

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra informatiky a výpočetní techniky

Bakalářská práce

Výběr obchodní strategie s podporou neuronové sítě

ZÁPADOČESKÁ UNIVERZITA V PLZNI

Fakulta aplikovaných věd

Akademický rok: 2021/2022

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Jan CHODORA**
Osobní číslo: **A19B0066P**
Studijní program: **B0613A140015 Informatika a výpočetní technika**
Specializace: **Informatika**
Téma práce: **Výběr obchodní strategie s podporou neuronové sítě**
Zadávající katedra: **Katedra informatiky a výpočetní techniky**

Zásady pro vypracování

1. Prostudujte problematiku obchodování (komodity, akcie) a možnost (polo-)automatického získávání obchodních dat.
2. Analyzujte dostupné veřejné zdroje obchodních dat a vytvořte SW pro získávání těchto dat ve vhodném formátu.
3. Navrhněte množinu vhodných indikátorů a neuronovou síť pro podporu obchodních rozhodnutí.
4. Ověřte funkci algoritmu a vyhodnoťte dosažené výsledky.

Rozsah bakalářské práce: **doporuč. 30 s. původního textu**
Rozsah grafických prací: **dle potřeby**
Forma zpracování bakalářské práce: **tištěná/elektronická**

Seznam doporučené literatury:

Dodá vedoucí bakalářské práce.

Vedoucí bakalářské práce: **Ing. Tomáš Mainzer, Ph.D.**
Katedra informatiky a výpočetní techniky

Datum zadání bakalářské práce: **4. října 2021**
Termín odevzdání bakalářské práce: **5. května 2022**

L.S.

Doc. Ing. Miloš Železný, Ph.D.
děkan

Doc. Ing. Přemysl Brada, MSc., Ph.D.
vedoucí katedry

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím citovaných pramenů.

V Plzni dne 6. května 2022

Jan Chodora

Abstract

This thesis focuses on investments on the capital market, mainly on trading decisions based on a neural networks predictions. First, the data is downloaded from its sources, then it proceeds with to be normalized and pre-processed using indicators from the technical analysis. The result of this process is transferred to an input layer of the neural network which returns a prediction for the test (data) set. This thesis also focuses on the methods of creating a training signal, which is represented as a 7 or 6 dimensional signal. Part of this signal is predicted by the neural network. The predicted model is then tested in several experiments where it is tested if it matches the pattern it obtained. Based on the model, trading is simulated. This thesis also includes experiments where the model is trained on data from different sources than the test source.

Abstrakt

Tato práce se zabývá obchodováním na kapitálových trzích založeném na neuronové síti. Data jsou nejprve stažena z příslušných zdrojů, poté probíhá jejich normování a předzpracování indikátory technické analýzy. Toto tvoří vstup do neuronové sítě, která vrátí pro testovací data predikci (očekávaný testovací signál). V práci jsou zpracovány dvě metody tvorby vstupního signálu, dvousložková a šestisložková. Výsledná predikce neuronové sítě je testována na několika experimentech, kdy je kontrolována shoda naučeného modelu s testovacím signálem a schopnost utvářet predikce, na jejichž základě se budou provádět obchody generující zisk. V rámci této práce jsou mimo jiné natrénované modely testovány na datech z jiného zdroje než je ten, na kterém byly natrénovány.

Obsah

1	Úvod	8
2	Trhy	10
2.1	Kapitálový trh	10
2.1.1	Akcie	10
2.2	Trhy s cizími měnami	11
2.2.1	Devizový trh a měnové páry	11
2.2.2	Kryptoměny	11
2.3	Komoditní trhy	11
3	Indikátory technické analýzy	13
3.1	SMA	13
3.2	EMA	13
3.3	RSI	15
3.4	CCI	16
3.5	ATR	16
3.6	ADX	18
4	Neuronové sítě	20
4.1	Dopředné neuronové sítě	20
4.1.1	Struktura dopředných neuronových sítí	20
4.1.2	Perceptron	22
4.1.3	Vícevrstvý perceptron	23
4.2	Zpětnovazební neuronové sítě	23
4.3	Konvoluční neuronové sítě	24
4.4	Učení neuronových sítí	25
4.4.1	Učení s učitelem	25
4.4.2	Učení bez učitele	25
4.4.3	Učení pod částečným dohledem	25
4.5	Existující realizace	25
5	Návrh realizace	27
5.1	Předzpracování dat	27
5.1.1	Stahování dat	27
5.2	Neuronová síť	28
5.2.1	Šestiprvkový model	28

5.2.2	Dvouprvkový model	29
5.3	Hodnocení	30
5.3.1	Počítání zisku	30
5.3.2	Střední kvadratická chyba	30
6	Výsledky a experimenty	31
6.1	Experimenty s jednotnými daty	31
6.1.1	Počet neuronů ve skryté vrstvě modelu	31
6.1.2	Hodnocení	34
6.2	Experimenty s různými daty	34
6.2.1	Počet neuronů ve skryté vrstvě modelu	34
6.2.2	Hodnocení	36
6.2.3	Možné zisky	38
7	Závěr	41
	Literatura	42

1 Úvod

Jednou z možností, jak lze zhodnotit majetek, jsou investice, čili vložení peněz do něčeho, na čem peníze nebudou ztrácet na ceně. Lidé investují do čehokoliv, kde se hodnota za čas alespoň zvýší o hodnotu inflace, aby investování mělo nějaký smysl. V tomto případě se hodnota majetku nezvýší, ale alespoň se nesníží. Velká část malých investorů vstoupila do světa investic právě za účelem ochrany majetku před inflací. Předmětem investic se pak stávají například nemovitosti nebo kapitálové trhy. Těmi mohou být akcie, dluhopisy, měny a to včetně v posledních letech oblíbených kryptoměn, nebo naopak jeden z nejstarších instrumentů, komodity.

Investování je ale velice riziková záležitost, což znamená, že co člověk může získat, může i ztratit. Přes noc může mít náhle dvojnásobek svého mění, nebo prakticky nic. Menší investoři, kteří pouze chtějí uchránit svůj majetek před dlouhodobou inflací, která by jej znehodnotila, tak často raději svěřují své úspory někomu jinému, kdo investování věnuje svůj čas a kdo se v něm také vyzná.

Nemusí se však nutně jednat o člověka. Pokud je člověk pouze tím, kdo zpracuje data a rozhodne, do čeho kdy investovat, vyvstává logicky otázka, zda není možné tohoto člověka nahradit strojem. Stroje totiž často bývají oproti lidem, minimálně z dlouhodobého hlediska, levnější a je-li program správně napsán a má k dispozici dostatek dat, mohou být i efektivnější.

Jde tedy o vytvoření programu, který bude alespoň z části zastávat funkci makléře, to znamená vyhodnocovat data a posuzovat, kdy je vhodné co nakoupit a kdy naopak prodat. Vymyslet kritéria, podle kterých se program bude rozhodovat však není jednoduchou záležitostí, proto je vhodné využít některé z metod umělé inteligence. Často se například využívá genetických algoritmů nebo neuronových sítí. A právě využitím neuronových sítí se bude zabývat tato práce.

Program se tedy nejdříve naučí na historických datech predikovat vývoj trhu, a pak tyto znalosti uplatní na datech nových, neznámých. Pro zlepšení schopnosti rozhodování budou data předzpracována vybranými indikátory technické analýzy, které byly navrženy analytiky zblhlými v oblasti inves-

tování. Nakonec bude neuronová síť testována na různých datech z různých trhů.

2 Trhy

Obecně se trhy rozdělují na veřejné, na kterých může obchodovat prakticky kdokoli, a neveřejné, které nabízejí možnost obchodovat pouze jednomu člověku či omezenému okruhu osob. Pro malého investora je ale bezpochyby více příležitostí na veřejném trhu. Rozhodne-li se člověk investovat své finance, pak jedna z prvních otázek, kterou si položí, zcela jistě bude, do čeho zainvestuje.

2.1 Kapitálový trh

Kapitálový trh je určen pro obchodování finančních instrumentů, které mají povahu dlouhodobých investic. Jsou skrze něj obchodovány dlouhodobé úvěry nebo dlouhodobé cenné papíry.[12]

Oproti kupříkladu peněžnímu trhu je ten kapitálový obecně rizikovější, a tedy zároveň potenciálně výnosnější.

2.1.1 Akcie

Akiový trh je kapitálový trh, na kterém se obchoduje s cennými papíry, nejčastěji se jedná o akcie společností, dluhopisy či deriváty. Obchody probíhají buď na burzovním nebo na mimoburzovním trhu. Na burzách lze typicky obchodovat ve všední dny a to pouze během dané otevírací doby.

Akcie jsou cenné papíry, které označují hodnotu dané akciové společnosti, tedy emitenta akcií, v čase. Držitel těchto akcií má (běžně) právo na svůj podíl ze zisku společnosti a také právo hlasovat na valné hromadě akcionářů. Jednou z věcí, kterou akcionáři na valné hromadě řeší, je vyplácení dividend. Vyplácení dividend znamená rozdělení zisku společnosti mezi akcionáře.

Právě obchody s akciemi budou jedním z témat, kterým se tato práce bude zabývat. A to především proto, že data z této oblasti jsou rozmanitá a investování do akcií bývá mezi lidmi jednou z nejběžnějších investic. Cena akcií různých emitentů se však značně liší, někdy se pohybuje v řádu korun, jindy v řádu destitisíců či statisíců.

2.2 Trhy s cizími měnami

Trhy s cizími měnami se dělí na dva základní segmenty. Prvním segmentem jsou devizové trhy, na těch dochází ke vzájemnému bezhotovostnímu směňování různých měn, čímž je zároveň utvářen jejich kurz. Významnými subjekty transakcí probíhajících na devizových trzích jsou například dealeri centrálních či obchodních bank. Druhým segmentem jsou trhy valutové, které jsou odvozovány z devizových trhů, obchoduje se na nich s hotovostními formami cizích měn.[12]

2.2.1 Devizový trh a měnové páry

Měnový pár se skládá ze dvou měn, základní a kотаční. Základní měnou je ta, kterou chceme nakoupit/prodat; naopak kотаční měna je měnou konverze. Máme-li například měnový pár EUR/USD, a otevřeme na tomto instrumentu nákupní pozici, budou základní měnou eura a kотаční měnou budou dolary. Jinými slovy budeme nakupovat eura za dolary.

S měnovými páry lze obchodovat na devizovém trhu, kterému se obecně říká Forex. Oproti burzám má Forex tu výhodu, že nikdy nezavírá, kurzy měnových párů se tedy neustále mění.[7]

2.2.2 Kryptoměny

Tato práce se též bude zabývat obchodováním kryptoměn. Na rozdíl od běžných měn popsaných výše, jsou kryptoměny zcela virtuální. Jedná se také o jednu z nejnovějších možností obchodování, a možná proto bývá oblíbenou investicí.

Vezměme si například bitcoin, dnes asi nejznámější kryptoměnu, jehož hodnota je nepochybně velice volatilní. 20. 11. 2015 byla cena bitcoinu 8 300 korun, 12. 11. 2021, tedy přibližně o 6 let později, byla jeho hodnota 1 420 825 korun. Potenciální investor tak měl příležitost svou investici více jak 171-krát zvýšit a to během pouhých šesti let. Vývoj ceny této kryptoměny lze pozorovat na obrázku 2.1.

2.3 Komoditní trhy

Komodity jsou zemědělské produkty, suroviny a materiály jednotné hodnoty a kvality. Škála komodit tak sahá od zlata, přes kávu, až po ropu. S



Obrázek 2.1: Graf vývoje ceny Bitcoinu v CZK. Obrázek je převzat z Google Finance [4].

komoditami se obchoduje především na komoditních burzách, ty si samy určí vlastnosti a obchodovatelnou kvantitu každé komodity. Ceny komodit jsou určeny událostmi, ať už politického či ekonomického charakteru, počasím a samozřejmě nabídkou a poptávkou. Většina komodit je vázána na cenu amerického dolaru, takže přirozeně vývoj jeho hodnoty je pak může ovlivnit.[12]

3 Indikátory technické analýzy

Pro lepší vyhodnocení grafu vývoje ceny se využívají indikátory technické analýzy, které pomáhají odhalit možné trendy. Některé indikátory pouze vyhladí křivku, jiné třeba určí sílu trendu a jeho šanci na to, že se bude ubírat daným směrem. Indikátory technické analýzy nejen že pomáhají lidským expertům v praxi, mohou ale pomoci i stroji¹.

Níže jsou popsány konkrétní příklady indikátorů technické analýzy. Některé z nich, jako například SMA, byly vybrány kvůli jejich jednoduchosti a tomu, že se jedná o základní prostředky v této oblasti, jiné naopak byly vybrány kvůli své komplexnosti či tomu, že se jedná o horkou novinku v oblasti indikátorů technické analýzy.

Pro ilustraci byly následující indikátory obohaceny o grafické ukázky, všechny tyto ukázky jsou prováděny nad stejnými daty, která jsou vykreslena na obrázku 3.1. Osa Y vždy zobrazuje hodnoty, kterých daný indikátor na těchto datech dosáhl, na ose X jsou zobrazeny počty dnů od začátku období.


3.1 SMA

Jedním z nejjednodušších indikátorů technické analýzy je klouzavý průměr (Simple Moving Average). Ten slouží k vypočítání průměrné hodnoty z údajů za posledních n dní. Příklad toho, jak tento klouzavý průměr vypadá, vidíme na obrázku 3.2. Výpočet: $SMA = \frac{\sum_{i=1}^n A_i}{n}$. [6]


3.2 EMA

Exponenciální klouzavý průměr vychází z klouzavého průměru, avšak liší se od něj v tom, že čím novější daný údaj je, tím vyšší váha mu je přiřkládána. $EMA_i = x_i * k + EMA_{i-1} * (1 - k)$, kde $k = \frac{Smoothing}{1+n}$. Konstanta *Smoothing* bývá často nastavena na *Smoothing* = 2. Dále pak n značí celkový počet dní, neboli délku jedné periody. EMA za danou periodu tedy


¹Například v práci [13], ve které tým vědců vytváří systém pro obchodování s akcemi. Ve zmiňované práci byly mimo jiné použity indikátory RSI či MACD.



Obrázek 3.1: Akcie firmy Microsoft Corporation za období 10. 1. 2000 až 10. 1. 2022.



Obrázek 3.2: SMA nad daty Microfot Corporation.



Obrázek 3.3: EMA nad daty Microsoft Corporation.

vypočteme jako $EMA = \sum_{i=1}^n EMA_i$. [2] Ukázka je znázorněna na obrázku 3.3.


3.3 RSI

Index relativní síly (Relative Strength Index) je indikátor převážně využívaný na trzích, kde je spíše dlouhodobý trend růstu/poklesu. RSI ukazuje trend trhu. RSI také může pomoci odhalit překoupený či přeprodaný trh.

RSI se pro období posledních n dní počítá následovně: $RSI(n)_i = 100 - \frac{100}{1 + \frac{U(n)}{D(n)}}$.

Kde $U(n)$ značí průměr z růstových zavíracích změn za posledních n dní. Obdobně $D(n)$ značí průměr z poklesových zavíracích změn za posledních n dní.

Je doporučeno dosazovat za n hodnotu 9, 14 nebo 26 dní. Hodnoty RSI se pohybují v intervalu $< 0; 100$). [3] Grafická ukázka tohoto indikátoru je představena v obrázku 3.4.



Obrázek 3.4: RSI nad daty Microfot Corporation.


3.4 CCI

(Commodity Channel Index) pomáhá v rozhodování, zda se trh blíží spíše překoupenosti, nebo naopak přeprodanosti. $CCI = \frac{TypicalPrice - SMA}{0.015 * MeanDeviation}$


Kde SMA značí výše zmíněný klouzavý průměr. $TypicalPrice = \sum_{i=1}^n \frac{(High + Low + Close)}{3}$, $MeanDeviation = \frac{(\sum_{i=1}^n |TypicalPrice - SMA|)}{n}$, $High$ pak označuje nejvyšší hodnotu za daný den, analogicky Low označuje nejnižší hodnotu za daný den, $Close$ pak označuje hodnotu, na které trh daný den skončil. Tvůrce indikátoru CCI doporučil dělení konstantou 0.015, díky tomu typicky připadá 70-80% výsledných hodnot do intervalu $< -100, 100 >$. [10] I tento indikátor je opatřen grafickou ukázkou - obrázek 3.5.

3.5 ATR

V překladu průměrný skutečný rozsah (Average True Range) je indikátor, původně vyvinutý pro komoditní trh. Výpočet: $ATR = (\frac{1}{n}) \sum_{i=1}^n TR_i$, $TR_i = Max[(High_i - Low_i), (|High_i - Close_{i-1}|), (|Low_i - Close_{i-1}|)]$, obecně se používá $n = 14$ dní. [5] Obrázek 3.6 znázorňuje ukázkou tohoto indikátoru.



Obrázek 3.5: CCI nad daty Microfot Corporation.



Obrázek 3.6: ATR nad daty Microfot Corporation.

3.6 ADX

Indikátor indexu průměrného směru (Average Directional Index) bývá využíván pro posouzení síly trendu. Tvůrce ADX, J. Welles Wilder, předpokládá, že je-li hodnota $ADX \in < 0, 25)$, je trend slabý. Naopak jako silný trend je považován ten, pro který je $ADX \in < 25, 50)$. Velmi silný je při $ADX \in < 50, 75)$, a extrémě silný trend je pak pro $ADX \in < 75, 100 >$.

Výpočet:

$$UpMove = High_i - High_{i-1},$$


$$DownMove = Low_i - Low_{i-1}.$$

Je-li $UpMove > Max(DownMove, 0)$, pak $DM^{(+)} = UpMove$, jinak $DM^{(+)} = 0$.

Je-li $DownMove > Max(UpMove, 0)$, pak $DM^{(-)} = DownMove$, jinak $DM^{(-)} = 0$.

Poté se vybere délka periody, Wilder původně použil 14-denní periodu ($n = 14$). $DI^{(+)} = 100 \frac{SMMA(DM^{(+)})}{ATR}$, $DI^{(-)} = 100 \frac{SMMA(DM^{(-)})}{ATR}$. Kde SMMA (Smoothed Moving Average): $SMMA = \frac{n-1}{n} \sum_{j=1}^{i-1} (Close_j) + Close_i$. Místo SMMA je možno dosadit jiné druhy klouzavých průměrů, například EMA či SMA.

Konečné ADX se vypočítá takto: $ADX = 100 \frac{SMMA(|DI^{(+)} - DI^{(-)}|)}{DI^{(+)} + DI^{(-)}}$. Kde $High$ označuje nejvyšší hodnotu, kterou trh v daném dni dosáhl, naopak Low označuje nejnižší hodnotu trhu v daném dni. Podobně $Close$ je přiřazena hodnota, při které trh daný den zavíral. Index i značí dnešní den, včerejší by byl $i - 1$ apod. [9]. Grafické znázornění tohoto možná na první pohled složitého výpočtu, vidíme na obrázku 3.7.



Obrázek 3.7: ADX nad daty Microfot Corporation.

4 Neuronové sítě

Jeden z výpočetních modelů používaných v oblasti umělé inteligence jsou umělé neuronové sítě, které jsou založené na principu vycházejícího z biologického fungování mozku, především neuronů. A to hlavně kvůli schopnosti biologických neuronových sítí řešit nelineární úlohy, učit se, zevšeobecňovat a extrahovat někdy na první pohled nezřetelné souvislosti. Přirozeně se pak umělá neuronová síť skládá z umělých neuronů. Umělé neuronové sítě se nadále dělí dle použitých přenosových funkcí a způsobu propojení neuronů.

Neuronové sítě přiřazují sadě vstupních hodnot $x_i, i = 1, \dots, k$ set jedné či více výstupních hodnot $y_j, j = 1, \dots, k^*$. Což je stejné jako u ostatních aproximačních metod (polynomiálních či lineárních). Avšak rozdíl spočívá v tom, že umělé neuronové sítě často obsahují jednu či více skrytých vrstev, ve kterých jsou vstupní proměnné transformované specifickou funkcí, taktéž známou jako logistická či logsigmoidní transformace. [8]

4.1 Dopředné neuronové sítě

Dopředné neuronové sítě získaly svůj název kvůli tomu, že informace jde skrze neuronovou síť pouze jedním směrem, což je hlavní rozdíl oproti rekurentním neuronovým sítím, kde se síť učí na základě zpětné vazby. Tento typ sítí hraje velice důležitou roli v oblasti umělé inteligence, příkladem mohou být konvoluční sítě, které se využívají při rozpoznávání obrázků.

Dopředné neuronové sítě si kladou za cíl aproximaci funkce f^* . Například pro klasifikátor $y = f^*(x)$, kde je vstupu x přiřazena kategorie y . Dopředné neuronové sítě definují přiřazení $y = f(x; \theta)$, ze kterého se odvodí parametr θ , díky kterému lze získat nejlepší aproximaci dané funkce.

4.1.1 Struktura dopředných neuronových sítí

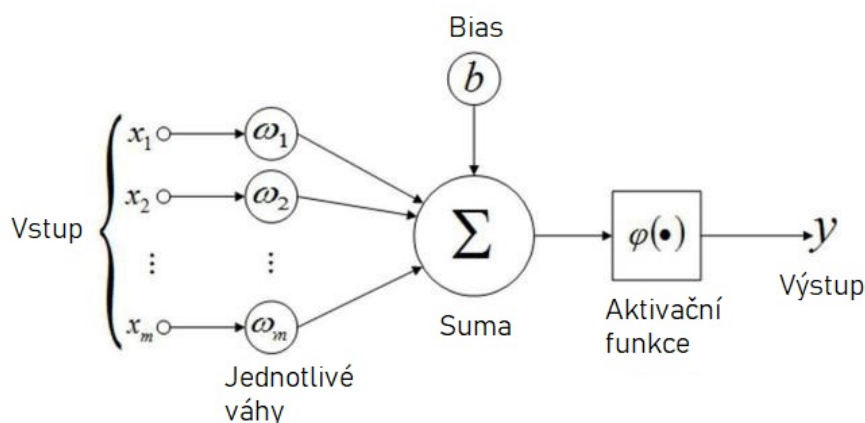
Celá tato sekce čerpá informace z kapitoly Deep Forward Networks knihy Deep Learning [1].

Na začátek je důležité vysvětlit, proč se dopředným neuronovým sítím říká sítě. Je tomu tak proto, že typicky bývají reprezentovány kompozicí mnoha různých funkcí. Tento model lze popsat acyklickým orientovaným

grafem, který popisuje celkovou kompozici těchto funkcí. Toto tvrzení lze jednoduše ilustrovat na následujícím příkladu: mějme tři funkce $f^{(1)}$, $f^{(2)}$ a $f^{(3)}$, které jsou do sebe postupně vnořeny, což může vypadat jako funkce $f(x) = f^{(3)}(f^{(2)}(f^{(1)}))$. V prezentovaném modelu se funkci $f^{(1)}$ říká vstupní vrstva nebo též první vrstva modelu, $f^{(2)}$ je druhá vrstva, $f^{(3)}$ je analogicky třetí vrstva modelu. Zároveň, protože je poslední, se jedná o výstupní vrstvu. Je vhodné dodat, že v tomto případě, protože jsou vrstvy celkem tři, je druhá vrstva skrytá. Celková délka řetězce či celkový počet zanořených funkcí udává hloubku modelu. Z této terminologie vychází také název hluboké učení.

Během trénovací fáze se snažíme o to, aby byla výsledná funkce $f(x)$ co nejpodobnější pomyslné funkci $f^*(x)$, která vygenerovala data, z nichž čerpáme. Na trénovací data lze tedy pohlížet jako na množinu příkladů aproximace funkce $f^*(x)$. Tyto příklady jsou ohodnoceny na různých bodech této funkce, které jsou určeny trénovacími daty. Nutno ještě dodat, že trénovací data bývají typicky zašuměná. Každý zmíněný příklad x je tedy vhodné označit spíše jako $y \approx f^*(x)$. Tyto příklady, na kterých model trénujeme, přímo specifikují chování výstupní vrstvy v každém bodě x , konkrétně musí mít na výstupu hodnotu blízkou y . Avšak chování ostatních vrstev není trénovacími daty přímo specifikováno. Trénovací algoritmus musí zjistit, jak tyto jednotlivé vrstvy přimět k tomu, aby vytvářely požadovaný výstup, který zajistí, že funkce f^* může být co nejpřesněji aproximována. A právě proto, že trénovací data neukazují, co by mělo být výstupem těchto vrstev, se jim říká skryté vrstvy.

Stále ale nebylo vysvětleno, proč se těmito sítím říká neuronové. Vysvětlení se skrývá v jejich vzniku, neboť při jejich návrhu byly inspirovány právě poznatky z neurologie. Jednotlivé skryté vrstvy bývají typicky ohodnoceny vektory. Dimenze těchto skrytých vrstev určuje takzvanou šířku modelu. Jednotlivé prvky těchto vektorů plní stejnou roli jako neurony. Možná pochopitelnější je pohlížet na vrstvu neuronové sítě spíše nežli jako na vektorovou funkci, jako na vrstvu skládající se z mnoha paralelně pracujících součástí, přičemž každá z nich reprezentuje vektorově-skalární funkci. Zde se každá součástka podobá neuronu v tom smyslu, že jako vstup přijímá vstup z jiných součástí, a vypočítává si svoji vlastní aktivační funkci $f^i(x)$. Tato funkce je též inspirována neurologií, konkrétně tím, jak ji vypočítávají biologické neurony. Avšak dnes se neuronové sítě řídí spíše matematickými modely, než aby se snažily dokonale simulovat funkce mozku. Strukturu umělého neuronu lze pozorovat na obrázku 4.1.



Obrázek 4.1: Umělý neuron

Nejjednodušším modelem dopředných neuronových sítí je perceptron, ve kterém se nenachází žádná skrytá vrstva. Pokud tento model rozšíříme o skryté vrstvy, jedná se o vícevrstvý perceptron. Oba tyto modely jsou více popsány v následujícím textu.

4.1.2 Perceptron

Jeden z nejjednodušších modelů neuronové sítě s dopředným zpracováním. Jedná se o jednovrstvou neuronovou síť s dopředným šířením a učením s učitelem. Je složen z jediného neuronu. Použití tohoto typu neuronové sítě je však omezeno na lineárně separovatelné úlohy. Je-li potřeba řešit složitější úlohy, je nutno použít vícevrstvý perceptron.

Perceptron obsahuje několik vstupů ohodnocených váhami a jediný výstup. Probíhají v něm dva výpočty, těmi jsou potenciál neuronu a aktivační funkce.

Potenciál neuronu

$\xi = \sum_{i=0}^n w_i x_i$. Zde x_i označuje signál přijatý z neuronu i předešlé vrstvy. w_i označuje váhu, kterou tomuto signálu přiřadíme. Tato váha bývá určena během trénovací fáze, výsledkem učení neuronové sítě je tedy nastavení hodnot těchto vah. Stejně tak jsou označeny i na již zmiňované obrázku 4.1.

Aktivační funkce

Hodnota výstupu neuronu je počítána pomocí přenosové (aktivační) funkce. Zde se často používá sigmoida či schodovitá funkce. V této práci bude vy-

užita funkce sigmoida, ta je vypočtena následovně: $\sigma_i(z) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$. Na obrázku 4.1 je místo σ použita φ .

4.1.3 Vícevrstvý perceptron

Vícevrstvý perceptron obsahuje jednu či více skrytých vrstev, ty jsou zavedeny mezi vstupní a výstupní vrstvou. Princip fungování je následující: Vstupní vrstva přijme signál, který má být zpracován. Výstup každé vrstvy jde na vstup vrstvy, která je právě o jednu úroveň níže. Výstupem poslední (výstupní) vrstvy je pak požadovaná akce, kterou je například klasifikace či predikce.

Celé propojení můžeme vidět na obrázku 4.2. Vrstev samozřejmě může být i více než 3. Každý z kroužků na tomto obrázku si můžeme představit jako neuron z obrázku 4.1, kde x_i by byly na jednotlivých hranách, které vedou mezi vrstvami. Zároveň by y , výstupní hodnota neuronu, představovala x_i , vstupní hodnotu neuronů následující vrstvy.


Právě vícevrstvý perceptron bude použit pro reprezentaci neuronové sítě v této práci. Je tomu tak především proto, že samotný perceptron by práci nezádl, nemusí se totiž jednat o lineární úlohu. Vstupem do programu budou data předzpracovaná indikátory technické analýzy a znormovaná. Na výstupu bude množina signálů jako například "koupit", "prodat", "určitě prodat" a další. Přesný návrh je detailně rozebrán v příslušné sekci této práce.

Velikost neuronové sítě

Jak ale určit velikost neuronové sítě, respektive počet neuronů ve skryté vrstvě? Na tuto otázku se přesná odpověď hledá těžko. Obecně se uvádí, že počet neuronů ve skryté vrstvě by se měl pohybovat mezi počtem neuronů ve vstupní vrstvě a počtem neuronů ve výstupní vrstvě. Univerzální velikost skryté vrstvy však zřejmě neexistuje.

4.2 Zpětnovazební neuronové sítě

Zpětnovazební architektura dovoluje použít výstup neuronů jako vstup do neuronů z předešlých vrstev nebo i do nich samotných. Tento typ architektury neuronových sítí nachází své využití například v predikci časových řad. Dalším možná srozumitelnějším příkladem využití zpětnovazebních sítí může



Obrázek 4.2: Dopředná neuronová síť (MLP)

být tvorba textového našeptávače, či jiná práce s textem a jeho zpracováváním. Zde se projeví schopnost této architektury nalézt vzájemné závislosti, v tomto případě závislosti slov ve větě, na jejichž základě neuronová síť vytváří predikci.[11]

4.3 Konvoluční neuronové sítě

Na konvoluční síti lze do jisté míry pohlížet jako na vícevrstvé dopředné síti (MLP), avšak s tím rozdílem, že konvoluční síti jsou obohaceny o regularizaci, jejíž hlavním úkolem je zabránit přetrénování¹ sítě. Regularizace může obecně probíhat například skrze penalizaci parametrů během fáze testování. Avšak v konvolučních sítích probíhá tak, že síť dává přednost jednodušším vzorcům v datech před těmi složitějšími. Respektive tyto vzory řadí hierarchicky. Informace je pak prosévána skrze filtry tvořené těmito vzorci.

Konvoluční síti, jak bylo uvedeno v předešlém odstavci, hledají v datech vzory. Není tedy překvapující, že se využívají převážně, avšak nikoli výlučně,

¹Přetrénování (overfitting) je stav, kdy je síť naučena na trénovací sadu dat tak moc, že na jiné sadě dat by prakticky selhala. Tento stav lze odhalit testovací sadou dat. Je-li model přetrénovaný, tak má sice na trénovací sadě vysokou míru úspěšnosti, avšak v okamžiku nasazení na testovací sadu jsou tyto výsledky výrazně horší.

při práci s obrázky či videem. Další možnou aplikací je například oblast zpracování přirozeného jazyka.[11]

4.4 Učení neuronových sítí

Neuronové sítě lze rozdělit i dle způsobu jejich učení (trénování).

4.4.1 Učení s učitelem

Učení neuronové sítě probíhá často takzvaně s učitelem. To probíhá tak, že je síť dotázána na predikci k danému příkladu a následně je určena chyba modelu. Proveďte se upravení vah a celá síť je znovu testována. To se provádí do té doby, dokud chyba převyšuje stanovenou odchylku.

4.4.2 Učení bez učitele

Ne vždy je ale výstup znám dopředu, takže není být možné dávat síti zpětnou vazbu. V tomto případě je nutno zvolit metodu učení bez učitele. Zde jsou síti pouze předkládány vzory, které si síť sama třídí, například tak, že je rozdělí do skupin (klasifikuje). Typickým cílem použití učení bez učitele je nalezení nějakého vzoru v datech.

4.4.3 Učení pod částečným dohledem

Poskytují-li data pro množinu vstupních hodnot x pouze část množiny výstupních hodnot $z \subset y$, dává smysl použít aspoň tuto část. Tudíž je při učení využito hybridního přístupu mezi učením s učitelem a bez učitele.

4.5 Existující realizace

Naštěstí není potřeba tuto síť vytvářet celou od základu, neboť je možné využít existující realizace. Kupříkladu je možné použít Keras, TensorFlow či PyTorch.

Knihovna Keras poskytuje rozhraní ke knihovně TensorFlow, díky tomu je mnohem snadnější ji použít, a to například proto, že Keras obohacuje TensorFlow o často i obecně aplikovatelné funkce. Použití knihovny Keras je tedy vhodné (nejen) pro začátečníky, kteří nechtějí ztrácet čas s učením se používat TensorFlow.

Naopak experti využijí širokých a komplexních možností TensorFlow. Tato knihovna má i další fundamentální výhodu, byť její rozhraní je vytvořené v jazyce Python, její matematické výpočty jsou naprogramované v jazyce C++. Díky tomu mají tyto výpočty šanci proběhnout o něco rychleji.

Knihovna PyTorch je po stránce výkonu srovnatelná s knihovnou TensorFlow, po aplikační stránce je PyTorch obecnější, díky tomu má využití i na jiné oblasti strojového učení než jen na oblast hlubokého učení.

5 Návrh realizace

Díky snadné implementaci a velkému množství kvalitních knihovných funkcí a nástrojů je program implementován v jazyce Python.

5.1 Předzpracování dat

Nejdříve budou zvoleny předměty investice, například akcie zatím neznámé firmy. Poté bude za pomoci indikátorů technické analýzy zpracován graf vývoje cen v čase tohoto předmětu investice. Jednotlivé indikátory technické analýzy budou na vstupu neuronové sítě. Pravděpodobně však bude ještě nutné všechny tyto indikátory (individuálně) normalizovat.

5.1.1 Stahování dat

Pro správnou funkci celého programu je potřeba vycházet z historických dat. Ta mohou být mnohdy získávána z více zdrojů. Dále jsou uvedeny zdroje dat rozřazené do sekcí podle toho, k jakému účelu budou primárně sloužit.

Akcie a kryptoměny

Jedním z nejpoužívanějších zdrojů dat v oblasti investování jsou Yahoo Finance. Je tomu tak především díky jejich snadné přístupnosti. V této práci budou z tohoto zdroje získávána data o akciích či kryptoměnách.

Měnové páry

The Forex API bylo vytvořeno Evropskou centrální bankou a je jí spravováno. Lze tedy bezpečně usoudit, že se jedná o důvěryhodný zdroj informací. Odtud budou čerpána data o měnových párech, dále pak bude toto API sloužit jako záložní zdroj dat o kryptoměnách.

Komodity

Jako nejobtížnější se ukázalo nalézt spolehlivý zdroj dat o komoditních trzích. Nakonec bylo rozhodnuto čerpat data ze stránky investing.com - skrze knihovnu investpy.

5.2 Neuronová síť

Pro reprezentaci algoritmu, který se bude učit vzájemné závislosti dat, byla vybrána neuronová síť. Ta bude mít tři vrstvy, z čehož bude jedna vrstva skrytá. Je tomu tak proto, že pouze dvě vrstvy by zajišťovaly úspěch u lineárně separovatelné úlohy, tou však problematika obchodování není. Kvůli potřebě této skryté vrstvy bude použit vícevrstvý perceptron (MLP) s dopředným učením. Jako nástroj pro knihovni implementaci neuronových sítí byla zvolena knihovna Keras.

5.2.1 Šestiprvkový model

Jak bylo zmíněno výše, na vstupní vrstvě neuronové sítě budou indikátory technické analýzy. Za ní bude následovat jedna skrytá vrstva, jejíž počet neuronů bude zvolen experimentálně. Na výstupní vrstvě neuronové sítě budou následující neurony:

Určitě nakoupit

Aktivace tohoto neuronu znamená, že neuronová síť předpovídá intenzivní růst daného předmětu investice.

Nakoupit

Tento výstup znamená to samé co předešlý, jen s menší intenzitou růstu.

Spíše nakoupit

Nejmenší růst ceny daného předmětu investice, kdy neuronová síť odhaduje, že cena daného předmětu investice půjde spíše nahoru než dolů.

Spíše prodat

Toto je analogie k předešlé variantě, "Spíše nakoupit". Ale v tomto případě se neuronová síť domnívá, že cena předmětu investice spíše klesne.

Prodat

Tento výstup značí, že neuronová síť vyhodnotila trend investice jako potenciálně klesající.

Určitě prodat

Zde neuronová predikuje, že cena předmětu investice zaznamená výrazný propad.

Tento model výstupu neuronové sítě má tu výhodu, že je lépe odhalena chyba neuronové sítě. Jestliže se aktivuje například "Prodat" a "Určitě prodat", je zcela jisté, že neuronová síť své tvrzení "myslí vážně". Naopak aktivují-li se například neurony "Určitě prodat" a "Určitě nakoupit", pak nejsme schopni určit, co se bude dít s cenou předmětu investice. Na výstupní vrstvě může být samozřejmě aktivováno více i méně neuronů.

Tento návrh byl posléze zrealizován formou prahů. Například pro "Určitě koupit" je zvolen práh 5%. Přesáhne-li relativní maximální zisk v následujícím časovém okně 5%, je jeho hodnota nastavena na 1, jinak je 0. Časové okno je procházeno postupně den po dni. Pokud bude relativní zisk například 3%, je splněna podmínka pro prvek "Možná koupit", jehož práh je 1%. Zároveň je ale splněna podmínka pro "Koupit", jehož práh jsou 2%. V takovémto případě je vždy upřednostněna významnější varianta (tedy "Koupit"). To, co platí pro varianty "Koupit", platí i opačným směrem pro varianty "Prodat", kdy je místo zisku predikována ztráta.

5.2.2 Dvouprvkový model

Nezávisle na šestiprvkovém modelu bude testován ještě typ modelu, který má pouze dva prvky (dimenze), zisk a ztrátu. Výpočet: $E_{1,i} = \min(E_{1,i-1}, (Prodej_{1,i} - Nakup_{1,0})/Nakup_{1,0})$, $E_{2,i} = \max(E_{2,i-1}, (Prodej_{2,i} - Nakup_{2,0})/Nakup_{2,0})$. Oproti šestiprvkovému modelu má tento tu výhodu, že předpovídá přímo vývoj ceny a má pouze dvě složky. Mohl by být tedy přesnější než šestiprvkový. Pro ulehčení natrénování neuronovou sítí jsou vstupní data zbavena hodnot nižších než daný práh, ten je pro všechny experimenty nastaven na hodnotu 5%.

Zisk

Jak název vypovídá, bude hodnota tohoto prvku značit výši potenciálního zisku v následujícím časovém okně.

Ztráta

Analogicky bude pak ztráta značit největší možný prodělek během následujícího časového okna.

5.3 Hodnocení

5.3.1 Počítání zisku

Jak lépe zjistit funkčnost predikce finančního trhu nežli skutečnými obchody? Je-li střední hodnota predikce pro následující časové okno větší než daný práh, realizuje se nákup. Pokud během okna nastane přírůstek o hodnotě vypočtené střední hodnoty, provede se prodej. Nenastane-li tato situace, provede se prodej automaticky na konci časového okna. Tato forma hodnocení je totožná pro oba typy modelů.

5.3.2 Střední kvadratická chyba

Jedná se o výpočet odchylky modelu od reálných dat. Zmíněná odchylka je vypočtena následovně: $Err_i = (P_i - R_i)^2$. Kde i označuje den, P označuje predikci neuronové sítě, naopak R označuje reálný průběh. Pro každou složku je nejprve vypočtena střední kvadratická chyba pro jednotlivé dny Err_i , poté jsou tyto chyby zprůměrovány. Pro každý prvek výstupní vrstvy modelu je odchylka vypočtena nezávisle na ostatních prvcích.

6 Výsledky a experimenty

6.1 Experimenty s jednotnými daty

Jedná se o experimenty, kde jsou trénovací data stejným předmětem investice jako data pro testování, liší se pouze časovým obdobím.

Následující experimenty s neuronovou sítí mají stejný počet iterací (epoch) 60 a stejnou velikost dávky (batch size) 5. Na obrázku 6.1 a obrázku 6.2 lze pozorovat přesnost učení se zmíněnými parametry¹. Počet prvků výstupní vrstvy se liší podle použité metody (šestisložková a dvousložková).

6.1.1 Počet neuronů ve skryté vrstvě modelu

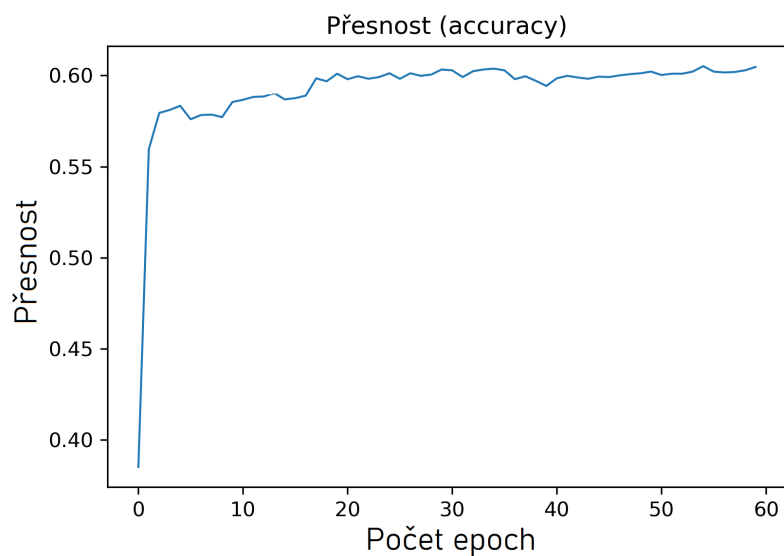
Prvním experimentem je nalezení ideálního počtu neuronů ve skryté vrstvě. Ten bude vybrán skrze experiment, ve kterém budou porovnávány střední kvadratické chyby predikce neuronové sítě od reality. Vzhledem k tomu, že jsou použity dva různě velké výstupy neuronové sítě, proběhne experiment pro oba typy výstupu zvlášť.

Jako vstupní data byl zvolen vývoj ceny akcií společnosti Coca Cola za časové období 10/01/2000 až 10/01/2022. Veškeré následující experimenty budou používat data o vývoji ceny daného předmětu investice za toto období, experimenty s různými daty budou používat data za stejné časového období.

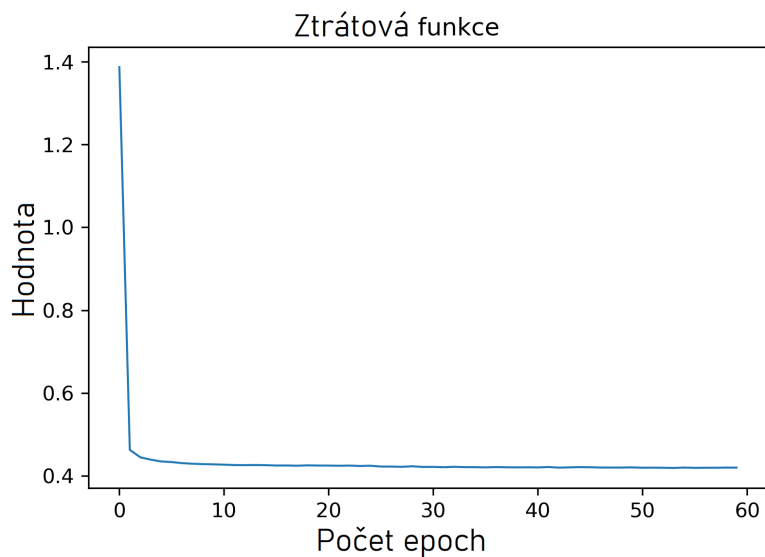
Výsledky experimentu můžeme pozorovat v tabulce 6.1. Nejnižší chybu měla neuronová síť při použití 8 neuronů, s vyšším počtem neuronů se výsledky moc nezměnily. Proto bude v následujících experimentech pro šestisložkovou metodu využita skrytá vrstva s 8 neurony.

V tabulce 6.2 jsou vyobrazeny výsledky testu a nejnižší chyba je pro skrytou vrstvu o velikosti 6 neuronů. Pro následující experimenty bude pro dvousložkovou metodu použita skrytá vrstva se 6 neurony.

¹Grafické vyjádření obou funkcí znázorňuje učení šestisložkového modelu s velikostí okna 7 na datech Coca Coly.



Obrázek 6.1: Přesnost učení v závislosti na čase (počtu iterací).



Obrázek 6.2: Ztrátová (loss) funkce učení v závislosti na čase (počtu iterací).

Počet neuronů	Změna trendu [%]						
	Průměr	-5	-2	-1	1	2	5
6	145	57	130	165	206	253	54
7	145	57	130	165	207	253	54
8	141	53	123	166	200	249	54
9	162	59	138	179	239	304	56
10	144	54	120	163	207	266	55
11	141	51	119	162	194	266	55
12	145	50	126	167	215	255	55
13	141	57	120	159	196	262	53
14	157	57	130	179	223	300	55
15	153	62	137	171	227	268	55
16	140	53	119	160	194	258	54

Tabulka 6.1: Střední kvadratická chyba $[10^{-3}]$ v závislosti na počtu neuronů ve skryté vrstvě pro šestisložkový model.

Počet neuronů	Změna trendu		
	Průměr	Zisk	Ztráta
2	13	7	19
3	13	7	20
4	13	7	20
5	13	7	20
6	12	6	20
7	33	45	20
8	16	12	20
9	11	65	16
10	13	9	20

Tabulka 6.2: Střední kvadratická chyba $[10^{-3}]$ v závislosti na počtu neuronů ve skryté vrstvě dvousložkového modelu.

6.1.2 Hodnocení

Výsledný model bude hodnocen na základě dvou kritérií, střední kvadratické chyby a zisku z obchodů uzavřených na základě předpovědi. První kritérium měří kvalitu natrénování, druhé kritérium měří míru úspěšnosti při obchodování. Oba typy modelů budou hodnoceny zvlášť.

Práh pro vstup do obchodu² byl nastaven na 0.006. Tato velikost byla zvolena experimentálně.

Šestisložkový model

Výsledek experimentu zachycuje tabulka 6.3. Nejnižší odchylku měl měnový pár EUR/CZK pro 7denní okno, nejvyšší měl naopak Bitcoin pro časové okno o velikosti 14 dní. Nejvyšší zisky měly akcie Coca Coly s průměrným ziskem 0.6% za obchod. Nejvyšší průměrnou ztrátu o hodnotě 0.56% měl Natural Gas pro časové okno 7 dní.

Dvousložkový model

Tabulka 6.4, nejnižší odchylku měl měnový pár EUR/CZK, tato odchylka se pohybovala v okolí nuly. Naopak nejhorší odchylku měl Bitcoin pro 14denní okno. Nejvyšší průměrný zisk měl Natural Gas, následoval Bitcoin.

6.2 Experimenty s různými daty

Tato sekce se zabývá přenesením informací o obchodování s jedním předmětem investice na jiný předmět investice. Primárně budou zkoumány stejné typy předmětů investice.

6.2.1 Počet neuronů ve skryté vrstvě modelu

Předmětem investice v tomto experimentu budou akcie Coca Coly, na kterých bude neuronová síť natrénována a akcie Pepsi Coly, na kterých bude natrénovaný model testován.

²Práh pro vstup do obchodu je konstanta. Čím vyšší práh, tím vyšší musí být střední hodnota pro růst, aby se provedl obchod. Kromě tohoto prahu jsou obchody ještě omezeny tím, že podíl střední hodnoty pro pokles a střední hodnoty pro růst E_{gain}/E_{loss} musí být větší než 2.

Vstup		Ochylka od trendu							Zisk z obchodů
Data	Vel. okna [dny]	Průměr	-5	-2	-1	1	2	5	Průměr za obchod [%]
Bitcoin	7	272	346	277	219	272	282	235	0.15
Bitcoin	14	338	359	308	248	338	398	380	0.3
Coca Cola	7	140	53	123	166	200	249	53	0.6
Coca Cola	14	190	110	197	230	181	231	191	-0.17
EUR/CZK	7	47	0	10	27	225	14	4	0
EUR/CZK	14	76	0	25	58	292	73	10	-0.01
Natural Gas	7	135	10	171	227	246	151	7	-0.56
Natural Gas	14	192	63	260	290	248	238	56	0

Tabulka 6.3: Střední kvadratická chyba [10^{-3}] a průměrný zisk z obchodů pro šestisložkový model.

Vstup		Ochylka od trendu			Zisk z obchoů
Data	Velikost okna [dny]	Průměr	Zisk	Ztráta	Průměr za obchod [%]
Bitcoin	7	32	389	250	0.4
Bitcoin	14	467	510	526	0.6
Coca Cola	7	14	9	20	0
Coca Cola	14	36	29	44	0
EUR/CZK	7	0	0	0	0
EUR/CZK	14	1	2	0	0
Natural Gas	7	1	1	1	0
Natural Gas	14	6	6	6	1.6

Tabulka 6.4: Střední kvadratická chyba [10^{-3}] a průměrný zisk z obchodů pro dvousložkový model.

Počet neuronů	Změna trendu [%]						
	Průměr	-5	-2	-1	1	2	5
6	145	48	140	170	210	250	51
7	135	39	120	160	195	246	50
8	137	41	122	162	199	249	50
9	136	41	121	161	196	247	51
10	136	41	122	161	196	248	50
11	137	40	123	162	196	248	50
12	137	41	123	163	198	246	50
13	135	39	120	159	195	245	50
14	136	40	122	161	197	246	50
15	135	40	119	160	195	247	50
16	135	39	120	160	193	246	50

Tabulka 6.5: Střední kvadratická chyba [10^{-3}] v závislosti na počtu neuronů ve skryté vrstvě pro šestisložkový model.

Šestiprvkový model

Výsledek experimentu pro šestiprvkový model je vyobrazen v tabulce 6.5. Střední kvadratická chyba je zde rozepsána po složkách, dále je zde sloupec pro celkový aritmetický průměr této chyby.

Nejhorší výsledky má skrytá vrstva se šesti neurony, naopak vrstva se sedmi neurony má výsledky podstatně lepší. Vyšší počty neuronů vykazují téměř stejné výsledky jako sedm neuronů.

Dvousložkový model

V tabulce 6.6 lze pozorovat výsledek experimentu pro dvousložkový model. Chyba je ovlivněna signálem, pro který ji počítáme, dvousložkový model má na testovaných datech nižší hodnoty, tudíž i chyby jsou oproti šestiprvkovému modelu výrazně nižší. Nejnižší chyba je zde pro sedm a deset neuronů. Takže v dalších experimentech bude pro dvousložkový model, stejně jako pro ten šestisložkový, použita skrytá vrstva obsahující sedm neuronů.

6.2.2 Hodnocení

V experimentech je opět používán práh o hodnotě 0.006.

Počet neuronů	Změna trendu		
	Průměr	Zisk	Ztráta
2	7	5	9
3	8	5	11
4	8	5	11
5	7	5	9
6	7	5	9
7	6	5	8
8	7	5	9
9	7	5	8
10	6	5	8

Tabulka 6.6: Střední kvadratická chyba [10^{-3}] v závislosti na počtu neuronů ve skryté vrstvě dvousložkového modelu.

Šestisložkový model

Výsledek tohoto experimentu je zachycen v tabulce 6.7. Kvalita natrénování se liší jak pro různé instrumenty tak i pro různé velikosti časového okna.

Z výsledků je patrné, že zisk z obchodů souvisí s volbou předmětu investice. Bitcoin-Ethereum má průměrný zisk 0.6% (pro velikost okna 7 dní), u 14-denního obchodu je to 0.59%. Měnové páry EUR/CZK-USD/CZK mají zisk z obchodů v obou velikostech okna 0, zde se natrénovaný model rozhodl pro danou velikost prahu nedělat žádné obchody. Natural Gas-Crude Oil WTI pro okno o velikosti 7 dní dokonce prodělával, a jeho průměrná ztráta činila 0.24% za obchod.

Podle střední kvadratické chyby modelu vyšel nejlépe měnový pár EUR/CZK-USD/CZK s velikostí okna 7 dní, jehož chyba byla 0.047. Naopak nejhůře vyšel Bitcoin-Ethereum (14-ti denní velikost okna) s průměrnou střední kvadratickou chybou modelu o velikosti 0.217.

Dvousložkový model

Z výsledků, které jsou zachyceny v tabulce 6.8, vyplývá z velké části to samé, co z výsledků šestisložkového modelu. Opět střední kvadratická chyba koreluje jak s různými instrumenty, tak s velikostí časového okna. Pro pár Bitcoin-Ethereum je pro velikost okna 7 průměrná chyba 0.382, pro velikost okna 14 je tato chyba 0.903. Naopak pro měnový pár EUR/CZK-USD/CZK

Vstup			Ochylka od trendu							Zisk z obchodů
Trénovací data	Testovací data	Vel. okna [dny]	Průměr	-5	-2	-1	1	2	5	Průměr za obchod [%]
Bitcoin	Ethereum	7	217	235	216	169	219	238	226	0.6
Bitcoin	Ethereum	14	224	233	222	202	231	214	241	0.59
Coca Cola	Pepsi Cola	7	135	39	120	160	195	246	50	0
Coca Cola	Pepsi Cola	14	168	83	184	216	155	222	147	0.03
EUR/CZK	USD/CZK	7	47	2	22	92	147	14	2	0
EUR/CZK	USD/CZK	14	83	3	63	149	216	64	6	0
Natural Gas	Crude Oil	7	128	10	137	217	241	146	14	-0.24
Natural Gas	Crude Oil	14	171	46	201	249	240	228	65	0.28

Tabulka 6.7: Střední kvadratická chyba [10^{-3}] a průměrný zisk z obchodů pro šestisložkový model.

jsou tyto chyby 0.0001 a 0.0006. Mezi různými předměty investice je tak řádový rozdíl v chybách, přestože data, ze kterých vychází vstupní signál i model, byla normována³.

Nejvyšší zisky měl pár Coca Cola-Pepsi Cola (pro časové okno 7 dní), kde průměrný zisk činil 3.4%. Naopak nejhorší výsledky měly měnové páry EUR/CZK-USD/CZK, které v obou velikostech časového okna nedoporučily žádný obchod.

6.2.3 Možné zisky

Tento experiment cíl odhalit jaký je rozdíl v ziscích vlivem natrénování neuronové sítě.

Experiment byl prováděn se stejným prahem jako předešlé experimenty, 0.006. Výsledky jsou zaneseny do tabulky 6.9.

³Normování vstupních dat proběhlo tak, že hodnoty byly převedeny do intervalu (0, 100>. Normování jednotlivých složek dat (denní maxima; denní minima; hodnoty, na kterých trh zavíral) proběhlo nezávisle na ostatních složkách dat.

Vstup			Ochylka od trendu			Zisk z obchodů
Trénovací data	Testovací data	Velikost okna[dny]	Průměr	Zisk	Ztráta	Průměr za obchod [%]
Bitcoin	Ethereum	7	382	323	442	0.62
Bitcoin	Ethereum	14	903	1149	656	0.4
Coca Cola	Pepsi Cola	7	9	7	11	3.4
Coca Cola	Pepsi Cola	14	19	18	21	3.14
EUR/CZK	USD/CZK	7	0.1	0.1	0.2	0
EUR/CZK	USD/CZK	14	0.6	0.7	0.5	0
Natural Gas	Crude Oil	7	0.2	0.2	0.2	0
Natural Gas	Crude Oil	14	7	9	5	0.36

Tabulka 6.8: Střední kvadratická chyba [10^{-3}] a průměrný zisk z obchodů pro dvousložkový model.

Vstupní data a nastavení				Průměr za obchod	
Model [složky]	Trénovací data	Testovací data	Velikost okna [dny]	Zisk podle testovacího signálu [%]	Zisk z predikce [%]
2	Bitcoin	Ethereum	7	-0.34	0.62
2	Bitcoin	Ethereum	14	-0.5	0.4
2	Coca Cola	Pepsi Cola	7	5.37	3.4
2	Coca Cola	Pepsi Cola	14	1.2	1.51
2	EUR/CZK	USD/CZK	7	0	0
2	EUR/CZK	USD/CZK	14	0	0
2	Natural Gas	Crude Oil WTI	7	0	0
2	Natural Gas	Crude Oil WTI	14	0	0.36
6	Bitcoin	Ethereum	7	-0.34	0.6
6	Bitcoin	Ethereum	14	0.17	0.59
6	Coca Cola	Pepsi Cola	7	0.52	0
6	Coca Cola	Pepsi Cola	14	0.09	0.03
6	EUR/CZK	USD/CZK	7	0	0
6	EUR/CZK	USD/CZK	14	-0.04	0
6	Natural Gas	Crude Oil WTI	7	0.13	-0.24
6	Natural Gas	Crude Oil WTI	14	0.17	-0.28

Tabulka 6.9: Potenciální zisk z obchodů.

7 Závěr

Na základě experimentů uvedených v této práci lze říci, že 14denní časové okno z pravidla nevykazuje tak dobré výsledky jako 7denní. Z toho lze usoudit, že predikce fungují lépe na kratší časové intervaly.

Mezi experimenty nad shodnými zdroji dat (předmětů investice) a experimenty, kde bylo trénování prováděno na datech z jednoho zdroje a testování na datech jiného zdroje, jsou nepatrné rozdíly. V obou případech jsou ale výsledky spíše kladné (obchody bývají spíše ziskové).

Znatelný rozdíl je pak vidět mezi dvousložkovou a šestisložkovou metodou. Dvousložkové modely často vykazují lepší výsledky než ty šestisložkové.

Rovněž lze pozorovat, že samotný testovací signál nevykazuje vždy spolehlivé zisky. Tento signál je generovaný automaticky na základě pohledu do budoucnosti v datech. Lze z toho odvodit, že strategie vyhodnocení obchodu nefunguje zcela v souladu se vstupním signálem, a tedy i predikcí neuronové sítě.

Pro vzájemné porovnání výsledků byl práh pro vstup do obchodu zvolen jako konstanta, některé instrumenty by vykazovaly lepší výsledky po jeho zvýšení, jiné zase po jeho snížení. Pro lepší výsledky z obchodů by bylo vhodné zvážit možnost individuální volby prahu v závislosti na vstupních datech.

Obchodování na základě predikce neuronové sítě výlučně podle dat o vývoji ceny daného předmětu investice nemusí být zcela dostačující. Bylo by potřeba zahrnout do vstupních dat i další informace, jako jsou zprávy související s daným předmětem investice.

Literatura

- [1] COURVILLE A., G. I. *DEEP LEARNING*. Massachusetts Institute of Technology, 2017. ISBN 978-0-262-03561-3.
- [2] CHEN, J. *Exponential Moving Average (EMA)* [online]. Investopedia, 2021. [cit. 2021/12/28]. Technical Analysis. Dostupné z: <https://www.investopedia.com/terms/e/ema.asp>.
- [3] FERNANDO, J. *Relative Strength Index (RSI)* [online]. Investopedia, 2021. [cit. 2021/12/28]. Technical Analysis. Dostupné z: <https://www.investopedia.com/terms/r/rsi.asp>.
- [4] *BTC / CZK • Kryptoměna* [online]. Google, 2022. [cit. 2022/1/2]. Google Finance. Dostupné z: <https://www.google.com/finance/quote/BTC-CZK?sa=X&ved=2ahUKEwjFrYqjjpP1AhXvwQIHhcZBCIQQ-fUHegQIEBAS&window=MAX>.
- [5] HAYES, A. *Average True Range (ATR)* [online]. Investopedia, 2021. [cit. 2021/12/28]. Technical Analysis. Dostupné z: <https://www.investopedia.com/terms/a/atr.asp>.
- [6] HAYES, A. *Simple Moving Average (SMA)* [online]. Investopedia, 2021. [cit. 2021/12/22]. Technical Analysis. Dostupné z: <https://www.investopedia.com/terms/s/sma.asp>.
- [7] HORNER, R. *Forex tradingem k maximálním ziskům, (První vydání)*. Computer Press, a. s., 2011. ISBN 978-80-251-2921-0.
- [8] MCNELIS, P. D. *Neural Networks in Finance GAINING PREDICTIVE EDGE IN THE MARKET*. ELSEVIER ACADEMIC PRESS, 2005. ISBN 0-12-485967-4.
- [9] MITCHELL, C. *Average Directional Index (ADX)* [online]. Investopedia, 2021. [cit. 2021/12/28]. Technical Analysis. Dostupné z: <https://www.investopedia.com/terms/a/adx.asp>.
- [10] MITCHELL, C. *Commodity Channel Index (CCI)* [online]. Investopedia, 2021. [cit. 2021/12/28]. Technical Analysis. Dostupné z: <https://www.investopedia.com/terms/c/commoditychannelindex.asp>.
- [11] PAI, A. *CNN vs. RNN vs. ANN – Analyzing 3 Types of Neural Networks in Deep Learning* [online]. Analytics Vidhya, 2020. [cit. 2020/2/17]. NN. Dostupné z: <https://www.analyticsvidhya.com/blog/2020/02/cnn-vs-rnn-vs-mlp-analyzing-3-types-of-neural-networks-in-deep-learning/>.

- [12] REJNUŠ, O. *Peněžní ekonomie (Finanční trhy), (6. aktualizované vydání)*. Vysoké učení technické v Brně, Fakulta podnikatelská, 2012. ISBN 978-80-214-4415-7.
- [13] SEZER, O. – OZBAYOGLU, M. – DOGDU, E. *An Artificial Neural Network-based Stock Trading System Using Technical Analysis and Big Data Framework* [online]. 04 2017.