



ДУБОКО УЧЕЊЕ ЗА ПРЕДВИЋАЊЕ ФИНАНСИЈСКИХ ВРЕМЕНСКИХ СЕРИЈА

WHEN FINANCE MEETS DEEP LEARNING

МИЛИЦА ЗУКАНОВИЋ¹, АНА ПОЛЕДИЦА²

¹ Универзитет у Београду, Факултет организационих наука, milica.zukanovic@fon.bg.ac.rs

² Универзитет у Београду, Факултет организационих наука, ana.poledica@fon.bg.ac.rs

Резиме: Предвиђање финансијских временских серија је најактуелнија истраживачка тема када је реч о примени рачунарске интелигенције у финансијама. Утицај великог броја фактора на тржишну динамику као и њена комплексна природа довели су до све веће примене напреднијих модела за предвиђање попут неуронских мрежа, поред већ традиционално примењиваних линеарних и нелинеарних техника. Последњих година, присутан је растући тренд у примени дубоког учења у различитим доменима, а посебно у домену финансијских временских серија. Основни циљ ове студије је да кроз систематски преглед релевантних научних радова током претходних 18 година (2005–2023) анализира примену модела дубоког учења у области финансијских временских серија. Радови су груписани према доменима и коришћеним моделима.

Кључне речи: дубоко учење, финансијске временске серије, предвиђање, рачунарска интелигенција.

Abstract: Financial time series forecasting is the most attractive research topic when it comes to the application of computational intelligence in finance. The influence of a large number of factors on market dynamics, as well as its complex nature, have led to the increasing use of more sophisticated forecasting models such as neural networks, in addition to the traditionally applied linear and non-linear techniques. In recent years, there has been a growing trend in the application of deep learning in various domains, especially in the domain of financial time series. The main goal of this study is to analyse the application of deep learning models in the field of financial time series through a systematic review of relevant scientific papers during the previous 18 years (2005–2023). Papers are grouped according to domains and models.

Keywords: deep learning, financial time series, forecasting, computational intelligence.

1. УВОД

Анализа и предвиђање кретања тржишта акција је значајна тема за инвеститоре и за истраживаче. Од почетка двадесетог века, проучавани су модели предвиђања и спроведена су бројна истраживања о предвиђању финансијских временских серија користећи разноврсне статистичке и технике засноване на рачунарској интелигенцији [5, 29, 32].

Конвенционалне методе, као што су АРИМА [3, 4] ослањају се на историјске податке о ценама приликом предвиђања кретања на тржишту. Приоритет ових модела јесте смањење стохастичности и уочавање конзистентних образаца. Политички и економски фактори, понашање инвеститора, финансијски извештаји и други утицаји који се често не могу прецизно описати, значајно делују на динамику тржишта. У последње време, са развојем друштвених мрежа и обрадом природних језика, мноштво података се користи из медијских вести и објава за успешније предвиђање. Поред примене класичних “плитких” неуронских мрежа, велика количина сложених података из различитих извора, као и различите природе, наводи даља истраживања на дубоке неуронске мреже.

Дубоко учење се примењује у области компјутерске визије, обради природног језика и аудио-визуелном препознавању и његов успех је изазвао интересовање научно-академске

заједнице за шири опсег примене. Иако је развијен за домен рачунарских наука, примена дубоког учења допрла је у различите области попут медицине, физике, астрономије и финансија. Предвиђање финансијских временских серија помоћу дубоког учења добило је пажњу због своје способности да управља великим скуповима података и мапира податке са већом прецизношћу [4].

У овом раду дат је преглед литературе и анализа примене различитих техника дубоког учења код финансијских временских серија. Истраживање је вршено по угледу на рад [38]. Поређени су радови на основу примењених техника, области финансијских серија, тржишта акција, врсте часописа и конференција где су радови објављени.

Рад је организован на следећи начин. У другом поглављу описани су основни концепти дубоког учења. Затим је представљен преглед литературе са акцентом на предвиђање различитих финансијских временских серија. На крају су дати основни закључци.

2. ДУБОКО УЧЕЊЕ

Дубоко учење заправо означава вишеслојну неуронску мрежу са високим нивоом апстракције моделирања [12]. Концепт дубоког учења уведен је још осамдесетих година прошлог века, а детаљно је објашњен у раду [5]. Раније су ограничење за коришћење алгоритама дубоког учења представљали рачунарски ресурси. Са развојем процесора и меморије, значајно се смањило време неопходно за обраду велике количине података. Кључна предност модела дубоког учења је њихова способност да обрађују велике и сложене скупове података које је тешко обрадити другим техникама рачунарске интелигенције. Такође, дубоко учење може да открије нелинеарне везе и између структурираних и неструктурираних података.

У оквиру овог рада посебну пажњу смо посветили моделима дубоког учења који су погодни за временски зависне податке: дубоки вишеслојни перцептрон, рекурентне и конволуционе неуронске мреже. Дубоки вишеслојни перцептрон је издвојен због чињенице да се вишеслојни перцептрон у великој мери показао као успешан алгоритам за предвиђање различитих финансијских временских серија [38]. С обзиром на велики број скривених слојева и неурона, поменути алгоритам може да апроксимира било коју континуалну функцију.

Алгоритми дубоког учења као што су рекурентне мреже (енг. recurrent neural network, RNN) и мреже дуготрајно краткорочне меморије (енг. long short-term memory, LSTM) су посебно погодне за рад са секвенцијалним подацима и обраду природних језика. Ови алгоритми имају способност да чувају претходне информације путем краткорочне или дугорочне меморије. Како предвиђање финансијских временских серија није повезано само са тренутним, већ и са историјским подацима, информације које се преносе могу бити изгубљене уколико се користе само тренутни подаци. Информације се селективно филтрирају кроз „капије“ јединице дуготрајно краткорочне меморије, а значајније информације се издвајају током тренирања.


Поред дубоког вишеслојног перцептрона и рекурентних мрежа, конволуционе неуронске мреже (енг. convolutional neural network, CNN) су такође примењиване у истраживањима финансијских временских серија [2, 17, 18, 22, 26, 30, 36, 38]. Најважнија карактеристика ових мрежа јесу конволуциони слојеви који се прерачунавају померањем прозора кроз улазне податке креирајући мапе карактеристика. С обзиром на добре резултате у истраживањима [7, 27, 34, 35, 40, 48, 49], конволуционе неуронске мреже имају солидну перспективу за даље истраживање.

3. ПРЕДВИЂАЊЕ ФИНАНСИЈСКИХ ВРЕМЕНСКИХ СЕРИЈА

Број радова над којима је спроведена ова студија је 187, обухватајући прегледно истраживање [38] са 140 радова и 47 новијих радова. То укључује објављене чланке из


часописа са импакт фактором од издавача *Springer, Elsevier, IEEE, MDPI* и *Wiley Online Library*, радова са конференција и докторских дисертација између 2005. и 2023. године.

На Слици 1 приказана је атрактивност различитих финансијских временских серија током претходних 26 година. Предвиђање тржишта акција је примарно поље истраживања када су у питању финансијске временске серије. Студије које предвиђају цене акција [1-3, 5-8, 10-11, 14, 16-19, 22, 24-25, 27-32, 35-38, 40-41, 43-49], тржишне индексе [4, 13, 20, 38] или тренд [15, 33, 38-39] чине чак 78% свих радова као што је истакнуто на Слици 2.



Слика 1: Број објављених радова за различите финансијске временске серије по годинама

Такође, Слика 2 потврђује доминацију модела заснованих на рекурентним неуронским мрежама, потом следе конволуционе неуронске мреже и дубоки вишеслојни перцептрон. Истраживачи углавном користе дуготрајно краткорочну меморију због релативно једноставног развоја модела [1-6, 8-9, 16-19, 22-24, 26, 28-30, 32-33, 36-39, 41, 43-45, 47]. Конволуционе неуронске мреже су се показале као погодније за предвиђање цена са сложенијом структуром података [2-3, 7, 13, 17-18, 22, 26-27, 29-30, 34-36, 38, 40, 46-49], док је дубоки вишеслојни перцептрон најчешће примењиван на проблеме предвиђања цена [3, 6] и класификације тренда у три групе, растући, стационарни и опадајући [38].



Слика 2: Расподела објављених радова на основу коришћених техника и домена за предвиђање финансијских временских серија

Иако су америчке берзе (нпр. NASDAQ, NYSE) најзаступљеније у финансијским истраживањима, када је реч о моделима дубоког учења занимљиво је запажање да се

најчешће примењују на тржишта акција Индије и Кине. Експерименти су доминантно извршени у Python програмском окружењу.

5. ЗАКЉУЧАК

Основни циљ рада је био да пружи свеобухватан преглед литературе о примени дубоког учења у домену финансијских временских серија. Прегледано је 187 радова из академских база података објављених између 2005. и 2023. године. Препознато је осам различитих група финансијских временских серија и идентификоване су најчешће коришћене технике дубоког учења за сваку од њих. На основу прегледа, закључујемо да су за временски зависне финансијске податке најзаступљенији модели дуготрајно краткорочне меморије, а затим и рекурентне неуронске мреже. Као наставак истраживања, спроведена је додатна анализа успешности модела дубоког учења која превазилази опсег овог рада.

Захвалница

Истраживање је финансирано уз подршку Факултета организационих наука, Универзитета у Београду.

ЛИТЕРАТУРА

- [1] Agrawal, M., Shukla, P. K., Nair, R., Nayyar, A., & Masud, M. (2022). Stock prediction based on technical indicators using deep learning model. *Computers, Materials & Continua*, 70(1).
- [2] Aldhyani, T. H., & Alzahrani, A. (2022). Framework for predicting and modeling stock market prices based on deep learning algorithms. *Electronics*, 11(19), 3149.
- [3] Alkhatib, K., Khazaleh, H., Alkhazaleh, H. A., Alsoud, A. R., & Abualigah, L. (2022). A new stock price forecasting method using active deep learning approach. *Journal of Open Innovation: Technology, Market, and Complexity*, 8(2), 96.
- [4] Althelaya, K. A., Mohammed, S. A., & El-Alfy, E. S. M. (2021). Combining deep learning and multiresolution analysis for stock market forecasting. *IEEE Access*, 9, 13099-13111.
- [5] Biswas, M., Shome, A., Islam, M. A., Nova, A. J., & Ahmed, S. (2021, April). Predicting stock market price: A logical strategy using deep learning. In *2021 IEEE 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)* (pp. 218-223). IEEE.
- [6] Cao, J., Li, Z., & Li, J. (2019). Financial time series forecasting model based on CEEMDAN and LSTM. *Physica A: Statistical mechanics and its applications*, 519, 127-139.
- [7] Chandar, S. K. (2022). Convolutional neural network for stock trading using technical indicators. *Automated Software Engineering*, 29, 1-14.
- [8] Chandola, D., Mehta, A., Singh, S., Tikkiwal, V. A., & Agrawal, H. (2022). Forecasting Directional Movement of Stock Prices using Deep Learning. *Annals of Data Science*, 1-18.
- [9] Chatterjee, A., Bhowmick, H., & Sen, J. (2022, October). Stock Volatility Prediction using Time Series and Deep Learning Approach. In *2022 IEEE 2nd Mysore Sub Section International Conference (MysuruCon)* (pp. 1-6). IEEE.
- [10] Chen, L., Pelger, M., & Zhu, J. (2023). Deep learning in asset pricing. *Management Science*.
- [11] Cheng, D., Yang, F., Xiang, S., & Liu, J. (2022). Financial time series forecasting with multi-modality graph neural network. *Pattern Recognition*, 121, 108218.
- [12] D'Amato, V., Levantesi, S., & Piscopo, G. (2022). Deep learning in predicting cryptocurrency volatility. *Physica A: Statistical Mechanics and its Applications*, 596, 127158.
- [13] Gao, R., Zhang, X., Zhang, H., Zhao, Q., & Wang, Y. (2022). Forecasting the overnight return direction of stock market index combining global market indices: A multiple-branch deep learning approach. *Expert Systems with Applications*, 194, 116506.

- [14] Hao, J., He, F., Ma, F., Zhang, S., & Zhang, X. (2023). Machine learning vs deep learning in stock market investment: an international evidence. *Annals of Operations Research*, 1-23.
- [15] Haq, A. U., Zeb, A., Lei, Z., & Zhang, D. (2021). Forecasting daily stock trend using multi-filter feature selection and deep learning. *Expert Systems with Applications*, 168, 114444.
- [16] Ji, X., Wang, J., & Yan, Z. (2021). A stock price prediction method based on deep learning technology. *International Journal of Crowd Science*, 5(1), 55-72.
- [17] Jing, N., Wu, Z., & Wang, H. (2021). A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction. *Expert Systems with Applications*, 178, 115019.
- [18] Kamara, A. F., Chen, E., & Pan, Z. (2022). An ensemble of a boosted hybrid of deep learning models and technical analysis for forecasting stock prices. *Information Sciences*, 594, 1-19.
- [19] Kumar, S., Chitradevi, D., & Rajan, S. (2022, April). Stock price prediction using deep learning LSTM (long short-term memory). In *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)* (pp. 1787-1791). IEEE.
- [20] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- [21] Li, Y., & Pan, Y. (2022). A novel ensemble deep learning model for stock prediction based on stock prices and news. *International Journal of Data Science and Analytics*, 1-11.
- [22] Liu, M. (2023). The Application of Deep Learning in Stock Prediction. *Highlights in Science, Engineering and Technology*, 31, 71-75.
- [23] Liu, Y. (2019). Novel volatility forecasting using deep learning–long short term memory recurrent neural networks. *Expert Systems with Applications*, 132, 99-109.
- [24] Liu, H., & Long, Z. (2020). An improved deep learning model for predicting stock market price time series. *Digital Signal Processing*, 102, 102741.
- [25] Liu, Q., Tao, Z., Tse, Y., & Wang, C. (2022). Stock market prediction with deep learning: The case of China. *Finance Research Letters*, 46, 102209.
- [26] Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural computing and applications*, 32, 17351-17360.
- [27] Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., ... & Muhammad, K. (2020). A local and global event sentiment based efficient stock exchange forecasting using deep learning. *International Journal of Information Management*, 50, 432-451.
- [28] Mehta, P., Pandya, S., & Kotecha, K. (2021). Harvesting social media sentiment analysis to enhance stock market prediction using deep learning. *PeerJ Computer Science*, 7, e476.
- [29] Mehtab, S., & Sen, J. (2020). A time series analysis-based stock price prediction using machine learning and deep learning models. *International Journal of Business Forecasting and Marketing Intelligence*, 6(4), 272-335.
- [30] Mehtab, S., & Sen, J. (2022). Analysis and forecasting of financial time series using CNN and LSTM-based deep learning models. In *Advances in Distributed Computing and Machine Learning: Proceedings of ICADCML 2021* (pp. 405-423). Springer Singapore.
- [31] Muhammad, T., Aftab, A. B., Ahsan, M., Muhu, M. M., Ibrahim, M., Khan, S. I., & Alam, M. S. (2022). Transformer-Based Deep Learning Model for Stock Price Prediction: A Case Study on Bangladesh Stock Market. *arXiv preprint arXiv:2208.08300*.
- [32] Nabipour, M., Nayyeri, P., Jabani, H., Mosavi, A., & Salwana, E. (2020). Deep learning for stock market prediction. *Entropy*, 22(8), 840.
- [33] 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.

- [34] Oyedele, A. A., Ajayi, A. O., Oyedele, L. O., Bello, S. A., & Jimoh, K. O. (2023). Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction. *Expert Systems with Applications*, 213, 119233.
- [35] Patil, P., Wu, C. S. M., Potika, K., & Orang, M. (2020, January). Stock market prediction using ensemble of graph theory, machine learning and deep learning models. In *Proceedings of the 3rd International Conference on Software Engineering and Information Management* (pp. 85-92).
- [36] Rezaei, H., Faaljou, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332.
- [37] Sen, J., Dutta, A., & Mehtab, S. (2021, May). Profitability analysis in stock investment using an LSTM-based deep learning model. In *2021 2nd International Conference for Emerging Technology (INCET)* (pp. 1-9). IEEE.
- [38] Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, 106181.
- [39] Shen, J., & Shafiq, M. O. (2020). Short-term stock market price trend prediction using a comprehensive deep learning system. *Journal of big Data*, 7(1), 1-33.
- [40] Shi, Y., Zheng, Y., Guo, K., & Ren, X. (2021). Stock movement prediction with sentiment analysis based on deep learning networks. *Concurrency and Computation: Practice and Experience*, 33(6), e6076.
- [41] Sisodia, P. S., Gupta, A., Kumar, Y., & Ameta, G. K. (2022, February). Stock market analysis and prediction for NIFTY50 using LSTM Deep Learning Approach. In *2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM)* (Vol. 2, pp. 156-161). IEEE.
- [42] Song, Y., Tang, X., Wang, H., & Ma, Z. (2023). Volatility forecasting for stock market incorporating macroeconomic variables based on GARCH-MIDAS and deep learning models. *Journal of Forecasting*, 42(1), 51-59.
- [43] Sunny, M. A. I., Maswood, M. M. S., & Alharbi, A. G. (2020, October). Deep learning-based stock price prediction using LSTM and bi-directional LSTM model. In *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)* (pp. 87-92). IEEE.
- [44] Swathi, T., Kasiviswanath, N., & Rao, A. A. (2022). An optimal deep learning-based LSTM for stock price prediction using twitter sentiment analysis. *Applied Intelligence*, 52(12).
- [45] Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091-2100.
- [46] Yadav, K., Yadav, M., & Saini, S. (2022). Stock values predictions using deep learning based hybrid models. *CAAI Transactions on Intelligence Technology*, 7(1), 107-116.
- [47] Yang, C., Zhai, J., & Tao, G. (2020). Deep learning for price movement prediction using convolutional neural network and long short-term memory. *Mathematical Problems in Engineering*, 2020.
- [48] Wan, R., Mei, S., Wang, J., Liu, M., & Yang, F. (2019). Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 8(8), 876.
- [49] Wang, X., Wang, Y., Weng, B., & Vinel, A. (2020). Stock2Vec: a hybrid deep learning framework for stock market prediction with representation learning and temporal convolutional network. *arXiv preprint arXiv:2010.01197*.