoregressive Conditional Heteroskedasticity
6. Seasonal AutoRegressive Integrated Moving Average
7. Engle
8. Vector Autoregression
9. Generalized Autoregressive Conditional Heteroskedasticity
10. Bollerslev
11. Exponential smoothing models
12. Brown
13. Shahi, Shrestha, Neupane & Guo
14. Artificial intelligence
15. Machin learning

نشان داده‌اند و از نظر دقت و انعطاف‌پذیری نسبت به مدل‌های اقتصادسنجی سنتی برتری شایان توجهی دارند. به‌ویژه، یادگیری عمیق^۱، به‌عنوان یکی از زیرمجموعه‌های یادگیری ماشین، برای تشخیص الگوهای پیچیده رویکرد قدرتمندی است. در تحلیل بازار سهام، الگوریتم‌های متعددی از یادگیری ماشین با موفقیت چشمگیری به کار گرفته شده‌اند. این الگوریتم‌ها شامل شبکه‌های عصبی مصنوعی (هایکین^۲، ۱۹۹۸)، شبکه‌های عصبی عمیق^۳ (شائو، وو و لی^۴، ۲۰۱۴)، الگوریتم‌های ژنتیک^۵ (هلند^۶، ۱۹۹۲)، ماشین‌های بردار پشتیبان^۷ (برجس^۸، ۱۹۹۸)، مدل‌های فازی^۹ (زاده^{۱۰}، ۱۹۶۵)، درختان تصمیم^{۱۱} (کوئینلان^{۱۲}، ۱۹۸۶)، جنگل‌های تصادفی^{۱۳} (بریمان^{۱۴}، ۲۰۰۱) و چندین روش دیگر هستند. این الگوریتم‌ها اثربخشی خود را در پیش‌بینی قیمت سهام نشان داده‌اند؛ اما باید توجه کرد که دقت آن‌ها همواره شامل حاشیه‌ای از خطاست که به انتخاب الگوریتم وابسته است (نیکو، منصورفر و باقرزاده^{۱۵}، ۲۰۱۹).

با پیشرفت‌های اخیر، شبکه‌های عصبی به‌عنوان ابزارهای قدرتمند و انعطاف‌پذیر یادگیری ماشین برجسته شده‌اند که می‌توانند داده‌های نویزدار و ناخطی را به‌خوبی مدیریت کنند، به‌ویژه در زمینه پیش‌بینی سری‌های زمانی (یو و یان^{۱۶}، ۲۰۲۰). از میان روش‌های شبکه‌های عصبی، یادگیری عمیق به‌عنوان رویکرد پیشرو در تفسیر داده‌های بازار سهام شناخته شده است که این امر عمدتاً به‌دلیل عملکرد بالای آن در پیش‌بینی سری‌های زمانی است. مدل‌های یادگیری عمیق، چندین لایه ساختاری دارند که فرایند مدل‌سازی محاسباتی را تسهیل می‌کنند و قادرند داده‌ها را در سطوح مختلف تفسیر کنند (ابونوری، تازه‌آبادی^{۱۷}، ۲۰۰۹؛ لکان، بنگیو و هینتون^{۱۸}، ۲۰۱۵).

با توجه به این چشم‌انداز در حال تحول، شرکت‌های مدیریت دارایی و بانک‌های سرمایه‌گذاری به‌طور فزاینده‌ای بودجه تحقیقاتی خود را به توسعه کاربردهای هوش مصنوعی، با تمرکز ویژه بر یادگیری عمیق، اختصاص داده‌اند. تحلیل‌های مقایسه‌ای نشان می‌دهند که مدل‌های یادگیری عمیق، به‌دلیل توانایی در پردازش مجموعه‌های داده بزرگ و کشف روابط پیچیده و ناخطی بین ویژگی‌های ورودی و نتایج پیش‌بینی‌شده، مدل‌های خطی سنتی و رویکردهای دیگر

1. Deep learning
2. Haykin
3. Deep neural networks
4. Shao, Wu & Li
5. Genetic algorithms
6. Holland
7. Support vector machines
8. Burges
9. Fuzzy sets
10. Zadeh
11. Decision trees
12. Quinlan
13. Random forests
14. Breiman
15. Nikou, Mansourfar & Bagherzadeh
16. Yu and Yan
17. Abounoori & Tazehabadi
18. Lecun, Bengio & Hinton

یادگیری ماشین را در پیش‌بینی حرکات بازار سهام پشت سر گذاشته‌اند (حبیب‌نیا و معصومی^۱، ۲۰۲۱؛ جیانگ^۲، ۲۰۲۱؛ حبیب‌نیا^۳، ۲۰۱۶).

علاوه بر این، استفاده از مدل‌های ترکیبی یادگیری عمیق در حوزه مالی، به‌ویژه در پیش‌بینی بازده و قیمت سهام، نتایج قابل توجهی به همراه داشته است. نقطه قوت اصلی یادگیری عمیق در توانایی ذاتی آن برای استخراج خودکار ویژگی‌ها از داده‌های خام نهفته است؛ فرایندی که نیاز به شناسایی دستی ویژگی‌ها را کاهش و دقت پیش‌بینی‌ها را افزایش می‌دهد (وو، ونگ و وو^۴، ۲۰۲۲). انواع مختلف معماری‌های یادگیری عمیق توسعه یافتند که هر یک برای حل مشکلات خاص طراحی شده‌اند و با پیکربندی‌های ذاتی مجموعه‌های داده سازگار می‌شوند (بانداری و همکاران^۵، ۲۰۲۲). مدل‌های یادگیری عمیق، مانند شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM)^۶، به‌خوبی قادرند وابستگی‌های بلندمدت و روابط ناخطی در داده‌های متوالی را شناسایی کنند و از این ویژگی‌ها برای پیش‌بینی بازار سهام بهره ببرند (هو، سان، نای، لی و لیو^۷، ۲۰۱۹).

این مقاله با نوآوری در بهره‌گیری از روش‌های یادگیری عمیق نظارت‌شده^۸، به‌ویژه ترکیبی از شبکه‌های LSTM و یادگیری عمیق، به پیش‌بینی قیمت پایانی در بازار سهام می‌پردازد. استفاده از شبکه‌های LSTM امکان مدل‌سازی دقیق وابستگی‌های زمانی ذاتی در داده‌های بازار سهام را فراهم می‌آورد و به این ترتیب، پیش‌بینی‌هایی دقیق‌تر و قابل اعتمادتر ارائه می‌دهد. این پژوهش به‌طور خاص بر داده‌های شاخص‌های بورس اوراق بهادار تهران تمرکز دارد. با بهره‌گیری از توانمندی‌های یادگیری عمیق نظارت‌شده، این مقاله می‌کوشد تا به مطالعات جاری برای افزایش دقت و قابلیت اطمینان مدل‌های پیش‌بینی بازار سهام کمک کند. ترکیب مدل LSTM و یادگیری عمیق، همراه با استفاده از داده‌های بورس اوراق بهادار تهران به‌عنوان نماینده‌ای از یک بازار در حال توسعه، رویکردی نوآورانه ارائه می‌دهد که می‌تواند بینش‌های ارزشمندی را برای سهامداران، از جمله سرمایه‌گذاران، مؤسسه‌های مالی و سیاست‌گذاران فعال در بازار ایران فراهم کند؛ چرا که این روش تا کنون برای پیش‌بینی قیمت پایانی سهم در بازار سهام بررسی نشده است.

ساختار مقاله بدین شرح تنظیم شده است: در ادامه، به مرور ادبیات موجود در زمینه پیش‌بینی سهام با استفاده از تکنیک‌های یادگیری ماشین و یادگیری عمیق پرداخته شده است. بخش روش‌شناسی به تشریح داده‌ها و متغیرهای استفاده‌شده اختصاص یافته است. در ادامه این بخش، مدل‌های یادگیری عمیق به‌کار رفته در این پژوهش بررسی و روش‌های الگوریتمی پیش‌بینی توضیح داده می‌شوند. بخش یافته‌های پژوهش، نتایج حاصل از آزمایش‌ها را ارائه می‌کند که با بحثی جامع درباره این یافته‌ها همراه است. در بخش پایانی، جمع‌بندی نهایی صورت می‌گیرد، محدودیت‌های موجود بررسی و مسیرهای ممکن برای تحقیقات آتی پیشنهاد می‌شود.

1. Habibnia & Maasoumi
2. Jiang
3. Habibnia
4. Wu, Wang & Wu
5. Bhandari et al.
6. Long Short-Term Memory
7. Hu, Sun, Nie, Li & Liu
8. Supervised Deep Learning Methods

پیشینه پژوهش

در دهه‌های اخیر با افزایش حجم داده‌های مالی و پیچیدگی روزافزون بازارهای سرمایه، روش‌های سنتی تحلیل و پیش‌بینی به تدریج جای خود را به تکنیک‌های نوین مبتنی بر هوش مصنوعی، به‌ویژه یادگیری ماشین و یادگیری عمیق، داده‌اند. این رویکردها با قابلیت شناسایی الگوهای پیچیده و غیرخطی در داده‌های سری زمانی مالی، افق‌های جدیدی را در جهت افزایش دقت پیش‌بینی قیمت دارایی‌ها، مدیریت ریسک و توسعه استراتژی‌های معاملاتی گشوده‌اند.

مرور ادبیات پژوهش در این حوزه، یک سیر تکاملی مشخص را نشان می‌دهد: از به‌کارگیری مدل‌های یادگیری عمیق پایه مانند شبکه‌های عصبی بازگشتی و حافظه طولانی کوتاه‌مدت برای تحلیل سری‌های زمانی، به سمت استفاده از مدل‌های کدکننده خودکار برای استخراج ویژگی و کاهش نویز و سپس حرکت به سوی معماری‌های ترکیبی^۱ که نقاط قوت چندین مدل را با هم ادغام می‌کنند (مانند CNN-LSTM^۲ یا مدل‌های مبتنی بر مکانیزم توجه). در ادامه، شاهد ظهور مدل‌های پشته‌ای^۳ مانند کدکننده‌های خودکار پشته‌ای^۴ یا LSTM‌های پشته‌ای بوده‌ایم که به دنبال یادگیری بازنمایی‌های پیچیده‌تر و سلسله‌مراتبی از داده‌ها هستند.

جدول ۱ با هدف نمایش این روند تکاملی و با مرور مطالعات مرتبط، تدوین شده است. این جدول پژوهش‌ها را به‌گونه‌ای دسته‌بندی و ارائه می‌کند که سیر حرکت از مدل‌های اولیه به سمت رویکردهای پیشرفته‌تر و در نهایت، جایگاه نوآوری مطرح شده در پژوهش حاضر (یعنی کدکننده خودکار نظارت‌شده حافظه طولانی کوتاه‌مدت پشته‌ای - SLSAE) را که در سطر پایانی جدول منعکس شده است، روشن سازد.

جدول ۱. خلاصه پژوهش‌های پیشین

یافته کلیدی	هدف اصلی	روش اصلی	پژوهشگر (سال)
الف: مطالعات متمرکز بر یادگیری ماشین			
بهبود دقت پیش‌بینی جهت در میان / بلند مدت	پیش‌بینی جهت قیمت سهام (صعودی/نزولی)	مقایسه الگوریتم‌های مختلف یادگیری ماشین: طبقه بندی ^۵ ، جنگل تصادفی ^۶ ، تصادفی ^۷ ، XGBoost ^۸	باساک، کار، ساها، خایدم و دی ^۵ (۲۰۲۰)
همولوژی پایدار با یادگیری ماشین پیش‌بینی را بهبود داد	بهبود عملکرد پیش‌بینی جهت قیمت سهام	ترکیب یادگیری ماشین و همولوژی پایدار ^{۱۰}	اسماعیل، نورانی، اسماعیل، رازاک و آلیاس ^۹ (۲۰۲۰)

- Hybrid
- Convolutional Neural Networks
- Stacked
- SDAE
- Basak, Kar, Saha, Khaidem & Dey
- Classification
- Random Forests
- Extreme gradient boost
- Ismail, Noorani, Ismail, Razak & Alias
- Persistent homology

پژوهشگر (سال)	روش اصلی	هدف اصلی	یافته کلیدی
ویجه، چاندولا، تیکیوال و کومار ^۱ (۲۰۲۰)	شبکه عصبی مصنوعی، جنگل تصادفی	پیش‌بینی قیمت پایانی روز بعد سهام	مدل‌ها در پیش‌بینی قیمت پایانی کارآمد بودند
کیم، کو، چنگ و سونگ ^۲ (۲۰۲۰)	انتروپی انتقال مؤثر (ETE) ^۳ با یادگیری ماشین	پیش‌بینی جهت قیمت سهام آمریکا	ETE پیش‌بینی را بهبود داد؛ MLP و LSTM مناسب‌ترند
مهتاب، سن و دوتا ^۴ (۲۰۲۰)	مدلسازی ترکیبی یادگیری ماشین/عمیق (LSTM)، اعتبارسنجی پیش‌رونده ^۵	پیش‌بینی مقادیر باز شدن شاخص NIFTY50	مدل LSTM تک‌متغیره (داده مربوط هفته قبل) دقیق‌ترین بود
نبی‌پور ^۶ (۲۰۲۰)	مقایسه مدل‌های یادگیری ماشین و عمیق (LSTM، RNN)	کاهش ریسک پیش‌بینی روند سهام	RNN و LSTM برترند، خصوصاً با داده پیوسته ^۷
ب: مدل‌های مبتنی بر یادگیری عمیق			
سینگ و سریواستاوا ^۸ (۲۰۱۷)	شبکه عصبی عمیق (DNN) ^۹ به‌علاوه تحلیل مؤلفه اصلی دوبعدی دو جهته	بهبود دقت پیش‌بینی بازار سهام با یادگیری عمیق	روش پیش‌بینی PCA ^{۱۰} + DNN (2D) دقت را بهبود داد
نایک و موهان ^{۱۱} (۲۰۱۹)	شبکه عصبی بازگشتی (RNN) با LSTM، حذف بازگشتی ^{۱۲}	پیش‌بینی بازده آتی سهام، کمیته‌سازی خطا	RNN با LSTM از شبکه عصبی پیشخور ^{۱۳} بهتر عمل کرد
بودیهارتو ^{۱۴} (۲۰۲۱)	علم داده و حافظه طولانی کوتاه‌مدت (LSTM)	پیش‌بینی قیمت سهام اندونزی (OHLC)	LSTM برای پیش‌بینی کوتاه‌مدت مؤثر است (دقت ۹۴/۵۷ درصد)
همایل و اودا ^{۱۵} (۲۰۲۱)	مقایسه انواع شبکه عصبی بازگشتی (Bi-LSTM، LSTM، GRU)	پیش‌بینی قیمت رمزارزهای بیت‌کوین، لایت‌کوین، اتریوم	GRU بهترین عملکرد را در پیش‌بینی قیمت رمزارز داشت
رنجان، ماهادانی و کومار ^{۱۶} (۲۰۲۲)	مقایسه RNN، LSTM، Bi-LSTM (ویژگی‌های تک/چند متغیره)	پیش‌بینی قیمت سهام، یافتن بهترین مدل	RNN با ویژگی‌های تک/چند متغیره دقت بالایی داشت
الخصاونه، رازا، خان و خان ^{۱۷} (۲۰۲۴)	شبکه عصبی بازگشتی LSTM یادگیری عمیق	بهبود دقت پیش‌بینی شاخص پایانی بورس پاکستان	پیش‌بینی می‌شود مدل‌های یادگیری عمیق از روش‌های سنتی بهتر باشند

- Vijh, Chandola, Tikkiwal & Kumar
- Kim, Ku, Chang & Song
- Effective Transfer Entropy
- Mehtab, Sen & Dutta
- walk-forward validation
- Nabipour
- continuous data
- Singh and Srivastava
- Deep Neural Network
- 2-Directional 2-Dimensional Principal Component Analysis
- Naik and Mohan
- recurrent dropout
- feed forward ANN
- Budiharto
- Hamayel and Owda
- Ranjan, Mahadani & Kumar
- Al-Khasawneh, Raza, Khan & Khan

بژوهشگر (سال)	روش اصلی	هدف اصلی	یافته کلیدی
چاندار ^۱ (۲۰۲۴)	LSTM با شاخص‌های فنی، نرمال‌سازی داده	پیش‌بینی قیمت‌های آتی سهام (یک روز جلوتر)	مدل LSTM پیشنهادی دقت پیش‌بینی بالایی نشان داد
ج: مدل‌های مبتنی بر کدکننده خودکار			
وو و همکاران (۲۰۲۲)	چارچوب ترکیبی تبدیل موجک گسسته (DWT)، رمزگذار خودکار (AE) و ماشین یادگیری شدید (ELM) تحت عنوان (DAELM)	پیش‌بینی روند بازار سهام، بهبود مدیریت پورتفولیو/ریسک	DAELM برتر؛ دقت پیش‌بینی و بازده سرمایه‌گذاری بالاتر
بانو، یو و راتو ^۴ (۲۰۱۷)	چارچوب ترکیبی تبدیل موجک، خودرمزگذار پشته‌ای، LSTM	پیش‌بینی قیمت پایانی روز بعد سهام	مدل پیشنهادی در دقت و سودآوری از سایرین بهتر بود
بیگانوفسکی و اسلیپاچوک ^۵ (۲۰۲۴)	خودرمزگذارهای نظارت‌شده، افزایش نویز ^۶ ، برچسب‌گذاری سد سه‌گانه ^۷	بهبود پیش‌بینی مالی، ارتقای عملکرد استراتژی سرمایه‌گذاری	خودرمزگذارهای نظارت‌شده متعادل، اثربخشی استراتژی را افزایش دادند
د: مدل‌های ترکیبی و پیشرفته‌تر			
رادر ^۸ (۲۰۲۱)	طرح رگرسیون جدید مبتنی بر LSTM، مدل پورتفولیوی جدید	پیش‌بینی قیمت سهام، ساخت پورتفولیوی سرمایه‌گذاری	مدل پیشنهادی از مدل‌های استاندارد پیش‌بینی/پورتفولیو بهتر بود
کانوال، لائو، نگ، سیم و چاندراسکاران ^۹ (۲۰۲۲)	مدل ترکیبی BiCuDNNLSTM ^{۱۰} و CNN یک‌بعدی	پیش‌بینی به‌موقع و کارآمد قیمت سهام برای سرمایه‌گذاران	مدل ترکیبی پیشنهادی برای پیش‌بینی کارآمد و قابل اعتماد است
رن، خو و دوان ^{۱۱} (۲۰۲۲)	مدل LSTM مبتنی بر تبدیل فوریه ^{۱۲} ، تجزیه شوک نفتی	تحلیل تأثیر شوک‌های نفتی بر پیش‌بینی نوسانات سهام	LSTM فوریه پیش‌بینی نوسان را بهبود داد؛ شوک‌ها متفاوتند
آکوناگارسیا، لوز کانچولا ماگدالانو و اولموس ترجو ^{۱۳} (۲۰۲۲)	تبدیل موجک پیوسته ^{۱۴} ، شبکه عصبی بازگشتی ^{۱۵} LSTM	پیش‌بینی قیمت سهام مالی (کوتاه/میان مدت)	روش‌شناسی، پروجکشن بسیار موفق از قیمت سهام نشان داد

1. Chandar
2. discrete wavelet transform
3. extreme learning machine
4. Bao, Yue & Rao
5. Bieganowski and Slepaczuk
6. noise augmentation
7. triple barrier labeling
8. Rather
9. Kanwal, Lau, Ng, Sim & Chandrasekaran
10. Bidirectional Cuda Deep Neural Network Long Short-Term Memory
11. Ren, Xu & Duan
12. Fourier transform-based
13. Acuna-García, Luz Canchola-Magdaleno & Olmos Trejo
14. Continuous Wavelet Transform
15. recurrent neural network

پژوهشگر (سال)	روش اصلی	هدف اصلی	یافته کلیدی
خدایی، اصفهانی‌پور و طاهری ^۱ (۲۰۲۲)	مدل ترکیبی CNN-LSTM-ResNet، متعادل‌سازی ^۲ ، بخش‌بندی فازی ^۳	پیش‌بینی نقاط عطف قیمت سهام برای سود بیشتر	مدل پیشنهادی سود و دقت را به‌طور قابل توجهی افزایش داد
گولمز ^۴ (۲۰۲۳)	شبکه LSTM عمیق بهینه‌شده با الگوریتم ARO	پیش‌بینی قیمت سهام با دقت بهبودیافته	مدل LSTM-ARO از سایر مدل‌ها عملکرد بهتری داشت
دژکام و منظوری ^۵ (۲۰۲۳)	مدل HHT-XGB شامل ترکیب تبدیل هیلبرت-هونگ ^۶ و XGBoost	پیش‌بینی روند قیمت، بهینه‌سازی پرتفوی سهام	مدل HHT-XGB عملکرد پرتفوی را (۹۹.۸٪) بهبود داد
لی و همکاران ^۷ (۲۰۲۲)	BiLSTM مبتنی بر توجه ^۸ (AttBiLSTM) با شاخص‌های تکنیکال	طراحی استراتژی معاملاتی، پیش‌بینی روند قیمت سهام	AttBiLSTM با شاخص‌های فنی برای پیش‌بینی و بازده مؤثر بود
شارما و شخاوات ^۹ (۲۰۲۲)	DBRNN ^{۱۰} ترکیبی با بهینه‌سازی HH-DHO ^{۱۱}	پیش‌بینی بازده برای تشکیل و انتخاب پورتفولیو	روش پیشنهادی از نظر بازده و ریسک برتر بود
جیرو، جبایی و لحنانی ^{۱۲} (۲۰۲۵)	مدل ترکیبی تنظیم دقیق شده DWT-LSTM ^{۱۳}	پیش‌بینی بازده رماراز (بیت‌کوین، ریپل)، بررسی پیش‌بینی‌کننده‌ها	DWT-LSTM برتـــــ؛ استراتژی‌های معاملاتی عملکرد بهتری داشتند
هـ: مطالعات داخلی (ایران) با رویکردهای متنوع			
افشاری راد، علوی و سینایی (۱۳۹۷)	تحلیل تکنیکال، انتخاب ویژگی، یادگیری ماشین، رأی اکثریت	پیش‌بینی روند شاخص کل سهام	روش پیشنهادی نرخ پیش‌بینی صحیح ۹۷ درصد داشته است
سعیدی‌اقدم، صادقی، بحیرایی و حاجی‌اصغری (۱۴۰۱)	مدل ترکیبی شبکه‌های عصبی مصنوعی (ANN) با الگوریتم‌های بهینه‌سازی	پیش‌بینی روند حرکتی قیمت سهام با دقت بالا	مدل در پیش‌بینی روند، دقیق‌تر از روش‌های سنتی بود
محبی، فدائی‌نژاد، اصولیان و حمیدی‌زاده (۱۴۰۱)	کاهش ابعاد (PCA ^{۱۴} و MID ^{۱۵})، شبکه‌های عصبی (RBF و DNN)، الگوریتم ISF_MID	انتخاب مدل و ویژگی برای پیش‌بینی روزانه شاخص بورس	مدل RBF با انتخاب ویژگی MID دقیق‌تر بود؛ ISF_MID پیشنهاد شد

1. Khodaei, Esfahanipour & Taheri
2. balancing
3. Fuzzy C-Means segmentation
4. Gülmez
5. Dezhkam and Manzuri
6. Hilbert-Huang
7. Lee et al.
8. Attention-based BiLSTM
9. Sharma and Shekhawat
10. Deep Belief-Recurrent Neural Network
11. Harris Hawks-Deer Hunting Optimization
12. Jirou, Jebabli & Lahiani
13. Discrete Wavelet Transform LSTM
14. Mutual Information Difference
15. Principal Component Analysis

پژوهشگر (سال)	روش اصلی	هدف اصلی	یافته کلیدی
حیدری و امیری (۱۴۰۱)	مقایسه مدل‌های یادگیری ماشین (خطی، خودهم‌بسته، جنگل تصادفی، عصبی)	بررسی و پیش‌بینی روند قیمت سهام با یادگیری ماشین	دقت مدل‌ها (یادگیری عمیق ۸۰-۷۰ درصد)؛ نتایج خیره‌کننده نبود
ترابی‌پور و سیادت (۱۴۰۱)	شبکه عصبی ترکیبی کانولوشن و LSTM	پیش‌بینی قیمت سهام (دیتاست وب ملت و سهام دیگر)	روش پیشنهادی در دیتاست‌های بزرگ بهتر و با خطای کمتر عمل کرد
سهرابی، میربرگ‌کار، چیرانی و خریدار (۱۴۰۱)	مقایسه یادگیری ماشین (جنگل تصادفی، SVM، ANN، RNN، LSTM، استخراج جهش ARJI-GARCH)	بررسی دقت پیش‌بینی جهش‌های شاخص سهام با یادگیری ماشین	شبکه عصبی بازگشتی (LSTM) بهترین نتیجه را در پیش‌بینی جهش داشته است
هادی‌زاده، تارخ و میرزایی قزآنی (۱۴۰۱)	یادگیری تقویتی عمیق ^۱ ، شبکه عصبی کانولوشن، حجم معاملات	مدل‌سازی وظایف معامله‌گر، پیش‌بینی روند سهام نقد شونده	برتری مدل پیشنهادی نسبت به استراتژی خرید و نگهداری مقایسه شد
رجبی و خالوزاده (۱۴۰۲)	مرور جامع و تحلیل رویکردهای پیش‌بینی بازار سهام	ارائه نقشه راه، چالش‌ها و روندهای آتی پیش‌بینی سهام	ارائه بررسی جامع، تحلیل، و مسیرهای تحقیقاتی آینده
مرادی، نشاط و سرداری (۱۴۰۳)	مقایسه مدل‌ها (RF، DQN، LSTM، SVR، تحلیل حساسیت، خوشه‌بندی)	خوشه‌بندی شرکت‌ها بر اساس تأثیرپذیری از تحریم‌ها، پیش‌بینی بازده	LSTM مدل برتر؛ پیش‌آمدهای سیاسی بیشترین تأثیر را داشتند
زکایی، ثنایی و میرزاپور باباجان (۱۴۰۳)	ترکیب LSTM، PCA، SVD؛ مقایسه با روش‌های هوش مصنوعی	ارائه مدل هوشمند پیش‌بینی قیمت سهام برای مدیریت سبد	کاهش ابعاد PCA عملکرد یادگیری عمیق را بهبود بخشید
غلامی و شمس قارنه (۱۴۰۳)	مدل‌های LSTM-CNN و CNN، LSTM، بهینه‌سازی PSO، تقویت مدل	پیش‌بینی قیمت سهام بورس تهران با یادگیری عمیق	مدل LSTM-CNN با PSO بهترین عملکرد و بازده مالی را داشتند
اصولیان، نیک‌مرام و کریمی (۱۴۰۴)	شبکه عصبی ترکیبی (CNN و LSTM)، استخراج ویژگی چندمقیاسی	پیش‌بینی روند شاخص کل بورس تهران با شبکه هیبریدی	مدل ترکیبی توانایی کافی نداشته؛ CNN به تنهایی بهتر بوده است
ایزدی، آشتاب و زواری رضایی (۱۴۰۴)	مقایسه ۲۵ مدل یادگیری ماشین و ۱۰ مدل آماری، منحنی راک ^۲	مقایسه دقت پیش‌بینی مدل‌ها برای جهت تغییرات سود	مدل‌های یادگیری ماشین کارا تر بودند؛ درخت تصمیم و استنتاج قوانین نیز بهینه بوده‌اند
و: نوآوری پژوهش حاضر			
پژوهش حاضر	استفاده از SLSAE (LSTM) خودرم‌گذار نظارت‌شده پشته‌ای و مقایسه مدل‌ها	پیش‌بینی قیمت سهام در بازار ایران با تاکید بر استخراج ویژگی‌های سلسله‌مراتبی و نظارت‌شده با SLSAE و بهبود دقت پیش‌بینی	بهبود قابل توجه دقت پیش‌بینی مدل SLSAE نسبت به مدل‌های پایه و ترکیبی پیشین از طریق یادگیری بازنمایی‌های کارآمدتر و مرتبط‌تر با هدف

1. deep reinforced learning
2. ROC curve

همان گونه که در مرور ادبیات و جدول ۱ مشهود است، جامعه علمی به‌طور مستمر در حال حرکت به سمت مدل‌های پیچیده‌تر و کارآمدتر برای پیش‌بینی بازارهای مالی است. این مسیر از مدل‌های پایه‌ای مانند LSTM (بخش ب جدول ۱)، به سمت استفاده از کدکننده‌های خودکار برای استخراج ویژگی (بخش ج جدول ۱، مانند پژوهش وو و همکاران، ۲۰۲۲)، و سپس به توسعه مدل‌های ترکیبی و پیشرفته (بخش د جدول ۱) که قابلیت‌های مختلفی نظیر مکانیزم توجه، ترکیب با پردازش سیگنال یا CNN را به کار می‌گیرند، تکامل یافته است. در مطالعات داخلی ایران نیز در سال‌های اخیر، روش‌های پیش‌بینی بازار سهام با استفاده از الگوریتم‌های یادگیری عمیق به دلیل توانایی‌های منحصربه‌فرد خود در شناسایی الگوهای پیچیده و ناخطی، توجه بسیاری از پژوهشگران و متخصصان را به خود جلب کرده است.^۱ در این راستا، سیزده مطالعه اخیر در حوزه بازار سرمایه ایران به بررسی این روش‌ها پرداخته‌اند و یافته‌های قابل توجهی را ارائه داده‌اند که در جدول ۱ (بخش ه) قابل مشاهده می‌باشد.

پژوهش حاضر که در ردیف پایانی جدول ۱ (بخش و) خلاصه شده است، در ادامه همین مسیر تکاملی قرار دارد و با الهام از نقاط قوت و ضعف رویکردهای پیشین، نوآوری خود را ارائه می‌دهد. به‌طور مشخص، نوآوری اصلی مقاله حاضر در ارائه و به‌کارگیری یک معماری نوین یادگیری عمیق با عنوان کدکننده خودکار نظارت‌شده شبکه حافظه طولانی کوتاه‌مدت پشته‌ای (SLSAE)^۲ است که به‌طور خاص برای پیش‌بینی دقیق قیمت پایانی سهام در بازارهای مالی، با تمرکز بر داده‌های با ابعاد بالا طراحی شده است. در حالی که کدکننده‌های خودکار استاندارد (مانند آنچه در پژوهش وو و همکاران، ۲۰۲۲ استفاده شد) و حتی مدل‌های پشته‌ای آن‌ها (مانند SDAE که در ادبیات عمومی مطرح است، اما در پژوهش‌های مرور شده به‌طور خاص برای پیش‌بینی قیمت سهام کمتر دیده شد)، اغلب به‌صورت بدون نظارت برای کاهش ابعاد یا حذف نویز به کار می‌روند. این پژوهش، ضمن توجه به بازار سهام ایران به‌عنوان یک زمینه کمتر مطالعه‌شده در پژوهش‌های پیشرفته، شکاف تحقیقاتی موجود در پردازش و یادگیری از داده‌های مالی پیچیده و چندبعدی را هدف قرار می‌دهد.

وجه تمایز و نوآوری کلیدی SLSAE نسبت به رویکردهای پیشین، به‌ویژه بسیاری از شبکه‌های عمیق موجود، در مکانیزم یادگیری ویژگی‌های آن نهفته است. در حالی که روش‌های قبلی اغلب بر یادگیری ویژگی‌ها به‌صورت نظارت‌نشده^۳ برای استخراج اطلاعات کلی از داده‌های خام تکیه می‌کنند، معماری SLSAE یک رویکرد نظارت‌شده^۴ و سلسله‌مراتبی را برای یادگیری ویژگی‌ها اتخاذ می‌کند. این بدان معناست که SLSAE به‌طور مستقیم و هدفمند، ویژگی‌های عمیقی را از داده‌های ورودی خام می‌آموزد که ارتباط تنگاتنگی با متغیر هدف، یعنی قیمت پایانی سهام، دارند. این فرایند از طریق انباشتن چندین لایه کدکننده خودکار نظارت‌شده (SAE) صورت می‌پذیرد که در آن هر لایه،

۱. برای مطالعه بیشتر به منابع زیر رجوع شود:

Dami and Esterabi (2021), Nabipour (2020), Abounoori and Tour (2019), Abounoori et al. (2016)

2. Stacked LSTM Supervised Autoencoder

3. unsupervised

4. supervised

ویژگی‌های مرتبط‌تر و سطح بالاتری را از لایه قبلی استخراج می‌کند و هم‌زمان اطلاعات نامربوط و نویز را کاهش می‌دهد. این ساختار سلسله‌مراتبی و نظارت‌شده تضمین می‌کند که ویژگی‌های آموخته‌شده در هر سطح، به‌طور معناداری به بهبود پیش‌بینی قیمت در لایه خروجی کمک می‌کنند. در نتیجه، SLSAE قادر است الگوهای پیچیده و غیرخطی موجود در داده‌های سری زمانی مالی را با دقت بیشتری شناسایی کند و به پیش‌بینی‌های قابل اطمینان‌تری منجر شود. برتری این رویکرد در نتایج مقاله که نشان‌دهنده عملکرد بهتر SLSAE نسبت به مدل‌های LSTM، ANN و ARIMA در معیارهای مختلف ارزیابی است، تأیید می‌شود و کارآمدی آن را در بهبود چشمگیر دقت پیش‌بینی قیمت پایانی سهام به اثبات می‌رساند.

بدین ترتیب، مقاله حاضر با ارائه معماری SLSAE، یک گام مهم در جهت افزایش دقت و قابلیت اتکای پیش‌بینی‌ها در بازارهای مالی، به‌ویژه بازار سهام ایران با ویژگی‌های خاص خود، برمی‌دارد. این رویکرد نه تنها از نظر فنی نوآورانه است، بلکه با تمرکز بر یادگیری ویژگی‌های نظارت‌شده و سلسله‌مراتبی، به رفع برخی محدودیت‌های مدل‌های پیشین در استخراج اطلاعات واقعاً مرتبط برای پیش‌بینی کمک می‌کند و شکاف موجود در ترکیب بهینه یادگیری بازنمایی عمیق و پیش‌بینی نظارت‌شده را در این حوزه پر می‌کند.

روش‌شناسی پژوهش

داده‌ها

سهام منتخب

شناسایی رابطه بین رویدادهای گذشته و آینده در داده‌های سری زمانی مالی یکی از چالش‌های اصلی در پیش‌بینی محسوب می‌شود (پایوا، کاردوسو، هاناوکا و دوآرته^۱، ۲۰۱۹). با توجه به ماهیت پیوسته داده‌های مالی، استفاده از دوره طولانی‌تری از داده‌های نمونه، احتمال ثبت اطلاعات تاریخی و حافظه را افزایش می‌دهد (فیشر و کروس^۲، ۲۰۱۸؛ لانگ، لو و کوی^۳، ۲۰۱۹). در نتیجه، آزمایش‌های تجربی به حجم زیادی از داده‌های بلندمدت نیاز دارند (چورموزیادیس و چاتزگلو^۴، ۲۰۱۶). در این مطالعه، ما داده‌های روزانه سهام از بورس اوراق بهادار تهران را که از ۲۱ بهمن ۱۳۹۱ (۹ فوریه ۲۰۱۳) تا ۱۱ تیر ۱۴۰۲ (۲ ژوئیه ۲۰۲۳) را دربرمی‌گیرد و شامل بیش از ۲۵۰۰ مشاهده است، گردآوری کرده‌ایم. شایان ذکر است که بیشتر تحقیقات مرتبط با استفاده از یک بازه زمانی ۱۰ ساله یا کمتر انجام شده است (چن و هائو^۵، ۲۰۱۸؛ کارا، بویاچی اوغلو و بایکان^۶، ۲۰۱۱؛ پاتل، شاه، تاکار و کوتچا^۷، ۲۰۱۵). بنابراین، لحاظ نمونه‌های ما که به بیش

1. Paiva, Cardoso, Hanaoka & Duarte
2. Fischer and Krauss
3. Long, Lu & Cui
4. Chourmouziadis and Chatzoglou
5. Chen and Hao
6. Kara, Boyacioglu & Baykan
7. Patel, Shah, Thakkar & Kotecha

بیش از ۱۰ سال گسترش می‌یابد، می‌تواند به‌عنوان ارائه حجم کافی از داده‌ها برای دستیابی به نتایج آماری معنادار تلقی شود.

بورس اوراق بهادار تهران به‌عنوان یکی از بازارهای مالی مهم در ایران، ۳۹۲ شرکت پذیرفته‌شده در بورس اوراق بهادار تهران تا پایان سال ۱۴۰۳ را در فهرست خود دارد که اکثر آن‌ها طی سال‌های اخیر، عرضه‌های اولیه عمومی هستند. بورس تهران شامل صنایع متنوعی از جمله خودروسازی، مخابرات، کشاورزی، پتروشیمی، معدن، فولاد، آهن، مس، بانکداری و بیمه است. به‌منظور انجام پیش‌بینی بر تعداد نمونه‌های کافی در صنایع مختلف، ۱۰ سهم که از وضعیت بنیادی خوبی برخوردار بوده‌اند انتخاب شده است که به‌عنوان نمونه مورد مطالعه قرار گیرند.

در این پژوهش، به‌منظور انجام پیش‌بینی‌های تحلیلی و کاهش اثر محدودیت‌های موجود در دسترسی به داده‌های کامل بازار سرمایه ایران، یک نمونه هدفمند متشکل از ده شرکت از صنایع مختلف انتخاب شده است. انتخاب این ده شرکت با تکیه بر رویکردی علمی و بر اساس مجموعه‌ای از معیارهای کمی و کیفی صورت گرفته است که هدف آن، دستیابی به نمایندگانی معتبر و اثرگذار از ساختار بازار سرمایه کشور بوده است. نخست، از میان تمامی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران، شرکت‌هایی مورد بررسی قرار گرفتند که در صنعت خود از نظر ارزش بازار در بین ده درصد برتر قرار داشتند. این معیار سبب شد تنها شرکت‌هایی در نمونه نهایی گنجانده شوند که سهم قابل‌توجهی از ارزش بازار صنعت خود را دارا هستند و در نتیجه، رفتار آن‌ها می‌تواند منعکس‌کننده روندهای کلی بازار باشد.

در گام بعدی، میزان نقدشوندگی سهام شرکت‌ها از طریق بررسی حجم معاملات روزانه مورد ارزیابی قرار گرفت و تنها شرکت‌هایی انتخاب شدند که حجم معاملات آن‌ها بیش از میانگین صنعت خود بوده است؛ این اقدام به‌منظور اطمینان از کیفیت بالای داده‌های قیمتی و کاهش نویزهای آماری صورت گرفت. در ادامه، ارزیابی ویژگی‌های بنیادین شرکت‌ها از طریق چهار شاخص اصلی شامل فروش کل، حاشیه سود ناخالص، ارزش دفتری دارایی‌ها و نسبت بدهی به دارایی انجام شد. شرکت‌هایی که حداقل در سه مورد از این چهار شاخص در بین ده درصد برتر صنعت خود قرار داشتند، به‌عنوان شرکت‌های پیشرو شناسایی و وارد نمونه شدند.

همچنین، برای تضمین اینکه نوسان‌های قیمتی شرکت‌های منتخب به‌خوبی نمایانگر تغییرات صنعت مربوطه باشد، ضریب هم‌بستگی بین بازده قیمتی هر شرکت با بازده شاخص صنعت متناظر محاسبه شد و تنها شرکت‌هایی که این هم‌بستگی بیش از ۰/۷۵ داشتند، در نمونه نهایی حفظ شدند. این معیار موجب شد که تحلیل‌های انجام‌شده از اتکای بیشتری نسبت به رفتار صنعت برخوردار باشند. در نهایت، ده شرکت منتخب که بر اساس معیارهای فوق شناسایی شدند، عبارت‌اند از: خگستر، خودرو، وغدیر، فملی، پارسان، کگل، شپاکسا، ستران، وبشهر و اخبر. این شرکت‌ها نه تنها در صنایع خود پیشرو محسوب می‌شوند، بلکه به‌تنهایی بیش از ۳۰ درصد از ارزش کل بازار بورس تهران را دربرمی‌گیرند. چنین ترکیبی از معیارهای بنیادی، بازاری و ساختاری باعث می‌شود که نمونه انتخاب‌شده واجد مبانی علمی مشخص و قابل دفاع باشد و نتایج حاصل از آن از قابلیت تعمیم مناسبی به کل بازار برخوردار باشد.

متغیرهای ورودی و خروجی

انتخاب دقیق متغیرهای ورودی^۱ در پیش‌بینی سری‌های زمانی از اهمیت بالایی برخوردار است. با تکیه بر نتایج تحقیقات پیشین، مشخص شده است که شاخص‌های تکنیکال به‌عنوان ویژگی‌های مؤثری برای توصیف و بازتاب دینامیک واقعی بازار عمل می‌کنند. به‌عنوان مثال چن و هائو (۲۰۱۸) پیشنهاد می‌کنند که میانگین متحرک نمایی (EMA)^۲، شاخص قدرت نسبی (RSI)^۳ و شاخص مومنتوم (MoM)^۴ با نوسان‌های بازار سهام هم‌بستگی دارند. به همین ترتیب، کارا و همکاران (۲۰۱۱) ده شاخص تکنیکال را به‌عنوان زیرمجموعه‌ای از ویژگی‌های ورودی انتخاب می‌کنند. علاوه‌براین، پیش‌بینی سری‌های زمانی مالی معمولاً شامل مشاهدات با وقفه نیز می‌شود. برای نمونه، فیشر و کروس (۲۰۱۸) از توالی زمانی بازدهی به طول ۲۴۰ برای آموزش استفاده می‌کنند، در حالی که پایوا و همکاران (۲۰۱۹) از چندین متغیر با وقفه بازدهی به‌عنوان ورودی برای پیش‌بینی بازدهی سهام آینده بهره می‌گیرند.

با تکیه بر نکات به‌دست‌آمده از ادبیات مرتبط، ما در نهایت ۲۱ شاخص کلیدی شامل شاخص‌های تکنیکال و مشاهدات قیمتی را به‌عنوان متغیرهای ورودی برای پیش‌بینی قیمت پایانی به‌عنوان متغیر خروجی انتخاب کرده‌ایم. برای اطمینان از سازگاری و کاهش خطاهای ناشی از محدوده‌های عددی متفاوت بین شاخص‌ها، تمامی مقادیر قیمت و شاخص‌های تکنیکال در بازه (۰, ۱) استاندارد شده‌اند. داده‌های جمع‌آوری‌شده از دوره ۱۳۹۱ تا ۱۴۰۲ به نسبت ۸:۲ به مجموعه‌های آموزش (Train) و آزمایش (Test) تقسیم شده‌اند. مجموعه آموزش برای آموزش مدل و تنظیم مناسب آبر پارامترها به کار گرفته می‌شود تا به تعمیم قوی‌تری دست یابیم. در نهایت، عملکرد مدل نهایی با استفاده از مجموعه آزمایش ارزیابی می‌شود.

داده‌های نمونه ما شامل سری‌های تاریخی تعدیل‌شده‌ای از قیمت ابتدایی، قیمت پایانی، بالاترین قیمت، پایین‌ترین قیمت، آخرین قیمت، حجم معاملات، بازدهی، شاخص قدرت نسبی (RSI)، همگرایی و واگرایی میانگین متحرک (MACD)^۵، شاخص جریان پول (MFI)^۶، دامنه واقعی میانگین (ATR)^۷، استوکاستیک^۸، مومنتوم^۹،

1. Input variables

2. Exponential moving average

۳. Relative Strength index این شاخص سرعت و تغییرات حرکات قیمتی را اندازه‌گیری می‌کند و شرایط اشباع خرید یا فروش را نشان می‌دهد.

4. Momentum

۵. Moving Average Convergence Divergence این شاخص رابطه بین دو میانگین متحرک قیمت یک اوراق بهادار را نشان می‌دهد و سیگنال‌های خرید یا فروش احتمالی را برجسته می‌کند.

۶. Money Flow Index این شاخص قدرت جریان پول به داخل و خارج از یک اوراق بهادار را اندازه‌گیری کرده و به شناسایی شرایط اشباع خرید یا فروش کمک می‌کند.

۷. Average True Range این شاخص میانگین دامنه حرکت بازار را در یک دوره مشخص اندازه‌گیری می‌کند و در تعیین سطوح توقف ضرر مفید است.

۸. Stochastic این شاخص با مقایسه قیمت پایانی خاص با دامنه‌ای از قیمت‌ها، شرایط اشباع خرید یا فروش را آشکار می‌سازد.

۹. Momentum این شاخص میزان افزایش یا کاهش قیمت را در یک بازه زمانی معین اندازه‌گیری کرده و اطلاعاتی درباره قوت یا ضعف روند روند ارائه می‌دهد.

ویلیامز R%^۱، حجم متوازن (OBV)^۲، نرخ تغییر (ROC)^۳، میانگین متحرک ۱۰ روزه^۴، میانگین متحرک ۲۰ روزه، میانگین متحرک ۵۰ روزه، میانگین متحرک نمایی ۱۰ روزه^۵، میانگین متحرک نمایی ۲۰ روزه و میانگین متحرک نمایی ۵۰ روزه است.

مدل کدکننده خودکار نظارت‌شده

کدکننده خودکار (AE)

مدل AE یک نوع شبکه عصبی با ساختار سه لایه است که به صورت بدون نظارت عمل می‌کند. هدف اصلی آن، یادگیری و استخراج ویژگی‌های مهم از داده‌های ورودی از طریق فرایند بازسازی است. این شبکه شامل دو بخش کلیدی است: کدگذار و کدگشا. کدگذار داده‌های ورودی را از لایه ورودی دریافت کرده و آن‌ها را به یک نمایش با ابعاد کمتر در لایه پنهان تبدیل می‌کند. این تبدیل به کدگذار اجازه می‌دهد تا ویژگی‌های اساسی داده‌های ورودی را ضبط و کدگذاری کند.

از سوی دیگر، کدگشا این ویژگی‌های پنهان را گرفته و داده‌های ورودی اولیه را در لایه خروجی بازسازی می‌کند (یوان، لی، ونگ، یانگ و گوی^۶، ۲۰۲۰؛ یوان، کی و ونگ^۷، ۲۰۲۰؛ یوان، ونگ، یانگ و گوی^۸، ۲۰۲۰). ساختار یک AE و اجزای مختلف آن در شکل ۱ نمایش داده شده است. ساختار یک AE و اجزای مختلف آن در شکل ۱ نمایش داده شده است. در طول فرایند کدگذاری، N نمونه آموزش $x_i \in \{x_1, x_2, \dots, x_N\}$ که $x \in R^{d_x}$ به لایه ورودی تزریق می‌شود. با اعمال یک تابع فعال‌سازی ناخطی، بردار ورودی به داده‌های ویژگی مربوطه نگاشت می‌شود. بردار ویژگی به صورت $\{h_1, h_2, \dots, h_N\}$ بوده و $h \in R^{d_h}$ است. روابط ریاضی لایه پنهان به صورت زیر تعریف می‌شود (چنگ و همکاران^۹، ۲۰۲۱):

$$h = f(w^e x + b^e) \quad \text{رابطه ۱}$$

در رابطه بالا $w^e \in R^{d_h \times d_x}$ و $b^e \in R^{d_h}$ به ترتیب ماتریس وزنی و بردار بایاس کدگذار را نشان می‌دهند. در

۱. Williams %R این شاخص با مقایسه قیمت پایانی با محدوده بالا-پایین، شرایط اشباع خرید یا فروش را شناسایی می‌کند.

۲. On-Balance Volume این شاخص بر اساس حجم معاملات، فشار خرید یا فروش جمعی را اندازه‌گیری کرده و به تأیید روندهای قیمتی قیمتی کمک می‌کند.

۳. Rate of Change این شاخص درصد تغییر قیمت را در یک دوره معین ارزیابی کرده و مومنتوم یک اوراق بهادار را نشان می‌دهد.

۴. Moving Average (10) این شاخص با استفاده از میانگین‌گیری ساده قیمت‌ها در طول ۱۰ دوره گذشته، داده‌های قیمتی را هموار کرده و به شناسایی روندها کمک می‌کند.

۵. Exponential Moving Average (10) این شاخص میانگین متحرکی است که بر قیمت‌های اخیر تأکید بیشتری دارد و در طول ۱۰ دوره دوره گذشته محاسبه می‌شود.

6. Yuan, Li, Wang, Yang & Gui

7. Yuan, Qi & Wang

8. Yuan, Wang, Yang & Gui

9. Cheng et al.


مرحله کدگشا، ویژگی پنهان h به منظور بازسازی بردار ورودی به لایه خروجی نگاشت می‌شود. داده‌های ورودی بازسازی شده $\hat{x}_i \in \{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_N\}$ که در آن $\hat{x} \in R^{d_x}$ است همان خروجی AE است. با استفاده از تابع فعال‌سازی g رابطه ریاضی لایه خروجی به صورت زیر بیان می‌شود (لیو، ونگ، ونگ و یوان^۱، ۲۰۲۱):

$$\hat{x} = g(w^d h + b^d) \tag{رابطه ۲}$$

در معادله بالا، $w^d \in R^{d_x \times d_h}$ و $b^d \in R^{d_x}$ به ترتیب نشان‌دهنده ماتریس وزنی و بردار بایاس کدگشا هستند. به منظور به دست آوردن یک نمایش ویژگی معنادار و کارآمد از داده‌های ورودی، از الگوریتم پس‌انتشار برای تخمین پارامترهای بهینه کدگذار با به حداقل رساندن میانگین مربعات خطا (MSE) به عنوان تابع هزینه استفاده می‌شود.

$$E(w^e, w^d, b^e, b^d) = \sum_{i=1}^N (x_i - \hat{x}_i)^2 / 2N \tag{رابطه ۳}$$

الگوریتم پس‌انتشار (BP)^۲ به کدگذار خودکار اجازه می‌دهد تا با تنظیم دقیق پارامترها در طول فرایند آموزش، ویژگی‌های مهم را از داده‌های ورودی یاد بگیرد (کین، یانگ، ژو، پو و مائو^۳، ۲۰۲۳).



شکل ۱. ساختار کدکننده خودکار (AE)

کدکننده خودکار نظارت‌شده (SAE)

هدف اولیه AE بازسازی داده‌های ورودی در لایه خروجی است، جایی که ویژگی‌های آموخته‌شده برای بازسازی داده‌های ورودی استفاده می‌شود. با این حال، روش بازسازی ورودی برای استخراج ویژگی‌ها در پیش‌بینی بازار سهام مناسب نیست. در بازار سهام، یادگیری ویژگی‌هایی که مستقیماً با قیمت پایانی سهام مرتبط هستند بسیار مهم است. متأسفانه، AE که یک مدل بدون نظارت است، نمی‌تواند ارتباط ویژگی‌های آموخته‌شده را با متغیر قیمت پایانی سهام تضمین کند. این مسئله می‌تواند منجر به یادگیری اطلاعات نامربوط شود که بر دقت پیش‌بینی قیمت پایانی سهام تأثیر منفی می‌گذارد. برای مقابله با این چالش، یک مدل یادگیری ویژگی مرتبط با قیمت پایانی سهام به نام کدکننده خودکار

1. Liu, Wang, Wang & Yuan
 2. Backpropagation algorithm
 3. Qin, Yang, Zhou, Pu & Mao

نظارت‌شده (SAE) طراحی شده است (یوان، گو، ونگ، یانگ و گوی^۱، ۲۰۱۹). شبکه SAE بر یادگیری ویژگی‌هایی متمرکز است که مستقیماً با قیمت پایانی سهام مرتبط هستند و در نتیجه اطلاعات نامربوط کاهش می‌یابد. با استفاده از شبکه SAE در فرایند پیش‌آموزش، این مدل به‌طور مؤثر ویژگی‌های مرتبط با قیمت پایانی سهام را استخراج کرده و در نتیجه دقت پیش‌بینی‌های بازار سهام را بهبود می‌بخشد (لوبرینگ، گباوئر، رامورتی، سیفا و باکاژ^۳، ۲۰۲۱). SAE نیز یک شبکه سه لایه است که از لایه‌های ورودی، پنهان و خروجی تشکیل شده است. با این حال، تمایز اصلی بین ساختارهای SAE و AE در لایه خروجی نهفته است. در SAE، لایه خروجی به‌جای بازسازی داده‌های ورودی، متغیر قیمت پایانی سهام را پیش‌بینی می‌کند. ساختار SAE در شکل ۲ مشاهده می‌شود. در این شکل، $x_i \in \{x_1, x_2, \dots, x_N\}$ ورودی خام که $x \in R^{d_x}$ ، $y_i \in \{y_1, y_2, \dots, y_N\}$ داده‌های قیمت پایانی سهام که $y \in R^{d_y}$ و $h_i \in \{h_1, h_2, \dots, h_N\}$ که $h \in R^{d_h}$ ویژگی‌های لایه پنهان هستند. با ماتریس وزن $w^e \in R^{d_h \times d_x}$ بردار بایاس $b^e \in R^{d_h}$ تابع فعال‌سازی ناخطی f بردار ویژگی به‌صورت زیر محاسبه می‌شود:

$$h = f(w^e x + b^e) \quad \text{رابطه ۴}$$

سپس ویژگی پنهان h ، متغیر قیمت پایانی سهام y را در لایه خروجی با استفاده از پارامترهای کدگشا پیش‌بینی می‌کند. خروجی یا متغیر قیمت پایانی سهام با ماتریس وزن $w^d \in R^{d_y \times d_h}$ بردار بایاس $b^d \in R^{d_y}$ و تابع فعال‌سازی g به‌صورت به‌دست می‌آید:

$$\hat{y} = g(w^d h + b^d) \quad \text{رابطه ۵}$$


در رابطه بالا \hat{y} متغیر قیمت پایانی سهام پیش‌بینی‌شده را نشان می‌دهد. برای یادگیری ویژگی‌های مربوط به قیمت پایانی سهام از داده‌های ورودی، لازم است مجموعه‌ای از پارامترهای کدگذار و کدگشا با استفاده از الگوریتم پس‌انتشار آموزش داده شوند. هدف این آموزش به حداقل رساندن خطای پیش‌بینی و به‌دست آوردن پارامترهای بهینه است (چنگ، هو، وو، ژو و شائو^۴، ۲۰۲۱). تابع هزینه MSE به‌صورت زیر تعریف می‌شود:

$$E(w^e, w^d, b^e, b^d) = \sum_{i=1}^N (y_i - \hat{y}_i)^2 / 2N \quad \text{رابطه ۶}$$

برای مقایسه SAE و AE، توجه به این نکته مهم است که AE یک مدل خودآموز بدون نظارت بوده، در حالی که SAE یک مدل نظارت‌شده است. هدف AE یادگیری نمایشی از ویژگی‌ها برای بازسازی داده‌های ورودی است، بدون اینکه به قیمت پایانی توجهی داشته باشد. در مقابل، SAE به این نکته اهمیت می‌دهد که چگونه این ویژگی‌ها می‌توانند قیمت پایانی را پیش‌بینی کنند. با استفاده از داده‌های قیمت پایانی به‌عنوان راهنما، SAE قادر است ویژگی‌های مرتبط با

1. supervised autoencoder
 2. Yuan, Gu, Wang, Yang & Gui
 3. Lübbering, Gebauer, Ramamurthy, Sifa & Bauckhage
 4. Cheng, Hu, Wu, Zhu & Shao

قیمت پایانی را از داده‌های ورودی استخراج کند. به همین دلیل، SAE در استخراج دقیق ویژگی‌های مفید برای پیش‌بینی قیمت پایانی مؤثرتر عمل می‌کند (دائونکا، تریپاتی و سینگ، ۲۰۲۲).



شکل ۲. ساختار کدکننده خودکار نظارت‌شده (SAE)

شبکه بازگشتی حافظه طولانی کوتاه مدت (LSTM)

معماری RNN معمولی شامل سلول‌های بازگشتی استاندارد، مانند سلول‌های سیگما و سلول‌های \tanh است. ساختار یک سلول سیگما بازگشتی استاندارد در شکل ۳ نشان داده شده است. معادلات ریاضی آن به شرح زیر است:

$$h_t = \sigma(w_h h_{t-1} + w_x x_t + b) \quad \text{رابطه ۷}$$

$$y_t = h_t \quad \text{رابطه ۸}$$

در معادلات بالا، x_t ، h_t و y_t به ترتیب ورودی، اطلاعات بازگشتی و خروجی سلول در زمان t را نشان می‌دهند. w_x و w_h وزن‌ها هستند و b بایاس است. اگرچه سلول‌های بازگشتی معمولی در برخی وظایف عملکرد خوبی دارند، اما شبکه‌های بازگشتی با این نوع سلول‌ها در مدیریت وابستگی‌های بلندمدت با محدودیت‌هایی مواجهند (موگر و همیچ، ۲۰۲۰). شبکه در یادگیری و حفظ ارتباطات دچار چالش می‌شود. برای حل مشکل وابستگی‌های طولانی‌مدت^۳، سلول LSTM معرفی شد. این سلول با اضافه کردن مکانیسم دروازه^۴ به ساختار خود، توانایی حافظه سلول‌های بازگشتی استاندارد را بهبود می‌بخشد (عباسی مهر، شعبانی و یوسفی، ۲۰۲۰). معماری LSTM با دروازه‌های ورودی^۵، فراموشی^۶ و خروجی^۷، در شکل ۴ نشان داده شده است. هر دروازه در این مدل شامل یک لایه شبکه عصبی سیگموئید و یک عملیات ضرب نقطه‌ای است. لایه سیگموئید مقادیری بین ۰ و ۱ تولید می‌کند که نشان می‌دهد چه مقدار از

1. Dhanuka, Tripathi & Singh
2. Moghar and Hamiche
3. Long-term dependencies
4. Gate
5. Abbasimehr, Shabani & Yousefi
6. input
7. forget
8. output

اطلاعات ورودی باید عبور کند. شایان ذکر است که در شرایط خاص، می‌توان با استفاده از یک پنجره بر روی یک سری زمانی بزرگتر، چندین سری زمانی به‌دست آورد. اگرچه LSTM قادر به پردازش انواع مختلف داده‌های سری زمانی است، اما عملکرد آن ممکن است بسته به ویژگی‌های داده‌های ورودی متفاوت باشد.

در LSTM داده‌های سری زمانی به‌عنوان دنباله‌ای از ورودی $\{x_1, x_2, \dots, x_t, \dots, x_T\}$ نشان داده می‌شوند که در آن، $x_t \in R^{d_x}$ یک بردار d_x بعدی در نمونه‌ی زمانی t است. ابتدا LSTM تعیین می‌کند که کدام اطلاعات قبلی x_t باید فراموش شود. خروجی دروازه‌ی فراموشی به‌صورت زیر محاسبه می‌شود:

$$f_t = \sigma(w_{fx}x_t + w_{fh}h_{t-1} + b_f) \quad \text{رابطه ۹}$$

در این فرایند $\{h_1, h_2, \dots, h_t, \dots, h_T\}$ خروجی سلول LSTM است که در آن، $h_t \in R^{d_h}$ و h_{t-1} به خروجی در حالت $t-1$ اشاره دارد. همچنین $\{w_{fx}, w_{fh}, b_f\}$ به‌ترتیب نشان دهنده‌ی ماتریس‌های وزن و بردار بایاس دروازه‌ی فراموشی است. سپس، اطلاعاتی که برای بروزرسانی سلول LSTM فعلی استفاده می‌شود، از طریق دروازه‌ی ورودی i_t انتخاب می‌شود. تعریف این دروازه به‌شکل زیر است (وانگ، سو و دینگ^۱، ۲۰۲۰):

$$i_t = \sigma(w_{ix}x_t + w_{ih}h_{t-1} + b_i) \quad \text{رابطه ۱۰}$$

که در آن، $\{w_{ix}, w_{ih}, b_i\}$ به‌ترتیب ماتریس‌های وزن و بایاس دروازه‌ی ورودی هستند. سپس، برداری از مقادیر جدید \tilde{c}_t که توسط یک لایه \tanh تولید شده است، به حالت داخلی سلول اضافه می‌شود:

$$\tilde{c}_t = \tanh(w_{\tilde{c}x}x_t + w_{\tilde{c}h}h_{t-1} + b_{\tilde{c}}) \quad \text{رابطه ۱۱}$$

که در آن، $\{w_{\tilde{c}x}, w_{\tilde{c}h}, b_{\tilde{c}}\}$ به‌ترتیب ماتریس‌های وزن و بایاس حالت سلول‌های حافظه^۲ هستند. پس از آن، وضعیت سلول قبلی، c_{t-1} در f_t ضرب می‌شود و سپس به $\tilde{c}_t \times i_t$ اضافه می‌شود، تا وضعیت سلول به‌روزرسانی شود. فرایند به‌روزرسانی وضعیت سلول c_t به‌صورت زیر بیان می‌شود:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad \text{رابطه ۱۲}$$

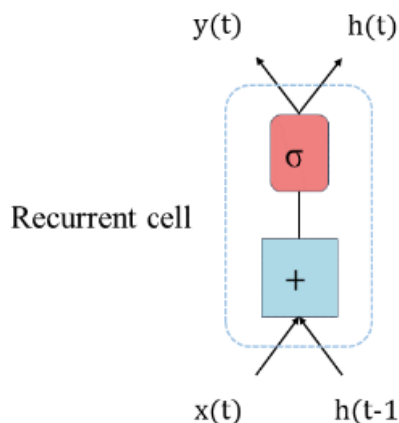
در نهایت، دروازه‌ی خروجی o_t ، که که تصمیم می‌گیرد چه داده‌ای به‌عنوان حالت پنهان خروجی^۳ h_t انتخاب شود، به‌صورت زیر نشان داده می‌شود:

$$o_t = \sigma(w_{ox}x_t + w_{oh}h_{t-1} + b_o) \quad \text{رابطه ۱۳}$$

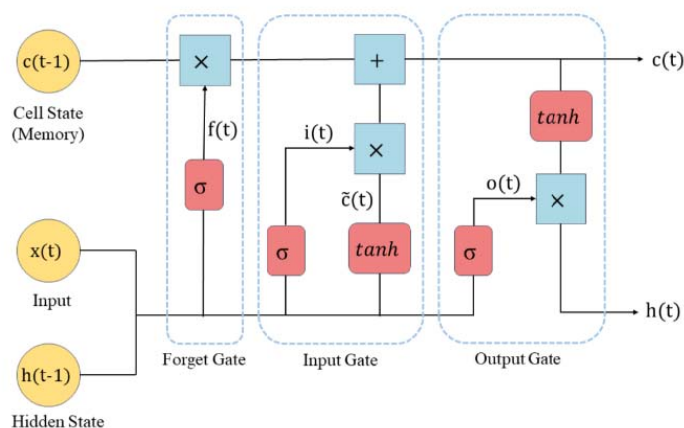
$$h_t = o_t \cdot \tanh(c_t) \quad \text{رابطه ۱۴}$$

1. Wang, Su & Ding
2. memory cell state
3. output hidden state

که در آن، $\{w_{ox}, w_{oh}, b_o\}$ به ترتیب ماتریس وزن و بایاس دروازه‌های خروجی هستند (وان، چانگ، خلیل و هی، ۲۰۲۳).



شکل ۳. ساختار یک سلول سیگما بازگشتی استاندارد



شکل ۴. ساختار شبکه حافظه طولانی کوتاه مدت (LSTM)

روش پیشنهادی: کدکننده خودکار LSTM نظارت‌شده پشته‌ای (SLSAE)

دقت پیش‌بینی قیمت پایانی سهام به‌شدت به کیفیت ویژگی‌های استخراج‌شده از داده‌های ورودی بستگی دارد. در حالی که یادگیری ویژگی‌های مرتبط با متغیرهای قیمت پایانی اهمیت دارد، AE‌های معمولی بدون نظارت تنها به بازسازی ورودی‌های خود تمرکز دارند و نمی‌توانند تضمین کنند که ویژگی‌های استخراج‌شده به‌طور مستقیم با متغیرهای قیمت

پایانی مرتبط هستند. در زمینه بازار سهام، SAE می‌تواند دقت پیش‌بینی قیمت پایانی را با یادگیری ویژگی‌هایی که ارتباط نزدیکی با متغیرهای قیمت پایانی دارند، بهبود بخشد. با این حال، SAE‌های مبتنی بر نورون‌های سنتی ممکن است در یادگیری الگوها از داده‌های سری زمانی با توالی‌های طولانی دچار مشکل شوند، زیرا این شبکه‌ها نیز از مشکل گرادیان نزولی رنج می‌برند (نام، جئونگ و پارک^۱، ۲۰۲۰). برای رفع این محدودیت‌ها، ترکیب سلول‌های LSTM در ساختار شبکه SAE بهبود قابل توجهی در عملکرد پیش‌بینی ایجاد کرده است. با این حال، LSAE^۲ که تنها یک لایه پنهان دارد و ساختاری کم‌عمق است، ممکن است در استخراج ویژگی‌های سلسله‌مراتبی از داده‌های بزرگ و پیچیده با ابعاد بالا با محدودیت‌هایی مواجه شود (نگوین، تران، توماسی و حمد^۳، ۲۰۲۱). برای مقابله با این مشکل، تکنیک‌های یادگیری عمیق نظارت‌شده پشته‌ای^۴ استفاده می‌کنند که ظرفیت پیش‌بینی قیمت پایانی را به‌طور قابل توجهی افزایش می‌دهد. شبکه SLSAE^۵ از یک رویکرد پیش‌آموزشی لایه‌به‌لایه^۶ پیروی می‌کند، به این معنی که هر لایه از لایه‌های پایین‌تر به لایه‌های بالاتر به‌صورت پیش‌آموزش داده می‌شود. برخلاف AE‌های پشته‌ای که از روش خودآموزی بدون نظارت استفاده می‌کند، SLSAE از روش یادگیری نظارت‌شده برای استخراج ویژگی‌های مرتبط با قیمت پایانی به‌صورت سلسله‌مراتبی بهره می‌برد. هدف SLSAE این است که اطمینان حاصل کند ویژگی‌های آموخته‌شده قادر به پیش‌بینی دقیق داده‌های قیمت پایانی هستند. با انباشتن چندین مدل LSAE، اطلاعات نامربوط با قیمت پایانی حذف شده و فرایند یادگیری توسط داده‌های بازگشتی در هر لایه هدایت می‌شود. بنابراین، این مقاله مفهوم LSAE انباشته را برای پیش‌بینی بازار سهام معرفی می‌کند و در بخش‌های بعدی به شرح مفصل مراحل پیش‌بینی خواهد پرداخت.

کدکننده خودکار LSTM نظارت‌شده (LSAE)

برای بهره‌برداری از مزایای مدل SAE و سلول LSTM، این پژوهش پیشنهاد می‌کند که مدل SAE با سلول‌های LSTM ترکیب شود. در این ترکیب، سلول‌های LSTM با نورون‌های معمولی در بخش‌های کدگذار جایگزین می‌شوند. ساختار LSAE در شکل ۵ نشان داده شده است. در این شبکه خاص، در مرحله کدگذاری، بردار ورودی x_t و ویژگی‌های پنهان دینامیکی در زمان قبلی یا h_{t-1} به LSTM وارد می‌شوند تا h_t استخراج شود (رابطه ۱۴). سپس ویژگی‌های پنهان دینامیکی h_{t-1} و بردار خروجی LSTM در زمان قبلی \hat{y}_{t-1} به‌طور مستقیم به‌عنوان ورودی برای نرون خطی در کدگشا مورد استفاده قرار می‌گیرند تا بردار خروجی LSTM، \hat{y}_t پیش‌بینی شود که به‌صورت زیر محاسبه می‌شود:

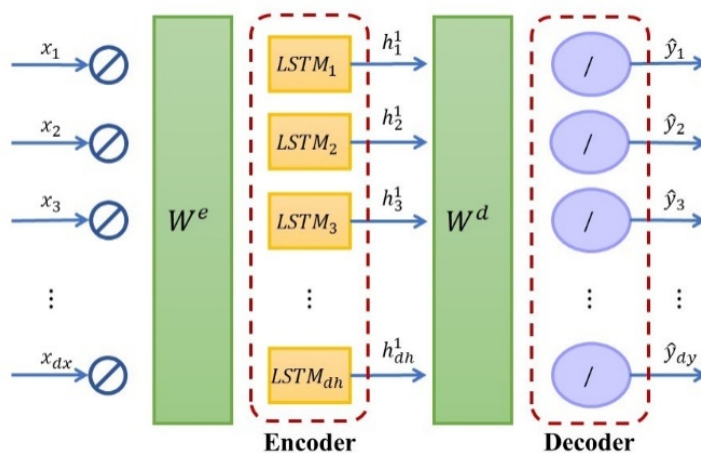
$$\hat{y}_t = g(w^d h_t + b^d) \quad (\text{رابطه ۱۵})$$

1. Nam, Jeong & Park
2. LSTM supervised Autoencoder
3. Nguyen, Tran, Thomassey & Hamad
4. stack
5. Stacked LSTM Supervised Autoencoder
6. a layer wise

در معادله بالا w^d و b^d به ترتیب ماتریس وزن و بردار بایاس کدگشا هستند. الگوریتم‌های پس‌انتشار برای آموزش LSAE و بهینه‌سازی پارامترهای با کمینه‌کردن خطای پیش‌بینی در تعداد T نمونه آموزشی، مورد استفاده قرار می‌گیرند (سومیا و سینگ، ۲۰۲۲).

$$J(w^e, b^e, w^d, b^d) = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2 \quad \text{رابطه ۱۶}$$

جایی که $w^e = \{w_{fx}, w_{fh}, w_{ix}, w_{ih}, w_{cx}, w_{ch}, w_{ox}, w_{oh}\}$ و $b^e = \{b_f, b_i, b_c, b_o\}$ هستند.

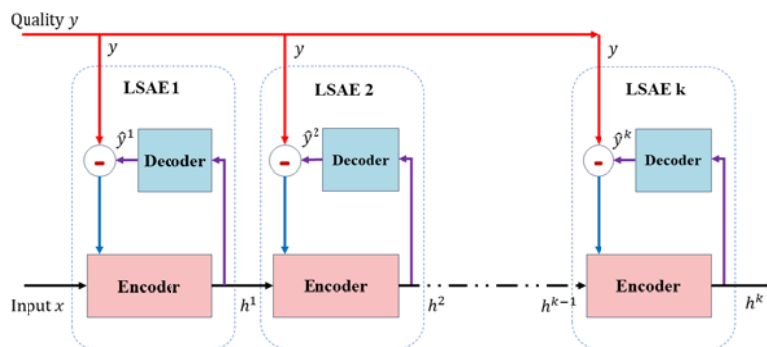


شکل ۵. ساختار LSAE

کدکننده خودکار نظارت‌شده پشته‌ای برای سهام

به‌منظور ایجاد یک شبکه یادگیری نظارت‌شده عمیق برای نمایش ویژگی‌های مرتبط با قیمت پایانی، می‌توان چندین مدل LSAE را به‌صورت سلسله‌مراتبی پشت هم قرار داد. نمودار شماتیک شبکه پشته‌ای SLSAE در شکل ۶ ارائه شده است. در ادامه مراحل فرایند ساختار شبکه SLSAE بیان می‌شود. ابتدا، برای طراحی LSAE1، داده‌های ورودی x_t به اولین لایه پنهان h_t^1 نگاشت می‌شود، سپس برای پیش‌آموزش LSAE1 از پیش‌آموزش دیده، از الگوریتم BP برای به حداقل رساندن خطای پیش‌بینی داده‌های قیمت پایانی y_t و مقدار قیمت پایانی پیش‌بینی شده \hat{y}_t^1 استفاده می‌شود که تابع هزینه آن برابر با $\sum_{t=1}^T (y_t - \hat{y}_t^1)^2$ است. همچنین، ویژگی‌های به‌دست آمده h_t^1 ، وزن‌های بهینه $\{w_{f*}^1, w_{i*}^1, w_{o*}^1, w_{c*}^1\}$ و بایاس‌ها $\{b_f^1, b_i^1, b_o^1, b_c^1\}$ در بخش کدگذار در کل شبکه SLSAE حفظ می‌ماند. پس از آن، h_t^1 به‌عنوان ورودی برای LSAE2 استخراج می‌شود. سپس، LSAE2 ساخته و پیش‌آموزش داده می‌شود. برای رسیدن به این هدف، خطای پیش‌بینی بین داده‌های CP واقعی y_t و مقادیر قیمت پایانی پیش‌بینی شده \hat{y}_t^2 تابع هزینه $\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t^2)^2$ کمینه می‌شود. پس از آن، ویژگی‌های استخراج شده h_t^2 ، وزن‌های $\{w_{f*}^2, w_{i*}^2, w_{o*}^2, w_{c*}^2\}$

بایاس‌ها $\{b_f^2, b_i^2, b_o^2, b_c^2\}$ در بخش کدگذار و نیز در کل شبکه SLSAE حفظ می‌ماند. به‌طور مشابه، مدل‌های LSAEK باقی‌مانده را می‌توان به‌صورت متوالی و یک به یک از پیش آموزش داد تا زمانی که Kامین ویژگی SLSAE یعنی h_t^K ، وزن‌های $\{w_{f*}^K, w_{i*}^K, w_{o*}^K, w_{c*}^K\}$ و بایاس‌ها $\{b_f^K, b_i^K, b_o^K, b_c^K\}$ به‌دست می‌آیند. SLSAE این قابلیت را دارد که ویژگی‌های عمیق مرتبط با قیمت پایانی را از داده‌های ورودی با ابعاد بالا استخراج کند. ویژگی‌های عمیق شامل اطلاعات مهمی از داده‌های قیمت پایانی است که به پیش‌بینی رگرسیون در بازار سهام کمک می‌کند. برای پیش‌بینی متغیر قیمت پایانی، یک مدل پیش‌بینی مانند یک شبکه سه لایه به لایه بالایی SLSAE اضافه شود. در این مرحله، تمام پارامترهای شبکه جدید با وزن‌ها و بایاس‌های حفظ‌شده مقداردهی اولیه می‌شوند، سپس با استفاده از الگوریتم BP، تنظیم دقیق برای تنظیم کل پارامترهای SLSAE انجام می‌شود. پس از به‌دست آوردن پارامترهای بهینه، داده‌های نمونه آزمایشی به‌عنوان ورودی در SLSAE آموزش‌دیده استفاده می‌شود و ویژگی‌های عمیق مرتبط با قیمت پایانی با انتشار رو به جلو^۱ محاسبه به‌دست می‌آیند. در نهایت، متغیرهای قیمت پایانی برای نمونه‌های آزمایشی با استفاده از ویژگی‌های عمیق استخراج‌شده پیش‌بینی می‌شوند (لیو و همکاران^۲، ۲۰۲۲).



شکل ۶. نمودار شماییک شبکه LSAE پشته‌ای (SLSAE)

یافته‌های پژوهش

در این بخش، برای انجام یک مقایسه جامع، از پنج مدل پیش‌بینی مختلف شامل SLSAE، LSTM، ANN و ARIMA استفاده می‌کنیم. برای ارزیابی دقت پیش‌بینی هر مدل، چهار معیار اصلی را در نظر می‌گیریم: ریشه میانگین مربعات خطا (RMSE)^۳، ضریب تعیین (R^2)^۴، میانگین مربعات خطا (MSE)^۵ و میانگین خطای مطلق (MAE)^۶ (گاندمال و کومار^۷، ۲۰۱۹).

1. forward propagation
2. Liu et al.
3. Root-mean-square error
4. Coefficient of determination
5. Mean-square error
6. Mean absolute error
7. Gandhmal and Kumar

جدول ۲. مقایسه عملکردهای پیش‌بینی قیمت پایانی سهام منتخب با معیارهای R^2 و RMSE

SLSAE		LSAE		LSTM		ANN		ARIMA		سهام
R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	
۰/۹۷۱۴	۰/۰۲۲۱	۰/۸۹۴۴	۰/۰۴۲۹	۰/۸۵۴۲	۰/۰۵۳۹	۰/۸۳۸۲	۰/۰۶۰۱	۰/۷۸۸۵	۰/۰۶۴۲	خگستر
۰/۹۸۰۹	۰/۰۲۱۷	۰/۹۷۲۴	۰/۰۲۹۰	۰/۹۵۴۲	۰/۰۳۸۶	۰/۹۲۵۴	۰/۰۵۹۱	۰/۷۹۵۸	۰/۰۶۲۰	خودرو
۰/۹۶۹۴	۰/۰۳۰۸	۰/۸۷۶۲	۰/۰۴۲۳	۰/۸۱۹۹	۰/۰۵۴۸	۰/۷۹۱۳	۰/۰۵۸۶	۰/۷۵۹۹	۰/۰۷۱۳	وغدیر
۰/۹۸۷۱	۰/۰۲۳۴	۰/۹۶۵۳	۰/۰۳۲۷	۰/۹۴۲۹	۰/۰۴۱۲	۰/۸۶۹۰	۰/۰۵۷۵	۰/۷۸۸۰	۰/۰۶۵۷	فملی
۰/۹۹۳۸	۰/۰۱۵۹	۰/۹۷۶۲	۰/۰۲۲۶	۰/۹۴۰۱	۰/۰۳۸۴	۰/۹۲۵۴	۰/۰۴۱۸	۰/۹۰۰۴	۰/۰۵۴۳	پارسان
۰/۹۸۱۶	۰/۰۲۸۱	۰/۹۶۴۳	۰/۰۳۶۹	۰/۹۴۴۱	۰/۰۴۵۷	۰/۹۰۱۵	۰/۰۶۲۳	۰/۸۷۹۵	۰/۰۷۰۴	کگل
۰/۹۷۴۷	۰/۰۲۴۷	۰/۸۹۶۲	۰/۰۴۳۴	۰/۸۷۵۵	۰/۰۵۸۹	۰/۸۴۱۱	۰/۰۶۴۸	۰/۸۴۱۱	۰/۰۶۴۸	شپاکسا
۰/۹۸۶۵	۰/۰۱۹۳	۰/۹۱۳۳	۰/۰۳۳۸	۰/۸۴۴۲	۰/۰۵۱۴	۰/۸۳۴۷	۰/۰۵۸۵	۰/۷۸۹۶	۰/۰۶۹۳	ستران
۰/۹۷۷۲	۰/۰۲۰۵	۰/۹۱۶۷	۰/۰۳۰۳	۰/۸۶۴۴	۰/۰۴۸۸	۰/۸۳۷۱	۰/۰۵۳۱	۰/۸۰۵۷	۰/۰۵۹۲	وبشهر
۰/۹۸۳۷	۰/۰۲۶۸	۰/۹۶۶۷	۰/۰۳۴۱	۰/۹۴۸۴	۰/۰۴۳۲	۰/۹۱۰۲	۰/۰۵۶۴	۰/۸۸۹۱	۰/۰۶۷۰	اخابر

جدول ۳. مقایسه عملکردهای پیش‌بینی قیمت پایانی سهام منتخب با معیارهای MAE و MSE

SLSAE		LSAE		LSTM		ANN		ARIMA		سهام
MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	
۰/۰۱۷۷	۰/۰۰۰۵	۰/۰۳۴۳	۰/۰۰۱۸	۰/۰۴۳۱	۰/۰۰۲۹	۰/۰۴۸۱	۰/۰۰۳۶	۰/۰۵۱۴	۰/۰۰۴۱	خگستر
۰/۰۱۷۴	۰/۰۰۰۵	۰/۰۲۳۲	۰/۰۰۰۸	۰/۰۳۰۹	۰/۰۰۱۵	۰/۰۴۷۳	۰/۰۰۳۵	۰/۰۴۹۶	۰/۰۰۳۸	خودرو
۰/۰۲۴۶	۰/۰۰۰۹	۰/۰۳۳۸	۰/۰۰۱۸	۰/۰۴۳۸	۰/۰۰۳۰	۰/۰۴۶۹	۰/۰۰۳۳	۰/۰۵۷۰	۰/۰۰۵۱	وغدیر
۰/۰۱۸۷	۰/۰۰۰۵	۰/۰۲۶۲	۰/۰۰۱۱	۰/۰۳۳۰	۰/۰۰۱۷	۰/۰۴۶۰	۰/۰۰۱۷	۰/۰۵۲۶	۰/۰۰۴۳	فملی
۰/۰۱۲۷	۰/۰۰۰۳	۰/۰۱۸۱	۰/۰۰۰۵	۰/۰۳۰۷	۰/۰۰۱۵	۰/۰۳۳۴	۰/۰۰۳۹	۰/۰۴۳۴	۰/۰۰۲۹	پارسان
۰/۰۲۲۵	۰/۰۰۰۸	۰/۰۲۹۵	۰/۰۰۱۴	۰/۰۳۶۶	۰/۰۰۲۱	۰/۰۴۹۸	۰/۰۰۳۹	۰/۰۵۶۳	۰/۰۰۵۰	کگل
۰/۰۱۹۸	۰/۰۰۰۶	۰/۰۳۴۷	۰/۰۰۱۹	۰/۰۴۷۱	۰/۰۰۳۵	۰/۰۵۱۸	۰/۰۰۳۹	۰/۰۵۱۸	۰/۰۰۴۲	شپاکسا
۰/۰۱۵۴	۰/۰۰۰۴	۰/۰۲۷۰	۰/۰۰۱۱	۰/۰۴۱۱	۰/۰۰۱۶	۰/۰۴۶۸	۰/۰۰۳۴	۰/۰۵۵۴	۰/۰۰۴۸	ستران
۰/۰۱۶۴	۰/۰۰۰۴	۰/۰۲۴۲	۰/۰۰۰۹	۰/۰۳۹۰	۰/۰۰۲۴	۰/۰۴۲۵	۰/۰۰۲۸	۰/۰۴۷۴	۰/۰۰۳۵	وبشهر
۰/۰۲۱۴	۰/۰۰۰۷	۰/۰۲۷۳	۰/۰۰۱۲	۰/۰۳۴۶	۰/۰۰۱۹	۰/۰۴۵۱	۰/۰۰۳۲	۰/۰۵۳۶	۰/۰۰۴۵	اخابر

در مقایسه روش‌های مختلف برای پیش‌بینی قیمت پایانی سهام، عملکرد مدل‌های مختلف بر اساس معیارهای خطای R^2 و RMSE در جدول ۲ و همچنین MAE و MSE در جدول ۳ مورد ارزیابی قرار گرفته است. نتایج نشان

می‌دهند که مدل‌های پیچیده‌تر و مبتنی بر شبکه‌های عصبی عمیق، به‌ویژه SLSAE و LSAE، دقت بالاتری نسبت به مدل‌های ساده‌تر مثل ARIMA و ANN دارند. در ادامه، هر یک از مدل‌ها و دلایل عملکرد آن‌ها بررسی شده است. در تمام سهام‌ها، SLSAE بهترین نتایج در دقت پیش‌بینی را در معیارهای مختلف به‌دست آورده است. این مدل کمترین مقادیر RMSE، MSE و MAE و همچنین بالاترین مقادیر R^2 را ارائه می‌دهد. دلیل این عملکرد برتر، استفاده از معماری نظارت‌شده چندلایه است که امکان شناسایی الگوهای پیچیده و ناخطی در داده‌های سری زمانی را فراهم می‌کند. این ویژگی‌ها باعث شده است که این مدل در شناسایی و پیش‌بینی جزئیات دقیق قیمت پایانی سهام بسیار موفق عمل کند. مدل LSTM نیز توانسته است نتایج بسیار خوبی به‌ویژه در کاهش خطای پیش‌بینی به‌دست آورد. در اکثر سهام‌ها، LSAE نتایج نزدیک به SLSAE دارد، اما اندکی دقت پایین‌تری نسبت به آن مشاهده می‌شود. این تفاوت به دلیل عدم وجود لایه‌های پشته‌ای است که در SLSAE موجود است و باعث می‌شود این مدل عمق بیشتری در شناسایی الگوها داشته باشد. به هر حال، LSAE با استفاده از LSTM در کدکننده خودکار نظارت‌شده کمک کرده تا ساختارهای مهم داده‌ها را شناسایی شود و خطای پیش‌بینی را به میزان قابل‌توجهی کاهش دهد. در مقایسه با SLSAE و LSAE، مدل LSTM به دلیل نبود کدکننده خودکار نتوانسته به‌خوبی الگوهای پنهان و جزئیات پیچیده داده‌ها را درک کند. نتایج آن نشان می‌دهند که هرچند قادر به کاهش RMSE و MSE نسبت به مدل‌های خطی و ساده‌تر است؛ اما MAE بالاتری نسبت به SLSAE و LSAE دارد. همچنین، این نتایج نشان می‌دهد که LSTM توانسته روابط زمانی را به‌خوبی شناسایی کند اما از نظر عمق و دقت در تشخیص الگوهای پیچیده از مدل‌های ترکیبی ضعیف‌تر است. در مقایسه با مدل‌های مبتنی بر LSTM، ANN نتایج ضعیف‌تری دارد. این مدل مقادیر بالاتری از RMSE، MSE و MAE را نشان می‌دهد که نشان می‌دهد در شناسایی جزئیات پیچیده داده‌ها محدودیت دارد. فقدان حافظه و امکان شناسایی الگوهای زمانی باعث شده که دقت ANN به‌ویژه در معیار R^2 پایین‌تر باشد. هرچند ANN بهتر از ARIMA عمل کرده است؛ اما در پیش‌بینی داده‌های پیچیده مانند قیمت سهام به‌خوبی مدل‌های پیچیده‌تر عمل نمی‌کند. ARIMA در تمامی معیارها، بالاترین مقادیر خطا RMSE و MAE و پایین‌ترین مقادیر دقت (R^2) را دارد. این مدل به دلیل خطی بودن و عدم توانایی در شناسایی الگوهای ناخطی موجود در داده‌های سری زمانی سهام، نتوانسته است دقت مطلوبی ارائه دهد. نتایج نشان می‌دهد که ARIMA برای داده‌های پیچیده و دارای الگوهای ناخطی مناسب نیست و نمی‌تواند به اندازه مدل‌های مبتنی بر شبکه‌های عصبی عمیق به جزئیات و پیچیدگی‌های داده‌ها پاسخ دهد.


برای ارزیابی دقت پیش‌بینی مدل‌های مختلف در مقایسه با یکدیگر، از آزمون DM Test¹ استفاده می‌کنیم. این آزمون یکی از روش‌های آماری معتبر برای سنجش تفاوت میان دقت پیش‌بینی دو مدل در طول یک بازه زمانی است و بر پایه ارزیابی خطاهای پیش‌بینی، می‌تواند نشان دهد که آیا تفاوت میان این دو مدل از نظر آماری معنادار است یا خیر. آزمون DM در شرایطی به کار می‌رود که دو مدل متفاوت برای پیش‌بینی یک سری زمانی استفاده شده باشند و ما بخواهیم بدانیم کدام مدل عملکرد بهتری دارد. در این آزمون، ابتدا اختلاف میان خطاهای پیش‌بینی هر دو مدل را

1. Diebold-Mariano Test


محاسبه می‌کنیم. سپس میانگین و واریانس این اختلافات برای مقایسه مدل‌ها استفاده می‌شوند. با استفاده از آماره DM که نشانگر تفاوت میان خطاهای دو مدل است، میزان معناداری آماری تفاوت عملکرد آن‌ها ارزیابی می‌شود. در نهایت، با مقایسه آماره آزمون DM با مقدار بحرانی، می‌توان به این نتیجه رسید که آیا یکی از مدل‌ها به‌طور معناداری عملکرد بهتری نسبت به دیگری دارد یا خیر.

در این مقاله، پنج مدل مختلف برای پیش‌بینی قیمت پایانی سهام مورد بررسی قرار گرفته‌اند: ANN، ARIMA، LSTM، LSAAE و SLSAAE. برای سنجش دقت پیش‌بینی مدل‌ها از دو معیار MSE و MAE استفاده شده و سپس با استفاده از آزمون DM، تفاوت‌های آماری بین مدل‌ها بررسی شده است. بر اساس نتایج آزمون DM، مشخص شد که مدل SLSAAE در مقایسه با سایر مدل‌ها، بهترین دقت پیش‌بینی را دارد و اختلاف عملکرد آن با سایر مدل‌ها از نظر آماری معنادار است. پس از مدل SLSAAE، مدل LSAAE به‌عنوان مدل دوم با دقت بالا قرار می‌گیرد، سپس مدل‌های LSTM و ANN به‌ترتیب در جایگاه‌های بعدی هستند. مدل ARIMA در رتبه آخر قرار می‌گیرد که نشان می‌دهد در مقایسه با سایر روش‌ها، دقت پیش‌بینی کمتری دارد. به‌طور کلی، آزمون DM تأیید می‌کند که مدل‌های مبتنی بر شبکه‌های عصبی و الگوریتم‌های پیشرفته‌تر مانند LSAAE و SLSAAE دقت پیش‌بینی بالاتری نسبت به مدل‌های کلاسیک دارند. به‌عبارت دیگر، مدل SLSAAE نه‌تنها از نظر معیارهای آماری بلکه از نظر عملی نیز به‌عنوان بهترین مدل برای پیش‌بینی قیمت پایانی سهام در این تحقیق شناسایی شده است. بنابراین، در راستای اهداف این مقاله، نتایج آزمون DM تأیید می‌کند که مدل SLSAAE به‌دلیل استفاده از معماری پیچیده‌تر و داده‌های عمیق‌تر، توانایی بالاتری در پیش‌بینی صحیح قیمت‌ها دارد.


برای ارائه یک تصویر واضح‌تر، نتایج دقت پیش‌بینی و همچنین منحنی‌های خطای دقت پیش‌بینی روش SLSAAE بر روی مجموعه داده آزمایش برای ۱۰ سهام در شکل‌های ۷ تا ۱۶ به‌صورت ردیف‌های الف و ب نشان داده شده است. همان‌طور که مشاهده می‌شود، در تمام سهام پیش‌بینی قیمت پایانی مطابقت نسبتاً خوبی با روند قیمت پایانی داشته و استفاده از تکنیک‌های یادگیری عمیق، به‌ویژه SLSAAE، در به حداقل رساندن انحرافات برای نمونه‌های آزمایشی متعدد، اثر بخش است. در واقع، هنگامی که شبکه SLSAAE ساخته می‌شود، ویژگی‌های عمیق مرتبط با قیمت پایانی را برای پیش‌بینی محتوای قیمت پایانی یاد می‌گیرد و در نتیجه خط پیش‌بینی شده با منحنی قیمت پایانی همسو می‌شود. علاوه‌بر این، شکل‌های ردیف (ب) منحنی‌های خطای پیش‌بینی دقیق را برای ۱۰ سهام در روش SLSAAE در مجموعه داده‌های آزمایشی نشان می‌دهند. با مقایسه منحنی‌های خطی پیش‌بینی دقیق روش SLSAAE، آشکار می‌شود که خطاهای پیش‌بینی حول صفر هستند. علاوه‌بر این، دامنه خطا در روش SLSAAE به‌طور کلی کمتر از سه روش دیگر در نقاط نمونه متعدد است. در نتیجه، مدل SLSAAE از نظر دقت از سایر روش‌های پایه برتری دارد.




شکل ۷. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام خگستر




شکل ۸. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام خودرو




شکل ۹. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام و غدیر




شکل ۱۰. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام فملی




شکل ۱۱. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام پارسان




شکل ۱۲. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام کگل




شکل ۱۳. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام شپاکسا



شکل ۱۴. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام ستران



شکل ۱۵. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام وبشهر



شکل ۱۶. نتایج پیش‌بینی (شکل الف) و خطاهای پیش‌بینی (شکل ب) به‌روش SLSAE در سهام‌آخابر

نتیجه‌گیری و پیشنهادها

پیش‌بینی بازار سهام، به‌دلیل ناخطی بودن ذاتی موجود در داده‌های ورودی، چالش مهمی را ایجاد می‌کند؛ بنابراین، یک مدل پیش‌بینی دقیق برای پیش‌بینی رفتار آتی بازار سهام مورد نیاز است. روش‌های یادگیری عمیق برای این کار مناسب هستند، به‌ویژه زمانی که با متغیرهای ورودی متنوعی سروکار داریم که بر قیمت پایانی تأثیر می‌گذارند. هنگامی که چنین متغیرهای متنوعی به‌عنوان ورودی ارائه می‌شوند، تکنیک‌های یادگیری عمیق عملکرد برتری را نشان می‌دهند. برای افزایش دقت پیش‌بینی بازار سهام، ما از معماری یادگیری عمیق متشکل از SAE، LSAE و ترکیبی به‌نام SLSAE استفاده کردیم.

در این مقاله، یک چارچوب یادگیری نظارت‌شده عمیق جدید برای یادگیری ویژگی‌های عمیق مرتبط با قیمت پایانی، بر اساس شبکه SAE پیشنهاد دادیم. برخلاف شبکه‌های عمیق موجود که به‌طور عمده بر یادگیری ویژگی‌های نظارت‌نشده برای استخراج ویژگی‌های مفید از داده‌های ورودی خام تمرکز می‌کنند، این رویکرد نیاز به ساخت یک مدل رگرسیون را که به‌طور خاص برای پیش‌بینی قیمت پایانی طراحی شده است، تشخیص می‌دهد. با این حال، روش SLSAE قادر است که ویژگی‌های عمیق مرتبط با قیمت پایانی را به‌طور مستقیم از داده‌های ورودی خام یاد بگیرد. این روش ساختار سلسله‌مراتبی‌ای را به‌کار می‌گیرد که در آن، ویژگی‌های مرتبط با قیمت پایانی سطح بالا از طریق ساخت چندین مدل SAE از نمونه‌های سطح پایین قبلی آموخته می‌شود. هر مدل SAE تضمین می‌کند که ویژگی‌های آموخته‌شده به‌طور شایان توجهی به پیش‌بینی داده‌های قیمت در لایه خروجی کمک می‌کند. در نتیجه، ویژگی‌های مرتبط با قیمت پایانی به‌تدریج آموخته می‌شوند، در حالی که اطلاعات نامربوط به‌تدریج از طریق انباشته شدن سلسله‌مراتبی مدل‌های SAE کاهش می‌یابد. در این مطالعه، روش پیشنهادی خود را با روش پیش‌بینی رایج در اقتصادسنجی ARIMA مقایسه کردیم. برای اعتبارسنجی اثربخشی و برتری SLSAE، یک مثال عددی با استفاده از داده‌های ۱۰ سهام در بورس اوراق بهادار تهران، در یک دوره بیش از ۱۰ سال (از ۱۳۹۱ تا ۱۴۰۲) انجام دادیم. از طریق مقایسه جامع با مدل‌های پیش‌بینی‌ای که قبلاً اجرا شده است، مشخص شد که نتایج این پژوهش کارایی SLSAE را از

نظر معیارهای مختلف عملکرد نشان می‌دهد. این مدل از LSAE و SAE چندلایه و همچنین ARIMA عملکرد بهتری دارد و برتری آن را در پیش‌بینی بازار سهام برجسته می‌کند. این پژوهش علی‌رغم ارائه یک مدل نوآورانه برای پیش‌بینی قیمت سهام، با چندین محدودیت مواجه است. نخست، داده‌های مورد استفاده تنها به بازار سهام ایران (بورس اوراق بهادار تهران) محدود شده که ممکن است، به دلیل ویژگی‌های خاص این بازار، نتایج به دست آمده را به سایر بازارهای سهام با ساختارها و پویایی‌های متفاوت تعمیم‌پذیر نسازد. همچنین، استفاده از داده‌های تاریخی طی یک دوره ده‌ساله (۱۳۹۱ تا ۱۴۰۲)، ممکن است به دلیل نوسان‌های اقتصادی و سیاسی خاص این دوره، بر نتایج تأثیر بگذارد. برای تحقیقات آتی، گسترش مدل به سایر بازارهای سهام جهانی و استفاده از داده‌های طولانی‌تر و متنوع‌تر، می‌تواند به ارزیابی بهتر کارایی مدل کمک کند. همچنین، استفاده از ترکیب مدل‌های یادگیری عمیق با دیگر روش‌های مدرن، همچون یادگیری تقویتی و بررسی تأثیر داده‌های جایگزین مانند احساسات بازار یا اخبار اقتصادی، می‌تواند مسیرهای جدیدی را برای بهبود پیش‌بینی‌ها فراهم سازد.

منابع

- اصولیان، محمد؛ نیک مرام، علی و کریمی، مهدی (۱۴۰۴). پیش‌بینی روند شاخص کل با استفاده از شبکه‌های عصبی هیبریدی با تمرکز بر استخراج ویژگی مقیاس زمانی چندگانه در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۷(۱)، ۸۵-۱۱۳.
- افشاری راد، الهام؛ علوی، سید عنایت اله و سینایی، حسنعلی (۱۳۹۷). مدلی هوشمند برای پیش‌بینی روند سهام با استفاده از روش‌های تحلیل تکنیکال. *تحقیقات مالی*، ۲۰(۲)، ۲۴۹-۲۶۴.
- ایزدی، مریم؛ آشتاب، علی و زواری رضایی، اکبر (۱۴۰۴). بررسی و تطبیق قدرت تخمین مدل‌های یادگیری ماشین و مدل‌های آماری در پیش‌بینی جهت تغییرات اجزای سود و انتخاب مدل بهینه. *تحقیقات مالی*، ۲۷(۱)، ۳۱-۵۷.
- ترابی‌پور، طوبی و سیادت، سیده صفیه (۱۴۰۱). روشی جهت پیش‌بینی قیمت سهام بازار بورس تهران مبتنی بر یادگیری عمیق. *نشریه علمی پدافند الکترونیکی و سایبری، مجله علمی و پژوهشی دانشگاه تهران*، ۱۰(۴)، ۹۱-۱۰۰.
- حیدری، مهدی و امیری، حمیدرضا (۱۴۰۱). بررسی قدرت مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی روند قیمت سهام بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۴(۴)، ۶۰۲-۶۲۳.
- رجبی، مهسا و خالوزاده، حمید (۱۴۰۲). رویکردهای نوین در مدل‌سازی و پیش‌بینی بازارهای مالی: پیشرفت‌های اخیر و افق‌های آینده. *مجله کنترل*، ۱۷(۲)، ۱۴۹-۱۶۳.
- زکایی، شهره؛ ثنائی، محمدرضا و میرزاپور باباجان، اکبر (۱۴۰۳). مدل هوشمند پیش‌بینی قیمت سهام مبتنی بر یادگیری عمیق: با رویکرد کاهش ابعاد. *مدیریت بازاریابی هوشمند*، ۵(۳)، ۲۹۹-۳۲۴.
- سعیدی اقدم، مهران؛ صادقی، احمد؛ بحیرایی، علیرضا و حاجی اصغری، سید یوسف (۱۴۰۱). ارائه مدل پیش‌بینی قیمت سهام با استفاده از الگوریتم‌های یادگیری عمیق و کاربرد آن در قیمت‌گذاری سهام بانک‌های اسلامی. *نشریه اقتصاد و بانکداری اسلامی*، ۱۱(۴۱)، ۱۱۷-۱۳۴.

- سهرابی، مریم؛ میربرگ کار، سید مظفر؛ چیرانی، ابراهیم و خریدار، سینا (۱۴۰۱). مدل سازی پیش بینی جهش های شاخص بازار سهام بر اساس رویکرد شبکه عصبی بازگشتی یادگیری عمیق. *نشریه بورس اوراق بهادار*، ۱۵ (۵۹)، ۲۴۵-۲۶۸.
- غلامی، نیما و شمس قارنه، ناصر (۱۴۰۳). ارائه مدلی برای پیش بینی قیمت سهام مبتنی بر CNN-LSTM بهینه شده در بورس اوراق بهادار تهران. *چشم/نداز مدیریت مالی*، ۱۴ (۴۵)، ۱۲۳-۱۴۷.
- محبی، سمیه؛ فدائی نژاد، محمد اسماعیل؛ اصولیان، محمد و حمیدی زاده، محمد رضا (۱۴۰۱). انتخاب ویژگی های مناسب برای مدل پیش بینی شاخص بورس اوراق بهادار تهران بر مبنای تکنیک کاهش ابعاد. *تحقیقات مالی*، ۲۴ (۴)، ۵۷۷-۶۰۱.
- مرادی، مریم؛ نشاط، نجمه و سرداری، محسن (۱۴۰۳). نمایش دانش سرمایه گذاری برحسب بازده در بازار سهام ایران با بهره گیری از مدل های عصبی عمیق در شرایط نااطمینانی محیطی. *تحقیقات مالی*، ۲۷ (۳)، ۵۳۱-۵۶۵.
- هادی زاده، آنیته؛ تارخ، محمد جعفر و میرزایی فزآئی، مجید (۱۴۰۱). پیش بینی رفتار بورس اوراق بهادار با به کارگیری اندیکاتورهای تکنیکال، مبتنی بر رویکردهای یادگیری تقویتی عمیق و شبکه های کانولوشن مطالعه موردی: بورس اوراق بهادار ایران. *پژوهش های نوین در تصمیم گیری*، ۷ (۴)، ۵۱-۸۰.

References

- Abbasimehr, H., Shabani, M. & Yousefi, M. (2020). An optimized model using LSTM network for demand forecasting. *Computers & Industrial Engineering*, 143, 106435.
- Abounoori, E. & Tazehabadi, A. G. (2009, April). Forecasting stock price using macroeconomic variables: A hybrid ardl, arima and artificial neural network. In *2009 International Conference on Information and Financial Engineering* (pp. 149-153). IEEE.
- Abounoori, E. & Tour, M. (2019). Stock market interactions among Iran, USA, Turkey, and UAE. *Physica A: Statistical mechanics and its applications*, 524, 297-305.
- Abounoori, E., Elmi, Z. M. & Nademi, Y. (2016). Forecasting Tehran stock exchange volatility; Markov switching GARCH approach. *Physica A: Statistical Mechanics and its Applications*, 445, 264-282.
- Acuna-García, J. A., Luz Canchola-Magdaleno, S. & Olmos Trejo, C. A. (2022). Stock Market Forecasting Using Continuous Wavelet Transform And Long Short-Term Memory Neural Networks. *International Journal of Advanced Research in Computer Science*, 13(6).
- Afsharirad, E., Alavi, S. E. & Sinaei, H. (2018). Developing an Intelligent Model to Predict Stock Trend Using the Technical Analysis. *Financial Research Journal*, 20(2), 249-264. (in Persian)
- Al-Khasawneh, M. A., Raza, A., Khan, S. U. R. & Khan, Z. (2024). Stock Market Trend Prediction Using Deep Learning Approach. *Computational Economics*, 66(1), 453-484.
- Bao, W., Yue, J. & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PloS one*, 12(7), e0180944.

- Basak, S., Kar, S., Saha, S., Khaidem, L. & Dey, S. R. (2019). Predicting the direction of stock market prices using tree-based classifiers. *The North American Journal of Economics and Finance*, 47, 552–567.
- Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R. & Khatri, R. K. (2022). Predicting stock market index using LSTM. *Machine Learning with Applications*, 9, 100320.
- Bieganowski, B. & Slepaczuk, R. (2024). Supervised Autoencoder MLP for Financial Time Series Forecasting. *Journal of Big Data*, 12(1), 207.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 31(3), 307-327.
- Box, G. E., Jenkins, G. M., Reinsel, G. C. & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Brown, R. G. (2004). *Smoothing, forecasting and prediction of discrete time series*. Courier Corporation.
- Budiharto, W. (2021). Data science approach to stock prices forecasting in Indonesia during Covid-19 using Long Short-Term Memory (LSTM). *Journal of big data*, 8, 1-9.
- Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- Chandar, S. K. (2024). Deep learning framework for stock price prediction using long short-term memory. *Soft Computing*, 28(17), 10557-10567.
- Chen, Y. J. & Hao, Y. J. (2018). Integrating principle component analysis and weighted support vector machine for stock trading signals prediction. *Neuro-computing*, (321), 381–402.
- Cheng, J., Zhao, W., Liu, J., Xie, X., Wu, S., Liu, L., ... & Liu, J. (2021a). Automated diagnosis of covid-19 using deep supervised autoencoder with multi-view features from CT images. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 19(5), 2723-2736.
- Cheng, Y., Hu, K., Wu, J., Zhu, H. & Shao, X. (2021b). Autoencoder quasi-recurrent neural networks for remaining useful life prediction of engineering systems. *IEEE/ASME Transactions on Mechatronics*, 27(2), 1081-1092.
- Chourmouziadis, K. & Chatzoglou, P. D. (2016). An intelligent short term stock trading fuzzy system for assisting investors in portfolio management. *Expert Systems with Applications*, (43), 298–311.
- Dami, S. & Esterabi, M. (2021). Predicting stock returns of Tehran exchange using LSTM neural network and feature engineering technique. *Multimedia Tools and Applications*, 80(13), 19947-19970.
- Dezhkam, A. & Manzuri, M. T. (2023). Forecasting stock market for an efficient portfolio by combining XGBoost and Hilbert-Huang transform. *Engineering Applications of Artificial Intelligence*, 118, Article 105626.

- Dhanuka, R., Tripathi, A. & Singh, J. P. (2022). A semi-supervised autoencoder-based approach for protein function prediction. *IEEE Journal of Biomedical and Health Informatics*, 26(10), 4957-4965.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the econometric society*, 987-1007.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, 25(2), 383-417.
- Fama, E. F. (1995). Random walks in stock market prices. *Financial analysts journal*, 51(1), 75-80.
- Fischer, T. & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270, 654–669.
- Gandhmal, D. P. & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, 34, 100190.
- Gholami, N. & Shams Gharne, N. (2024). Presenting an Optimized CNN-LSTM Model for Stock Price Forecasting in the Tehran Stock Exchange. *Financial Management Perspective*, 14(45), 123-147. (in Persian)
- Gülmez, B. (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems with Applications*, 227, 120346.
- Habibnia, A. (2016). *Essays in high-dimensional nonlinear time series analysis* (Doctoral dissertation, London School of Economics and Political Science).
- Habibnia, A. & Maasoumi, E. (2021). Forecasting in big data environments: an adaptable and automated shrinkage estimation of neural networks (AAShNet). *Journal of Quantitative Economics*, 19(Suppl 1), 363-381.
- Hadizadeh, A., Tarokh, M. J. & Mirzaee Ghazani, M. (2022). Forecasting Stock market behavior through implementing technical indicators, based on deep reinforcement learning and convolutional network approaches Case study: Iran Stock Market. *Modern Research in Decision Making*, 7(4), 51-80. (in Persian)
- Hamayel, M. J. & Owda, A. Y. (2021). A novel cryptocurrency price prediction model using GRU, LSTM and bi-LSTM machine learning algorithms. *AI*, 2(4), 477-496.
- Haykin, S. (1998). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Heidari, M. & Amiri, H. (2022). Inspecting the Predictive Power of Artificial Intelligence Models in Predicting the Stock Price Trend in Tehran Stock Exchange. *Financial Research Journal*, 24(4), 602-623. (in Persian)
- Holland, J. H. (1992). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press.
- Hu, Y., Sun, X., Nie, X., Li, Y. & Liu, L. (2019). An enhanced LSTM for trend following of time series. *IEEE Access*, 7, 34020-34030.

- Ismail, M. S., Noorani, M. S. M., Ismail, M., Razak, F. A. & Alias, M. A. (2020). Predicting next day direction of stock price movement using machine learning methods with persistent homology: Evidence from Kuala Lumpur Stock Exchange. *Applied Soft Computing*, 93, 106422.
- Izadi, M., Ashtab, A. & Zavari Rezaei, A. (2025). Comparing the Estimation Power of Machine Learning Models and Statistical Models in Predicting Profit Component Changes and Selecting the Optimal Model. *Financial Research Journal*, 27(1), 31-57. (in Persian)
- Jiang, W. (2021). Applications of deep learning in stock market prediction: recent progress. *Expert Systems with Applications*, 184, 115537.
- Jirou, I., Jebabli, I. & Lahiani, A. (2025). A hybrid deep learning model for cryptocurrency returns forecasting: Comparison of the performance of financial markets and impact of external variables. *Research in International Business and Finance*, 73, 102575.
- Kanwal, A., Lau, M. F., Ng, S. P., Sim, K. Y. & Chandrasekaran, S. (2022). BiCuDNNLSTM-1dCNN—A hybrid deep learning-based predictive model for stock price prediction. *Expert Systems with Applications*, 202, Article 117123.
- Kara, Y., Boyacioglu, M. A. & Baykan, O. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the istanbul stock exchange. *Expert Systems with Applications*, (38), 5311–5319.
- Khodaei, P., Esfahanipour, A. & Taheri, H. M. (2022). Forecasting turning points in stock price by applying a novel hybrid CNN-LSTM-ResNet model fed by 2D segmented images. *Engineering Applications of Artificial Intelligence*, 116, 105464.
- Kim, S., Ku, S., Chang, W. & Song, J. W. (2020). Predicting the Direction of US Stock Prices Using Effective Transfer Entropy and Machine Learning Techniques. *IEEE Access*, 8, 111660–111682.
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep Learning. *nature*, 521(7553), 436-444.
- Lee, M. C., Chang, J. W., Yeh, S. C., Chia, T. L., Liao, J. S. & Chen, X. M. (2022). Applying attention-based BiLSTM and technical indicators in the design and performance analysis of stock trading strategies. *Neural Computing and Applications*, 34(16), 13267-13279.
- Liu, C., Wang, Y., Wang, K. & Yuan, X. (2021). Deep learning with nonlocal and local structure preserving stacked autoencoder for soft sensor in industrial processes. *Engineering Applications of Artificial Intelligence*, 104, 104341.
- Liu, P., Sun, X., Han, Y., He, Z., Zhang, W. & Wu, C. (2022). Arrhythmia classification of LSTM autoencoder based on time series anomaly detection. *Biomedical Signal Processing and Control*, 71, 103228.
- Long, W., Lu, Z. & Cui, L. (2019). Deep learning-based feature engineering for stock price movement prediction. *Knowledge-Based Systems*, (164), 163–173.
- Lübbering, M., Gebauer, M., Ramamurthy, R., Sifa, R. & Bauckhage, C. (2021). Supervised autoencoder variants for end to end anomaly detection. In *Pattern Recognition. ICPR*

- International Workshops and Challenges: Virtual Event, January 10–15, 2021, Proceedings, Part II* (pp. 566-581). Springer International Publishing.
- Mehtab S., Sen J. & Dutta A. (2020). Stock price prediction using machine learning and LSTM-based deep learning models. arXiv preprint arXiv:2009.10819.
- Moghar, A. & Hamiche, M. (2020). Stock market prediction using LSTM recurrent neural network. *Procedia Computer Science*, 170, 1168-1173.
- Mohebi, S., Fadaeinejad, M. E., Osoolian, M. & Hamidizadeh, M. R. (2022). Feature Selection for the Prediction Model of the Tehran Stock Exchange Index by Dimensionality Reduction Techniques. *Financial Research Journal*, 24(4), 577-601. (in Persian)
- Moradi, M., Neshat, N. & Sardari, M. (2025). Display investment knowledge in terms of returns in Iran's stock market using deep neural models in environmental uncertainty. *Financial Research Journal*, 27(3), 531-565. (in Persian)
- Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S. & Mosavi, A. (2020). Predicting Stock Market Trends Using Machine Learning and Deep Learning Algorithms Via Continuous and Binary Data; a Comparative Analysis. *IEEE Access*, 8, 150199–150212.
- Naik, N. & Mohan, B. R. (2019). Study of stock return predictions using recurrent neural networks with LSTM. In *Engineering Applications of Neural Networks: 20th International Conference, EANN 2019, Xersonisos, Crete, Greece, May 24-26, 2019, Proceedings 20* (pp. 453-459). Springer International Publishing.
- Nam, H. S., Jeong, Y. K. & Park, J. W. (2020, October). An anomaly detection scheme based on LSTM autoencoder for energy management. In *2020 international conference on information and communication technology convergence (ICTC)* (pp. 1445-1447). IEEE.
- Nguyen, H. D., Tran, K. P., Thomassey, S. & Hamad, M. (2021). Forecasting and Anomaly Detection approaches using LSTM and LSTM Autoencoder techniques with the applications in supply chain management. *International Journal of Information Management*, 57, 102282.
- Nikou, M., Mansourfar, G. & Bagherzadeh, J. (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting, Finance and Management*, 26(4), 164-174.
- Osoolian, M., Nikmaram, A. & Karimi, M. (2025). Predicting Index Trend Using Hybrid Neural Networks with a Focus on Multi-Scale Temporal Feature Extraction in the Tehran Stock Exchange. *Financial Research Journal*, 27(1), 85-113. (in Persian)
- Paiva, F. D. A., Cardoso, R. T. N., Hanaoka, G. P. & Duarte, W. M. (2019). Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert Systems with Applications*, (115), 635–655.
- Patel, J., Shah, S., Thakkar, P. & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, (42), 259–268.

- Qin, Y., Yang, J., Zhou, J., Pu, H. & Mao, Y. (2023). A new supervised multi-head self-attention autoencoder for health indicator construction and similarity-based machinery RUL prediction. *Advanced Engineering Informatics*, 56, 101973.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1, 81-106.
- Rajabi, M. & Khaloozadeh, H. (2023). New approaches in modeling and forecasting financial markets: recent progress and future horizons. *Journal of Control*, 17(2), 149-163. (in Persian)
- Ranjan, A., Mahadani, Kumar, A. (2022). Stock price prediction using deep learning-based univariate and multivariate LSTM and RNN. In: *Sikdar Biplab, R.A., Prasad, Maity (Eds.), Proceedings of the 3rd International Conference on Communication, Devices and Computing*. Springer Singapore, Singapore, pp. 95–103.
- Rather, A. M. (2021). LSTM-Based deep learning model for stock prediction and predictive optimization model. *EURO Journal on Decision Processes*, 9, 100001.
- Ren, X., Xu, W. & Duan, K. (2022). Fourier transform based LSTM stock prediction model under oil shocks. *Quantitative Finance and Economics*, 6(2), 342–358.
- SaeidiAghdam, M., Sadeghi, A., Bahiraie, A. & HajiAsghari, S. Y. (2023). Provide a stock price forecasting model using deep learning algorithms and its use in the pricing of Islamic bank stocks. *Journal of Islamic Economics and Banking*, 11(41), 117-134. (in Persian)
- Saumya, S. & Singh, J. P. (2022). Spam review detection using LSTM autoencoder: an unsupervised approach. *Electronic Commerce Research*, 22(1), 113-133.
- Shahi, T. B., Shrestha, A., Neupane, A. & Guo, W. (2020). Stock price forecasting with deep learning: A comparative study. *Mathematics*, 8(9), 1441.
- Shao, L., Wu, D. & Li, X. (2014). Learning deep and wide: A spectral method for learning deep networks. *IEEE Transactions on Neural Networks and Learning Systems*, 25(12), 2303-2308.
- Sharma, M. & Shekhawat, H. S. (2022). Portfolio optimization and return prediction by integrating modified deep belief network and recurrent neural network. *Knowledge-Based Systems*, 109024.
- Singh, R. & Srivastava, S. (2017). Stock prediction using deep learning. *Multimedia Tools and Applications*, 76(18), 18569–18584.
- Sohrabi, M., Mirbargkar, S. M., Chirani, E. & Kheradyar, S. (2022). Modeling the Prediction of Stock Market Jumps Based on the Recurrent Neural Network and Deep Learning. *Journal of Securities Exchange*, 15(59), 245-268. (in Persian)
- Torabypour, T. & Siadat, S. (2023). A way to predict the stock price of the Tehran Stock Exchange in relation to knowledge. *Electronic and Cyber Defense*, 10(4), 91-100. (in Persian)
- Vijh, M., Chandola, D., Tikkiwal, V. A. & Kumar, A. (2020). Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599–606.

- Wan, A., Chang, Q., Khalil, A. B. & He, J. (2023). Short-term power load forecasting for combined heat and power using CNN-LSTM enhanced by attention mechanism. *Energy*, 282, 128274.
- Wang, Z., Su, X. & Ding, Z. (2020). Long-term traffic prediction based on lstm encoder-decoder architecture. *IEEE Transactions on Intelligent Transportation Systems*, 22(10), 6561-6571.
- Wu, D., Wang, X. & Wu, S. (2022). A Hybrid Framework Based on Extreme Learning Machine, Discrete Wavelet Transform, and Autoencoder with Feature Penalty for Stock Prediction. *Expert Systems with Applications*, 118006.
- Wu, D., Wang, X. & Wu, S. (2022). Jointly modeling transfer learning of industrial chain information and deep learning for stock prediction. *Expert Systems with Applications*, 191, 116257.
- Yu, P. & Yan, X. (2020). Stock price prediction based on deep neural networks. *Neural Computing and Applications*, 32, 1609-1628.
- Yuan, X., Gu, Y., Wang, Y., Yang, C. & Gui, W. (2019). A deep supervised learning framework for data-driven soft sensor modeling of industrial processes. *IEEE transactions on neural networks and learning systems*, 31(11), 4737-4746.
- Yuan, X., Li, L., Wang, Y., Yang, C. & Gui, W. (2020a). Deep learning for quality prediction of nonlinear dynamic processes with variable attention-based long short-term memory network. *The Canadian Journal of Chemical Engineering*, 98(6), 1377-1389.
- Yuan, X., Qi, S. & Wang, Y. (2020b). Stacked enhanced auto-encoder for data-driven soft sensing of quality variable. *IEEE Transactions on Instrumentation and Measurement*, 69(10), 7953-7961.
- Yuan, X., Wang, Y., Yang, C. & Gui, W. (2020c). Stacked isomorphic autoencoder based soft analyzer and its application to sulfur recovery unit. *Information Sciences*, 534, 72-84.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3), 338-353.
- Zokaei, S., Sanaei, M. & Mirzapour Babajan, A. (2024). An intelligent stock price forecasting model based on deep learning: with dimensionality reduction approach. *Journal of Intelligent Marketing Management*, 5(3), 299-324. (in Persian)