

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2018

Bc. Adam Nimrichter



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

ANALÝZA FINANČNÍCH TRHŮ S POMOCÍ HLUBOKÉHO UČENÍ

FINANCIAL MARKET ANALYSIS USING DEEP LEARNING ALGORITHM

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Adam Nimrichter

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jan Mašek, Ph.D.

BRNO 2018



Diplomová práce

magisterský navazující studijní obor **Telekomunikační a informační technika**

Ústav telekomunikací

Student: Bc. Adam Nimrichter

ID: 158203

Ročník: 2

Akademický rok: 2017/18

NÁZEV TÉMATU:

Analýza finančních trhů s pomocí hlubokého učení

POKYNY PRO VYPRACOVÁNÍ:

Prostudujte aktuální metody pro analýzu finančních trhů, zejména se zaměřte na virtuální měny. Dále prostudujte hluboké neuronové sítě (LSTM) a finanční strategie (RSI, moving momentum, ...). Vytvořte systém, který se bude skládat z predikce budoucí hodnoty virtuální měny a dále bude na základě finanční strategie rozhodnuto o prodeji nebo koupi měny. Natrénujte modely pro 4 nejvýznamnější virtuální měny a dále proveďte optimalizace modelů pro LSTM i pro finanční strategie. Výsledky diskutujte a vykreslete v grafech.

DOPORUČENÁ LITERATURA:

[1] D. M. Q. Nelson, A. C. M. Pereira and R. A. de Oliveira, "Stock market's price movement prediction with LSTM neural networks," 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, 2017, pp. 1419-1426. doi: 10.1109/IJCNN.2017.7966019

[2] R. Akita, A. Yoshihara, T. Matsubara and K. Uehara, "Deep learning for stock prediction using numerical and textual information," 2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS), Okayama, 2016, pp. 1-6. doi: 10.1109/ICIS.2016.7550882

Termín zadání: 5.2.2018

Termín odevzdání: 21.5.2018

Vedoucí práce: Ing. Jan Mašek, Ph.D.

Konzultant:

prof. Ing. Jiří Mišurec, CSc.
předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Práce se zabývá metodami pro analýzu finančních trhů zaměřených na virtuální měny. V souvislosti s virtuálními měnami je v teoretické části práce pojednáno o technologii decentralizované databáze, pomocných finančních indikátorech a umělých neuronových sítích s rekurentní architekturou. Konkrétním cílem práce je vytvořit systém pro udělení doporučení k nákupu, či prodeji dané měny. Systém sestává z navržené finanční strategie a predikované hodnoty, k čemuž je využito finančních ukazatelů a neuronové LSTM sítě. Testování bylo realizováno na historických datech z roku 2017 pro měny Bitcoin, Litecoin a Ethereum.

KLÍČOVÁ SLOVA

Neuronová síť, virtuální měna, predikční systém, LSTM, Keras, TensorFlow.

ABSTRACT

The thesis deals with methods for analysis of financial markets, focused on cryptocurrencies. The theoretical part, in a context of virtual currencies, describes block-chain technology, financial indicators and neural networks with recurrent architectures. Main goal is to create a system for giving a recommendation either for buy, or sell the currency. The system consists of designed financial strategy and predicted value of the currency, for which is used financial indicators and LSTM neural network. Tests were performed on Bitcoin, Litecoin and Ethereum historical data from year 2017.

KEYWORDS

Neural network, virtual currency, prediction system, LSTM, Keras, TensorFlow.

NIMRICHTER, Adam. *Analýza finančních trhů s pomocí hlubokého učení*. Brno, 2018, 61 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací. Vedoucí práce: Ing. Jan Mašek, Ph.D

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Analýza finančních trhů s pomocí hlubokého učení“ jsem vypracoval(a) samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor(ka) uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil(a) autorská práva třetích osob, zejména jsem nezasáhl(a) nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom(a) následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora(-ky)

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Janu Maškovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Brno

.....

podpis autora(-ky)



Faculty of Electrical Engineering
and Communication
Brno University of Technology
Purkynova 118, CZ-61200 Brno
Czech Republic
<http://www.six.feec.vutbr.cz>

PODĚKOVÁNÍ

Výzkum popsany v této diplomové práci byl realizován v laboratořích podpořených z projektu SIX; registrační číslo CZ.1.05/2.1.00/03.0072, operační program Výzkum a vývoj pro inovace.

Brno

.....
podpis autora(-ky)



EVROPSKÁ UNIE
EVROPSKÝ FOND PRO REGIONÁLNÍ ROZVOJ
INVESTICE DO VAŠÍ BUDOUCNOSTI



OBSAH

Úvod	11
1 Současné metody analýz pro předpověď vývoje finančního trhu	12
1.1 Časové řady	13
1.2 Pomocné indikátory technické analýzy	13
2 Učící se algoritmy umělé inteligence	16
2.1 Hluboké učení	16
2.2 Neuronové sítě	18
2.3 Rekurentní neuronové sítě (RNN)	20
2.4 Systém zpětné propagace	22
2.5 LSTM sítě	24
3 Virtuální měny	27
3.1 Historie	27
3.2 Virtuální měny	27
3.3 Technologie decentralizované databáze	28
3.4 Nejpoužívanější virtuální měny	28
4 Návrh systému	29
4.1 Pracovní prostředí	30
4.1.1 Keras	30
4.1.2 TensorFlow	30
4.2 Popis navrženého řešení	31
4.2.1 Vstupní data	31
4.2.2 Příprava dat	32
4.2.3 LSTM	33
4.2.4 Strategie	40
5 Testování	43
5.1 Způsob testu	43
5.2 Výsledky	45
6 Závěr	52
Literatura	54
Seznam symbolů, veličin a zkratk	58

SEZNAM OBRÁZKŮ

2.1	Porovnání výkonosti s množstvím předložených dat.	17
2.2	Základní topologie umělé neuronové sítě [21].	18
2.3	Obecný neuron.	19
2.4	Průběhy aktivačních funkcí.	20
2.5	Rekurentní neuron.	20
2.6	Topologie rekurentní neuronové sítě.	21
2.7	Jednoduchý příklad LSTM.	24
2.8	Příklad LSTM paměťového bloku.	25
4.1	Schéma navrženého systému pro udělení doporučení.	29
4.2	Příklad predikce více krokového sekvenčního modelu.	33
4.3	Konkrétní příklad predikce více krokového sekvenčního modelu.	33
4.4	Porovnání různých optimalizačních technik.	34
4.5	Přesnost různých optimalizačních technik.	34
4.6	Porovnání aktivačních funkcí.	35
4.7	Porovnání aktivační funkce <i>tanh</i> a <i>linear</i>	35
4.8	Výsledky testování parametru dropout.	36
4.9	Test topologie s jednou vrstvou a s rozdílným počtem neuronů.	37
4.10	Test topologie se dvěma vrstvami a 32 neurony v první vrstvě.	37
4.11	Test topologie se třemi vrstvami, 32 neuronů v první vrstvě a 64 neuronů ve vrstvě druhé.	38
4.12	Test velikosti okna na přesnost predikce.	38
4.13	Grafická vizualizace navržené neuronové sítě.	39
4.14	Vstupní data bloku Strategie.	40
4.15	Grafická interpretace navržené obchodní strategie.	40
5.1	Struktura dat pro trénink základního modelu.	43
5.2	Graficky znázorněný způsob testování.	44
5.3	Pseudokód pro přetrénování modelu.	44
5.4	Pseudokód pro validaci modelu.	45
5.5	Modelem predikované hodnoty na neznámých datech.	46
5.6	Testování přesnosti predikce základního modelu na známých datech.	46
5.7	Hodnota RMSE měřená na tréninkových datech v průběhu roku.	47
5.8	Hodnota RMSE měřená na validačních datech v průběhu roku.	47
5.9	Odchylka predikované a skutečné hodnoty v čase $t+1$	48
5.10	Odchylka predikované a skutečné hodnoty v čase $t+2$	48
5.11	Odchylka predikované a skutečné hodnoty v čase $t+3$	49
5.12	Test počtu průchodů dat sítí během přetrénování pro hodnoty $t+1$	49
5.13	Test počtu průchodů dat sítí během přetrénování pro hodnoty $t+2$	50

5.14	Test počtu průchodů dat sítí během přetrénování pro hodnoty $t+3$. . .	50
6.1	Výstup testování systému za rok 2017 na virtuální měně Bitcoin. . . .	59
6.2	Výstup testování systému za rok 2017 na virtuální měně Litecoin. . .	60
6.3	Výstup testování systému za rok 2017 na virtuální měně Ethereum. . .	61

SEZNAM TABULEK

3.1	Tržní hodnota nejúspěšnějších virtuálních měn k datu 15.03.2018 [22].	28
4.1	Příklad transformace dat pro učení s učitelem	33
4.2	Popis parametrů neuronové sítě	39
5.1	Testování úspěšnosti systému.	51

ÚVOD

Žijeme v době, kdy nás digitální data každodenně obklopují doslova na každém kroku. Dnes jsme jimi přemíru zahlceni a i proto v nedávné minulosti vznikla potřeba tato data dále zpracovávat a třídit. To se ukázalo jako velmi výhodné z mnoha různých úhlů pohledu. Analýzou digitálních dat lze, mimo jiné, odhalit opakující se vzory v chování, čehož lze využít například při obchodování na burze.

Obchodování na burze bylo dříve výsadou pouze velkých korporací a bank, což se ale změnilo s nástupem internetu. S příchodem mnoha různých obchodních platforem se obchodování otevřelo i běžným lidem, kterým pro založení účtu stačí pouze základní kapitál v řádu tisíců korun. V dnešní době se tedy obchoduje s mnoha různými komoditami, mezi které patří mimo jiné i virtuální měny, které se v současnosti těší stále rostoucí popularitě. Výstupem každé uskutečněné transakce s virtuální měnou je zápis v podobě digitálních dat, jenž je podrobně zaznamenán v obchodní knize, která je volně dostupná k nahlédnutí.

V této práci je této skutečnosti využito pro získání historických záznamů o transakcích virtuální měny Bitcoin, Ripple, Ethereum a Litecoin. Nabytá data jsou využita na výpočet pomocných finančních indikátorů, které slouží jako vstup pro neuronovou síť, jejíž úkolem je natrénovat predikční model pro předpověď budoucích hodnot. Hlavním cílem celé práce je poté vytvořit systém, sestávající z predikované hodnoty a aplikované finanční strategie, pro udělení doporučení k nákupu, či prodeji dané virtuální měny.

Mimo samotný návrh systému pro udělení doporučení, je hlavním přínosem této práce také výzkum a experimentování s časovými řadami finančního charakteru a jejich zpracování pomocí algoritmů strojového učení a umělé inteligence. Použitím navrženého systému, bylo nejvyššího profitu za uplynulý testovaný kalendářní rok 2017, dosaženo u měny Litecoin ve výši 556,8%.

Práce je rozdělena do dvou částí. První, teoretická, je rozčleněna do tří kapitol. První kapitola teoretické části pojednává o současných metodách a přístupech k analýze finančních trhů 1, popisu časových řad 1.1 a pomocných finančních indikátorů 1.2. Druhá kapitola se zabývá učícími se algoritmy umělé inteligence 2, konkrétně hlubokým učením 2.1, neuronovými sítěmi 2.2 a systémem zpětné propagace chyby 2.4. V kapitole třetí jsou popsány virtuální měny 3, jejich stručná historie 3.1 a technologie decentralizované databáze 3.3. Druhá část se věnuje návrhu systému pro udělení doporučení k nákupu, či prodeji virtuální měny. Jsou zde popsány nástroje a knihovny použité při návrhu systému 4.1, charakter vstupních dat a jejich předzpracování 4.2.1, návrh a test hyperparametrů neuronové sítě 4.2.3, obchodní strategie 4.2.4 a test funkčnosti systému 5.1.

1 SOUČASNÉ METODY ANALÝZ PRO PŘEDPOVĚĎ VÝVOJE FINANČNÍHO TRHU

Analýzou chování a vývojem finančních trhů se již po dlouhá desetiletí zabývají nej-různější vědní obory od ekonomie, přes fyziku, psychologii, statistiku, až po počítačové vědy. Vlivem neustálého masivního rozvoje informačních technologií a mnohem snazší dostupnosti k obchodování na burze se tak tato oblast stala velmi perspektivní nejen pro velké korporace, ale stala se i předmětem zájmu široké veřejnosti. Sestavení funkčního vzoru, pomocí kterého by bylo možno dosáhnout přesné a neomylné predikce budoucího vývoje finančního trhu je ovšem nesmírně složitý úkol. Z hlediska obtížnosti se totiž jedná o velmi komplexní problematiku zahrnující velký počet dynamických faktorů a celou řadu proměnných, od aktuální politické situace, až po jednotlivé zprávy na sociálních sítích.

Na dnešních finančních trzích, kde se transakce realizují v plném rozsahu elektronickými prostředky, je drtivá většina z nich již plně zautomatizována. Odhaduje se, že více než 85% všech obchodů je uzavřeno pomocí algoritmu [9]. Vzhledem k tomu, že všechny transakce jsou podrobně digitálně zaznamenávány, můžeme na tyto data pohlížet jako na časové řady a efektivně je využít k důkladné analýze a nalezení opakujících se vzorů.

Problematikou zpracování číselných časových řad finančního charakteru za účelem predikce budoucího vývoje se zabírají například práce postavené na Boltzmanových strojích (Restricted Boltzmann Machines) [13], konvolučních neuronových sítích (CNN - Convolutional Neural Networks) [10], bayesovské regresi [8][14], nebo plastických neuronových sítích [15].

Celková analýza je tvořena spojením tří základních skupin stručně popsaných níže:

- První, fundamentální analýza, se soustředí na celospolečenskou a politickou situaci a na celkové ekonomické podmínky na základě kterých se snaží předpovědět, jakým způsobem ovlivní pohyby cen aktiv.
- Psychologická analýza, jejíž cílem je včasné odhalení tržních maxim a minim, se zabývá lidským způsobem myšlení ve chvílích, kdy trhem hýbe davové chování a trh se chová iracionálně.
- Třetí a zároveň poslední skupinou je analýza technická. Její podstatou je zkoumání historického výkonu finančních nástrojů s cílem určit vzor, dle kterého bude možné předpovědět budoucí vývoj trhu. Technická analýza i její nástroje jsou blíže popsány v kapitole 1.1.

1.1 Časové řady

Časová řada představuje chronologicky uspořádanou posloupnost hodnot určitého statistického ukazatele. Formálně je realizací náhodného procesu a její hodnoty podstatně závisí na čase v němž byly získány, přičemž tyto časové okamžiky jsou od sebe většinou vzdáleny s konstantním rozestupem. Vstupními daty pro technickou analýzu a trénink predikčního modelu jsou data finančního charakteru sestávající z následujících šesti údajů:

- Datum,
- otevírací cena,
- zavírací cena,
- cenové maximum,
- cenové minimum,
- objem obchodů.

Cílem analýzy časové řady je konstrukce vhodného modelu za účelem porozumění mechanismu generujícím hodnoty časové řady a pochopení podmínek a vazeb působících na vznik těchto hodnot.

1.2 Pomocné indikátory technické analýzy

V souvislosti s finančními daty mluvíme při jejich zkoumání o analýze technické. Předpokladem technické analýzy je promítnutí veškerých dostupných relevantních informací do tržní hodnoty daného aktiva, což zahrnuje fundamentální, psychologické, tak i technické faktory [25]. Fluktuace cen na trhu je tak přímým odrazem nabídky a poptávky, která je neustále ovlivňována v závislosti na nově příchozích informacích a reakcích na ně. Technická analýza se nicméně jednotlivými faktory podrobně nezabývá. Jejím hlavním úkolem je zachycení a zaznamenání těchto změn, bez ohledu na jejich přesnou příčinu, s cílem zorientovat se v minulosti a stanovit určité závěry pro vývoj do budoucna. Nástroji technické analýzy jsou pomocné ukazatele a indikátory, realizované různými matematickými operacemi. Základní indikátory jsou uvedeny v následující části textu 1.2. Využitím informací získaných z těchto nástrojů lze získat rozšiřující pohled nad danou situací. Nutno však poznamenat, že ohledně vyvozování závěrů získaných z těchto pomocných výpočtů neexistuje unifikovaný pohled na věc a dalo by se také říci, že závěr vyvozený z technické analýzy je vysoce individuální záležitostí, neboť každá entita využívá svých specifických přístupů a metod (know-how).

Klouzavé průměry

Klouzavé průměry (MA - Moving Average) jsou základním nástrojem trendových indikátorů a slouží k rozpoznávání trendu na trhu. Jedná se o jeden z nejstarších a také nejpoužívanějších indikátorů technické analýzy. Zpravidla se počítají ze záviracích cen, a to vždy s určitou periodou. Rozeznáváme několik typů klouzavých průměrů, jednoduchý (*MA*) a exponenciální (*EMA*).

$$MA = \frac{cena(1) + cena(2) + \dots + cena(n)}{n}, \quad (1.1)$$

kde proměnná *cena* představuje závirací cenu a proměnná *n* periodu, pro kterou *MA* počítáme. Jejich velká nevýhoda spočívá v tom, že reagují na ceny i zpětně - tedy 2x, což může vést ke zkreslení údajů. Nejprve *MA* zareaguje na novou cenu, ale pak reaguje ještě jednou, když se tato cena po určité periodě z výpočtu vypustí. Dnes se již jednoduchý *MA* téměř nepoužívá a pro přesnější zanalyzování situace na trhu lépe poslouží exponenciální klouzavé průměry, které reagují na cenu pouze jednou. Zde je to popsáno rovnicí:

$$EMA[t] = (cena[t] * K) + (EMA[t - 1] * (1 - K)), \quad (1.2)$$

kde

$$K = \frac{2}{n + 1}. \quad (1.3)$$

Na rozdíl od jednoduchého *MA*, přiklání *EMA* větší důraz na poslední změny ceny a nereaguje již zavádějícími pohyby na starší data.

RSI

Index relativní síly (RSI - Relative Strength Index) měří rychlost a změnu cenového pohybu. Obvyklou standardní délkou je perioda 14. Je dobrým indikátorem v trendových obdobích, ale dá se také využívat do netrendových trhů k protitrendovému obchodování. Indikátor se pohybuje mezi spodní hranicí (0) a horní hranicí (100), přičemž se zde nastavují překoupené a přeprodané úrovně. Standardně je to 20 a 80 bodů (nebo také 30 a 70 bodů či 35 a 75 bodů) pro trhy bez trendu a 40 a 60 bodů pro trhy s trendem. Díky těmto hranicím překoupenosti a přeprodanosti se dá dobře načasovat vstup do obchodu ještě před tím, než na trhu nastane vůbec nějaký pohyb [25]. Vzorec pro výpočet tohoto indikátoru je následující:

$$RSI = 100 - \frac{100}{1 + RS}, \quad (1.4)$$

kde

$$RS = \frac{\text{Průměrný zisk}}{\text{Průměrná ztráta}}. \quad (1.5)$$

Momentum

Tento indikátor ukazuje rychlost trendu a jeho akceleraci/zpomalení tím, že porovná současnou cenu s cenou z minulého období [25]. Jestliže je současná cena vyšší, než cena z období minulého, je trend rostoucí a indikátor zakresluje kladné hodnoty. Pokud je naopak aktuální cena nižší, je trend klesající a indikátor zakresluje hodnoty záporné. Obecně lze říci, že pokud se indikátor pohybuje nad nulovou úrovní, vyplatí se vstupovat do dlouhých pozic a když se pohybuje pod nulovou úrovní, vyplatí se vstupovat do krátkých pozic. Samotné překřížení nulové linie však žádné významnější signály nepřináší.

$$\text{Momentum} = \frac{\text{Dnešní zavírací cena}}{\text{Zavírací cena před } N \text{ dny}}, \quad (1.6)$$

hodnota N se standardně pohybuje v rozmezí od 5 do 20 dní, převážně se ale odvíjí od zvoleného obchodního stylu a strategie. Momentum je u většiny obchodníků využíváno hlavně na protitrendové obchodování a odhalení divergencí.

MACD

Jedním z nejpopulárnějších indikátorů technické analýzy je sbíhavost a rozbíhavost klouzavých průměrů (MACD - Moving Average Convergence/Divergence) [25]. Skládá se ze dvou křivek – rychlé a pomalé. Rychlá křivka je tvořena rozdílem dvou klouzavých průměrů (standardně EMA 12 a EMA 26), pomalá je vyhlazená dalším EMA od křivky rychlé (standardně o EMA 9), tudíž reaguje na ceny o něco pomaleji. Jakmile rychlá křivka překříží zespoda křivku pomalou, značí to předpokládaný nárůst cen. Pokud rychlá křivka překříží shora křivku pomalou, jedná se naopak o signál pravděpodobného budoucího poklesu.

2 UČÍCÍ SE ALGORITMY UMĚLÉ INTELIGENCE

Analýzou strukturovaných dat (tzv. data miningem) se zabývají algoritmy umělé inteligence spadající do oblasti strojového učení [20]. Tato práce se věnuje tzv. učícím se algoritmům s učitelem, jejichž principem je na základě vstupního ohodnoceného souboru dat natrénovat znalost (trénovací proces - obvykle výpočetně náročný) a poté ji aplikovat (testovací proces - obvykle výpočetně nenáročný) na datech neohodnocených, s cílem dosáhnout co největší přesnosti klasifikace. Použití učících se algoritmů na datech nestrukturovaných (text, audio, video atd.) je podmíněno předzpracováním dat ve formě zvolení a vygenerování vhodných příznaků, po jejichž aplikaci následně dojde k extrahování hodnot vhodných pro učící se algoritmy.

Mezi nejvíce používané učící se algoritmy patří [23]:

- Rozhodovací stromy (DT - Decision Trees),
- k -nejbližších sousedů (k -NN - Nearest Neighbors),
- náhodné lesy (RF - Random Forests),
- neuronové sítě (NN - Neural Networks),
- systémy podpurných vektorů (SVM - Support Vector Machines).

V rámci této práce budou využity algoritmy neuronových sítí, dále popsány v 2.1.

2.1 Hluboké učení


Deep learning, nebo též hluboké učení spadá do oblasti strojového učení zaměřeného na algoritmy, schopné efektivně analyzovat a zpracovat data například v podobě textu, obrazu, hlasu atd. V posledních letech se jedná o velmi často používaný přístup pro řešení komplexnějších problémů v oblasti umělé inteligence [1]. Nejvýznamnějším a nejvíce využívaným představitelem jsou neuronové sítě imitující strukturu lidského mozku. Založeny jsou na hierarchickém vrstevném modelu, kde je každá vrstva složena z jednotlivých neuronů a učena na rozdílne sadě funkcí, přicházejících z výstupů vrstvy předchozí. Čím hlouběji se síť prochází, tím komplexnější rozsah jsou jednotlivé neurony schopny rozeznat v závislosti na tom, že všechny naučené informace jsou spojením a kombinací všech vrstev předchozích.

Rozdíl mezi klasickými učícími algoritmy umělé inteligence a hlubokým učením spočívá především ve způsobu předzpracování vstupních dat [20]. U klasických algoritmů probíhá zpracování z již předem extrahovaných hodnot obrazu, zvuku, textu, kdežto u hlubokého učení je většinou vstupem kompletní obraz, zvuk, text a jejich zpracování probíhá samotným algoritmem hlubokého učení bez předešlé interakce s daty.

Nejznámějšími algoritmy hlubokého učení jsou zejména:

- Konvoluční neuronové sítě (CNN - Convolutional Neural Networks),
- rekurentní neuronové sítě (RNN - Recurrent Neural Network),
- omezené Boltzmannovy systémy (RBM - Restricted Boltzmann Machines),
- tzv. „deep belief“ sítě (DBN - Deep Belief Networks),
- auto-ekodéry (SAE - Stacked Auto-Encoders).

Za rozmachem hlubokého učení stojí zejména významný pokrok ve studiu aplikovaných algoritmů, efektivním zpracování dat a bezpochyby také výpočetním nárůstem výkonu dnešních počítačů. Přesnost algoritmů hlubokého učení, i jiných nelineárních technik strojového učení, se zpravidla zvyšuje s rostoucím množstvím použitých vstupních dat, jak je také patrné z následujícího obrázku 2.1 [38].




Obr. 2.1: Porovnání výkonnosti s množstvím předložených dat.

Hluboké učení se ukázalo jako významné vylepšení oproti jiným metodám strojového učení zejména v oblastech rozpoznávání řeči [11], obrazu [12] a umělé inteligence. Další část textu bude zaměřena na popis rekurentní neuronové sítě a algoritmus LSTM, jelikož byl vybrán pro řešení v další části práce.

2.2 Neuronové sítě

Umělé neuronové sítě napodobují proces přemýšlení biologických organizmů [3]. Standardní topologie modelu je rozdělena do tří vrstev: vrstvu vstupní, sloužící jako zdroj externích informací. Vrstvu výstupní, stanovující výsledky na základě předchozích vstupů a vrstvu skrytou, která nemá vazby na externí okolí sítě a využívá pouze informace od vrstvy vstupní, popřípadě sama od sebe. Na neuronových sítích je postavena například práce [31], zabývající se včasným odhalením rakoviny prsu na základě předložených lékařských snímků, nebo práce zaobírající se počítačovým viděním [33][34] a identifikací objektů v obraze v reálném čase [32].




Obr. 2.2: Základní topologie umělé neuronové sítě [21].

Základní stavební jednotkou každé neuronové sítě je neuron, jehož formální struktura je znázorněna na obrázku 2.3. Jednotlivé vstupní vektory x_1, \dots, x_n jsou ohodnoceny vahami w_1, \dots, w_n stanovujícími propustnost jednotlivých vstupů, čímž udávají míru, s jakou se daný vstup podílí na celkovém výstupu neuronu. Má-li neuron I vstupů, jeho výstup je dán vztahem:

$$y = f\left(\sum_{n=1}^I w_n x_n + b\right), \quad (2.1)$$

kde I představuje celkové množství vstupů daného neuronu, w váhu spojení mezi neurony, x vstup, b bias a f aktivační funkci neuronu.



Obr. 2.3: Obecný neuron.

Aktivační funkce

Aktivační (nebo-li přenosová) funkce rozhoduje o aktivaci jednotlivých neuronů a následné propagaci signálu. Jelikož výstup neuronu je dán lineární agregací všech vstupů, je dále nepoužitelný pro problémy lineárně neseparabilní. Tento problém je vyřešen použitím nelineární aktivační funkce na výstup každého neuronu. Jako aktivační funkce se nejčastěji používají matematické operace, které jsou spojité, diferencovatelné v celém definičním oboru a vykazují tzv. smršťovací efekt (squashing effect). Mezi nejčastěji používané usměrňovací funkce v neuronových sítích patří logistická sigmoida a hyperbolický tangens.

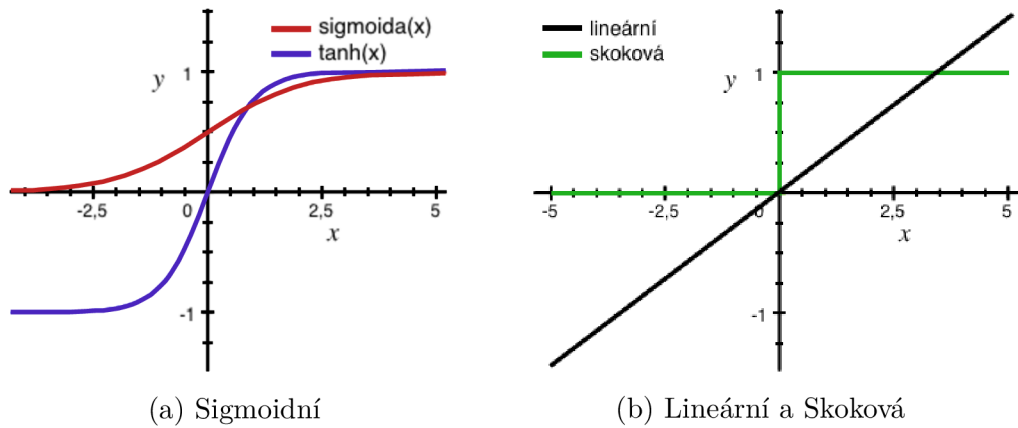
Logistická sigmoida s parametrem β určujícím strmlost (gain):

$$\text{sigmoida}(x) = \frac{1}{1 + e^{-\beta x}} \quad (2.2)$$

Hyperbolický tangens:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$

Sigmoidní funkce disponují průběžnou změnou přechodu a jejich definiční obor leží v intervalu $[0, 1]$, resp $[-1, 1]$. Nepatrná změna vah zapříčiní jen malou změnu výstupu neuronu, což oproti klasickým skokovým funkcím, kde výstup nabývá pouze hodnot 0 a 1, představuje daleko větší flexibilitu celé sítě. Vyhodnocení výstupu je ošetřeno stanovením podmínky aktivace.




Obr. 2.4: Průběhy aktivačních funkcí.

2.3 Rekurentní neuronové sítě (RNN)

Lidé nezačínají přemýšlet „od nuly“ každých pár vteřin. Při čtení textu rozumíte jednotlivým slovům na základě porozumění kontextu slov předešlých, což jinými slovy znamená, že vaše myšlenky jsou perzistentní. Tradiční neuronové sítě touto vlastností ovšem neoplývají, což je považováno za jejich hlavní nedostatek [2].

Tento problém řeší Rekurentní Neuronové sítě. RNN jsou typem umělých neuronových sítí, které mají vstupy od neuronů ve stejných či vyšších vrstvách téže sítě, čímž efektivně tvoří vnitřní cykly. Díky této vlastnosti disponují funkcí obdobnou paměti, což z nich dělá velmi vhodný nástroj pro rozpoznání určitého vzoru v dlouhé sekvenci dat [3]. Uchovávání sekvenční informace v rekurentních sítích vede k nalezení korelace mezi hodnotami oddělenými mnoha časovými kroky, takové korelace pak nazýváme dlouho-časovými závislostmi (long-term dependencies). RNN sítě jsou vhodné například pro rozpoznávání obrazu [36], hlasu [24], nebo rukopisu [35].



Obr. 2.5: Rekurentní neuron.


Nechť je v každém časovém kroku t definován vstup x_t , stav skryté vrstvy h_t a aktivace skryté vrstvy z_t , přičemž všechny tyto proměnné jsou realizovány vektory o velikosti $K \times 1$, $N \times 1$, a $L \times 1$, pak lze rekurentní neuronovou síť z obrázku 2.6 popsat vzorcí:

$$h_t = f(W_{xh}x_t + W_{hh}h_{t-1}), \quad (2.4)$$

kde W_{xh} představuje matici vah o velikosti $N \times K$ spojujících K vstupních neuronů s N neurony ve skryté vrstvě a W_{hh} reprezentuje matici vah realizující propagaci signálu z předešlého časového kroku. Vnitřní potenciál vrstvy skrytých neuronů lze vyjádřit vektorem u_t , jenž je roven součtu $W_{xh}x_t$ a $W_{hh}h_{t-1}$. $f(u_t)$ je poté aktivační funkcí.

$$z_t = g(W_{hy}h_t) \quad (2.5)$$

W_{hy} je matice vah o velikosti $L \times N$ spojující N neuronů skryté vrstvy s L neurony vrstvy výstupní. Vektor v_t , který je roven součinu W_{hy} a h_t vyjadřuje vnitřní potenciál výstupní vrstvy a $f(v_t)$ je aktivační funkcí.



Obr. 2.6: Topologie rekurentní neuronové sítě.

V rekurentních neuronových sítích se hojně využívá aktivačních funkcí logistická sigmoida 2.2 a hyperbolický tangens 2.3. Z důvodu časových závislostí mezi jednotlivými vstupy a zejména kvůli problému explodujícího a mizejícího gradientu, jsou RNN sítě výpočetně náročnější na trénování a mají i větší požadavky na paměť [24]. K trénování je využíván modifikovaný algoritmus zpětného šíření chyby,

jenž zohledňuje chyby z předchozích časových úseků. Označuje se jako algoritmus zpětného šíření chyby v čase (BPTT - BackPropagation Through Time) 2.4. Důležitou modifikací RNN sítí jsou zejména bránové rekurentní neuronové sítě LSTM (Long-Short-Term-Memory) popsáné v 2.5.

2.4 Systém zpětné propagace

Nejčastěji používaným systémem pro trénování vícevrstevných neuronových sítí, je systém zpětné propagace (backpropagation). Pracuje tak, že nalezené řešení je porovnáno s řešením očekávaným, čímž dojde ke zjištění chyby v nastavení vah jednotlivých neuronů [3]. Chyba se následně zpětně šíří sítí a váhy jednotlivých neuronů jsou přepočteny tak, aby se odchylka od správného řešení co nejvíce snížila. V drtivé většině případů se využívá sigmoidní aktivační funkce a sít tudíž není limitována binární klasifikací jednotlivých neuronů. Celý systém je pak určen zejména pro rychlou adaptaci na problémy spojené s učením s učitelem.

Popis algoritmu:

1. Zcela náhodná počáteční inicializace všech vah v intervalu $\langle -1, 1 \rangle$.
2. Na vstup vstupní vrstvy je přiveden vzorek z trénovací množiny dat, který projde sítí a jeho výsledek je porovnán se známým požadovaným výsledkem dle učitele.
3. Rozdíl výsledků je použit pro výpočet chyby v neuronech výstupní vrstvy.
4. Pro každou vrstvu od konce k začátku se porovná vypočítaný výstup a poměrový požadovaný vstup další vrstvy.
5. Na základě chyb v jednotlivých neuronech jsou přepočteny nové váhy.
6. Návrat ke kroku 2, dokud všechny vstupy nejsou klasifikovány správně, nebo není dosaženo některé z dalších koncových kritérií.

Chybová funkce je vypočtena jako kvadrát vzdálenosti mezi očekávaným a skutečným výstupem:

$$E = \frac{1}{2} \sum_j (d_j - y_j)^2, \quad (2.6)$$

kde y_j představuje očekávaný výstup j -tého vzoru.

Parciální derivací pak získáme:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}} \quad (2.7)$$

a použitím sigmoidní aktivační funkce dostaneme:

$$\delta_j = f'(\xi_j)(d_j - y_j) = (1 - y_j)y_j(d_j - y_j), \quad (2.8)$$

kde δ představuje velikost změny váhy.

Nová váha je vypočítána jako:

$$w_{ij}^s(t+1) = w_{ij}^s(t) + \alpha \delta_j^{s+1} y_i^s, \quad (2.9)$$

kde w_{ij} představuje váhu mezi i -tým a j -tým neuronem v s -té vrstvě a kroku t , α je parametrem učení a δ_j^s jsou chyby neuronů v uvažované vrstvě.

Jedná-li se o vrstvu poslední, potom $s = M$ a platí:

$$w_j^M = y_j(1 - y_j)(d - y_j). \quad (2.10)$$

V ostatních vrstvách platí:

$$\delta_j^s = y_j^{s+1}(1 - y_j^{s+1}) \sum_{k=1}^{p^{s+1}} \delta_k^{s+1} w_{jk}^{s+1}, \quad (2.11)$$


kde $s = M - 1, \dots, 1$ a k prochází všemi neurony v $s + 1$ vrstvě.

Koeficient učení α určuje poměr aplikace chyby na změnu sítě v jednom kroku. Jinými slovy udává, jak rychle se síť učí [4]. Nastavení nízkého koeficientu má za následek velmi pomalé učení a neschopnost rozeznat určité špatné příznaky sítě, naproti tomu zvolení příliš vysoké hodnoty koeficientu umožní síti se učit rychleji, avšak na úkor kvality, což může mít za následek oscilaci protichůdných hodnot a celý algoritmus se tak může stát nestabilním. Největším nedostatkem zpětné propagace je, že využíváním postupné minimalizace chyby se systém může ustálit na lokálních minimech chyby [3], přičemž správným (nebo lepším) řešením může být jiná varianta. Obvyklým postupem je proto opakované učení sítě s různě nastavenými počátečními vahami a následně zvolení té, jež dosahuje nejlepších výsledků.

2.5 LSTM sítě

Speciálním druhem rekurentních neuronových sítí schopných učit se dlouhočasové závislosti jsou sítě LSTM (Long Short Term Memory) [5]. Poprvé byly představeny už v roce 1977 dvojicí německých vědců Hochreiterem & Schmidhuberem a od té doby dále rozvíjeny vědeckou komunitou. V současnosti jsou tyto sítě velmi populární, jelikož řeší problém mizejícího gradientu u metod používajících zpětné propagace chyby a jejich struktura obsahuje prvky umožňující dlouhodobé uchování informace.

Sítě LSTM mají velký potenciál, jejich využití zkoumají například práce zabývající se predikcí trajektorie autonomních vozidel na dálnici [28], rozpoznáním obličejů v obrazu [29], odezíráním a rozpoznáváním slov ze rtů na základě videa [30] a mnohé další.

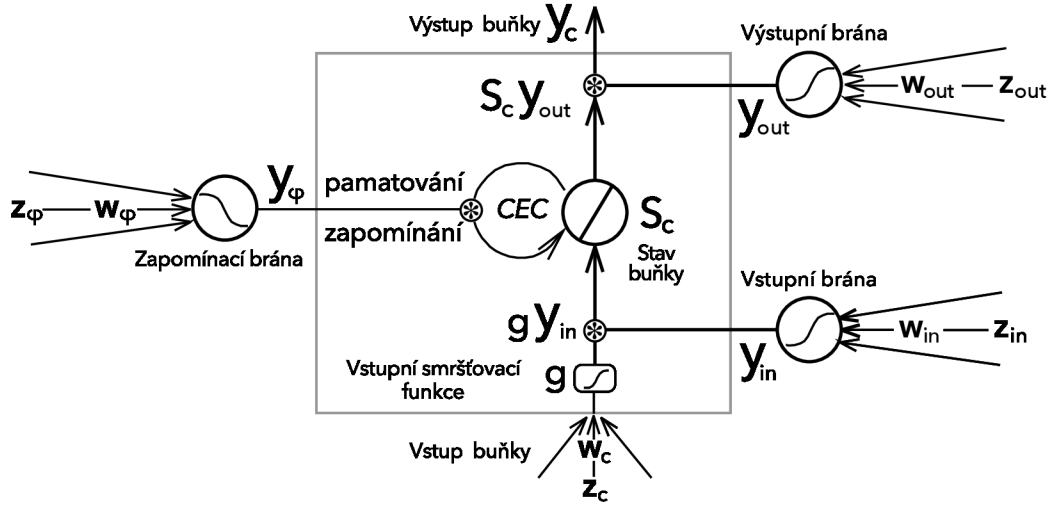


Obr. 2.7: Jednoduchý příklad LSTM.

LSTM sítě jsou tvořeny jednotlivými paměťovými bloky, schopnými udržet konkrétní informaci pro potřebnou délku času. Tyto bloky jsou řízeny několika branami, jež nesou zodpovědnost za rozhodování o tom, jaké informace ukládat a kdy se tyto informace použijí. Struktura paměťového bloku je zobrazena na obrázku 2.8.

Jednotlivé prvky paměťového bloku pak plní následující funkci:

- Vstupní brána – rozhoduje, zda se má informace přivedená na vstup zaznamenat do vnitřní paměti.
- Výstupní brána – rozhoduje, zda se má informace uložená uvnitř bloku přivést na výstup.
- Zapomínací brána – V případě zjištění nepotřebné informace slouží jako mazač prvek.
- Blok paměti – Zodpovídá za dlouhodobé uchování informací.



Obr. 2.8: Příklad LSTM paměťového bloku.

V následujících rovnicích představuje j paměťový blok, v index buňky v bloku j . w_{lm} je váha mezi jednotkou m a l . Index m se pohybuje nad všemi zdrojovými jednotkami dle topologie sítě. Pokud zdrojová aktivační jednotka $y_m(t-1)$ odkazuje na jednotku vstupu, použije se namísto ní současný externí vstup $y_m(t)$. Výstup y_c paměťového bloku c je vypočítán ze současného stavu buňky s_c a čtyř vstupních zdrojů: z_c vstup do buňky samotné, z_{in} vstup vstupní brány, z_φ vstup zapomínací brány a z_{out} je vstup brány výstupní.

LSTM sítě pracují v diskrétních časových krocích $t = 0, 1, 2, \dots$, v každém kroku dojde k aktualizaci všech aktivačních jednotek (forward pass) a následnému výpočtu chyby pro všechny váhy (backward pass). V průběhu každého Forward Pass je nejdříve vypočítán vstup buňky sítě:

$$z_{c_j^v}(t) = \sum_m w_{c_j^v m} y_m(t-1), \quad (2.12)$$

následně je aplikována vstupní smršťovací funkce g v rozsahu $[-2, 2]$:

$$g(x) = \frac{4}{1 + e^{-x}} - 2. \quad (2.13)$$

Výsledek je násoben aktivační funkcí paměťového bloku vstupní brány a výpočet proveden aplikováním logické sigmoidní funkce f_{in} na vstupní bránu z_{in} v rozsahu $[0, 1]$:

$$z_{in_j}(t) = \sum_m w_{in_j m} y_m(t-1), \quad y_{in_j}(t) = f_{in_j}(z_{in_j}(t)). \quad (2.14)$$

Aktivací vstupní brány y_{in} je vstup násoben do všech buněk paměťového bloku. V případě, kdy se ($y_{in} \approx 1$) je vstup do buňky povolen, naopak při ($y_{in} \approx 0$) je vstup informací odepřen.

Při $t = 0$ je stav S_c paměťové buňky c nastaven na nulu. Výpočet aktivace paměťového bloku zapomínající brány:

$$y_{\varphi_j}(t) = f_{\varphi_j}(z_{\varphi_j}(t)) \quad z_{\varphi_j}(t) = \sum_m w_{\varphi_j m} y_m(t-1), \quad (2.15)$$

kde je f_{φ} logickou sigmoidní funkcí v rozsahu $[0, 1]$. Nový stav buňky je získán přidáním vstupu do předchozího stavu vynásobeného aktivační funkcí zapomínací brány:

$$s_{c_j^v}(t) = y_{\varphi_j}(t) s_{c_j^v}(t-1) + y_{in_j}(t) g(z_{c_j^v}(t)), \quad s_{c_j^v}(0) = 0. \quad (2.16)$$

Výstup buňky y_c je spočítán jako součin stavu buňky S_c a aktivační funkce y_{out} paměťového bloku výstupní brány:

$$y_{c_j^v}(t) = y_{out_j}(t) s_{c_j^v}(t). \quad (2.17)$$

Vynásobením výstupu CEC řídí výstupní brána přístup k zápisu do paměťového bloku. Její aktivace je vypočtena aplikováním logické sigmoidní funkce f_{out} v rozsahu $[0, 1]$ na vstup sítě:

$$z_{out_j}(t) = \sum_m w_{out_j m} y_m(t-1), \quad y_{out_j}(t) = f_{out_j}(z_{out_j}(t)). \quad (2.18)$$

U topologie obsahující vstupní vrstvu, výstupní vrstvu a skrytou vrstvu skládající se z paměťových bloků, je aktivace výstupních jednotek k spočtena následovně:

$$y_k(t) = f_k(z_k(t)), \quad z_k(t) = \sum_m w_{km} y_m(t). \quad (2.19)$$

K učení LSTM sítí se pak ve valné většině případů používá adaptovaného učícího algoritmu zpětné propagace sítě [3]. Na rozdíl od jiných, zpětnovazebních sítí zde nedochází k nežádoucímu cyklení zpětně distribuovaných chyb a veškeré návratové chyby jsou promítány do funkce bran které rozhodují o tom, co a na jak dlouho má být v paměti bloku uloženo [6].

3 VIRTUÁLNÍ MĚNY

V této kapitole bude stručně shrnut obecný popis technologie virtuálních měn, počínaje jejich vznikem, technickým řešením, až po krátký přehled jejich současných nejvýznamnějších představitelů.

3.1 Historie

Virtuální měny, kryptoměny, nebo též měny digitální mají svůj prapůvod již v raných počátcích let osmdesátých, kdy se poprvé objevila myšlenka digitálních peněz. Rozmach internetu v devadesátých letech a vznik společností jako DigiCash a eGold, zabývajících se tvorbou a pohybem virtuálních peněz, znamenalo pomyslné položení základních kamenů v oblasti virtuálních měn a přineslo také nový úhel pohledu do finančního sektoru [7].

Začátek nového tisíciletí se nesl ve znamení pokusů o vytvoření nezávislé online banky, tento projekt postupem času přerostl v jednu z nejznámějších platebních sítí na světě – PayPal. Zásadním přetrvávajícím nedostatkem všech dosavadních systémů však byla bezpodmínečná nutnost centralizace, což vedlo ke zranitelnosti celého systému. S řešením přišla až osoba, nebo skupina osob vystupující pod pseudonymem Satoshi Nakamoto, jenž svou studií [39] položila základy elektronických peněz bez centrální finanční instituce, čímž dala vzniknout plně decentralizovanému nezávislému modelu a kryptoměnám, jak je známe dnes.

3.2 Virtuální měny

Virtuální měny jsou analogií klasických, státem podporovaných oficiálních platidel, s rozdílem distribuce ve formě dat v digitální podobě. Tyto peníze tak existují pouze ve virtuálním světě a nelze je tudíž hmotně vlastnit. Celý koncept měnového systému je postaven na principu decentralizované peer-to-peer sítě [41]. Neexistuje zde žádná nadřazená autorita, která by měnu nějakým způsobem uměle regulovala a síť je tak imunní i vůči manipulaci ze strany vlád a nepodléhá dokonce ani inflaci při státem řízeném tisku a vpuštění nových peněz do oběhu. Její hodnota je čistým vyjádřením dané nabídky a poptávky jejich uživatelů. Virtuální měny jsou postaveny na kryptografii pro řetězení digitálních podpisů převodů. Znamená to, že peníze jsou ve skutečnosti vyjádřeny řetězcem bitů poslaným sítí jako zpráva, která je následně ověřena a zanesena do účetní knihy tzv. block-chainu. K zaručení integrity a autenticity se hojně využívá kryptografických funkcí a mechanismů, například asymetrického šifrování nebo mechanismů proof-of-work a proof-of-stake [42][43].

3.3 Technologie decentralizované databáze

Drtivá většina všech virtuálních měn disponuje veřejně dostupnou a distribuovanou účetní knihou sdílenou napříč celou sítí, která se se označuje anglickým termínem block-chain [40]. Jedná se o technologii veřejné transakční databáze sdílené všemi účastnickými uzly v síti, kde jsou anonymně zaznamenávány veškeré transakce, jež byly s danou měnou uskutečněny. Block-chain je chronologický řetězec záznamů (bloků) o transakcích, který neustále roste a který je mezi jednotlivé uživatele sítě všesměrově distribuován pomocí záplavového protokolu. Tvorba nových bloků je nutným procesem a v síti ji obstarávají tzv. těžaři, kteří ověřují provedené transakce, hromadí je a následně soupeří s ostatními uživateli o to, komu se jako první podaří z těchto dat vytvořit nový blok [43]. Vítězný těžař rozešle svůj výsledek pro kontrolu zbytku sítě, přijde-li několik na sobě nezávislých ověření, je transakce povolena, zapsána v block-chainu a vítěz je odměněn formou určitého vytěženého obnosu v dané měně. Tato operace je však velmi výpočetně náročná, a proto se uživatelé často slučují do tzv. výpočetních skupin, kde sdílejí svůj výpočetní výkon za účelem rychlejšího výpočtu a sestavení nového bloku. Každý nový blok databáze obsahuje kryptografický otisk (hash) bloku předešlého, což má za následek vznik provázaného řetězce bloků od počátečního, až po ten nejaktuálnější. Jakmile informace (blok) do block-chainu jednou vstoupí, není již možno ho jakkoliv modifikovat, jelikož každý jednotlivý zápis ovlivní zápisy následující. Block-chain je plně transparentní a obsahuje kompletní informace o datu, času, sumě a účtu všech provedených transakcí. S touto informací tak lze snadno dohledat jakoukoliv transakci zpět v čase až do úplného počátku.

3.4 Nejpoužívanější virtuální měny

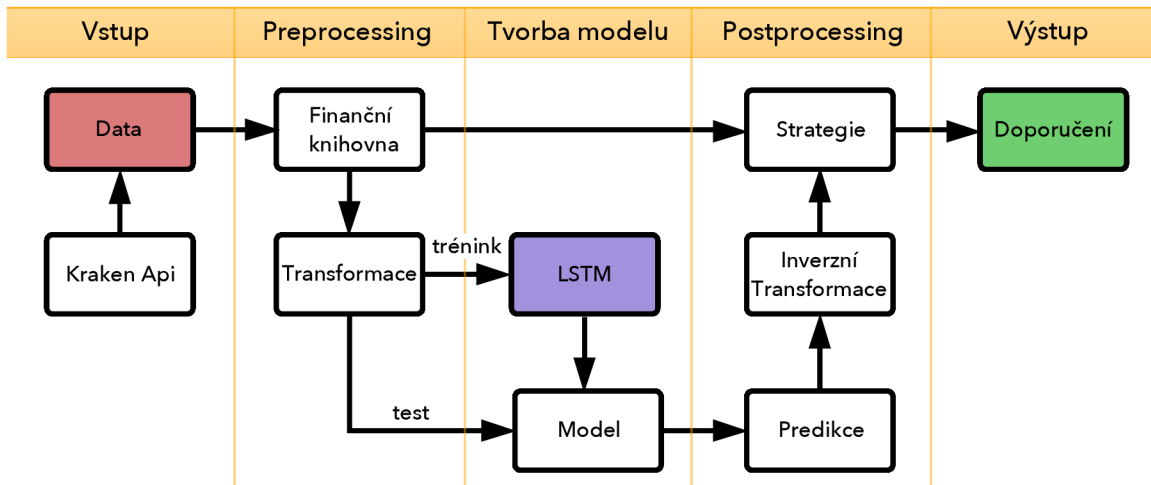
Nejvíce populární virtuální měnou současnosti je Bitcoin, v těsném závěsu za ním se drží Ethereum. Momentálně existuje již více než 1500 různých kryptoměn [22], z nichž ovšem drtivá většina nemá na trhu téměř žádnou nominální hodnotu. Pět nejúspěšnějších, dle aktuální hodnoty na finančním trhu zobrazuje tabulka 3.1.

Tab. 3.1: Tržní hodnota nejúspěšnějších virtuálních měn k datu 15.03.2018 [22].

Název	Zkratka	Cena [\$]	Počet v oběhu	Kapitalizace [\$]
Bitcoin	BTC	8283.7	16 920 987	140 321 345 734
Ethereum	ETH	605.2	98 209 117	59 435 568 618
Ripple	XRP	0.7	39 091 716 516	27 092 005 939
Bitcoin Cash	BCH	934.7	17 019 550	15 907 850 014
Litecoin	LTC	163.3	55 642 856	9 084 920 404

4 NÁVRH SYSTÉMU

V následující části práce je popsán návrh a optimalizace systému pro doporučení k prodeji, nebo koupi virtuální měny. Grafické znázornění navrženého řešení představuje obrázek 4.1. Samotný systém poté sestává z predikce předpokládané budoucí hodnoty dané měny a následné aplikace zvolené obchodní strategie, k čemuž je využito neuronové LSTM sítě 2.2 a finanční knihovny TA-lib 4.1.2.



Obr. 4.1: Schéma navrženého systému pro udělení doporučení.

Hodnocení chybovosti

Ohodnocení výsledné úspěšnosti natrénovaného modelu bylo rozděleno do dvou rovin. První rovina je založena na výsledné profitabilitě systému za dané časové období. Druhá zahrnuje výpočet střední kvadratické chyby (RMSE - Root Mean Square Error), přičemž tato metoda penalizuje větší chyby a její výpočet je dán následujícím vztahem :

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z_p - Z_s)^2}, \quad (4.1)$$

kde Z_p představuje predikovanou hodnotu, Z_s hodnotu skutečnou a N počet pozorování. RMSE určuje rozptyl rozdělení četnosti odchylek mezi skutečnými a predikovanými hodnotami. Vyšší hodnota RMSE odpovídá většímu rozptylu a tudíž i větší chybě.

4.1 Pracovní prostředí

Pro práci s daty bylo využito knihoven a nástrojů určených zejména pro strojové učení. Jejich výpis, spolu se stručným popisem funkce, je uveden níže.

4.1.1 Keras

Keras je volně dostupná knihovna s vysokou úrovní abstrakce určená pro projektování neuronových sítí [17]. Napsána je programovacím jazykem Python a navržena byla za účelem umožnění rychlého experimentování s ohledem na vysoký výpočetní výkon. Obsahuje podporu pro konvoluční neuronové sítě, rekurentní neuronové sítě, jejich kombinace a velmi dobře také spolupracuje s jinými matematickými knihovnami, například (Numpy a SciPy). Umožňuje provádět výpočty jak pomocí CPU, tak i GPU. Disponuje kvalitně zpracovanou dokumentací, širokou uživatelskou základnou a podporou backend nástrojů Theano, CNTK a TensorFlow [16]. V této práci byl použit Keras ve verzi 2.1.1.

4.1.2 TensorFlow

TensorFlow je volně dostupná knihovna s otevřeným zdrojovým kódem určená pro numerické výpočty využívající abstrakce grafů znázorňujících datový tok [37]. Graf je sestaven pomocí vysokoúrovňového skriptovacího jazyka, jenž umožňuje pracovat s různými architekturami a optimalizačními algoritmy bez potřeby modifikace podprogramu popisujícího nízkoúrovňovou funkcionalitu. Uzly grafu reprezentují matematické operace (maticové násobení, konvoluce, ...) a hrany grafu reprezentují vícerozměrné datové pole (tenzory), které mezi nimi komunikují. Knihovna obsahuje operace a funkce umožňující tvorbu a práci s programy, využívající principů strojového učení, mezi které patří například neuronové sítě [18]. Program používající knihovnu TensorFlow se obvykle skládá ze dvou částí: definice programu, neuronové sítě a pravidel pro její trénování jako grafu toků dat a interpretace tohoto grafu na jednom nebo více zařízeních. Jelikož interpretace grafu vyžaduje, aby byl graf kompletní a během ní i neměnný, je možné provést optimalizaci založenou na kompletní znalosti celého grafu. Znalost informace, které operace si navzájem předcházejí a které je možné provést zároveň, umožňuje přesně naplánovat a optimalizovat celý výpočet ještě před tím, než vůbec započne. Příkladem je rozložení zátěže a paralelizace výpočtu pouze s jedním aplikačním rozhraním na mnoha různých zařízeních jako například mobilních telefonech, osobních počítačích, nebo distribuovaných systémech skládajících se z velkého počtu navzájem propojených grafických karet a procesorů [19].

Finanční knihovna

Pro výpočet pomocných finančních indikátorů byla použita knihovna s otevřeným zdrojovým kódem TA-lib [27].

Numpy

Jedná se o základní analytickou a vědeckou knihovnu pro programovací jazyk Python. Definuje typ matice, n-rozměrné homogenní pole a poskytuje taktéž velké množství pokročilých matematických funkcí pro práci s nimi [46].

Pandas

Knihovna s otevřeným zdrojovým kódem určená pro zpracování a analýzu dat. Základním datovým typem je *Datový Rámec (DataFrame)* [47].

4.2 Popis navrženého řešení

V této části je blíže pojednáno o jednotlivých blocích navrženého systému z obrázku 4.1. Konkrétně pak o struktuře a charakteru vstupních dat 4.2.1, předzpracování dat 4.2.2, nastavení a parametrech neuronové sítě 4.2.3 a o aplikované strategii 4.2.4.

4.2.1 Vstupní data

Vstupními daty jsou historické hodnoty čtyř, v současné době nejvýznamnějších, virtuálních měn získané pomocí aplikačního programového rozhraní z burzy virtuálních měn Kraken [26]. Konkrétně se jedná o měny Bitcoin, Litecoin, Ethereum a Bitcoin Cash. Data jednotlivých měn se skládají z následujících šesti údajů zaznamenaných v šestihodinových intervalech:

- Datum a čas,
- otevírací cena,
- zavírací cena,
- cenové maximum,
- cenové minimum,
- objem obchodů.

Tyto hodnoty jsou poté použity jako vstup pro finanční knihovnu 4.1.2, která do počítává pomocné finanční indikátory.

4.2.2 Příprava dat

Neuronové LSTM sítě pracují nejlépe s daty v normalizovaném tvaru, je proto třeba vstupní data ošetřit a převést do požadovaného formátu, což je v bloku transformace realizováno následujícími operacemi:

- Změna měřítka do intervalu $(0, 1)$.
- Transformace dat do stacionární podoby.
- Transformace dat pro učení s učitelem.

Z důvodu budoucí použitelnosti jsou nejdříve k datům přidány dvě hodnoty představující umělou spodní a horní hranici (minimální a maximální hodnota). Agregovaná data jsou pro použití aktivační funkce následně transformována do intervalu $(0, 1)$ aplikováním funkce *MinMaxScaler()*. Ihned po změně měřítka jsou hodnoty použité pro stanovení umělých hranic z dat odstraněny. K zamezení nežádoucích efektů způsobených strukturou vstupních dat vykazujících trend, je vhodné data převést do stacionární podoby, což obstarává funkce *difference()*, realizující následující operaci:

$$difference(t) = observation(t) - observation(t - 1). \quad (4.2)$$

Inverzní operací je poté:

$$inverted(t) = differenced(t) + observation(t - 1). \quad (4.3)$$

Transformace dat pro učení s učitelem

Knihovna Keras vyžaduje pro práci s LSTM modelem data rozdělená na vstupní a výstupní komponentu. Transformaci dat do tohoto formátu obstarává funkce *shift()* z knihovny Pandas 4.1.2. Vstupní data (x), jsou data z časového kroku $(t - n)$ a data výstupní (y) jsou data z časového kroku $(t + n)$. Následným spojením obou hodnot je vytvořen datový rámec a data jsou převedena do formátu učení s učitelem. Příklad takové transformace udává tabulka 4.1. Vrstva LSTM očekává svůj vstup v maticovém formátu o třech dimenzích: počtu vzorků, počtu časových kroků a počtu atributů. Počet vzorků odpovídá celkovému počtu dat, obvykle bývá vyjádřen celkovým počtem řádků. Počet časových kroků je počet nezávislých pozorování vzorků v čase a počet atributů je vyjádřen celkovým počtem různých pozorování, obvykle počet sloupců. Transformaci do trojrozměrné dimenze obstarává funkce *reshape()*.

Tab. 4.1: Příklad transformace dat pro učení s učitelem

t-2	t-1	t	t+1
A	B	C	D
B	C	D	E
C	D	E	F
D	E	F	G


4.2.3 LSTM

V tomto bloku je pomocí knihovny Keras 4.1.1 vybudována neuronová LSTM síť 4.13, do které přichází již předzpracovaná data z bloku Transformace. Hlavním úkolem již zkonstruované sítě je poté z těchto dat vytvořit a natrénovat sekvenční model určený pro více krokovou predikci číselných hodnot. Zejména pak tříkrokovou predikci po šesti hodinách. Jednoduchý demonstrativní příklad více krokové predikce je uveden na obrázku 4.2.



Obr. 4.2: Příklad predikce více krokového sekvenčního modelu.

Konkrétní příklad potom znázorňuje obrázek 4.3, kde modrá křivka představuje hodnoty reálné a červená křivka hodnoty predikované. Rozdíl mezi těmito dvěma hodnotami v čase $t+1$, $t+2$ a $t+3$ je použit pro výpočet hodnoty RMSE 4.




Obr. 4.3: Konkrétní příklad predikce více krokového sekvenčního modelu.

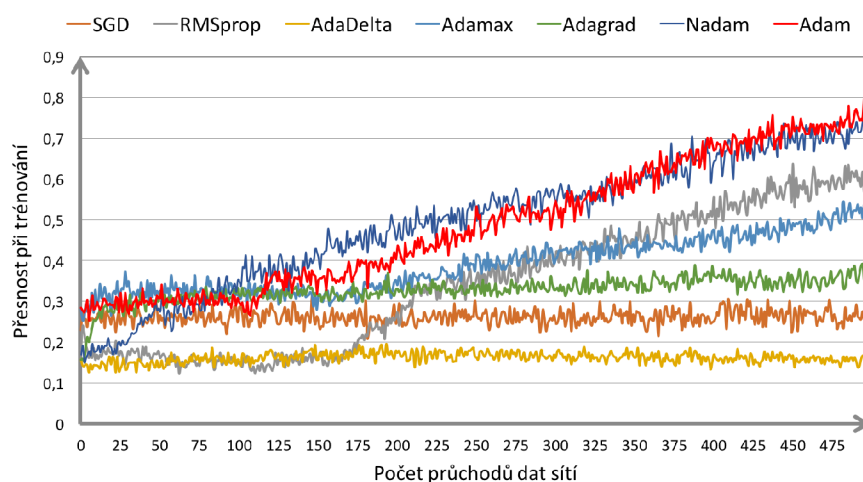
K určení následujících parametrů byla z důvodu značné časové náročnosti tréninku modelu použita pouze část datasetu obsahující šestihodinové historické hodnoty od data 2017-12-12 do 2018-03-31. Počet průchodů dat sítí byl nastaven na 500, okno na velikost 3. Výsledky byly validovány na datech od 2018-04-01 do 2018-04-06. Celý proces testování jednotlivých parametrů byl pro ověření třikrát opakován.

Optimalizační algoritmus

Pro svou výpočetní efektivitu a nízké paměťové nároky [45], byl jako optimalizační algoritmus aktualizace vah neuronové sítě v průběhu trénování zvolen algoritmus Adam. Porovnání optimalizačních algoritmů udává obrázek 4.4 a 4.5.




Obr. 4.4: Porovnání různých optimalizačních technik.




Obr. 4.5: Přesnost různých optimalizačních technik.

Výběr aktivační funkce

Pomocí již zvoleného optimalizačního algoritmu Adam, byly na výstupu sítě testovány jednotlivé aktivační funkce z knihovny Keras 4.1.1. Výsledky testování znázorňují obrázky 4.6 a 4.7. Jako nejvíce vhodná, byla zvolena aktivační funkce lineární. Velmi dobrou úspěšnost při testování vykazovala také aktivační funkce *tanh* a naopak jako naprosto nevhodné se pro daná data ukázaly funkce *sigmoida*, *hard sigmoida* a *ReLU*.




Obr. 4.6: Porovnání aktivačních funkcí.



Obr. 4.7: Porovnání aktivační funkce *tanh* a *linear*.

Technika náhodné deaktivace spojení

Mezi jednotlivé vrstvy modelu je umístěna vrstva Dropout, zabraňující přeučení sítě. Jedná se o regularizační techniku, kdy je při tréninku náhodně deaktivován procentuálně specifikovaný počet spojení některých neuronů, čímž jsou ostatní neurony donuceny k interakci a tím dochází k nalezení redundantních závislostí. Na základě testování, při kterém byla sledována odchylka od skutečné hodnoty v čase $t+1$, $t+2$ a $t+3$, byl jako parametr vykazující nejnižší chybovost vybrán dropout 30%. Výsledky tohoto testu jsou graficky znázorněny na obrázku 4.8.



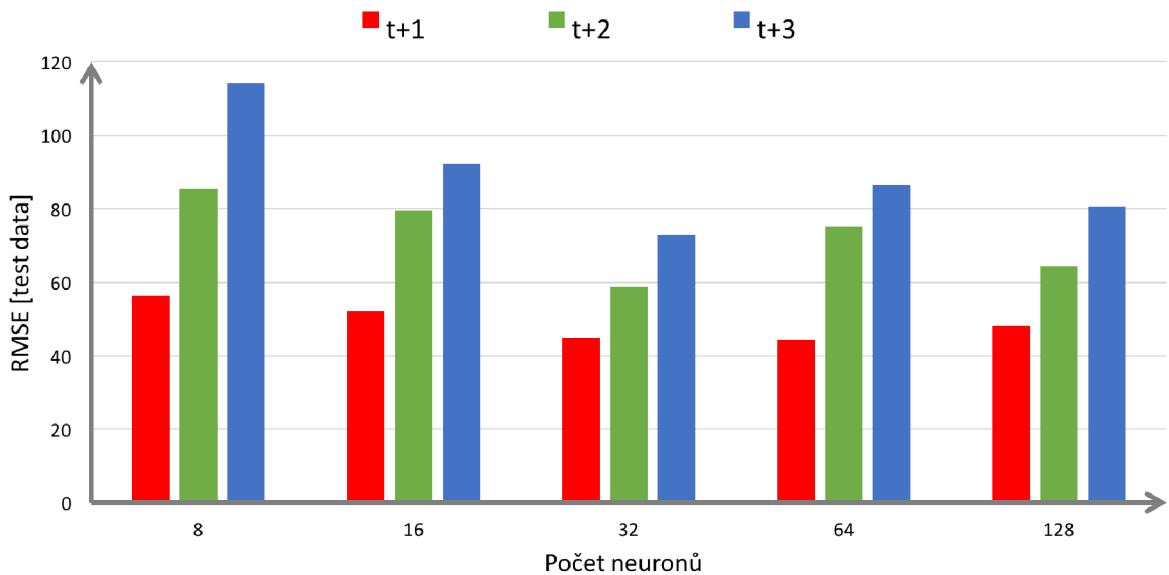
Obr. 4.8: Výsledky testování parametru dropout.

Parametr počet epoch

Udává celkový počet průchodů veškerých dat modelem během trénování. Jedna epocha představuje průchod dat sítí právě jedenkrát. Jelikož je učení neuronových sítí iterativním procesem zmenšování chyby, nelze určit optimální počet průchodů jinak, než testováním.


Topologie sítě

Návrh topologie LSTM sítě byl proveden iterativně, přidáváním vrstev o různém počtu neuronů (8, 16, 32, 64 a 128) a následným vyhodnocením chybovosti na testovacích datech. Výsledky tohoto procesu jsou zaneseny v následujících grafech.




Obr. 4.9: Test topologie s jednou vrstvou a s rozdílným počtem neuronů.

Při testování topologie s jednou vrstvou dosáhla nejlepších výsledků síť se 32 neurony. Na tomto základě byla přidána další vrstva :




Obr. 4.10: Test topologie se dvěma vrstvami a 32 neurony v první vrstvě.

S přidáním druhé vrstvy se ukázalo řadové zlepšení přesnosti. Nejlepších výsledků bylo dosaženo kombinací 32 neuronů v první vrstvě a 64 neuronů ve vrstvě druhé.



Obr. 4.11: Test topologie se třemi vrstvami, 32 neuronů v první vrstvě a 64 neuronů ve vrstvě druhé.

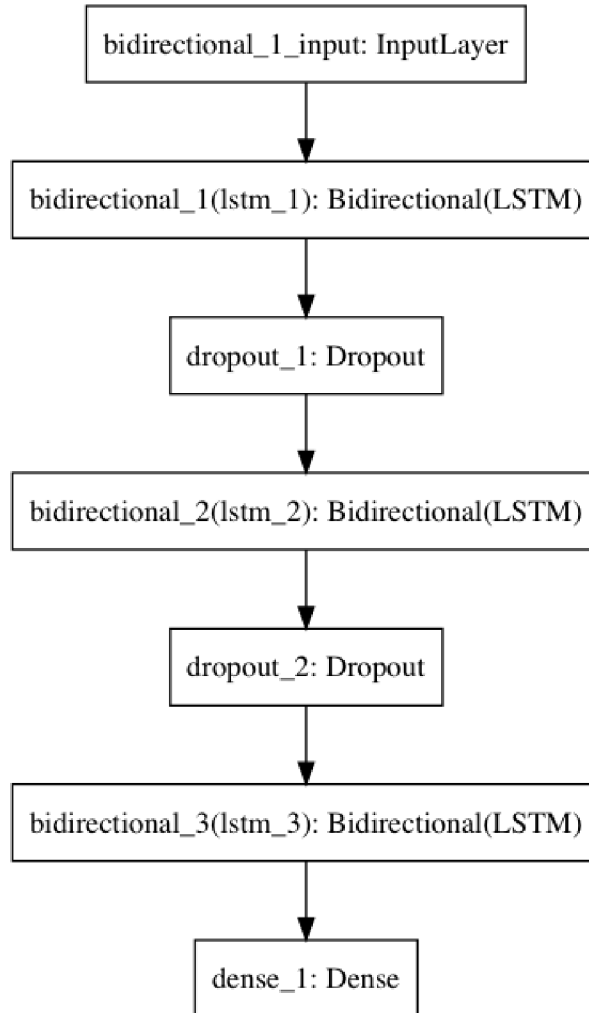
V tomto kroku byla vybrána vrstva se 64 neurony. Přidáváním dalších vrstev již nedocházelo k výraznému zlepšení přesnosti predikce. Na základě zvolené topologie bylo nyní přistoupeno k testování velikosti okna,



Obr. 4.12: Test velikosti okna na přesnost predikce.

kde se jako nejvíce vhodné ukázalo použití okna o velikosti pět.

Strukturu navrženého sekvenčního modelu vytvořenou pomocí LSTM sítě graficky znázorňuje obrázek 4.13. Složení jednotlivých vrstev pak popisuje tabulka 4.2.



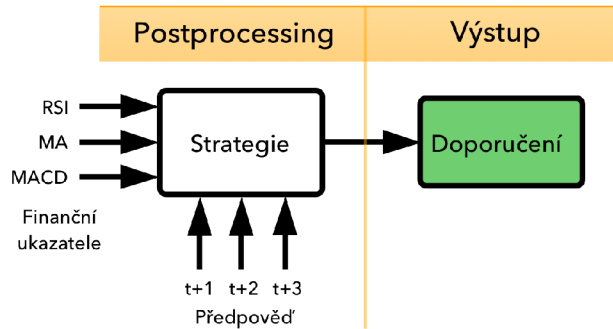
Obr. 4.13: Grafická vizualizace navržené neuronové sítě.

Tab. 4.2: Popis parametrů neuronové sítě

Vrstva	Počet neuronů	Dropout
1. vrstva	32	0,3
2. vrstva	64	0,3
3. vrstva	32	-
Výstupní	3	-

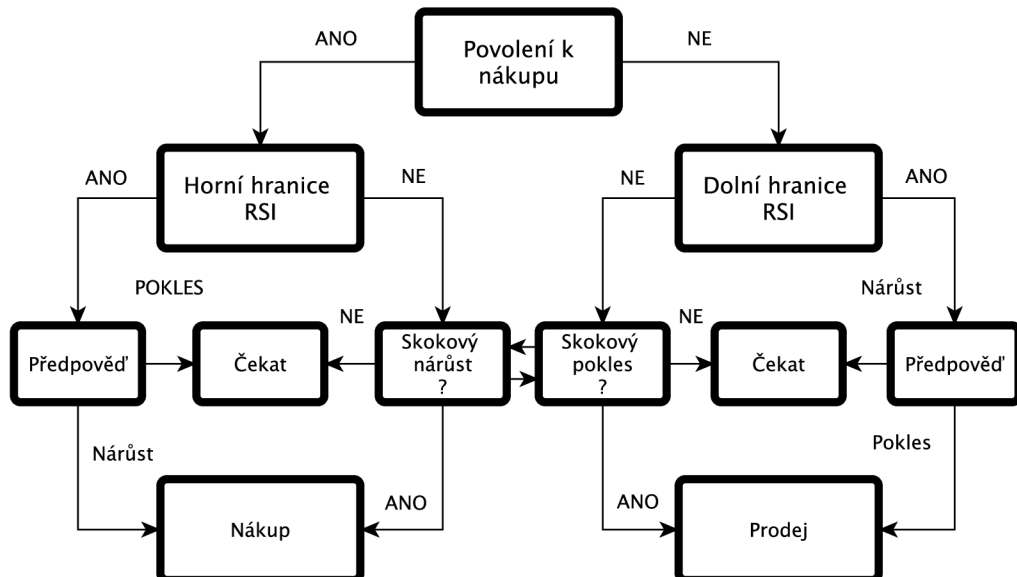
4.2.4 Strategie

Z již dříve vypočtených ukazatelů v bloku finanční knihovny 4.1.2 a výstupních hodnot predikčního modelu neuronové LSTM sítě 4.2, je nyní na základě aplikace pravidel rozhodnuto o doporučení k nákupu, nebo naopak prodeji. Na obrázku 4.14 jsou znázorněny data přicházející do tohoto bloku.



Obr. 4.14: Vstupní data bloku Strategie.

Pro testovací účely byla zvolena strategie povolující nákup pouze v případě, jsou-li všechna dříve nakoupená aktiva dané měny již prodána, nebo za předpokladu, že žádný obchod doposud neproběhl. Toto pravidlo je v navržené a aplikované obchodní strategii, graficky znázorněné na obrázku 4.15, vyjádřeno parametrem *Povolení k nákupu*.



Obr. 4.15: Grafická interpretace navržené obchodní strategie.

Pomocným indikátorem RSI 1.2 byla definována horní a dolní hranice udávající míru překoupenosti dané měny. Tyto hranice jsou v systému reprezentovány proměnnými $rsi_hranice_horní$ a $rsi_hranice_dolní$. Překročení některé z těchto hranic, udává spolu s predikovanými hodnotami signál pro udělení doporučení k nákupu či prodeji tak, jak je znázorněno na obrázku 4.15.

V následujících rovnicích je pro zjednodušení zápisu stanovena proměnná $predikce_18$, popsána je následujícím vztahem :

$$predikce_18 = (predikce[t + 1] \vee predikce[t + 2] \vee predikce[t + 3]). \quad (4.4)$$

Na základě předpovědi hodnot v čase $t+1$, $t+2$ a $t+3$ jsou dále definována kontrolní pravidla $skokový_nárůst$ a $skokový_pokles$. Pravidlo $skokový_nárůst$ je popsáno vztahem :

$$(cena[t] + \frac{cena[t]}{100} * par1) < predikce_18. \quad (4.5)$$

Je-li očekáván náhlý propad, aplikuje se pravidlo $skokový_pokles$:

$$(cena[t] - \frac{cena[t]}{100} * par2) > predikce_18. \quad (4.6)$$

Parametry $par1$ a $par2$ určují procentuální míru změny ceny.

Pravidla pro nákup, za předpokladu splnění podmínky $povolení\ k\ nákupu$.

$$(rsi_14[t] < rsi_hranice_dolní) \wedge (cena[t] < predikce_18) \vee skokový_nárůst \quad (4.7)$$

Pravidla pro prodej:

$$(rsi_14[t] > rsi_hranice_horní) \wedge (cena[t] > predikce_18) \vee skokový_pokles \quad (4.8)$$

a zároveň:

$$(cena[t] > predikce[t + 1]) \vee (cena[t - 2] > cena[t]). \quad (4.9)$$

Podstata uděleného doporučení je založena na filozofii levně nakoupit a vzápětí prodat s maximálním možným ziskem. Návrh strategie byl testován a laděn na datech virtuální měny Bitcoin Cash za období srpen 2017 až únor 2018. Budoucí hodnoty pro každý bod v čase $t+1$, $t+2$ a $t+3$ byly systému dopředu známy. Jinými slovy, byla simulována 100% přesnost predikce. Při použití neznámých dat je taková situace krajně nepravděpodobná, nicméně pro návrh strategie byl tento postup výhodný.

5 TESTOVÁNÍ

Na základě poznatků a výsledků uvedených v části 4.2 bylo přistoupeno k testování systému. Popsaný test byl realizován na historických šestihodinových datech virtuální měny Bitcoin za období 2017-01-01 až 2017-12-31. Dále byla stejným způsobem otestována i virtuální měna Litecoin a Ethereum.

5.1 Způsob testu


Je znázorněn na obrázku 5.2. Nejprve byla vybudována neuronová LSTM síť se strukturou popsanou v 4.13 a 4.2. Parametry, dopočítané finanční knihovnou, vstupující do této sítě byly následující: konečná denní cena, denní objem obchodů, index relativní síly, index peněžního toku, momentum, směrové hnutí plus, směrový pohybový index, index komoditních kanálů, Aroon, chande momentum oscilátor, míra změny ceny, poměr změny míry ceny, William's, rovnováha sil, Chaikin A/D, zbytkový objem, průměrná cena, medián ceny, typická cena, vážená konečná denní cena, průměrný pravý rozsah, normalizovaný pravý rozsah, pravý rozsah, střední cena za období, celkem tedy 24 atributů.

Základní model byl trénován na datech obsahujících dva měsíce historických záznamů (2017-01-01 až 2017-02-28). Strukturu dat pro trénink základního modelu udává obrázek 5.1. Z důvodu výskytu *NaN* hodnot po výpočtu inicializačních finančních indikátorů bylo z dat odstraněno prvních čtrnáct hodnot, okno bylo dle 4.12 nastaveno na velikost pět, spodní hranice ceny na 0, horní na 20000 a parametr *n_seq* na hodnotu tři ($t+1$, $t+2$, $t+3$).



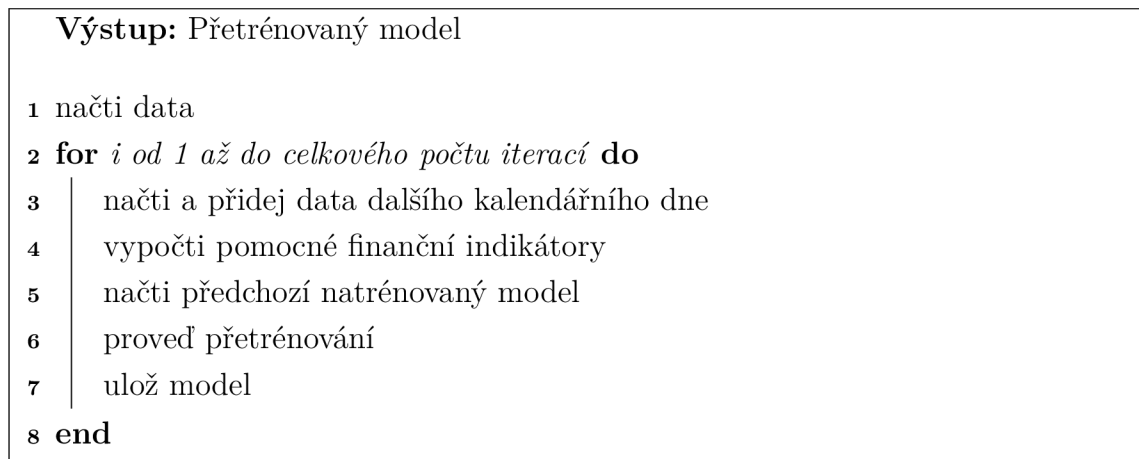
Obr. 5.1: Struktura dat pro trénink základního modelu.

Počet průchodů dat sítí byl 2000, parametr dropout mezi jednotlivými vrstvami 30%, jako optimalizační algoritmus byl vybrán Adam a aktivační funkce na výstupu byla zvolena lineární. Natrénovanému základnímu modelu byla předložena data následujícího kalendářního dne (2017-03-01) a byla provedena validace, která obsahovala výpočet hodnoty chyby RMSE pro jednotlivé predikční časy a také záznam o uděleném doporučení. Po procesu validace byla testovaná data agregována s daty použitými pro trénink základního modelu a bylo provedeno přetrénování. Přetrénovanému modelu byla poté předložena nová data dalšího kalendářního dne pro validaci. Celý postup se takto opakoval ve smyčce až do konce roku.



Obr. 5.2: Graficky znázorněný způsob testování.

Následující dva obrázky blíže pseudokódem naznačují výše popsany postup pro přetrénování 5.3 a validaci 5.4 modelu. Operace samotné jsou pak v rámci práce řešeny dvěma samostatnými zdrojovými soubory typu *python*, a sice *validace.py* a *přetrénuj_model.py*.



Obr. 5.3: Pseudokód pro přetrénování modelu.

Proces přetrénování modelu zahrnuje obdobný postup jako proces trénování. Rozdíl je v inicializaci a nastavení neuronové sítě, přičemž při přetrénování tohoto kroku již není zapotřebí. Veškerá nastavení, počet vrstev, počet neuronů, váhy jednotlivých spojení, optimalizační algoritmus a jeho nastavení jsou načtena z předchozího modelu zavoláním funkce *load_model* z knihovny Keras 4.1.1. Výstupem *přetrénuj_model.py* je poté model s příponou *.h5*, kterému byla v každé smyčce předložena nová data k tréninku.

```

Výstup: Ohodnocení přesnosti modelu, záznam udělených doporučení
1 načti data
2 for i od 1 až do celkového počtu iterací do
3   načti a přidej data dalšího kalendářního dne
4   vypočti pomocné finanční indikátory
5   načti natrénovaný model
6   proved predikci hodnot
7   aplikuj finanční strategii a uděl doporučení
8   vypočti chybovost RMSE
9   zapiš výsledky do souboru
10 end

```

Obr. 5.4: Pseudokód pro validaci modelu.

Průběh validace je naznačen na obrázku 5.2 a 5.4. Nejprve byla načtená data agregována s daty obsahujícími následující kalendářní den a byly vypočteny pomocné finanční indikátory. Následně byl do paměti načten dříve natrénovaný model a tato data mu byla předložena pro výpočet predikované ceny. Aplikováním pomocných finančních indikátorů a použitím predikovaných hodnot v čase $t+1$, $t+2$ a $t+3$ bylo poté na základě finanční strategie rozhodnuto o uděleném doporučení. Chyba RMSE 4 byla vypočítána ze známých a predikovaných hodnot v jednotlivých časech dle vztahu 5.3. Celková profitabilita systému byla vypočítána jako součet všech provedených transakcí na validačních datech při uděleném doporučení.


5.2 Výsledky

Obrázek 5.5 udává grafickou interpretaci výsledků z první iterace procesu testování. Byl použit základní model a validace proběhla na datech jemu neznámých, pro hodnoty ze dne 2017-03-01. Predikce byla učiněna i pro data, na kterých se model učil a to za účelem zjištění tréninkové chyby 5.6. Predikované hodnoty jsou vyobrazeny červenými křivkami. Hodnoty RMSE pro validovaná data v čase $t+1$, $t+2$ a $t+3$:


$$RMSE_{t+1} = 12,27 \quad (5.1)$$

$$RMSE_{t+2} = 20,21 \quad (5.2)$$

$$RMSE_{t+3} = 21,34 \quad (5.3)$$




Obr. 5.5: Modelem predikované hodnoty na neznámých datech.




Obr. 5.6: Testování přesnosti predikce základního modelu na známých datech.

Stejným způsobem bylo nadále postupováno až do konce roku 2017. Následující dva grafy udávají velikost chyby RMSE v průběhu přetrénování modelu. Graf 5.7 uvádí velikost chyby RMSE pro tréninková data a graf 5.11 pro jednotlivé validované dny.




Obr. 5.7: Hodnota RMSE měřená na tréninkových datech v průběhu roku.




Obr. 5.8: Hodnota RMSE měřená na validačních datech v průběhu roku.

Nejnižších hodnot RMSE bylo výlučně dosaženo v kroku $t+1$. Vyšší hodnoty RMSE ke konci roku, jsou způsobeny výrazným nárůstem ceny a charakterem dat. Následující grafy znázorňují odchylku, vyjádřenou v absolutní hodnotě, predikovaných hodnot od těch skutečných v čase $t+1$, $t+2$ a $t+3$.


Pro zachování přehlednosti vyobrazených grafů, byla při jejich konstrukci použita každá čtvrtá hodnota z těchto dat.



Obr. 5.9: Odchylka predikované a skutečné hodnoty v čase $t+1$.




Obr. 5.10: Odchylka predikované a skutečné hodnoty v čase $t+2$.




Obr. 5.11: Odchylka predikované a skutečné hodnoty v čase $t+3$.

Přetrénování modelu


V rámci iterativního postupu při testování, bylo po přidání nových dat (následujícího kalendářního dne) vždy zapotřebí model přetrénovat. Následující grafy ukazují porovnání chyby RMSE na validačních datech, při nastavení 20 a 50 epoch.



Obr. 5.12: Test počtu průchodů dat sítí během přetrénování pro hodnoty $t+1$.



Obr. 5.13: Test počtu průchodů dat sítí během přetrénování pro hodnoty $t+2$.



Obr. 5.14: Test počtu průchodů dat sítí během přetrénování pro hodnoty $t+3$.

Čas, potřebný k přetrénování modelu na ročních datech byl značný. Při použití padesáti průchodů dat sítí na model se tato doba, při konfiguraci Intel(R) Xeon(R) CPU E5-2640 v2 @ 2.00GHz a Nvidia GeForce GTX 1080 Ti, pohybovala kolem čtyřiceti hodin výpočetního času. Nastavením dvaceti průchodů, se časové náklady snížily o více než polovinu. Z uvedených grafů je zjevné, že dvacet epoch je pro přetrénování modelu plně dostačujících. Z tohoto důvodu byl tento počet nastaven i při testování měny Litecoin a Ethereum.

Obchodní úspěšnost

Při hodnocení úspěšnosti systému u dané měny, byl sledován počet udělených doporučení k nákupu a prodeji. Rozlišovalo se, kolik uskutečněných obchodů na doporučení skončilo ve ztrátě a kolik v zisku. Celkové hodnocení je poté založeno na výsledné profitabilitě systému za dané časové období.

Proměnné parametry finanční strategie byly následující: *skokový_nárůst* 4.5, *skokový_pokles* 4.6, *rsi_hranice_horní* a *rsi_hranice_dolní*. Z důvodů časové náročnosti testování, nebyly vyzkoušeny všechny možné kombinace těchto parametrů. Nejlepších výsledků bylo, u virtuální měny Bitcoin, dosaženo s nastavením :

- *rsi_hranice_horní* = 85,
- *rsi_hranice_dolní* = 30,
- *skokový_nárůst* = 5%
- *skokový_pokles* = 5%.

Grafické výstupy systému, obsahující výčet udělených doporučení v průběhu testovaného období, jsou pro jednotlivé měny uvedeny v rámci přílohy na konci práce. Stejná konfigurace byla použita i pro měnu Litecoin a Ethereum. Výsledky počtu udělených doporučení k nákupu, prodeji se ziskem (Prodej +), se ztrátou (Prodej -) a celkového profitu jsou uvedeny v tabulce 5.1.

Tab. 5.1: Testování úspěšnosti systému.

Měna	Počet udělených doporučení			Profit [%]
	Nákup	Prodej(+)	Prodej(-)	
Bitcoin	42	25	17	198,6
Litecoin	39	26	13	556,8
Ethereum	28	20	8	342,3

Systém vykazoval zisk u všech třech testovaných měn. Nejvyššího ročního profitu dosáhl u měny Litecoin a to 556,8%. Tento markantní rozdíl byl způsoben skokovým nárůstem ceny v závěru roku, kdy byl uskutečněn obchod který navýšil výslednou profitabilitu o 299,7%. V dalším případném rozšíření práce by úpravou obchodní strategie, zvolením jiné topologie neuronové sítě, nebo použitím dalších finančních indikátorů mohlo dojít k dalšímu zlepšení výsledné profitability systému.

6 ZÁVĚR

Práce se zabývá analýzou finančních trhů se zaměřením na virtuální měny. Obchodování na burze je dnes pro běžné lidi dostupnější, než kdykoli jindy v dějinách lidstva. Virtuální měny představují, v porovnání se svým historickým ekvivalentem, zcela novou technologii, která se během posledních několika málo let dostala do podvědomí široké veřejnosti a stala se také velmi oblíbenou komoditou pro obchodování na finančních trzích. Díky velkému pokroku ve zpracování dat a veřejně dostupným záznamům o provedených burzovních transakcích, je možné tyto data dále zkoumat za účelem hledání opakujících se vzorů.

Vlastní řešení práce se nejprve věnuje rozboru stávajícího stavu problematiky, kde jsou probrány současné metody pro analýzu finančních trhů, virtuální měny a technologie decentralizované databáze, učící se algoritmy umělé inteligence včetně hlubokého učení, neuronové sítě s rekurentní architekturou a algoritmus zpětné propagace chyby.

V následující části práce je navržen systém pro udělení doporučení k nákupu, či prodeji virtuální měny. Dříve zmíněné záznamy o provedených transakcích byly získány pomocí aplikačního programového rozhraní z burzy virtuálních měn Kraken. Systém samotný byl napsán v programovacím jazyce Python a sestává ze tří stěžejních částí: finanční knihovny, neuronové LSTM sítě a obchodní strategie. Finanční knihovna dopočítává z nabytých dat pomocné finanční indikátory, které jsou použity jako vstupní data pro neuronovou LSTM síť, která na jejich základě trénuje sekvenční model pro více krokovou predikci. Další uplatnění mají vypočtené indikátory v bloku strategie, kde se na základě aplikovaných pravidel a predikovaných hodnot rozhoduje o odělení doporučení.

Hlavním úkolem bylo sestavit systém pro udělení doporučení k nákupu či prodeji dané virtuální měny, nicméně hlavní přínos této práce spočívá, mimo jiné, také ve výzkumu a experimentování s časovými řadami finančního charakteru a jejich zpracováním algoritmy strojového učení a umělé inteligence.

Navržený systém byl testován na historických datech z roku 2017 pro virtuální měnu Bitcoin, Litecoin a Ethereum. Nejlepších výsledků bylo dosaženo s konfigurací $rsi_hranice_horní = 85$, $rsi_hranice_dolní = 30$, $skokový_nárůst = 5\%$ a $skokový_pokles = 5\%$. Nejvyššího ročního profitu, mezi testovanými měnami, bylo dosaženo u Litecoinu a to 556,8%. Tento markantní zisk byl způsoben skokovým nárůstem ceny v závěru roku, kdy byl uskutečněn obchod který navýšil výslednou profitabilitu o 299,7%.

V rámci optimalizace se ukázalo, že při tréninku a validaci modelů ve smyčce TensorFlow ukládá informace o každém modelu do mezipaměti. Tato skutečnost se po krátké době běhu programu výrazným způsobem negativně projevila vyčerpáním operační paměti počítače a exponenciálním nárůstem výpočetního času, což vedlo ke zpomalení celého procesu. Tento problém byl vyřešen zavoláním funkce `clear_session_()` z backend knihovny Keras, která uložené informace na konci každé smyčky z paměti odstranila. Výpočetní čas pro validaci jednoho kalendářního dne (čtyř hodnot) byl, s konfigurací zmíněnou v sekci 5.2, tak v čase konstatní a roven 10 sekundám. Pro jeden kalendářní rok, se tato doba, po odečtení dvou měsíců dat pro trénink základního modelu, pohybovala na pomezí 52 minut. Největším podílem časové náročnosti však nadále zůstalo načítání natrénovaného modelu. Doba trvání přetrénování modelu narůstala se zvyšujícím se množstvím předložených dat k tréninku. S nastavením dvaceti průchodů dat sítí na model, se časové náklady přetrénování, při použití ročních dat, rovnaly 27 hodinám.

Přesto, že u všech třech testovaných měn bylo na konci roku dosaženo zisku, je aktuální burzovní hodnota každé virtuální měny, tak jako každé jiné komodity na finančním trhu, neustále ovlivňována mnoha vnějšími faktory. Ty se promítají do konečné ceny a je tak vnesen i prvek v podobě náhody, který nelze předvídat. Nutno podotknout, že s ohledem na charakter burzovních dat nelze s určitostí říci, že navržený systém bude za každé situace profitabilní. Konec konců, návrhem obchodních systémů se, mnohdy neúspěšně, zabývají i korporace s miliardovými rozpočty.

Za účelem dalšího vylepšení, by práce mohla být v budoucnu rozšířena o specifický výběr kombinace pomocných indikátorů, vybraných například pomocí genetických algoritmů na základě simulace přirozeného výběru tak, aby systému poskytovaly nejvhodnější informace pro co nejpřesnější určení předpovědí. Další rozšíření by mohlo být v podobě přidání fundamentální analýzy, experimentování s topologií neuronové sítě, optimalizace kódu a obchodní strategie.

LITERATURA

- [1] LUKAČOVIČ, Martin. *SEGMENTACE OBRAZU S VYUŽITÍM HLU-BOKÉHO UČENÍ* [online]. Brno, 2017 [cit. 2017-11-20]. Dostupné z: <https://dspace.vutbr.cz/handle/11012/65794>. Diplomová práce. Vysoké učení technické v Brně.
- [2] *Understanding LSTM Networks* [online], 2015 [cit. 2017-11-20]. Dostupné z: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [3] UHLÍŘ, Václav. *Zpracování a využití informací na trzích alternativních měn* [online]. Brno, 2016 [cit. 2017-12-05]. Dostupné z: <http://hdl.handle.net/11012/59260>. Diplomová práce. Vysoké učení technické v Brně.
- [4] *Biologické algoritmy - Neuronové sítě* [online]. 2012 [cit. 2017-11-20]. Dostupné z: <https://www.root.cz/clanky/biologicke-algoritmy-5-neuronove-site/>
- [5] *Understanding LSTM Networks* [online]. 2015 [cit. 2017-11-20]. Dostupné z: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [6] GRÁCA, Martin, 2016. *Využití veřejných obchodních informací pro automatický trading* [online]. Brno [cit. 2018-03-17]. Dostupné z: <http://hdl.handle.net/11012/62105>. Bakalářská práce. Vysoké učení technické v Brně.
- [7] ŠKAPA, Jan. *Kryptoměny a budoucnost finančních trhů* [online]. Brno, 2017 [cit. 2017-12-05]. Dostupné z: <http://hdl.handle.net/11012/64769>. Diplomová práce. Vysoké učení technické v Brně.
- [8] Florian Tschorsch, Björn Scheuermann, "*Bitcoin and Beyond: A Technical Survey on Decentralized Digital Currencies*", Communications Surveys & Tutorials IEEE, vol. 18, pp. 2084-2123, 2016, ISSN 1553-877X.
- [9] *Financial Times* [online]. <https://www.ft.com/content/da5d033c-8e1c-11e1-bf8f-00144feab49a#axzz1t4qPww6r>
- [10] A. Tsantekidis and N. Passalis, *Forecasting Stock cenas from the Limit Order Book Using Convolutional Neural Networks: 2017 IEEE 19th Conference on Business Informatics (CBI)*. Thessaloniki, Greece: IEEE, 2017.
- [11] A. Graves, A. r. Mohamed, and G. M. Hinton, *Speech recognition with deep recurrent neural networks: 2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. Vancouver, BC, Canada: IEEE, 2013.


- [12] S. Qu, Y. Xi, and S. Ding, *Visual attention based on long-short term memory model for image caption generation: 2017 29th Chinese Control And Decision Conference (CCDC)*. Chongqing, China: IEEE, 2017.
- [13] TAKEUCHI, Lawrence a Yu-Ying LEE. *Applying Deep Learning to Enhance Momentum Trading Strategies in Stocks*. 2013.
- [14] D. Shah and K. R. S. Zhang, *Bayesian regression and Bitcoin: 2014 52nd Annual Allerton Conference on Communication, Control, and Computing (Allerton)*. Monticello, IL, USA: IEEE, 2015.
- [15] G. M. Khan, D. Nayab, S. A. Mahmud, and H. Zafar, *Evolving Dynamic Forecasting Model for Foreign Currency Exchange Rates Using Plastic Neural Networks: 2013 12th International Conference on Machine Learning and Applications*. Miami, FL, USA: IEEE, 2013.
- [16] KOLARŽÍK, Martin. *Hluboké učení pro klasifikaci textů* [online]. Brno, 2017 [cit. 2017-12-05]. Dostupné z: <http://hdl.handle.net/11012/65880>. Diplomová práce. Vysoké učení technické v Brně.
- [17] keras.io, [cit. 2018-03-17]. Dostupné z: <https://keras.io>
- [18] Abadi, M., Agarwal, A., Barham, P. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems* CoRR. 2015, roč. 1, č. 212. S. 19.
- [19] ŠLAMPA, Ondřej, 2017. *Paralelní trénování hlubokých neuronových sítí* [online]. Brno [cit. 2018-03-17]. Dostupné z: <http://hdl.handle.net/11012/69598>. Diplomová práce. Vysoké učení technické v Brně.
- [20] MAŠEK, Jan. *Automatické strojové metody získávání znalostí z multimediálních dat* [online]. Brno, 2016 [cit. 2017-12-05]. Dostupné z: <http://hdl.handle.net/11012/63076>. Disertační práce. Vysoké učení technické v Brně.
- [21] Artificial neural network. In: <https://en.wikipedia.org/> [online]. [cit. 2017-12-01]. Dostupné z: https://en.wikipedia.org/wiki/Artificial_neural_network
- [22] Cryptocurrency Market Capitalizations. In: *Coinmarketcap* [online]. [cit. 2017-12-04]. Dostupné z: <https://coinmarketcap.com>
- [23] HAN, Jiawei, Micheline KAMBER a Jian PEI.: “Data mining: concepts and techniques.”, *Morgan Kaufmann series in data management systems*. 2012, ISBN 978-0-12-381479-1.

- [24] NOVÁČIK, Tomáš. *Rekurentní neuronové sítě pro rozpoznávání řeči* [online]. Brno, 2016 [cit. 2017-12-05]. Dostupné z: <http://hdl.handle.net/11012/61863>. Diplomová práce. Vysoké učení technické v Brně.
- [25] Sagefin.cz *Sagefin.cz* [online] Dostupné z: <http://www.sagefin.cz>
- [26] Kraken.com *Kraken.com* [online] Dostupné z: <http://www.kraken.com>
- [27] <http://ta-lib.org> *ta-lib.org* [online]. [cit. 2018-03-11]. Dostupné z: <http://mrjbjq7.github.io/ta-lib/index.html>
- [28] F. Altché and A. de La Fortelle, *An LSTM network for highway trajectory prediction: Intelligent Transportation Systems (ITSC)*. Yokohama, Japan: IEEE, 2018.
- [29] S. Kankanamge, C. Fookes, and S. Sridharan, *Facial analysis in the wild with LSTM networks: 2017 IEEE International Conference on Image Processing (ICIP)*. Beijing, China: IEEE, 2017.
- [30] W. Wand, J. Koutník, and J. Schmidhuber, *Lipreading with long short-term memory: 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Shanghai, China: IEEE, 2016.
- [31] F. F. Ting and K. S. Sim, *Self-regulated multilayer perceptron neural network for breast cancer classification: Robotics, Automation and Sciences (ICORAS)*. Melaka, Malaysia: IEEE, 2017.
- [32] Y. Zhang, Y. Tang, B. Fang, and Z. Shang, *Fast multi-object tracking using convolutional neural networks with tracklets updating: 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC)*. Shenzhen, China: IEEE, 2017.
- [33] S. R. Sujana, S. S. Abisheck, A. T. Ahmed, and K. R. S. Chandran, *Real time object identification using deep convolutional neural networks: Communication and Signal Processing (ICCSP)*. Chennai, India: IEEE, 2017.
- [34] E. Nishani and B. Çiço, *Deep neural networks for video analysis of human pose estimation: Computer vision approaches based on deep learning and neural networks*. Bar, Montenegro: IEEE, 2017.
- [35] T. Bluche, H. Ney, J. Louradour, and C. Kermorvant, *Framewise and CTC training of Neural Networks for handwriting recognition: 2015 13th International Conference on Document Analysis and Recognition (ICDAR)*. Tunis, Tunisia: IEEE, 2015.


- [36] J. Donahue, *Long-term recurrent convolutional networks for visual recognition and description: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, MA, USA: IEEE, 2015.
- [37] Tensorflow.org, [cit. 2018-03-17]. Dostupné z: <https://www.tensorflow.org>
- [38] IBM.com, [cit. 2018-03-17]. Dostupné z: <https://www.ibm.com/blogs/systems/deep-learning-performance-breakthrough/>
- [39] Satoshi Nakamoto, *Bitcoin: A peer-to-peer electronic cash system* [online]. [cit. 2017-12-05]. Dostupné z: <http://bitcoin.org/bitcoin.pdf>
- [40] blockgeeks.com, <https://blockgeeks.com/what-is-blockchain-technology/>
- [41] learncryptography.com, <https://learncryptography.com/cryptocurrency>
- [42] blockgeeks.com, <https://blockgeeks.com/cryptocurrencies-cryptography/>
- [43] bitsonblocks.net, Dostupné z: <https://bitsonblocks.net/2015/09/09/a-gentle-introduction-to-blockchain-technology/>
- [44] machinelearningmastery.com, Dostupné z: <https://machinelearningmastery.com>
- [45] Diederik P. Kingma, Jimmy Ba, *Adam: A Method for Stochastic Optimization*. San Diego, CA, USA: 2014arXiv1412.6980K 2015.
- [46] numpy.org, [cit. 2018-04-15]. Dostupné z: <http://www.numpy.org>
- [47] pandas.pydata.org, [cit. 2018-04-15]. Dostupné z: <https://pandas.pydata.org>

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK


RBM	Restricted Boltzmann Machine – omezené Boltzmannovy systémy
NN	Neural Networks – Neuronové sítě
CNN	Convolutional Neural Networks – Konvoluční neuronové sítě
RNN	Recurrent neural network – Rekurentní Neuronové Sítě
LSTM	Long Short-Term Memory
PoW	Proof-of-Work
PoS	Proof-of-Stake
CPU	Central Processing Unit – Centrální Procesorová Jednotka
GPU	Graphic Processing Unit – Grafická Procesorová Jednotka
DBN	Deep Belief Network
SAE	Stacked Auto Encoder
k -NN	k -Nearest Neighbors – k -nejbližších sousedů
DT	Decision Trees – Rozhodovací stromy
RF	Random Forests
SVM	Support Vector Machines
BPTT	BackPropagation Through Time – Zpětná propagace chyby
RMSE	Root-Mean-Squared-Error – Střední kvadratická odchylka
bias	bias - Odchylka
x	Vstup
f	Aktivační funkce
w	Váha neuronového spoje
y	Výstup neuronu
β	Zisk
t	Časový krok
h	Stav skryté vrstvy
z	Aktivace skryté vrstvy
u_t	Vnitřní potenciál vrstvy skrytých neuronů
v_t	Vnitřní potenciál výstupní vrstvy
E	Chybová funkce
δ	Velikost změny váhy
α	Parametr učení
c	Paměťový blok LSTM
g	Smršťovací funkce
RSI	Relative Strength Index - Index Relativní Síly
MA	Moving Average - Klouzavý Průměr
EMA	Exponential Moving Average - Exponenciální Klouzavý Průměr
$MACD$	Sbíhavost a Rozbíhavost Klouzavých Průměrů



Obr. 6.1: Výstup testování systému za rok 2017 na virtuální měně Bitcoin.



Obr. 6.2: Výstup testování systému za rok 2017 na virtuální měně Litecoin.



Obr. 6.3: Výstup testování systému za rok 2017 na virtuální měně Ethereum.