

Strojové učenie ako srdce umelej inteligencie pre investora

Machine learning as the heart of artificial intelligence for the investor

Milan CIBULA

Abstrakt

Príspevok analyzuje inovatívny nástroj FinTech investovania umelú inteligenciu (AI) a jej reprezentanta strojové učenie (ML), ktoré je často nazývané aj ako srdce umelej inteligencie. Na základe literárneho prehľadu vedeckých výstupov tvorby investičnej stratégie pomocou strojového učenia príspevok podrobne vysvetľuje podstatu, výhody a nevýhody algoritmov strojového učenia ARIMA, Support Vector Machines (SVM) a Long Short-Term Memory (LSTM), predstavujúcich algoritmy s najlepšimi výsledkami so zameraním na dáta dlhých časových radov využívané pri predikcii investičných aktív.

Kľúčové slová: umelá inteligencia, strojové učenie, FinTech, inovatívne investovanie

Abstract

The paper analyzes FinTech's innovative artificial intelligence investment tool (AI) and its representative machine learning (ML), which is often referred to as the heart of artificial intelligence. Based on a literature review of the scientific outputs of creating an investment strategy using machine learning, the paper explains in detail the nature, advantages and disadvantages of ARIMA, Support Vector Machines (SVM) and Long Short-Term Memory (LSTM) machine learning algorithms representing the best-performing algorithms for long time series data used in the prediction of investment assets.

JEL code: F65, G11, G17, G23

Keywords: artificial intelligence, machine learning, FinTech, innovative investment

Vedecký časopis FINANČNÉ TRHY, Bratislava, Derivat 2022, ISSN 1336-5711, 1/2022

1 Úvod

Pred príchodom techník strojového učenia využívali investori a vedci rôzne štatistické modely, ktoré často predpokladajú linearitu, stacionárnosť a normálnosť, na popísanie časových radov ceny a objemu obchodovania investičných aktív s cieľom analyzovať a predpovedať ich budúci trend (Chen, 2010; Xie, 2011).

Rapídny vývoj umelej inteligencie, výpočtového počítačového hardvéru (CPU, GPU, RAM, atď.), či prístupu ku bezprecedentnému objemu finančných dát, v posledných rokoch umožnili prudký nárast využitia strojového učenia (ML) v predikcii finančných trhov (Cavalcantea – Brasileirob – Souzab – Nobregab – Oliveir, 2016).

Prehĺbenie výskumu inteligentných algoritmov od lineárnych modelov, cez základné neuronové siete, k modelom hlbokých neurónových sietí (DNN), predstavuje pre investičnú prax neustále nové možnosti využitia. Strojové učenie sa účinne uplatňuje v oblasti rozpoznávania obrázkov a pri analýze textu. Okrem toho sa autori ako Malagrino, Roman, a Monteiro (2018) domnievajú, že pokročilé algoritmy strojového učenia (ML) dokážu zachytiť dynamické zmeny na finančnom trhu, simulovať proces obchodovania s investičnými aktívami a vykonávať automatické investičné rozhodnutia.

Vysokovýkonné počítačové vybavenie, inteligentné algoritmy a finančné big dáta, spolu poskytujú podporu pri rozhodovaní o automatizovanom obchodovaní s investičnými aktívami, čo odborníci v sektore investícií postupne akceptujú. Sila finančne inovatívnych technológií FinTech, týmto pretvára spôsob a možnosti investovania.

Mnohé finančné organizácie postupne prechádzajú od používania tradičnej prediktívnej analýzy k používaniu algoritmov strojového učenia na predpovedanie finančných trendov. S pomocou strojového učenia môžu finanční špecialisti identifikovať zmeny na trhu oveľa skôr ako pri tradičných metódach.

Strojové učenie často nazývané aj ako srdce umelej inteligencie predstavuje nový inovatívny nástroj FinTech, ktorý umožňuje tvorbu nových inovatívnych FinTech modelov či produktov.

2 Strojové učenie (Machine learning)

Strojové učenie môžeme definovať, ako schopnosť počítačov učiť sa a konať bez toho, aby boli explicitne naprogramované. Strojové učenie tak hľadá funkciu, vzťah od vstupu X k výstupu Y, taktiež nám umožňuje riešenie problémov, pri ktorých nevieme dopredu definovať ako by mal výsledok vyzerieť. Rovnako v priebehu rokov tradičné metódy strojového učenia (ML) preukázali silnú schopnosť v predikcii trendov cien investičných aktív (Zhang et al., 2017; Ruta, 2014; Patel et al., 2015).

V súčasnosti existuje veľké množstvo machine learning algoritmov, ktoré sú špecifické pre problém, ktorý sa snažia vyjadriť. Práca bližšie rozoberá relevantné prístupy strojového učenia pre investora využívané pri predikcii investičných aktív, čiže algoritmy s najlepšimi výsledkami pri zameraní na dáta dlhých časových radov, ktoré pri analýze finančných trhov predstavujú chronologickú zbierku pozorovaní vývoja cien a objemu obchodovania (Fu et al., 2005).

Algoritmy strojového učenia môžeme rozdeliť na tri hlavné kategórie:

1. supervised learning (učenie pod dohľadom, s učiteľom),
2. unsupervised learning (učenie bez dohľadu, bez učiteľa),
3. reinforcement learning (učenie formou odmeňovania).

Pri supervised learning vytvára strojové učenie model na základe označených z ang. labelled údajov, čo algoritmu umožňuje definovať vstupné a výstupné hodnoty. Na týchto dátach sa potom algoritmus trénuje spôsobom, aby vedel pre daný vstup automaticky vyprodukovať požadovaný výstup na základe parametrov vybraného algoritmu. Po natrénovaní je stroj naučený predpovedať očakávaný výstup pre vstupný údajový bod.

Unsupervised learning sa využíva pre neoznačené z ang. unlabelled údaje, ktoré neboli vopred klasifikované. Cieľom algoritmov učenia bez učiteľa je potom v týchto neklasifikovaných dátach nájsť, modelovať a popísať vzory, koreláciu alebo zhuk v danom súbore údajov. Učenie bez učiteľa môže byť rovnako využité ako nástroj úpravy dát pre úlohy učenia s učiteľom (Bhardwaj et al., 2015).

Reinforcement learning algoritmy predstavujú osobitnú kategóriu strojového učenia, kde pre učenie modelu nie sú využívané označené, či neoznačené údaje. Zahŕňa stratégiu učenia na základe

vytvoreného systému (agenta), ktorý je osadený do prostredia, kde sa prostredníctvom interakcie (postupnosť akcií, pozorovaní a odmien) s prostredím učí (Kober et al., 2013).

Podľa Bernal et al. (2012) prístupy strojového učenia, špeciálne práve supervised learning algoritmy dosahujú pri predikcii investičných aktív sľubné výsledky. Techniky učenia pod dohľadom, ako napríklad Support Vector Machine (SVM) a Recurrent Neural Networks (RNN), sú schopné naučiť sa predpovedať ceny a trendy na finančných trhoch na základe historických údajov a poskytovať zmysluplnú analýzu historických cien.

Vedci, analytici a obchodníci sa väčšinou zameriavajú na krátkodobé (denné, týždenné, mesačné) predpovedanie cien finančných aktív založené na historických údajoch v porovnaní s tvorbou modelov na základe dlhých časových radov.

Autori Shah, Isah, a Zulkernine (2019) poukazujú na existenciu výskumu novších algoritmov strojového učenia, akými sú modely ARIMA a nové prístupy k umelej neurónovej sieti (ANN), konkrétne algoritmus LSTM, ktoré sú porovnávané s existujúcimi prístupmi pri predpovedaní dlhodobých závislostí v dátach a predstavujú pre investorov nové možnosti pri tvorbe modelov.

Xiong et al. (2016) aplikovali neurónovú sieť Long Short-Term Memory na modelovanie volatility akciového indexu S&P 500 s trendmi spoločnosti Google ako indikátormi makroekonomických faktorov, v práci využívali predpovedanie implicitnej volatility, ktoré napomáha pri predpovedaní cien akcií. Okrem OHLC denných historických údajov autori využívajú 25 domácich trendov, ktoré možno považovať za reprezentáciu verejného záujmu (sentiment) ako vstupné údaje. Pokiaľ ide o benchmark, používajú model GARCH ako porovnanie s modelom LSTM, pričom ich výsledky poukazujú na prekonanie výkonnosti modelu GARCH modelom LSTM.

Autori Hiransha et al. (2018) porovnávajú štyri typy hlbokých neurónových sietí (MLP, RNN, LSTM a CNN) na testovanie výkonnosti pri predpovedaní ceny na dvoch akciových trhoch. Súbor údajov denných uzatváracích cien je prevzatý z trhu National Stock Exchange of India (NSE) a New York Stock Exchange (NYSE). V tomto článku bol použitý model ARIMA ako benchmark a predstaviteľ lineárnych modelov. Výsledky práce ukazujú na prekonanie lineárneho modelu ARIMA nelineárnymi modelmi DNN.

Ding et al. (2015) využili prácu z oblasti spracovania prirodzeného jazyka (NLP) a uplatnili ju v predikcii akciového trhu. V tomto článku tím navrhol novú hlbokú neurónovú sieť (DNN) v predikcii akciového trhu riadeného udalosťami. Experimentálne výsledky ukazujú, že navrhovaný

model by mohol dosiahnuť takmer 6% zlepšenie v porovnaní s najmodernejšími základnými metódami.

Pri predpovedaní ceny finančne inovatívneho aktíva Bitcoin autori McNally et al. (2018) využívali špeciálne typy neurónových sietí RNN a LSTM. Analyzovaný dátový súbor predstavoval denné uzatváracie ceny BTC/USD vytvorené ako priemer hodnôt z 5 (v čase písania) hlavných Bitcoin zmenárni za obdobie od 19. augusta 2013 do 19. júla 2016. Na hodnotenie výkonnosti modelov autori využívajú Root Mean Squared Error (RMSE) uzatváraciej ceny a ďalej kategorizujú predikovanú cenu do kategorickej premennej odrážajúcej: cena hore, dole alebo bez zmeny. Vstupné premenné okrem dennej uzatváraciej ceny obsahujú aj informácie o otváracích, najvyšších a najnižších cenách, ako aj špecifické údaje pre Bitcoin network (mining difficulty a hash rate), a dva jednoduché kľzavé priemery (SMA). Model LSTM v príspevku dosahuje najvyššiu presnosť klasifikácie na úrovni 52% a RMSE 8%. Populárny model ARIMA na predpovedanie časových radov je implementovaný ako benchmark pre porovnanie s modelmi hlbokého učenia. Nelineárne metódy hlbokého učenia prekonávajú výsledky modelu ARIMA, ktorá dosiahla slabú výkonnosť s hodnotou RMSE na úrovni 53,74%.

Autori ako Persio a Honchar (2016); Gao, Zhang a Yang (2020); či už spomínaní autori Hiransha et al. (2018) využívali vo svojich výskumoch model Multi Layer Perceptron (MLP) na predikciu cien akcií. MLP však analyzuje iba jedno pozorovanie súčasne. Naproti tomu je výstup z každej vrstvy v rekurentnej neurónovej sieti (RNN) uložený v kontextovej vrstve, ktorá má byť naviazaná späť do výstupu s výstupom z nasledujúcej vrstvy. V tomto zmysle siete získava pamäť na rozdiel od MLP. Sieť LSTM si je tak schopná zapamätať aj dlhodobé závislosti ako už bolo poznamenané vyššie. Autori však poukazujú aj na nevýhodu siete RNN a LSTM, čím je výpočtová náročnosť. Kde napríklad 50-dňová LSTM sieť je porovnateľná s výcvikom 50 jednotlivých modelov MLP.

3 ARIMA

ARMA kombinuje autoregresné (AR) modely, ktoré sa snažia vysvetliť hybnosť (momentum), stredné efekty reverzie - často pozorované na finančných trhoch a modely kľzavého priemeru (MA), ktoré sa zameriavajú na zachytenie šokových efektov pozorovaných v časových radoch. Základným obmedzením modelu ARMA je to, že nezohľadňuje zoskupenie volatility, čo je kľúčový empirický jav v mnohých finančných časových radoch.

ARIMA je prirodzeným rozšírením triedy modelov ARMA a dokáže premeniť nestacionárnu sériu dát na stacionárnu sériu. ARIMA je prispôsobená údajom časových radov, čím odbúrava základné obmedzenia modelu ARMA pri predpovedaní budúcich bodov (Box et al., 2015).

Podľa autorov Šterba a Hil'ovska (2010) sú modely ARIMA známe svojou robustnosťou a efektívnosťou pri predpovedaní finančných časových radov a to najmä pri krátkodobých predikciách často prekonávajú aj populárnejšie ANN techniky.

Rovnako autori Ariyo et al. (2010) podporujú tvrdenie o významnosti modelov ARIMA, ktorí ich radia medzi najvýznamnejšie metódy finančného prognózovania.

Model Auto-Regressive Integrated Moving Averages (ARIMA) je široko používanou technikou pre analýzu finančných trhov. Modely ARIMA pracujú na základe nasledujúcich predpokladov:

1. dátový rad je stacionárny, čo znamená, že priemer a rozptyl by sa nemali meniť s časom (sériu je možné urobiť stacionárnou pomocou log transformácie alebo diferenciácie série),
2. dáta poskytnuté ako vstup musia byť vo forme jednorozmernej série, pretože ARIMA používa minulé hodnoty na predpovedanie budúcich hodnôt (Hiransha et al., 2018).

ARIMA má tri zložky p, q, d, ktoré predstavujú:

1. AR (autoregresná zložka z ang. AutoRegressive) - predstavuje minulú hodnotu použitú na predpoveď nasledujúcej hodnoty. Výraz AR je v ARIME definovaný parametrom „p“.
2. I (diferenciačná zložka z ang. Integrated) - predstavuje poradie diferenciácie, ktoré určuje počet opakovaní diferenčnej operácie na sérii, aby sa zabezpečila stacionarita. Výraz I je v ARIME definovaný parametrom „d“.
3. MA (zložka kľzavý priemer z ang. Moving Average) - termín sa používa na definovanie počtu minulých chýb predpovede použitých na predpovedanie budúcich hodnôt. Parameter „q“ v modely ARIMA predstavuje pojem MA.

Špeciálnym typom ARIMA modelov je model Seasonal ARIMA (SARIMA), ktorý sa využíva za predpokladu, že dataset časového radu obsahuje sezónnosť. Model SARIMA využíva na zohľadnenie jednotlivých období niekoľko parametrov navyše voči modelom ARIMA.

SARIMA môže byť definovaná ako $ARIMA(p,d,q)(P, D, Q)_m$, kde zložky p, q, d sú zhodné s modelom ARIMA, pričom novými parametrami sú:

1. m - odkazuje na počet období v každej sezóne,
2. (P, D, Q) - predstavuje (p, d, q) pre sezónnu časť časového radu (Pongdatu –Putra, 2018).

4 Support Vector Machines (SVM)

Autori Cortes a Vapnik (1995) predstavili Support Vector Machines (SVM), ktoré predstavujú často využívanú alternatívu k využitiu iných modelov kvôli ich schopnosti nájsť globálne maximum a inherentnému talentu odbúrať over-fitting pomocou regularizácie a minimalizácie chyby generalizácie.

Základnou myšlienkou SVM je transformovať údaje, ktoré sú nelineárne oddeliteľné v pôvodnom priestore do priestoru vyšších dimenzií, v ktorom môžu byť oddelené jednoduchou nadrovinou. Oddelenie bodov nájdením maximálneho rozpätia medzi podpornými vektormi (support vectors) a nadrovinou umožňuje SVM väčšiu spoľahlivosť v porovnaní s metódami, ako je lineárna regresia, ktoré nachádzajú vhodné, ale nie optimálne oddelenie (Pai et al., 2011).

Autori Meesad et al. (2013) dokázali, že pri správnom definovaní parametrov použitých pre vstupné vektory, modely SVM prekonal modely ako napríklad spätné šírenie umelých neurónových sietí (ANN) z hľadiska minimalizácie chýb a celkovej presnosti modelu.

V dôsledku transformácie údajov do lineárne oddeliteľného priestoru môžu tieto vstupné vektory trpieť tzv. kľatbou rozmerov, ktorá si vyžaduje množstvo pamäte a výpočtového času na tréningovanie (Wang, 2014).

SVM predstavuje vzťah medzi výstupom y a množinou vstupov x vo forme (Cortes – Vapnik, 1995):

$$f(x) = \sum_{i=1}^N w_i \Phi(x) + b \quad (1)$$

kde $\Phi(x)$ predstavuje nelineárne mapovanie x do priestoru vyšších dimenzionálnych znakov, t. j. bázikú funkciu, a w a b sú parametre naučené z N prípadov tréningových dát.

Hlavnou nevýhodou SVM sú už spomenuté veľmi vysoké požiadavky na výpočtovú silu, čas, SVM má však aj viacero výhod, medzi ktoré patria napríklad:

1. potreba definovať iba dva voľné parametre, hornú hranicu a parameter jadra (kernel),
2. riešenie SVM je jedinečné, optimálne a globálne, pretože učenie SVM sa vykonáva riešením lineárne obmedzeného kvadratického problému,
3. SVM sú založené na princípe minimalizácie štruktúrneho rizika, preto tento typ klasifikátora minimalizuje hornú hranicu skutočného rizika, zatiaľ čo iné klasifikátory minimalizujú empirické riziko (Shin et al., 2005).

5 Long Short-Term Memory (LSTM)

Umelé neurónové siete (ANN) sú nelineárne modely, ktoré simulujú procesy medzi neurónmi a synapsiami v mozgu s cieľom modelovať zložité problémy. Ich využitie je populárne pri predpovedaní akciového trhu kvôli svojej povahe čiernej skrinky, ktorá umožňuje používateľom vyskúšať ľubovoľné množstvo premenných (features) na generovanie použiteľných výsledkov bez toho, aby museli vedieť, akým spôsobom algoritmus funguje a generuje výsledky.

Existuje mnoho variácií umelých neurónových sietí, ktoré sa dajú použiť na predpovedanie časových radov. Príkladom najjednoduchšieho variantu je Multilayer Perceptrons (MLP), alebo Convolutional Neural Networks (CNN), ktoré kódujú informácie o cene do obrazových formátov. Pre použitie na časové rady finančných trhov sú však vhodnejšie pamäťové siete, ako sú siete Recurrent Neural Networks (RNN) a Long Short-Term Memory (LSTM), ktoré umožňujú zapamätanie a zabudnutie predpovedí, čo môže byť užitočné pri predpovedaní extrémnych zmien v krátkom čase prostredníctvom zapamätania si predchádzajúcich príkladov (Chen – Zhou – Dai, 2015).

V porovnaní s inými modelmi sú RNN a LSTM vhodné na sekvenčné údaje, ako sú ceny akcií, dlhopisov, či Bitcoinu zatiaľ čo iné modely musia brať nesekvenčnú interpretáciu údajov nezávislú od vzorky, berúc do úvahy iba jednu vstupnú a výstupnú vzorku súčasne.

Autori Di Persio a Honchar (2017) poukazujú v ich analýze na sieť LSTM (Long Short-Term Memory) a jej vysokú efektívnosť pri predikcii časových radov, kde autori použili na hodnotenie ceny akcií Google tri rôzne RNN modely (základnú RNN, LSTM a Gated Recurrent Unit (GRU))

aby vyhodnotili, ktorý RNN algoritmus je najvhodnejší pri práci s finančnými časovými radmi. Z výsledkov bolo zrejmé, že LSTM v päťdňovom horizonte predstihol iné RNN varianty so 72% presnosťou.


Roondiwala et al. (2017) implementovali sieť LSTM na predpovedanie cien indexu Nifty so vstupnými parametrami denných cien OHLC. Ich výsledky ukazujú, že LSTM dosahuje RMSE 0,00859 pre testovacie dáta, čo sa týka denných percentuálnych zmien.

Práca Shah et al. (2018) ukazuje, že model LSTM poskytuje nielen vynikajúce výsledky pre denné predpovede (na jeden deň dopredu), ale poskytuje aj viac než slušné výsledky na predpovedanie v dlhodobějších horizontoch (predpovede na 7 dní) iba s využitím dennej ceny ako funkcie. Autori zámerne využili väčší súbor tréningových údajov (údaje o cenách za 20 rokov), pretože toto obdobie zahŕňa viac býčích a medvedích cyklov trhu. To má za úlohu umožniť modelu LSTM lepšie možnosti učiť sa, a tým zvýšiť nádej na uplatnenie v budúcich časových obdobiach s podobnými pohybmi na trhu.

Siete LSTM sú typom Recurrent Neural Networks (RNNs), ktoré sú schopné naučiť sa závislosť poradia pri problémoch s predikciou sekvencie. Táto vlastnosť sa vyžaduje pri riešení zložitých problémov, ako je predpoveď časových radov, strojový preklad, či rozpoznávanie reči a jazyka.

Základným problémom používania tradičných neurónových sietí na otázky časových radov je skutočnosť, že štandardné neurónové siete si nie sú schopné zapamätať predchádzajúce informácie a tým pádom ich nemôžu brať do úvahy. Toto je hlavný nedostatok najmä pre datasety časových radov z dôvodu autokorelácie (Colah, 2015).


Tento problém riešia práve Recurrent Neural Networks (RNNs). RNN obsahuje vo svojej štruktúre slučky, ktoré im umožňujú zapamätať si a zohľadniť predchádzajúce informácie k súčasnej úlohe. Problémom RNNs pre súbor údajov časových radov je, že keď RNN v určitom okamihu narastajú, začínajú zabúdať na predchádzajúce informácie, pretože nie sú schopné prepojiť (preklenúť) väčšie medzery. Tento jav sa nazýva vanishing gradient problem a keďže nie sú schopné zvládnuť dlhodobé závislosti, nie sú vhodné na predpovedanie dlhých časových radov (Graves, 2009).



Obr. 1 RNNs vanishing gradient problem

Zdroj: Colah, 2015

Vanishing gradient problem vyvoláva pochybnosti o tom, či štandardné RNN môžu skutočne vykazovať významné praktické výhody oproti štandardným neurónovým sieťam bez pamäte pri aplikovaní na časové rady finančných aktív. Tento problém rieši model LSTM ako nadstavba štandardných RNNs.



Obr. 2 LSTM

Zdroj: Colah, 2015

LSTMs sú schopné naučiť sa prekonávať veľké medzery v datasete v rámci špeciálnych jednotiek nazývaných bunky (cells). Úspešnosť LSTMs spočíva v tvrdení, že predstavujú nástroj, ktorý rieši technické problémy RNNs.

LSTMs boli explicitne navrhnuté spôsobom, aby boli schopné zabrániť problém dlhodobých závislostí. Pamätanie si informácii za dlhé časové obdobie je ich základnou charakteristikou a nie je to nič čo by sa museli učiť (Gers, Schmidhuber & Cummins, 2000).

Týmto sú LSTMs ako špeciálny druh Recurrent Neural Networks (RNNs) obzvlášť vhodné na riešenie problémov s časovými radmi, a preto sa stali populárnymi pri pokuse o prognózu akciových trhov, čo môžeme využiť aj pri zameraní sa na trh kryptomien a Bitcoin ako investičné aktívum.

6 Záver

Každý investor či trader by chcel vytvoriť model, algoritmus, ktorý by prekonal trh, ktorý by bol automatizovaný, fungoval by bez potreby ľudskej intervencie a ktorý by pracoval bez ľudských emócií a chýb. V minulosti tradičné prístupy tvorby analýz, investičných modelov, či predikcií budúceho vývoja boli založené na neustálom manuálnom vylepšovaní výstupov na základe minulých skúsenosti. Umelá inteligencia a strojové učenie by však mohli byť kľúčom k budúcemu vytváraniu investičných modelov, predpovedí, pretože nám umožňuje vytvárať modely, aj keď dopredu nevieme, ako by mal výsledok vyzerat'. Príspevok ponúka ucelený obraz problematiky využitia umelej inteligencie a jej hlavného predstaviteľa strojového učenia pri riešení investičných modelov rozličnými autormi vo svete.

Príslušnosť k projektu

Tento príspevok je súčasťou projektu I-21-112-00: Využitie nástrojov umelej inteligencie na podporu finančných technológií.

Použitá literatúra

BHARDWAJ, A. – NARAYAN, Y. – DUTTA, M. 2015. *Sentiment analysis for Indian stock market prediction using Sensex and nifty*. In: *Procedia Computer Science*, 70 (1), s. 85–91. doi: 10.2307/2284112.

BOX, B. – GEORGE, E. P – GWILYM, M. J. – REINSEL, G. C – LJUNG, G. M. 2015. *Time Series Analysis: Forecasting and Control*. In: Journal of the American Statistical Association, 342 (68), s. 493–494. doi: 10.1109/BigData.2015.7364089.

CAVALCANTEA, R. C. – BRASILEIROB, R. C. – SOUZAB, V. F. – NOBREGAB, J. P. – OLIVEIR, A. I. 2016. *Computational intelligence and financial markets: a survey and future directions*. In: Expert Systems with Applications, 55 (1), s. 194–211. doi: 10.1016/j.eswa.2016.02.006.

CHEN, J. 2010. *SVM application of financial time series forecasting using empirical technical indicators*. In: ICINA information networking and automation, 10 (1), s. 1–77. doi: 10.1109/ICINA.2010.5636430.

CHEN, K. – ZHOU, Y. – DAI, F. 2015. *A LSTM-based method for stock returns prediction: A case study of China stock market*. In: International Conference on Big Data (Big Data), s. 2823–2824. doi: 10.1109/BigData.2015.7364089.

COLAH, C. 2015. *Understanding LSTM Networks*. In: Stanford [online] 2015 [cit. 2021-12-10]. Dostupné na internete: <
https://web.stanford.edu/class/cs379c/archive/2018/class_messages_listing/content/Artificial_Neural_Network_Technology_Tutorials/OlahLSTM-NEURAL-NETWORK-TUTORIAL-15.pdf >.

CORTES, C. – VAPNIK, V. 1995. *Support-vector networks*. In: Machine learning, 20 (3), s. 273–297. doi: 10.1007/BF00994018.

DING, X. – ZHANG, Y. – LIU, T. – DUAN, J. 2015. *Deep Learning for Event-Driven Stock Prediction*. In: Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015) [online] [cit. 2021-12-10]. Dostupné na internete: <
<https://www.ijcai.org/Proceedings/15/Papers/329.pdf> >.

DI PERSIO, L. – HONCHAR, O. 2016. *Artificial Neural Networks architectures for stock price prediction: comparisons and applications*. In: International Journal of Mathematics and Computers in Simulation [online] [cit. 2021-12-10]. Dostupné na internete: <
<https://www.naun.org/main/NAUN/circuitssystemsignal/2016/b482005-303.pdf> >.

DI PERSIO, L. – HONCHAR, O. 2017. *Recurrent neural networks approach to the financial forecast of Google assets*. In: International Journal of Mathematics and Computers in Simulation [online] [cit. 2021-12-10]. Dostupné na internete: <<https://www.naun.org/main/NAUN/mcs/2017/a042002-041.pdf>>.

FU, T.-CH. – CHUNG, F.-L. – LUK, R. W. P. – NG, C.-M. 2005. *Preventing Meaningless Stock Time Series Pattern Discovery by Changing Perceptually Important Point Detection*. In: International Conference Fuzzy Systems and Knowledge Discovery, s. 27–29. doi: 10.1007/11539506_146.

GAO, P. – ZHANG, R. – YANG, X. 2020. *The Application of Stock Index Price Prediction with Neural Network*. In: Mathematical and Computational Applications, 25 (3), 53, doi: 10.3390/mca25030053.

GERS, F. A. – SCHMIDHUBER, J. – CUMMINS, F. 2000. *Learning to forget: continual prediction with LSTM*. In: Ninth International Conference on Artificial Neural Networks, 12 (10), s. 850–855. doi: 10.1049/cp:19991218.

GRAVES, A. – LIWICKI, M. – SCHMIDHUBER, J. – FERNÁNDEZ, R. – BERTOLAMI, R. – BUNKE, H. 2009. *A Novel Connectionist System for Unconstrained Handwriting Recognition*. In: IEEE Transactions on Pattern Analysis and Machine Intelligence, 31 (5), s. 855–868. doi: 10.1109/TPAMI.2008.137.

HIRANSHA, M. – GOPALAKRISHNAN, E. A. – MENON, V. K. – SOMAN, K. P. 2018. *NSE Stock Market Prediction Using Deep-Learning Models*. In: Procedia Computer Science, 132 (1), s. 1351–1362. doi: 10.1016/j.procs.2018.05.050.

KOBER, J. – BAGNELL, J. A. – PETERS, J. 2013. *Reinforcement learning in robotics: a survey*. In: The International Journal of Robotics Research, 32 (11), s. 1238–1274. doi: 10.1177/0278364913495721.

MALAGRINO, L. S. – ROMAN, N. T. – MONTEIRO, A. M. 2018. *Did the Profitability of Momentum and Reversal Strategies Decline with Arbitrage Costs After the Turn of the Millennium?* In: The Journal of Portfolio Management, 41 (3), s. 70–83. doi: 10.1016/j.eswa.2018.03.039.

MCNALLY, S. – ROCHE, J. – CATON, S. 2018. *Predicting the price of bitcoin using machine learning*. In: Proceedings - 26th Euromicro international conference on parallel, distributed, and network-based processing, s. 339–343. doi: 10.1109/PDP2018.2018.00060.

MEESAD, P. – RASEL, R. I. 2013. *Predicting stock market price using Support Vector Regression*. In: International Conference on Informatics, Electronics and Vision, s. 1–6. doi: 10.1109/ICIEV.2013.6572570.

PAI, P. -F. – HSU, M. -F. – WANG, M. -C. 2011. *A support vector machine-based model for detecting top management fraud*. In: Knowledge-Based Systems, 24 (2), s. 314–321. doi: 10.1016/j.knosys.2010.10.003.

PATEL, J. – SHAH, S. – THAKKAR, P. – KOTTECHA, K. 2015. *Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques*. In: The Journal of Wealth Management, 18 (4), s. 75–89. doi: 10.1016/j.eswa.2014.07.040.

ROONDIWALA, M. – PATEL, H. – VARMA, S. 2015. *Predicting Stock Prices Using LSTM*. In: International Journal of Science and Research, 6 (4), s. 1754–1756. doi: 10.21275/ART20172755.

RUTA, D. 2014. *Automated trading with machine learning on big data*. In: BigData Congress, 3 (1), s. 259–268. doi: 10.1109/BigData.Congress.2014.143.

SHAH, D. – CAMPBELL, W. – ZULKERNINE, F. 2018. *A Comparative Study of LSTM and DNN for Stock Market Forecasting*. In: International Conference on Big Data (Big Data), s. 4148–4155. doi: 10.1109/BigData.2018.8622462.

SHAH, D. – ISAH, H. – ZULKERNINE, F. 2019. *Stock Market Analysis: A Review and Taxonomy of Prediction Techniques*. In: International Journal of Financial Studies, 7 (2), s. 26–48. doi: 10.3390/ijfs7020026.

ŠTERBA, J. – HILOVSKA, K. 2018. *The implementation of hybrid ARIMA neural network prediction model for aggregate water consumption prediction*. Aplimat- Journal of Applied Mathematics. In: Aplimat – Journal of Applied Mathematics, [online]. 3 (3), s. 123–130. [cit. 2021-12-10]. Dostupné na internete: <
https://www.aplimat.com/files/Journal_volume_3/Number_3.pdf>.

WANG, Y. 2014. *Stock price direction prediction by directly using prices data: an empirical study on the KOSPI and HSI*. In: International Journal of Business Intelligence and Data Mining, 9 (2), s. 145–160. doi: 10.1504/IJBIDM.2014.065091.

XIE, Q. 2011. *The optimization of share price prediction model based on support vector machine*. In: Automation and Systems Engineering, s. 1–4. doi: 10.1109/ICCASE.2011.5997714.

XIONG, R. – NICHOLS, E. P. – SHEN, Y. 2016. *Deep Learning Stock Volatility with Google Domestic Trends*. In: Cornell University, [online]. 2016 [cit. 2021-12-10]. Dostupné na internete: < <https://arxiv.org/pdf/1512.04916.pdf> >.

ZHANG, J. – CUI, S. – XU, Y. – LI, Q. – LI, T. 2017. *A novel data-driven stock price trend prediction system*. In: Expert Systems with Applications, 97 (1), s. 60–69. doi: 10.1016/j.eswa.2017.12.026.

Kontaktné údaje

Ing. Milan Cibula

Katedra finančného riadenia podniku

Podnikovohospodárska fakulta so sídlom v Košiciach

Ekonomická univerzita v Bratislave

Tajovského 13

041 30 Košice

Slovenská republika

milan.cibula@euba.sk