

УПОТРЕБА МАШИНСКОГ УЧЕЊА ЗА ПРЕДВИЂАЊЕ НА ФИНАНСИЈСКОМ ТРЖИШТУ

USING MACHINE LEARNING FOR FINANCIAL MARKET FORECASTING

Рајко Иванишевић

Универзитет у Новом Саду, Економски факултет у Суботици, Република Србија

rajko.ivanisevic@ef.uns.ac.rs

ORCID: 0000-0002-0601-2884

Апстракт: Иновације у области технологије довеле су до промене начина функционисања организација. Област машинског учења је, поред многих области, нашла своју примену у предвиђањима на финансијском тржишту, а вештачка интелигенција, као још једна од кључних иновације из области технологије, почиње да узима све више маха у области предвиђања. Глобализацијом и убрзаним процесом спровођења дигиталне трансформације под утицајем криза на светском нивоу захтевају напредовање у предвиђању кретања цена акција. Рад има за циљ да изнађе утицај машинског учења на предвиђање цена акција. Сходно убрзаном развоју машинског учења и вештачке интелигенције временски период на основу којег је спроведен преглед литературе је 2021-2023.

Кључне ријечи: машинско учење, вештачка интелигенција, финансијско тржиште

JEL класификација: G11, G12, G17

Abstract: Innovations in the field of technology have led to a change in the way organizations function. The field of machine learning, in addition to many fields, has found its application in predictions in the financial market, and artificial intelligence, as another key innovation in the field of technology, is starting to gain more momentum in the field of predictions. Globalization and the accelerated process of implementing digital transformation under the influence of crises at the world level require progress in predicting the movement of stock prices. The paper aims to find

the impact of machine learning on stock price forecasting. In accordance with the accelerated development of machine learning and artificial intelligence, the time period based on which the literature review was conducted is 2021-2023.

Key Words: *machine learning, artificial intelligence, financial market*

JEL classification: *G11, G12, G17*

1. УВОД

Машинско учење (*Machine Learning – ML*) представља огранак вештачке интелигенције. Оно се базира на различитим алгоритмима који су способни да уче на основу пређашњег искуства. Примена машинског учења у области финансија није новина, али развојем вештачке интелигенције и развојем различитих модела, долази се до све чешће употребе у области финансијских тржишта, берзе. Jabeen, Yasir, Ansari, Yasmin, Moon и Rho (2022) наводе да је берза водећи индикатор економског раста, штавише да уколико берза послује добро да и привреда функционише како треба. Поред различитих алгоритама, модела машинског учења појављује се и хибридни модел који се базира на сарадњи између експерата и машина (машинског учења).

До сада најчешће коришћен модел за машинско учење јесте неуронска мрежа, док у последње време нагли скок бележи „дубоко учење“ (*deep learning*). Такође, како тврде Warin и Стојков (2021), стр. 27, мешавином области лингвистике, рачунарства и вештачке интелигенције долази се до *NLP (Natural Language Processing)* које је нашло своју примену у области финансија.

Примена машинског учења за предвиђање на финансијском тржишту има за циљ предвиђање будућих кретања на берзи како на кратак рок, тако и на дужи период. Прегледом литературе дошло се и до сазнања да различите берзе са својим појединостима и специфичностима могу имати различите импликације када је реч о примени машинског учења.

2. ИСТРАЖИВАЧКА МЕТОДОЛОГИЈА И ПРОЦЕС СПРОВОЂЕЊА ПРЕГЛЕДА ЛИТЕРАТУРЕ

Xiao и Watson (2019) дефинишу начин спровођења прегледа литературе. Саветују да је потребно спровести кораке планирања прегледа, спровођење прегледа и извештавање о резултатима.

2.1. Процес планирања прегледа литературе

Планирање прегледа је спроведено кроз формулисање истраживачког проблема и кроз други корак, развијање и валидацију процеса прегледа.

Како је у раду реч о машинском учењу и његовој примени на финансијским тржиштима, дефинисано је истраживачко питање „Да ли машинско учење има значајан утицај на предвиђање будућих кретања на финансијском тржишту?“. Уколико је одговор на истраживачко питање потврдан, потребно је дефинисати да ли је дати утицај позитивног или негативног карактера.

Приликом спровођења прегледа дефинисан је временски оквир који обухвата радове од 2021. до 10.05.2023. године.

2.2. Процес спровођења прегледа литературе

Кораци који су спроведени да би се извршио преглед литературе обухватају претрагу литературе, преглед за укључивање у рад, оцењивање квалитета, издавање података и анализирање и синтетизовање података.

За претраживање литературе коришћена је електронска база „*Web Of Science*“. Фраза која је коришћена како би се дошло до релевантних радова јесте „*Machine learning predictions on financial market*“. Након извршене претраге уведен је критеријум да се посматра период 2021-2023. Број погодака ја био 407 (167, 189, 51 респективно по годинама). Укључено је прегледом наслова и апстракта 20 радова за даљи процес. Остатак радова није био погодан за постављено истраживачко питање. Од 20 издвојено је 11, те је 9 радова одстрањено из разлога немогућности проналаска целокупног рада. Оцењивањем квалитета није одстрањен ниједан рад. Наративни преглед је коришћен за издавање података и сви радови су пружили информације од значаја за постављену тему. Синтетизовањем података долази се до целокупне слике и извођења одређених закључака из области машинског учења и примене на финансијским тржиштима.

Резултати су приказани у наставку.

3. ИЗВЕШТАВАЊЕ О НАЛАЗИМА

На постављено истраживачко питање „Да ли машинско учење има значајан утицај на предвиђање будућих кретања на финансијском тржишту?“ дошло се до следећих сазнања.

Rouf, Malik, Arif, Sharma, Singh, Aich и Kim (2021) су посматрали *SMP* (*Stock Market Prediction*), тј. предвиђања на берзи. Они су своје прогнозирање базирали на временским серијама које посматрају прошле податке и предвиђају будуће. Представили су генеричку шему за предвиђање на берзи (*SMP*). Она се састоји из три области: типови података, машинско учење и методе за предобраду података. Код типова података извршили су класификацију на текстуалне податке и тржишне податке. Код текстуалних података највећи изазов представља претварање информација у виду текста у нумеричке вредности како би се то могло искористити као инпут за модел. Тржишни подаци обухватају историјске, нумеричке податке (цене). Када је реч о машинском учењу, представљају следеће методе машинског учења:

- *Artificial Neural Networks (ANN)*
- *Support Vector Machine (SVM)*
- *Naïve Bayes (NB)*
- *Genetic Algorithms (GA)*
- *Fuzzy Algorithms (FA)*
- *Deep Neural Networks (DNN)*
- *Regression Algorithms (RA)*
- *Hybrid Approaches (HA)*

Становишта су да је берза подложна утицају друштвених мрежа и да је осетљива на сајбер нападе. Као закључак износе да је *SVM* најпопуларнија

техника за предвиђање кретања на берзи, али да су технике *ANN* и *DNN* најчешће коришћене (да пружају тачније и брже предикције).

Попут њих, Albahli, Irtaza, Nazir, Mehmood, Alkhalifah и Albattah (2022), тврде да друштвене мреже представљају веома важан извор информација. Фаворизују твитер када је реч о утицају друштвених мрежа на предвиђање кретања на берзи.

Један од проблема код избора модела који ће се примењивати јесте различитост резултата приликом употребе тестног узорка и резултата који се добијају применом модела у реалном окружењу. О овоме говоре Gao, Wang и Yang (2022). Они су своје истраживање базирали на кретању цене сирове нафте. Истраживањем су показали да је најбољи резултат предвиђања дао *LGBM* (*Light Gradient-Boosting Machine*) модел. Како је карактеристика финансијског окружења константна и брза промена, као опасност предочена је могућност доношења нетачних и опасних одлука које су засноване на непотпуном разумевању модела.

Даље, проблем употребе машинског учења може бити везан и за карактеристике одређене берзе. Leipold, Wang и Zhou (2022) су посматрали кинеску берзу и неуронске мреже. Праве разлику између великих и малих акција. Закључили су да код кинеског тржишта долази до повећања краткорочне продаје, приликом доминирања малопродајних инвестиција. Ово доприноси проблему прецењености цена у поређењу са другим тржиштима. На становишту су да машинско учење има одличан ниво предиктивне моћи када је реч о акцијама на кинеском тржишту. Закључили су да ликвидносно засновани трговачки сигнали представљају кључан фактор, док сигнали засновани на кретању цена играју минорну улогу. Такође, становишта су да је машинско учење са својим методама могуће применити и на друга тржишта која имају различите карактеристике од тржишта Сједињених Америчких Држава, као што је Кина.

Као један од највећих изазова, Almaskati (2022), наводи избор који алгоритам је потребно користити код машинског учења. Рад говори о досадашњој окренутости апликацијама са машинским учењем ка одређивању цене имовине, предвиђању банкрота и откривању аномалија у финансијском извештавању и бодовању ризика. Almaskati наводи проблем преоптерећеног модела који пружа лажни осећај поверења применом у стварном свету. Насупрот тога стоји недовољно развијен модел који је, такође, извор проблема. Тврди да добар *ML* модел треба да обухвата тренд и најважније карактеристике дистрибуције које ће утицати на будуће податке, а не да је добар модел онај који уклапа податке са свим њиховим несавршеностима. Он закључује да попут улоге више аналитичара и узимања у обзир њихових мишљења, треба користити и више *ML* алгоритама. Наглашава да оваква примена са собом носи и одређене проблеме. Наводи и проблем рада *ML* алгоритма када је реч о несигурним временима, тачније непредвидивим догађајима који могу да наступе у наредном временском периоду. Упозорава да одређени алгоритми захтевају велике рачунарске ресурсе, те је стога тешко константно их усклађивати, поготово када је реч о огромном броју података. Закључује да *ML* алгоритми могу довести до позитивних последица уколико се употребе како треба.

Слично њему, Creamer, Sakamoto, Nickerson и Ren (2023), говоре о мешавини одређених фактора. У њиховом раду реч је о хибридном моделу, тј. коришћењу и експерата (људи) и машина (машинског учења, алгоритама). Посматрајући европску берзу, наглашавају да правом комбинацијом експерта/експерата и машина се може добити резултат који би најбољи експерт из одабране групе добио сам или резултат бољи од тога. Говоре о могућношћу човека да интерпретира податке, да се прилагоди новим условима, да тумачи податке, итд. Као главну предност машина, машинског учења, наводе могућност обраде великог броја података. Предлажу хибридни систем који обухвата човека и машину где човек, експерт, првенствено има улогу да припомогне код обезбеђивања релевантних улазних података машини. На послетку је потребан и за тумачење података.

Временским предвиђањем за један дан унапред бавили су се Wang, Tang, Xiong и Zhang (2021) и Lin, Liu, Yang, Wu и Jiang (2021). Први тројац се усредосредио на *RC (Reservoir Computing)*. Насумично повезани чворови код машинског учења омогућавају нелинеарност. Говоре о улазном слоју, резервоару и излазном слоју користећи метрике *MSE*, *MAE*, R^2 , *RMSE*, *MAPE*. Резервоар и улазни слој остају фиксни, док се коригује излазни слој. У резервоару се одиграва машинско учење, док су посматрани индекси *S&P500*, *NYSE*, *DJI*, *NASDAQ*, *FTSE*, *N225*, *SSE*. Установили су да за различите индексе не постоји један најбољи начин, тј. да у зависности од случаја ће одређена појединачна структура донети најбољи резултат. Такође, наглашавају да у зависности од улазних података (величине, комбинација, итд.) долази до значајних разлика у излазу, резултату. Помињу оптималну улазну величину историјских трговачких података као референтну тачку за процену сваког индекса. Наводе да у свом експерименту све преко 20 трговачких дана је сувишно, а насупрот томе, да премало дана неће повећати перформансе у већини предвиђања. Становишта су да је неопходно систематско истраживање различитих комбинација свих фактора како би се направило добро предвиђање. Закључују да је немогуће једном методом постићи најбоље перформансе предвиђања појединачних индекса.

Других петоро истраживача, Lin, Liu, Yang, Wu и Jiang (2021), су истражили препознавање шаблона и доношење одлука на берзи коришћењем машинског учења. Они напомињу да је најчешћа традиционална метода анализирања берзе, финансијског тржишта, техничка анализа, тј. графикон свећњака (свећа). Наводе да се за побољшање ефикасности предвиђања финансијског тржишта могу користити савремене методе рударења података и примена вештачке интелигенције. Рад говори о њиховом новоразвијеном моделу *PRML* – модел за препознавање образаца. Овај модел користи машинско учење како би побољшао доношење одлука за трговину акцијама. Дошли су до резултата да дводневни и тродневни обрасци свећњака имају најбољи ефекат када је реч о предвиђању један дан унапред. Наводе да њихов *PRML* смањује ризик несигурности и побољшава прецизност предвиђања. Посматрали су кинеско тржиште, што треба узети у обзир приликом тумачења резултата. Најбољи резултат постигао је дводневни образац свећњака за предвиђање један дан унапред.

Како се налазимо у ери криптовалута, за сам крај ове тачке, Sebastião и Godinho, (2021), су се бавили посматрањем криптовалута и то *Bitcoin*, *Ethereum* и *Litecoin*.

Они наводе да не постоји дефинисани став који модел је бољи или која је криптовалута најпредвидљивија. Тврде да је тачност предвиђања модела на ниском нивоу.

ЗАКЉУЧАК

Одговор на постављено истраживачко питање је потврдан, што значи да машинско учење има значајан утицај на предвиђање будућих кретања на финансијском тржишту. Оно што је ипак недовољно истражено и доказано јесте позитиван, тј. негативан утицај који примена машинског учења доноси. Данас је у повоју и наглом развоју вештачка интелигенција која ову област може значајно унапредити. Аутори радова над којима је вршен преглед су претежно говорили о позитивним странама, али су упозоравали на негативне лошом применом или лошим обезбеђивањем улазних података. Временски посматрано су се базирали на краћим временским периодима радије него на дужим. За подручје криптовалута посматрани рад је дао штуре информације, али са закључком да примена машинског учења код криптовалута није на довољном нивоу. Рад има простора за даље истраживање, поготово у области криптовалута, где све оно што је већ примењено на редовним берзама треба да дође као новитет.

ЛИТЕРАТУРА

- [1] Albahli, S., Irtaza, A., Nazir, T., Mehmood, A., Alkhalifah, A., & Albattah, W. (2022). A Machine Learning Method for Prediction of Stock Market Using Real-Time Twitter Data. *Electronics*, 11(20), 3414. <https://doi.org/10.3390/electronics11203414>
- [2] Almaskati, N. (2022). Machine learning in finance: Major applications, issues, metrics, and future trends. *International Journal of Financial Engineering*, 09(03). <https://doi.org/10.1142/S2424786322500104>
- [3] Creamer, G. G., Sakamoto, Y., Nickerson, J. V., & Ren, Y. (2023). Hybrid Human and Machine Learning Algorithms to Forecast the European Stock Market. *Complexity*, 2023, 1–20. <https://doi.org/10.1155/2023/5847887>
- [4] Gao, X., Wang, J., & Yang, L. (2022). An Explainable Machine Learning Framework for Forecasting Crude Oil Price during the COVID-19 Pandemic. *Axioms*, 11(8), 374. <https://doi.org/10.3390/axioms11080374>
- [5] Jabeen, A., Yasir, M., Ansari, Y., Yasmin, S., Moon, J., & Rho, S. (2022). An Empirical Study of Macroeconomic Factors and Stock Returns in the Context of Economic Uncertainty News Sentiment Using Machine Learning. *Complexity*, 2022, 1–18. <https://doi.org/10.1155/2022/4646733>
- [6] Leippold, M., Wang, Q., & Zhou, W. (2022). Machine learning in the Chinese stock market. *Journal of Financial Economics*, 145(2), 64–82. <https://doi.org/10.1016/j.jfineco.2021.08.017>
- [7] Lin, Y., Liu, S., Yang, H., Wu, H., & Jiang, B. (2021). Improving stock trading decisions based on pattern recognition using machine learning technology. *PLOS ONE*, 16(8), e0255558. <https://doi.org/10.1371/journal.pone.0255558>
- [8] Rouf, N., Malik, M. B., Arif, T., Sharma, S., Singh, S., Aich, S., & Kim, H.-C. (2021). Stock Market Prediction Using Machine Learning Techniques: A Decade Survey on Methodologies, Recent Developments, and Future Directions.

- Electronics*, 10(21), 2717. <https://doi.org/10.3390/electronics10212717>
- [9] Sebastião, H., & Godinho, P. (2021). Forecasting and trading cryptocurrencies with machine learning under changing market conditions. *Financial Innovation*, 7(1), 3. <https://doi.org/10.1186/s40854-020-00217-x>
- [10] Wang, W.-J., Tang, Y., Xiong, J., & Zhang, Y.-C. (2021). Stock market index prediction based on reservoir computing models. *Expert Systems with Applications*, 178, 115022. <https://doi.org/10.1016/j.eswa.2021.115022>
- [11] Warin, T., & Stojkov, A. (2021). Machine Learning in Finance: A Metadata-Based Systematic Review of the Literature. *Journal of Risk and Financial Management*, 14(7), 302. <https://doi.org/10.3390/jrfm14070302>
- [12] Xiao, Y., & Watson, M. (2019). Guidance on Conducting a Systematic Literature Review. *Journal of Planning Education and Research*, 39(1), 93–112. <https://doi.org/10.1177/0739456X17723971>

SUMMARY

Innovations in the field of technology have led to a change in the way organizations function. The field of machine learning, in addition to many fields, has found its application in predictions in the financial market, and artificial intelligence, as another key innovation in the field of technology, is starting to gain more momentum in the field of predictions. Globalization and the accelerated process of implementing digital transformation under the influence of crises at the world level require progress in predicting the movement of stock prices. In accordance with the accelerated development of machine learning and artificial intelligence, the time period based on which the literature review was conducted is 2021-2023. The research results showed the undeniable impact of machine learning on stock market predictions. The conclusion is that there is no single best algorithm that is universal. The growing cryptocurrency market opens up new horizons where machine learning has not yet established its application.



This work is licensed under the Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License