

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

PREDIKCE VÝVOJE KURZU POMOCÍ UMĚLÝCH
NEURONOVÝCH SÍTÍ

DIPLOMOVÁ PRÁCE
MASTER'S THESIS


AUTOR PRÁCE
AUTHOR

Bc. LUKÁŠ PUTNA

BRNO 2011



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ
FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

PREDIKCE VÝVOJE KURZU POMOCÍ UMĚLÝCH NEURONOVÝCH SÍTÍ

STOCK PREDICTION USING ARTIFICIAL NEURAL NETWORKS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. LUKÁŠ PUTNA

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. IGOR SZÖKE, PhD.

BRNO 2011

Vysoké učení technické v Brně - Fakulta informačních technologií

Ústav počítačové grafiky a multimédií

Akademický rok 2010/2011

Zadání diplomové práce

Řešitel: **Putna Lukáš, Bc.**

Obor: Inteligentní systémy

Téma: **Predikce vývoje kurzu pomocí umělých neuronových sítí
Stock Prediction Using Artificial Neural Networks**

Kategorie: Umělá inteligence

Pokyny:

1. Seznamte se s teorií neuronových sítí a intraday obchodování na burze.
2. Prostudujte dostupné techniky technické analýzy.
3. Seznamte se s vybraným nástrojem pro trénování neuronových sítí.
4. Definujte vhodná data pro trénování a testování predikčních metod. Vytvořte sadu baseline výsledků (obchodní model "člověka" a "náhodný" obchodní model)
5. Zvolte vhodné indikátory technické analýzy, natrénujte a otestujte základní predikční model.
6. Upravte výběr popř. vhodně zkombinujte indikátory a zlepšete váš základní predikční model.
7. Zhodnoťte výsledky, vyberte nejvhodnější metodu (parametry modelu a indikátory) a navhňte směry dalšího vývoj.

Literatura:

- Podle pokynů vedoucího.

Při obhajobě semestrální části diplomového projektu je požadováno:

- Body 1 až 4 ze zadání.

Podrobné závazné pokyny pro vypracování diplomové práce naleznete na adrese <http://www.fit.vutbr.cz/info/szz/>

Technická zpráva diplomové práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap, které byly vyřešeny v rámci ročníkového a semestrálního projektu (30 až 40% celkového rozsahu technické zprávy).

Student odevzdá v jednom výtisku technickou zprávu a v elektronické podobě zdrojový text technické zprávy, úplnou programovou dokumentaci a zdrojové texty programů. Informace v elektronické podobě budou uloženy na standardním nepřepisovatelném paměťovém médiu (CD-R, DVD-R, apod.), které bude vloženo do písemné zprávy tak, aby nemohlo dojít k jeho ztrátě při běžné manipulaci.

Vedoucí: **Szöke Igor, Ing.**, UPGM FIT VUT

Datum zadání: 20. září 2010

Datum odevzdání: 25. května 2011

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta informačních technologií
Ústav počítačové grafiky a multimédií
612 66 Brno, Božetěchova 2
L.S.



doc. Dr. Ing. Jan Černocký
vedoucí ústavu

Abstrakt

Tato diplomová práce se zabývá využitím neuronových sítí pro účely předpovědi vývoje kurzu trhu na burze. Zmiňuje základy teorie fungování burzy a obchodování na ní. V práci je dále popsána teorie neuronových sítí, jaké jsou možnosti jejich využití a jakým způsobem je vhodné neuronovou síť navrhnout pro danou aplikaci. V praktické části jsou navrženy dva predikční modely využívající neuronové sítě. Ty jsou dále využity navrženým obchodním modelem a simulovány na zvolených datech. Následně jsou výsledky porovnány s obchodním modelem člověka a náhodným obchodním modelem a jsou navrženy další směry vývoje systému.

Abstract

This work deals with the usage of neural network for the purpose of stock market prediction. A basic stock market theory and trading approaches are mentioned at the beginning of this work. Then neural networks and their application are discussed with their deeper description. Similar approaches are referred and finally two new prediction systems are designed. These systems are utilized by proposed trading model and tested on selected data. The results are compared to human and random trading models and new development steps are devised at the end of this work.

Klíčová slova

Predikce burzy, předpověď vývoje kurzu, umělá neuronová síť, obchodování na burze, intradenní obchodování.

Keywords

Stock market prediction, stock forecast, artificial neural network, stock trading, intraday trading.

Citace

Putna Lukáš: Predikce vývoje kurzu pomocí umělých neuronových sítí, diplomová práce, Brno, FIT VUT v Brně, 2011

Predikce vývoje kurzu pomocí umělých neuronových sítí

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením Ing. Igora Szöke, Ph.D.

Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....
Lukáš Putna

25. 5. 2011

Poděkování

Touto cestou bych chtěl poděkovat svému vedoucímu Ing. Igorovi Szöke, Ph.D. za ochotu při konzultacích, četné rady a návrhy a také za to, že se mi věnoval vždy, když to bylo potřeba.

© Lukáš Putna, 2011

Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.

Obsah

1	Úvod	2
2	Obchodování na burze	4
2.1	Co obchodovat	4
2.2	Jak obchodovat	5
2.3	Podoba dat	7
2.4	Technické indikátory	10
2.5	Technické obchodování - vstup do trhu	12
2.6	Výstup z trhu	13
3	Umělé neuronové sítě	15
3.1	Biologický neuron	15
3.2	Umělý neuron	16
3.3	Neuronové sítě v predikčním systému	19
4	Praktická část	21
4.1	Trénovací a testovací sada dat	21
4.2	Hodnocení systému – skórování	23
4.3	Náhodný obchodní model	24
4.4	Obchodní model člověka	26
4.5	Základní predikční model	27
4.6	Upravený predikční model	35
4.7	Porovnání výsledků	38
4.8	Varianty modelů a další pozorování	43
4.9	Směry dalšího vývoje	45
5	Závěr	47
	Literatura	48

1 Úvod

Obchodování s komoditami provází lidstvo již mnoho let. Podle některých pramenů sahá jeho historie až do 6000 let staré Číny. První skutečné doklady o komoditním obchodování jsou však zachovány ze 17. století našeho letopočtu z Japonska, jehož způsob se nijak významně neliší od obchodování komodit na dnešních burzách.[1]

Původním záměrem japonských farmářů bylo zajistit si kapitál na pěstování rýže jejím předprodejem. Vznikl tzv. futures kontrakt, který smlouval farmáře k prodeji rýže kupci za předem danou cenu, jakmile se rýže urodí. Jelikož se později ukázalo, že náklady na vypěstování rýže se často po uzavření kontraktu měnily například vlivem počasí, kontrakt byl jednostranně nevýhodný. Proto se s kontrakty začalo obchodovat resp. spekulovat na vývoj jejich ceny za účelem získání profitu, ovšem i za cenu možných finančních ztrát.

Podobným způsobem se komodity obchodují v současné době. A přidalo se k nim i obchodování s akciemi, fondy, akciovými indexy, komoditami na úrokové míry nebo se začalo spekulovat i na vývoj kurzu různých měn. Za cílem dosažení zisku v obchodování komodit se lze v dnešní době vydat několika cestami. Vždy jde ale o spekulaci na vývoj ceny dané komodity. Ta je možná odhadnout mnoha popsányými technikami a postupy s nebo i bez pomoci dnešní výpočetní techniky. Pokud obchodník využívá výpočetní techniku, většinou se jedná pouze o jakousi nápořvedu v podobě různých indikátorů vypočítaných z historického pohybu hodnoty kurzu, kdy o samotném nákupu či prodeji kontraktu rozhoduje sám na základě vlastních zkušeností a uvážení. Existují i komplexní automatické obchodní systémy, které ale nejsou mezi obyčejnými obchodníky běžně rozšířené. Nejspíše proto, že tyto systémy jsou s nemalými náklady dlouhodobě vyvíjeny velkými finančními společnostmi. Pokud se nakonec podaří úspěšný predikční systém vytvořit, daná společnost samozřejmě nemá zájem takový software šířit dále.

Existují některé odborné práce převážně z akademických prostředí, ze kterých se lze dovědět více o predikčních burzovních modelech, technikách a využitých postupech, a to od obyčejných výpočtů mnoha různých indikátorů, přes spekulaci na vývoj kurzu pomocí expertních systémů, neuronových sítí, genetických algoritmů, až například po odvozování cen komodit od počtu významných slov v novinových článcích, výročních zprávách či na sociálních sítích.

Tato práce se zabývá návrhem technického obchodního systému, který využívá neuronové sítě pro predikci vývoje cen kontraktů na trzích. Technické obchodování burzy je často otázkou vyhledávání známých vzorů a formací ve vývoji cen, na základě nichž je rozhodováno o obchodech. Neuronové sítě jsou vhodným výpočetním modelem právě pro takové rozpoznávání vzorů v signálu, což dokazuje jejich nasazení v počítačové grafice či v oblasti rozpoznávání řeči. V této práci bude popisován systém pro intradenní predikci vývoje kurzu trhů převážně s akciovými indexy. Úspěšnost predikce bude ověřena na simulovaných obchodech a výsledky budou zhodnoceny na rostoucím, či klesajícím množství pomyslných finančních prostředků.

Ve druhé kapitole bude blíže popsáno, jakým způsobem funguje burza a obchod na ní, což jsou informace a pojmy nutné k pochopení dalšího textu. Jsou přibliženy dnes používané obchodní

metody a jejich vztah k možnostem automatické predikce. Objeví se zde ukázky používaných dat a informace k jejich interpretaci.

Ve třetí kapitole jsou rozebrány obecné základy neuronových sítí. Je vybrán vhodný typ sítě a popsán postup při jejím trénování. Před návrhem konkrétního systému je na konci třetí kapitoly uvedeno několik příkladů podobných prací, což bude při hledání vlastního řešení v některých bodech inspirativní.

Praktická část v kapitole čtvrté se zabývá podrobným návrhem dvou predikčních systémů a způsobem jejich testování. Jsou zveřejněny výsledky testování systémů, ty jsou porovnány s náhodným obchodním modelem a obchodním modelem, který je lidmi v praxi využíván. Na závěr čtvrté kapitoly jsou doporučeny možné směry dalšího vývoje.

Tato práce navazuje na semestrální projekt vypracovaný v předešlém semestru, ze kterého s drobnými úpravami a doplněními převzala celou teoretickou část zabývající se obchodováním na burze (v kapitole druhé) a umělými neuronovými sítěmi (v kapitole třetí).

2 Obchodování na burze

V úvodu byl popsán způsob a účel, za jakým se v historii uzavíraly komoditní futures kontrakty a proč s nimi bylo dále obchodováno. Bylo uvedeno, že v dnešní době se na burzách obchoduje s více různými produkty. V následujících podkapitolách bude rozveden charakter trhů a způsoby jejich obchodování, dále bude popsána podoba dostupných dat. Reálného obchodování na burzách se týká mnoho dalších ekonomických faktů, pravidel, či vlastností trhů, které zde nejsou z relevantních důvodů uvedeny také proto, že jejich popis by mnohonásobně překračoval rozsah této práce.

2.1 Co obchodovat

Na celém světě existují tisíce produktů, odborně nazývaných podkladová aktiva, které lze obchodovat pomocí různých finančních derivátů na mnoha burzách. Nejčastěji burzovně obchodovaný derivát je tzv. futures. Obecně lze futures rozdělit podle podkladového aktiva do dvou skupin, na finanční a komoditní futures kontrakty. *„Ačkoliv objemy obchodů s finančními kontrakty již výrazně převyšují obchody s komoditami, historicky se pro futures kontrakty vžil název komodity.“* [2] Praktická část práce se bude zabývat predikcí kurzu finančních futures.

Většina futures se v dnešní době obchoduje tzv. pákovým efektem. Složením předem dané zálohy lze ovládat typicky mnohem větší množství aktiv, z jejichž nominální hodnoty a pohybu ceny (kurzu) plyne reálná hodnota obchodu. Reálná hodnota je často několikanásobně vyšší než složená záloha. Výhoda je v možnosti získání i většího profitu než je vložený kapitál, z čehož přímo plyne i nevýhoda takového obchodování – možnost ztratit rychle veškeré finanční prostředky. Poměry záloh k reálné ceně kontraktu se mohou pohybovat od 1:2 až např. po 1:100, což je předem určeno brokerem podle způsobu obchodování dané futures. [3]

Všechny finanční a komoditní trhy mají společné následující základní vlastnosti, které by měly být brány v úvahu při výběru konkrétního trhu pro obchodování, ale také při budování obchodní strategie, tedy obchodního systému: [4]

- **Cena jednoho bodu** – cena trhu je vždy uváděna v tzv. bodech. Při nákupu nebo prodeji kontraktu trhu je reálná hodnota vypočtena vynásobením ceny jednoho kontraktu a bodové hodnoty trhu. Minimální pohyb trhu se označuje jako „tick“, což je typicky část plného bodu. Ve specifikacích kontraktů je pak často uváděna cena jednoho ticku spolu s údajem, kolik ticků tvoří jeden plný bod. Z tohoto faktu plyne, že trhy jsou při různých pohybech různě drahé, a tak stejně velký bodový pohyb dvou různých trhů může znamenat v konečném důsledku rozdílnou hodnotu zisků či ztrát. Cena jednoho kontraktu je od vytvoření trhu pevně daná ve specifikaci, na rozdíl od bodové hodnoty trhu, která je určena v každý okamžik obchodního dne v rámci aktuální nabídky a poptávky. Pro zjednodušení terminologie bude v následujícím textu bodová hodnota trhu označována

jako **cena** (nebo také hodnota) **trhu** a reálná hodnota kontraktu trhu označována jako **cena** (nebo také hodnota) **obchodu**.

- **Volatilita** – určuje dravost trhu, rychlost, s jakou se hodnota trhu může měnit. Ve více dravém trhu se lze dočkat větších zisků, ovšem za cenu větších potenciálních ztrát. Prakticky to znamená, že ke každému trhu nutno přistupovat s odlišnou strategií.
- **Charakter trhu** – určuje celkové chování trhu, které se může lišit i v průběhu jednoho dne, například tím, jak rychle se trh dokáže dostat do trendu, nebo jak reaguje na své historické úrovně. Tyto informace nejsou běžně k dispozici a obchodníci si je často musí sami vypožičovat z hlediska svého obchodního přístupu.
- **Časové měřítko** – cenu trhu tvoří téměř spojitý signál, který se mění každým okamžikem. Aby se s cenou trhu dalo pracovat v různých obchodních strategiích, je signál vzorkovaný s určitou periodou – časovým měřítkem. Dle různě zvolených časových měřítek potom lze zobrazit a rozpoznat různé cenové formace. Časová měřítka mohou být různá, od několika vteřin až např. po jeden měsíc a více. V následujícím textu bude časové měřítko nazýváno dle odborné terminologie „timeframe“.

Na burzách lze obchodovat následující typy podkladových aktiv, každá jsou vhodná pro různé druhy obchodování: [4]

- **Klasické komodity** – jedná se o tradiční surovinové komodity, jako je maso, obiloviny, ropa, vzácné kovy apod., obchodované prostřednictvím futures komoditních kontraktů.
- **Akcie** – obchodování s cennými papíry konkrétních firem je v současné době nejrozšířenější formou obchodování na burze. Mimo řady výhod ale s obchodováním souvisí fakt, že ceny trhu jsou do značné míry ovlivňovány fundamentálními prvky.
- **Akciové indexy** – finanční futures kontrakty na akciové indexy představují čistě matematicky vypočítanou váženou hodnotu tržní kapitalizace velkého souboru firem. Výhodou indexů je fakt, že reagují méně bouřlivě na fundamentální podněty, než samotné akciové trhy, proto budou v této práci využity.
- **Burzovní indexy** – velice podobné futures jako akciové indexy. Jejich hodnota je vypočítána jako vážená hodnota velkého balíku vybraných trhů dané burzy.
- **Finanční měnové kontrakty, akciové futures kontrakty, fondy** a další...

Zajímavým faktem je, že některé trhy, zejména trhy s akciovými a burzovními indexy, se často vzájemně korelují [4], což se nabízí k využití v obchodním systému.

2.2 Jak obchodovat

Obchodováním na burze se prakticky ve většině případů rozumí spekulování na vývoj ceny kontraktu daného trhu za účelem jeho nákupu nebo prodeje a tím dosažení zisku. „*Kupující kontraktu se zavazuje, že ve stanovené době odebere dané množství podkladového aktiva (například ropy, zlata, kukuřice, ale i eura, dluhopisů nebo akcií) za určenou cenu. Prodávající se naopak*

zavazuje dodat ve stanovené době dané množství podkladového aktiva za určenou cenu.“ [5] Toto se týká nejen komoditních, ale i finančních futures, vyjma akciových kontraktů, které nemají dobu dodání (tzv. expirační cyklus) stanovenou. Před touto dobou je potřeba obchod uzavřít, aby nemuselo dojít k plnění závazku.

Základní rozdělení obchodníků spekulantů je podle způsobů jejich rozhodování o obchodech – fundamentální nebo technické.

Fundamentální obchodníci se orientují jen na několik málo trhů, dlouhodobě sledují jejich nabídku a poptávku, na jejichž základech se rozhodují o nákupu nebo prodeji. Fundamentální obchodování si žádá vědět o daném trhu různé detailní informace, které často nejsou ani běžnému obchodníkovi dostupné. Nutná je znalost mnoha dalších faktorů, které se na ceně kontraktu podílejí, od předpovědi počasí, přes stavy zásob u komoditních trhů, až ke globální celosvětové ekonomice.[6] Tento komplexní způsob obchodování je nevhodný pro automatický obchodní systém, protože zmíněných faktorů je mnoho a jejich vliv na cenu trhu se navzájem ovlivňuje. Některých dílčích faktorů je možné využít v kombinaci s technicky zaměřeným obchodem konkrétního trhu.

Technicky zaměřený obchod vychází ze studia grafů vývoje ceny trhu, ze kterých lze vyčíst známé cenové formace a vypočítat pomocné technické indikátory, na jejichž základě je rozhodováno o obchodech. Takové studium grafů se nazývá technická analýza a v práci bude dále označováno zkratkou TA. U tohoto typu obchodování není nutné znát podrobnosti o obchodované komoditě.[6] Technickým typem obchodování se zabývá tato práce. Fundamentální rozhodování je potom ponecháno na zvážení obchodníkovi.

Dalším důležitým rozdělením je doba, po kterou se obchodníci účastní obchodu, jinak řečeno drží otevřené pozice. U **pozičního obchodování** je doba omezena pouze expiračním cyklem daného trhu, obchodník může kontrakt nakoupit a poté prodat až po několika měsících. Na druhou stranu obchodník, který drží pozici otevřenou jen během jednoho obchodního dne, praktikuje obchod tzv. **intradenní**. [4] Intradenním obchodováním se v praktické části zabývá tato práce.


Obecně existují dva způsoby, jakým do trhu vstoupit a tzv. otevřít pozici: [5]

- Při vstupu **na dlouhou stranu** (*angl. long*) se jedná o spekulaci na růst ceny trhu a nákup jednoho nebo i více kontraktů tohoto trhu. V případě, že cena poté stoupá, roste zisk, pokud cena klesá, roste naopak ztráta z obchodu.
- Při vstupu **na krátkou stranu** (*angl. short*) se naopak jedná o investici na pokles ceny kontraktu a o jeho prodej. V případě, že cena kontraktu poté klesá, roste zisk, pokud cena stoupá, roste naopak ztráta z obchodu. Při prodeji není nutné kontrakt vůbec vlastnit, ovšem jeho prodej je závazek k jejímu pozdějšímu nákupu, případně k dodání aktiva. U některých akciových trhů nelze tímto způsobem do trhu vstoupit, ovšem to nebude případ této práce.

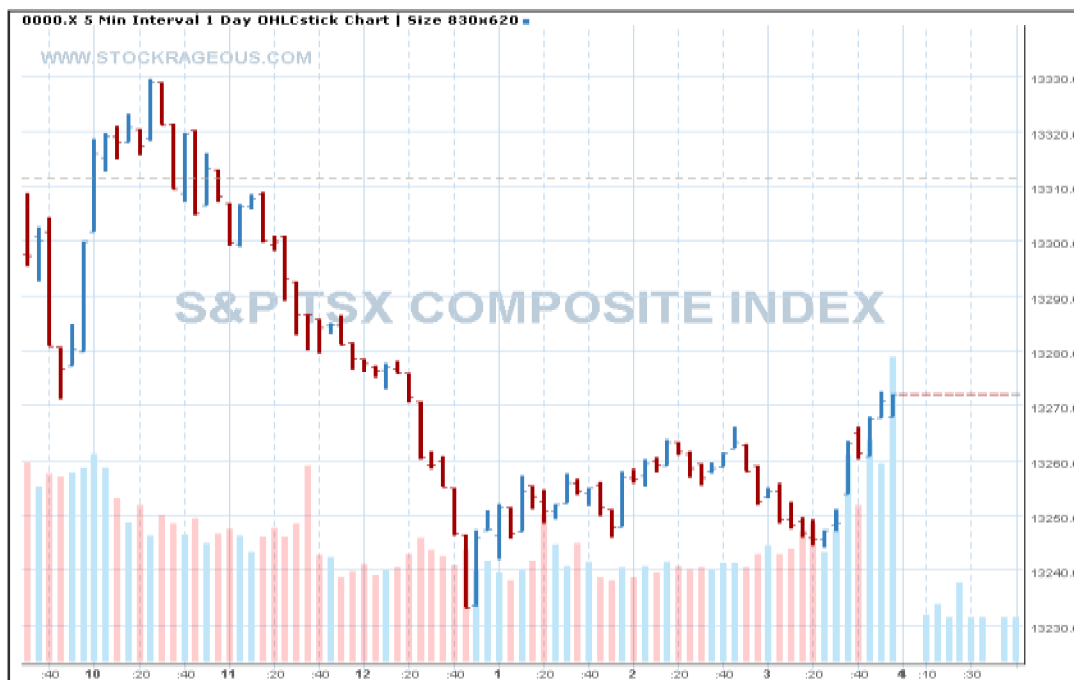
Důležitým momentem v obchodování je čas, kdy vstoupit do trhu, a volba, na kterou stranu vstoupit. O konečném zisku nakonec rozhoduje doba výstupu z obchodu.

2.3 Podoba dat

Veškerá data používaná pro obchodování mají podobu časové řady znázorňující změny a vývoj cen trhu a jsou často zakreslována do grafů. Grafy vývoje ceny v čase lze zobrazovat různými způsoby, nejčastějším způsobem je tzv. čárový graf, jehož základním elementem jsou čáry. Každá čára reprezentuje pohyb ceny za určité časové období a má tvar, který ilustruje obrázek č. 2.1. Cenové maximum, nazývané „high“, reprezentuje maximální cenu, na kterou se cena kontraktu dostala v daném období. Naopak cenové minimum, nazývané „low“, zobrazuje minimální hodnotu ceny kontraktu v daném období. Cena „open“ resp. „close“ reprezentuje cenu trhu na počátku resp. konci daného období. Grafy složené z mnoha takových čar se nazývají právě podle časového období, které jeho čáry zobrazují, tedy např. pětiminutový, patnáctiminutový až třeba měsíční (viz tzv. timeframe).[7] Graf 2.1 zobrazuje příklad pětiminutového grafu akciového indexu S&P TSX Composite Index.



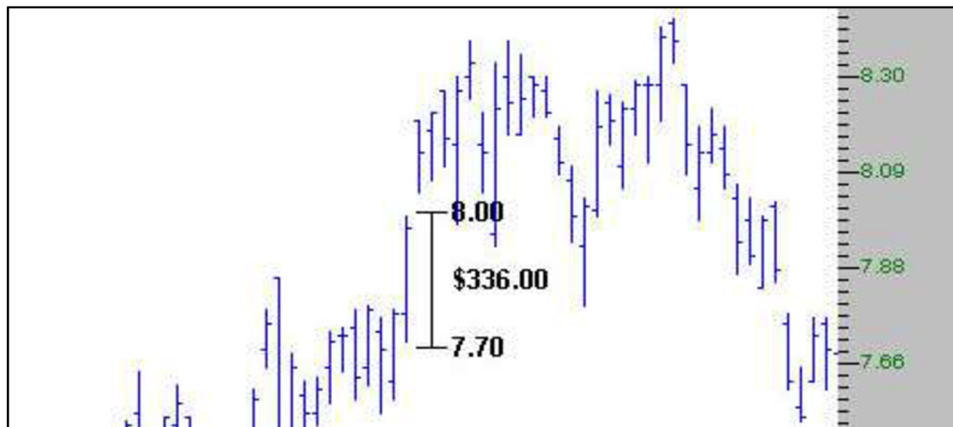
Obrázek 2.1 - Čára jako komponenta grafu. Jeden časový úsek je definován celkem čtyřmi hodnotami. Převzato z [7].



Graf 2.1 - Pětiminutový graf trhu S&P TSX, Zdroj: www.stockrageous.com

Vývoj ceny lze zobrazovat i tzv. svíčkovými nebo jinými grafy, ty ale ve své podstatě zobrazují stejné informace. Vlastností čárových grafů je skutečnost, že zobrazují data vždy po stejných časových úsecích i pokud se cena nehýbe žádným směrem nebo je uskutečňováno málo obchodů. Existují i tzv. tickové nebo volume grafy, které zobrazují ceny v závislosti na jiných údajích než na čase, např. po konstantně daných změnách ceny.[8] Jejich popis je zde vynechán, protože pro účely automatické predikce je vhodnější používat konstantní časovou jednotku.

Nejmenší jednotkou grafu je již zmiňovaný tick, který může u různých kontraktů představovat různou část plného bodu, tedy nejmenší jednotku kontraktu, za kterou lze pomocí pákového efektu kontrakt nakoupit nebo prodat. Další důležitou informací je hodnota ticku na kontrakt. Je to reálná cena, o kterou se změní hodnota pozice (obchodu) při pohybu o jeden tick. Z ceny kontraktu lze pak snadno vypočítat reálnou hodnotu závazku a tím i absolutní zisk či ztrátu. Graf č. 2.2 ilustruje skutečnou cenu pozice při změně kurzu na trhu s cukrem. Je zobrazeno rozpětí 0,3 bodů ceny trhu, což je při velikosti ticku jedna setina plného bodu a hodnotě ticku na kontrakt 11,20\$ rovno rozdílu celkem 336,00\$. [9]



Graf 2.2 - Ukázka části grafu trhu s cukrem. Rozdíl 0,3 bodů odpovídá celkem \$336 v případné obchodní pozici. Převzato z [9].

2.3.1 Základní formace cen

Základním prvkem, který lze z grafů vyčíst, jsou tzv. swingy – vlnky, ve kterých se cena kontraktu pohybuje. Swingy jsou definovány vrcholy a dny, mohou být různě dlouhé i vysoké. Automatické rozpoznávání swingu je mírně složité, protože každý swing má jiné parametry a také větší swing může být tvořen i několika malými swingy. Swing je ve své podstatě šumem ve vývoji ceny trhu.[4]

Nejdůležitější informací, které grafy (data) poskytují, je trend trhu. Přestože se trh pohybuje v menších vlnkách, dlouhodobě je trh v určitém trendu. „Pokud trh dlouhodobě stoupá, jedná se o býčí trend, pokud klesá, jedná se o medvědí trend.“ Nejziskovější obchodní strategie jsou ty, které následují trend. Pokud se trh neodvíjí jednoznačným směrem, jedná se o trh, který jde tzv. do strany.[10]

Dalšími důležitými prvky grafu jsou oblasti tzv. „support“ a „resistance“ (dále také S/R): [4]

- **Support** je oblast grafu, která označuje cenu, pod kterou již kupující odmítli kontrakty nakupovat, a kde se pokles ceny již několikrát pozastavil a později se od této hranice odrazil nebo ji prorazil.
- **Resistance** je opakem supportu, určuje hranici, kdy nakupující odmítli nakupovat kontrakty nad touto cenou.

Sílu S/R oblastí potom určuje, kolikrát se cena úrovně dotkla, konkrétně se za S/R oblast považuje úroveň, které se cena dotkla minimálně 3x. Přitom je uvažována určitá rezerva při doteku. S/R oblasti často poskytují důležité informace pro rozhodování o vstupech nebo výstupech z trhů, protože mají tendence se v grafu opakovat, měnit se mezi sebou ze supportu na resistenci a naopak a také cenu zastavit nebo alespoň zdržet. Typické support a resistance úrovně zobrazuje graf č. 2.3.



Graf 2.3 - Typické S/R úrovně. Převzato z [11].

Poslední zde popsanou formací je tzv. formace dvojitý vrchol / dvojité dno (dále DT/DB) reflektující psychologii davu obchodníků v komoditních a akciových trzích. „Pokud cena vytvoří nový vrchol či nové dno, ze kterého vytvoří korekci a následně již nový vrchol či nové dno nepřekoná, je to signál k tomu, že obchodníci odmítají obchodovat cenu ještě výše nebo naopak ještě níže, a tak můžeme s největší pravděpodobností očekávat obrát trendu.“ [12] Graf 2.4 ilustruje formaci dvojitý vrchol. Formace DT/DB i S/R jsou důležité v některých obchodních systémech, protože představují významné oblasti pro vstup do trhu.

Přestože nejsou uvedené formace v práci využívány přímo, jsou zde uvedeny jako příklad toho, že je v takových oblastech možné předpokládat určitý vývoj kurzu, tedy že vývoj trhu není zcela náhodný, a tím pádem mají technické obchodní strategie (této práce nevyjímaje), šanci na úspěch. V literatuře [4] je popsáno mnoho dalších cenových formací i v kombinaci s různými technickými indikátory. Jak bylo ale řečeno, tyto formace nebudou v navrženém systému explicitně definovány.



Graf 2.4 – Ukázka formace DT ve vývoji ceny. Převzato z [12].

2.4 Technické indikátory

Cena trhu v daném intervalu je určena čtyřmi různými hodnotami. Pro vyjádření ceny v takovém intervalu jednou hodnotou slouží tzv. **typická cena** (dále také zkratka TP), někdy anglicky označována jako *pivot point*. Jedná se o aritmetický průměr cen high, low a close, definovaný následovně:

$$TP_i = \frac{high_i + low_i + close_i}{3} \quad (2.1)$$

kde i je index aktuálního okamžiku.

TP není přímo indikátorem TA, ale je v praktické části v některých případech využita. [13]

Základním indikátorem technické analýzy trhu je **jednoduchý klouzavý průměr**, jehož parametrem je počet historických hodnot od aktuálního okamžiku zahrnutých ve výpočtu. Základní funkcí jednoduchého klouzavého průměru je v podstatě filtrace šumu. Jednoduchý klouzavý průměr (v práci dále označován zkratkou MA) je definován následovně:

$$MA_i(n) = \frac{(P_{i-n} + P_{i-(n-1)} + \dots + P_i)}{n} \quad (2.2)$$

kde n je parametrem MA, P_{i-n} až P_{i-1} jsou historické close (případně TP) hodnoty cen trhu a P_i je close (případně TP) hodnota v aktuálním okamžiku, pro který je MA počítán. [14]

Dalším indikátorem ze sady klouzavých průměrů je **exponenciální klouzavý průměr** (dále zkratka EMA). EMA je odlišný od MA tím, že přidává důležitost novějším hodnotám. Čím více je

hodnota umístěna v historii, tím má při výpočtu menší váhu. Výpočet je definován vztahem 2.3 a jeho parametrem je opět počet hodnot použitých pro výpočet.

$$EMA_i(n) = (P_i - EMA_{i-1}) \left(\frac{2}{n+1} \right) + EMA_{i-1} \quad (2.3)$$

kde i je index aktuálního okamžiku, $i - 1$ je index předešlého okamžiku, n je počet použitých hodnot historie a P_i je aktuální hodnota close (případně TP). Počáteční hodnotou EMA_0 může být zvolena nula.[15]

Posledním indikátorem z rodiny klouzavých průměrů je **indikátor konvergence a divergence klouzavého průměru** (dále zkratka MACD). Tento indikátor je definován jako rozdíl dvou EMA , nejčastěji s parametry 12 a 26, sleduje tedy sbíhavost a rozbíhavost exponenciálních klouzavých průměrů. Jeho definice je následující:

$$MACD_i = EMA_i(12) - EMA_i(26) \quad (2.4)$$

Stejně jako v předchozích případech index i reprezentuje aktuální okamžik. [16]

Indikátor s anglickým názvem „*Commodity Channel Index*“ a zkratkou CCI, měří zjednodušeně řečeno sílu a rychlost trendu vývoje ceny. [17] „*Technický indikátor Commodity Channel Index (CCI) měří odchylku ceny instrumentu od své průměrné statistické ceny. Vysoká hodnota indexu ukazuje, že je cena neobvykle vysoko ve srovnání s průměrem, a nízká hodnota indexu říká, že je cena příliš nízká.*“ Indikátor CCI je definován následovně:

$$MD_i(n) = \frac{(TP_{i-(n-0)} - MA_{TP_{i-(n-0)}}(n)) + \dots + (TP_{i-(n-n)} - MA_{TP_{i-(n-n)}}(n))}{n} \quad (2.5)$$

$$CCI_i(n) = \frac{(TP_i - MA_{TP_i}(n))}{0,15 * MD_i(n)} \quad (2.6)$$

kde i je index aktuálního okamžiku, MA_{TP} je jednoduchý klouzavý průměr vypočítaný z TP namísto close hodnot, n je parametr indikátoru určující velikost zahrnuté historie a MD je průměrná odchylka MA_{TP} od TP za posledních n hodnot včetně aktuálního okamžiku. [18]

Posledním indikátorem TA využitým v této práci je indikátor RSI, anglicky „*relative strength index*“. Indikátor měří sílu trhu a je jím možné určit, zda je trh překoupen nebo naopak přeprodán. Parametrem indikátoru je téměř vždy (v případě této práce je to vždy) číslo 14. Výpočet indikátoru je poměrně složitý, a proto zde není uveden. Kompletní výpočet může být nalezen v literatuře.[19]

2.5 Technické obchodování - vstup do trhu

Do trhu lze vstoupit na základě signálů technických indikátorů, známých cenových formací, významných historických úrovní hodnoty trhu nebo na základě kombinací zmíněného, v závislosti na charakteru trhu či zkušenosti obchodníka.

Nejjednodušší indikátor, který je možné pro vstup do trhu využít, je klouzavý průměr. Taková obchodní strategie využívá pro vstup do trhu momentu, kdy hodnota MA protne cenu trhu v grafu. Pokud cena protne MA směrem dolů, je to považováno za signál k nákupu, tedy vstupu do pozice long, pokud MA protne cenu směrem nahoru, je to signál k prodeji. Otázkou zůstává, kolik historických hodnot je pro výpočet MA vhodné použít. Bohužel neexistuje obecná odpověď a vždy záleží na charakteru trhu.[14] Graf 2.5 zobrazuje příklad takového obchodu při pozičním obchodování jednoho kontraktu s kukuřicí, kdy profit po sedmi týdnech držení pozice byl 3 450 USD. V grafu je červenou linkou znázorněn indikátor MA. Zmíněný postup je možné využít i při intradenním obchodování a stal se základem pro vytvoření výsledků obchodního modelu člověka v kapitole čtvrté.



Graf 2.5 – Červeně je zobrazen klouzavý průměr ceny trhu. Vstup do trhu na krátkou stranu je určen okamžikem, kdy klouzavý průměr protne cenovou řadu směrem nahoru. Výstup z obchodu je určen obdobným způsobem. Převzato z [14].

Ke vstupu do pozice je v různých obchodních systémech využíváno mnoho dalších technik, které zde z důvodu obsáhlosti nejsou blíže rozvedeny. Jedná se o kombinace různých formací, jako

např. dříve uvedené DT/DB nebo S/R úrovně. Obchodní systém *FinWin*¹ od autorů Petra Podhajského a Tomáše Nesnídala využívá převážně indikátor CCI. Tento identifikátor je využíván pro vstup do trhu při přechodech linií +100 a -100 jako indikátor překoupenosti nebo přeprodanosti, nebo při hledání divergencí, které jsou obvykle následovány cenovou korekcí. [18]

Otázka vstupu do trhu je obecně složité rozhodnutí, které pro úspěšný obchod vyžaduje rozvážnou a přitom často rychlou reakci.

2.6 Výstup z trhu

Důležitější částí obchodování, nežli samotné otevření pozice, je výstup z obchodu, protože na základě něj se rozhoduje o výši zisku. Neexistuje žádný univerzální vzorec nebo poučka o tom, kdy vystoupit, aby obchodník zůstal v obchodě co nejdéle, pokud se směr vyvíjí požadovaným směrem, nebo naopak co nejkratší dobu, pokud se vyvíjí směrem opačným.

Pro zamezení významných ztrát je vhodné používat tzv. **stop-loss** techniku (dále také SL). „*STOP-LOSS je předem definovaná krajní hranice, při které dobrovolně inkasujeme malou ztrátu dříve, než se taková rozroste do ztráty obří.*“ [20] Jinak řečeno, stop-loss umožňuje automatický výstup z pozice na předem definované úrovni. Graf č. 2.6 ilustruje význam použití techniky stop-loss.



Graf 2.6 – Ukázka techniky výstupu stop-loss. Obchod je brzy po otevření uzavřen, protože se trh nevyvíjí požadovaným směrem. Převzato z [20].

¹ <http://www.finwin.cz/>

Mimo nyní popsanou techniku existuje několik dalších možností pro určení výstupu v případě, že se obchod vyvíjí správným směrem:

- **Fixní „profit-target“** – (dále jen zkratka PT pro označení *profit-target*) je nejjednodušší typ výstupu, u kterého je předem zvolena úroveň zisku, na které je obchod uzavřen. Tato technika řeší výstup spíše ze statistického hlediska dřívějších zisků, než z hlediska aktuální situace na trhu. PT úroveň je zvolena na základě pokusných výsledků obchodování dané obchodní strategie konkrétního trhu a nelze ji určit obecně.
- **Posouvání stop-lossu** – pokud se trh pohybuje očekávaným směrem, úroveň stop-loss je postupně v tomto směru posouvána na úroveň ceny kontraktu o několik málo chvil zpět. Jakmile se směr trhu otočí, posouvaný stop-loss pozici uzavře bez výraznější ztráty profitu. Často je tato úroveň zvolena dle vrcholů (den) vlnek, které graf tvoří.
- **Podobně jako při vstupu do obchodu** je možné využít kombinace indikátorů TA nebo známých cenových formací.


3 Umělé neuronové sítě

Následující problematikou jsem se zabýval ve své bakalářské práci [21] a proto je z ní celá následující kapitola s některými úpravami převzata. Celá tato kapitola potom vychází z [22].

Umělé neuronové sítě jsou inspirovány jejich biologickými ekvivalenty, které jsou základem inteligence mnoha živých organismů. Podstatou neuronových sítí je modelování a napodobení funkce biologických neuronových sítí. Jejich využití nacházíme tam, kde lze úlohu velmi těžce nebo dokonce vůbec popsat matematicky, nebo je její matematické řešení příliš náročné, a také tam, kde je případná algoritmizace složitá. Neuronové sítě mají vynikající schopnost učit se, tedy vytvořit si vlastní zobecnění problému na základě předkládaných vzorů. Analogicky jako v biologickém světě, lze později využít znalosti získané učením a zhodnotit další podobnou situaci k řešení dané úlohy. Na rozdíl od analytického řešení problému lze toto navíc i bez znalosti algoritmického řešení úlohy. Neuronové sítě mají uplatnění hlavně v řešení složitých nebo nelineárních systémů. Škála oblastí použití je velká, lze je využít pro rozpoznávání vzorů, kompresi, expanzi, kódování, dekódování, transformace nebo analýzu signálů, pro predikci časových řad nebo rozhodování.

3.1 Biologický neuron

Základním prvkem neuronové sítě je neuron. Jeho schopnosti jsou zpracování, uchování a přenos informací ve formě signálů. Schéma biologického neuronu zobrazuje obrázek č. 3.1. Neuron se v základech neliší od ostatních typů buněk, skládá se také z buněčné membrány, cytoplazmy a jádra. Od jiných buněk se odlišuje četnými a bohatě rozvětvenými výběžky, které jsou dvojího druhu. První se nazývají axony, druhé dendrity. Axony jsou dlouhé a silné a umí rychle přenést informace v podobě nervových impulsů. Na konci se větví na další výběžky zvané synapse, které zajišťují přenos informace k dalším neuronům. Axony jsou výstupem neuronu, který je synapsemi spojen s dalšími neurony. Naopak dendrity mají funkci vstupu, protože vedou informace do buňky. Jsou slabší než axony a také mnohem kratší.




Obrázek 3.1 - Biologický neuron je tvořen tělem (v obrázku angl. název soma), jádrem (angl. nucleus), vstupními dendrity a výstupními axony. Převzato z [23].

Spojením mnoha neuronů pomocí synapsí vzniká neuronová síť. U člověka je to například mozková kůra, která je tvořena 13 až 15 miliardami neuronů.

3.2 Umělý neuron

U umělého neuronu jsou biologické funkce buňky nahrazeny funkcemi matematickými. Existuje množství různých variací, které se liší právě matematickými funkcemi realizujícími přenos. Obrázek č. 3.2 zobrazuje tzv. základní model neuronu (někdy nazýván podle svých autorů *McCulloch-Pittsův*).




Obrázek 3.2 - Schéma umělého neuronu. Funkce $y_a(x_i, w_i)$ je agregační funkce a $f(y_a)$ je aktivační funkce neuronu. Vstupem jsou vážené hodnoty x a výstupem je hodnota y .

Vstup do neuronu představují signály x_i , které převážně nabývají hodnoty z oboru reálných čísel. Podle umístění neuronu v síti jsou to pak vstupy, které jsou zároveň výstupy jiných neuronů, nebo jsou to vstupy z vnějšího okolí. Dohromady spolu tvoří vstupní vektor $X = [x_1, \dots, x_n]$. Jednotlivé vstupy neuronů jsou dále ovlivňovány váhami spojení w_i , které ve své podstatě určují průchodnost dané cesty, a tím také to, jak velké působení bude mít vstup neuronu na jeho výstup. Vhodným nastavením vah může být docílena shoda mezi požadovaným výstupem a výstupem neuronu. Nastavováním nejvhodnějších vah se zabývá proces učení. Prahová hodnota θ neuronu se aktivně podílí na výstupu z neuronu a často slouží k posunutí signálu do aktivační funkce. Tuto funkci ještě předchází agregační funkce $y_a(x_i, w_i)$, která slouží ke sloučení signálů x_i vektoru X . Vektor X je v čase k přetransformován na skalární signál y_a , který pokračuje do aktivační funkce neuronu. Agregační funkci lze matematicky vyjádřit následovně:

$$y_a(k) = \sum_{i=0}^n x_{i(k)} \cdot w_{i(k)} , \quad (3.1)$$

Aktivační funkce $f(y_a)$ převádí vstupní potenciál y_a na výstupní hodnotu z neuronu. Konkrétních forem přenosových funkcí je více a vždy je potřeba použít některou vhodnou podle typu a aplikace neuronové sítě. Nejčastěji používaným typem funkce je funkce sigmoidní. Průběh sigmoidní funkce s názvem hyperbolická tangenta je zobrazen v grafu č 3.1. Dalšími používanými funkcemi může být funkce skoková nebo lineární.



Graf 3.1 - Průběh sigmoidní funkce hyperbolická tangenta

Spojení několika neuronů vytváří neuronovou síť. Ta se dá popsat jakýmkoliv orientovaným grafem, kde vrcholy jsou tvořeny neurony a hrany zmíněnými propojeními s určitou vahou. Způsob, jakým jsou neurony propojeny, tzn. který je spojen se kterým apod., se nazývá *topologie* sítě. Existuje více typů topologií. Často se používá vrstevnatá architektura. Neurony jsou rozděleny do vrstev, které se podle pozice označují jako vstupní, jedna nebo více skrytých a výstupní vrstva. Počet vrstev spolu s počty neuronů ve vrstvách tvoří *konfiguraci* sítě. Podle toku signálu se síť dělí na rekurentní a dopředné, kterých bude dále využíváno. Neurony z každé vrstvy jsou spojeny s neurony (většinou všemi) vrstvy sousední. Proces učení potom spočívá v postupném nastavování vah těchto spojení a lze ho popsat jako algoritmus, který určuje, jakým způsobem budou váhy nastavovány. Základem učících algoritmů bývá tzv. *Hebbův zákon učení* [Donald Hebb, 1949] a lze ho vyjádřit následující rovnicí:

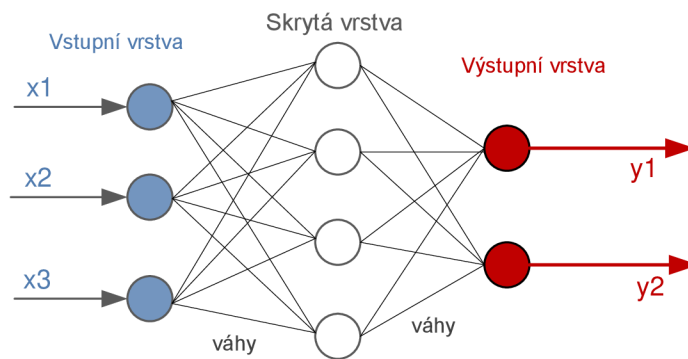
$$\Delta w_{ij(k+1)} = \alpha \cdot x_i(k) \cdot x_j(k) \quad (3.2)$$

která udává změnu váhy mezi dvěma neurony i a j jako zesílení v případě, že jsou oba neurony v čase k aktivní, a v případě, že jsou oba v neaktivním stavu, jako zeslabení, a kde α je důležitá konstanta udávající rychlost učení.

Učení může probíhat jako učení s učitelem nebo učení bez učitele podle způsobu aplikace. Učení s učitelem je v praxi použito, pokud předem existují trénovací dvojice vstupních a výstupních vektorů, tedy je známo to, co se má síť naučit. Vstupní vektor je zpracován neuronovou sítí a její výstup je porovnán se vzorovým výstupním vektorem. Váhy mezi neurony jsou následně modifikovány na základě chyby, jako rozdíl mezi požadovanou a získanou hodnotou.

Nejčastěji využívané jsou vícevrstvé dopředné neuronové sítě. Jejich zjednodušené schéma zobrazuje obrázek č. 3.3. Proces trénování dopředné neuronové sítě s učitelem spočívá v opakovaném přikládání vzorků na vstup sítě. Tyto vzorky se nazývají trénovací množina a musí být dostatečně reprezentativní, aby bylo dosaženo chtěného chování sítě. Průchod celé trénovací množiny je označován jako epocha nebo také iterace trénování. Jednotlivé epochy se opakují tolikrát, kolikrát určuje zvolený algoritmus při učení většinou do té doby, dokud se výsledky sítě zlepšují, nebo je dosaženo dostatečného zmenšení chyby mezi výstupem sítě a požadovaným

výstupem. Průběžné výsledky je vhodné zjišťovat na tzv. validační množině, což je část trénovací množiny vektorů, na které se učení neprovádí, a která slouží jen pro ověření funkčnosti sítě na neviděných datech. Algoritmy učení neuronových sítí pak určují, kdy a jaká data se bude síť v té které iteraci učit, jakou dobu se je bude učit, a zda v průběhu učení dochází ke změně faktoru učení α , a pokud ano, tak jakým způsobem.



Obrázek 3.3 – Umělou neuronovou síť tvoří několik umělých neuronů, které bývají často umístěny ve vrstvách. V tomto případě jsou navzájem propojeny veškeré neurony sousedních vrstev.

Účelem trénování je změna vah spojujících neurony. Pro učení dopředné sítě s učitelem v rámci jednoho vzorku se často používá algoritmus zpětného šíření chyby E , tzv. *zpětné propagační algoritmus* (z angl. *Back Propagation Algorithm*). Je založen na minimalizaci této chyby, vyjádřené jako funkce ve tvaru

$$E(p_e) = \sum_{k=1}^N e(p_e, k), \quad (3.3)$$

kde p_e je pořadové číslo epochy trénování, N je počet vzorků v trénovací množině, k je pořadové číslo takového vzorku a $e(p_e, k)$ je přírůstek kriteriální funkce mezi jednotlivými vzorky v trénovací množině, a kde

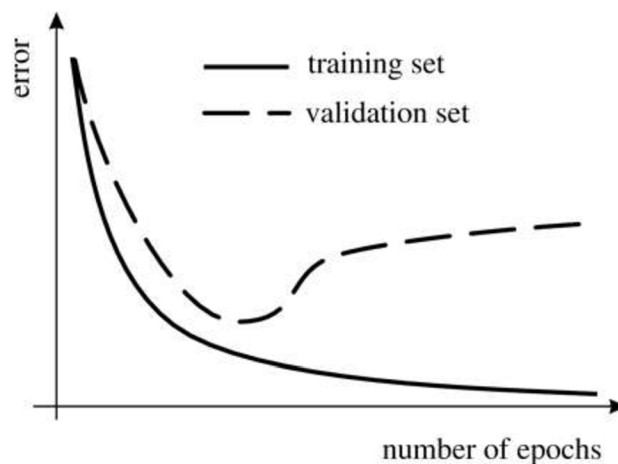
$$e(p_e, k) = \frac{1}{2} \sum_{h=1}^m \varepsilon_h^2(p_e, k) = \frac{1}{2} \sum_{h=1}^m (y_{s_h}(k) - y_{M_h}(p_e, k))^2, \quad (3.4)$$

kde m je počet výstupů sítě, h je h -tý výstup, $\varepsilon_h^2(p_e, k)$ jsou přírůstky kriteriální funkce od jednotlivých výstupů, $y_{M_h}(p_e, k)$ jsou hodnoty výstupů sítě a $y_{s_h}(k)$ jsou požadované hodnoty na výstupu. Chyba e je následně propagována zpět přes všechny neurony. Na jejím základě jsou pozměněny váhy spojení konkrétních dvou neuronů tak, aby tato chyba byla minimalizována. Pro každý uzel i v předcházející vrstvě I než množina uzlů J jsou vypočítány dílčí chyby e_I na základě dílčích chyb e_J a vah spojující uzel i s uzly J . Tímto způsobem je vytvořena chyba e pro každý uzel skryté vrstvy. Nová váha w' uzlu i , spojující ho s uzlem v předcházející vrstvě, je potom vypočítána na základě váhy stávající w , chyby e_i , konstanty α udávající rychlost učení a hodnoty y , která je

výstupem předchozího uzlu, s nímž je neuron spojen váhou w . Aktivační funkce neuronu je $f(y_a)$ a y_a je výstupem agregační funkce, tedy vstupní potenciál neuronu. Výpočet nové váhy w lze potom popsat následující rovnicí.

$$w = w' + \alpha \cdot e_i \frac{df(y_a)}{dy_a} y \quad (3.5)$$

Již bylo zmíněno, že vzorky dat ve formě dvojic vektorů, jsou rozděleny do tří množin. Na trénovací množině probíhá samotné trénování úpravou vah, validační sada slouží k řízení trénovacího algoritmu, který rozhoduje o rychlosti učení a o zastavení učícího procesu. Úspěšnost trénování a celková výkonnost sítě je nakonec změřena na testovací sadě dat. Typickou závislost celkových chyb trénovací a validační sady na počtu iterací trénování zobrazuje graf 3.2. Zde je vidět nutnost trénovacího algoritmu, který trénování zastaví, jakmile chyba na validační sadě přestane klesat, protože dále už se síť učí pouze konkrétní trénovací sadu namísto obecného problému.



Graf 3.2 - Chyba v závislosti na počtu iterací trénování. Přestože úspěšnost neuronové sítě na trénovací sadě stále klesá s rostoucím počtem iterací, výsledky na validační sadě se časem začínou zhoršovat. V takovém okamžiku je vhodné ukončit trénování nebo případně změnit parametry trénování. Převzato z [24].

3.3 Neuronové sítě v predikčním systému

V předcházejících částech byly uvedeny schopnosti neuronových sítí a také složitost rozhodování při obchodování na burze. Myšlenka tyto dvě oblasti spojit a vytvořit tím obchodní systém, který by fungoval se stejnou, ne-li s lepší úspěšností než zkušený obchodník, není nová. Několik odborných prací se tímto tématem již zabývaly.

Při využití neuronových sítí (dále NN) pro předpověď vývoje kurzu hraje důležitou roli řada faktorů. Základními prvky jsou volba architektury NN, způsob jejího trénování a testování. Architektura NN zahrnuje způsob rozložení neuronů, jejich vzájemné propojení a volbu přenosových funkcí jednotlivých neuronů. Dalšími podstatnými vlastnostmi systému je způsob

prezentace dat na vstupy NN a požadovaný výstup, jinak řečeno to, co by se měla NN naučit generalizovat a poté predikovat či klasifikovat. Neméně důležitým prvkem celého systému je také volba učícího algoritmu a parametrů učení, což souvisí i s topologií zvolené sítě. Testování takových systémů je různé. Pro odlišnost oblastí zájmů se výsledky těžko porovnávají, proto u následujících predikčních modelů nebudou uvedeny.

Ve vztahu aplikace k modelům dat bylo vyzkoušeno několik následující přístupů. Neuronové sítě jsou nejčastěji využity pro předpověď konkrétní ceny trhu, a to v různě dlouhých časových periodách na základě technických indikátorů vývoje ceny opět z různých časových rámců. Předpověď výkonnosti trhu jako celku je vhodná pro dlouhodobější investice a bývá často většinou odvozována od sekundárních zdrojů informací než přímo z historických dat trhu. Další model produkuje doporučení k otevření pozice na dlouhou nebo krátkou stranu pouze v závislosti na historických datech trhu. Existuje několik dalších přístupů, uvedeny byly nejběžnější tři. Pro zvýšení úspěšnosti predikcí je někdy NN zkombinována v hybridních systémech s expertním systémem filtrujícím výstupy sítě. [25]

Obecným příkladem využití NN je systém vyvinutý Robertem J. Eydensem [26], který modeluje vývoj burzy v Johannesburgu. Vstupem NN je 63 různých typů dat a indikátorů za účelem poskytnutí globálního pohledu na prostředí burzy, mezi nimiž se objevovaly fundamentální prvky (např. globální výnosy), indikátory technické analýzy (klouzavé průměry, trendy a další), vlastní ale i mezinárodní akciové indexy, ekonomické statistiky a další. Zajímavostí je, že po vypuštění jistých dvaceti indikátorů síť dosahovala stejných výsledků. Výstupem systému je hodnota ceny trhu ve zvoleném okamžiku. Eydensův systém je trénován algoritmem backpropagation a architektura NN byla navrhována automaticky genetickými algoritmy. [27]

Samoorganizující se neuronovou síť pro předpověď budoucí ceny využívá ve své práci Wilson [32]. Systém vytváří model trhu pomocí historických cen ve spojení s počty provedených obchodů. Informace potřebné pro predikci jsou zvoleny automaticky, stejně tak jako samotná topologie NN, která je organizována v průběhu trénování. Wilson používá dvě samoorganizující se NN ve spojení za sebou. První vybírá vhodné charakteristiky z poskytnutých dat a druhá potom provádí samotnou predikci. Problémem je způsob trénování takového systému. [27]

Zajímavý systém predikce vývoje trhu vyvinul Yoon. Systém byl založen na počtu významných slov použitých ve zprávách od prezidenta firmy jejím akcionářům. [27]

Ve své diplomové práci navrhl Chong Tan systém využívající stacionární vlnkovou transformaci (dále SWT) cenového signálu Haarovou vlnkou pro jeho reprezentaci pro NN. Několik sítí bylo trénováno paralelně s daty transformovanými SWT s různou bází. Výstupy všech takových sítí byly předány vstupu poslední NN, která byla trénována na krátkodobou předpověď ceny trhu. [28]

4 Praktická část

V této kapitole budou popsány hlavní body práce. V úvodu budou definovány trénovací a testovací sady dat. Dále bude podrobně popsán náhodný obchodní model, obchodní model člověka, základní obchodní model využívající neuronové sítě a jeho vylepšená varianta. Budou zveřejněny výsledky jednotlivých modelů, jejich vzájemné porovnání a také diskuze nad těmito výsledky. V samotném závěru kapitoly budou navržena další vylepšení systému.

4.1 Trénovací a testovací sada dat

V teoretické části bylo uvedeno, že existuje velké množství trhů obchodujících různá podkladová aktiva. Důležitých kritérií pro výběr konkrétních trhů pro účely trénování a testování navrženého systému je několik.

Protože se tato práce zabývá intradenním technickým obchodováním, je zapotřebí vybrat takové trhy, které jsou co nejméně ovlivněny fundamentálními vlivy. Nevhodným příkladem jsou např. akciové trhy. Vydání tiskové zprávy dané společností, nebo jen zveřejnění novinového článku z oblasti, v níž firma operuje, změní v danou chvíli myšlení obchodníků takovým způsobem, jež není navržený systém schopný předpovídat. Důvodem je často nemožnost očekávat čas zveřejnění takových podnětů, jejich různorodost nebo následně pak jejich složité matematické interpretace pro vstup do systému.

Pro maximální přiblížení podmínek reálnému obchodování je dalším důležitým faktorem při výběru vhodného trhu jeho likvidita. Jen v dostatečně likvidním trhu je možné exekuvovat (tzn. provést) obchodní příkaz za aktuální cenu. Pokud by v trhu neprobíhalo dostatečné množství obchodů, mohlo by se stát, že v danou chvíli nebude k dispozici druhý obchodní partner a s vykonáním příkazu by bylo nutné vyčkat. Při tom se ovšem pravděpodobně změní cena kontraktu, což není u krátkodobého obchodování žádoucí. Charakter dostupných historických dat sice neumožňuje při zpětné simulaci obchodování přímo určit, zda se podaří vykonat obchodní příkaz okamžitě za aktuální cenu, ovšem v dostatečně likvidním trhu to lze předpokládat.

Posledním faktorem je dostupnost dostatečného množství historických dat pro účely trénování a testování systému. Ukázalo se, že téměř všechny zdroje burzovních dat poskytují historická intradenní data za nemalé poplatky, což způsobilo, že se tento faktor stal velice limitujícím pro výběr vhodných trhů a celkově pak pro trénování a testování systému.

Podařilo se nalézt internetový zdroj², který zdarma poskytuje historická intradenní data vybraných světových trhů. Limitem je pouze fakt, že dostupná jsou jen data za poslední půlroční období. Tato data obsahují základní cenové údaje uvedené v kapitole 2.3 a navíc i hodnotu volume, díky níž lze určit likviditu trhu. Data jsou ke stažení v časovém rozlišení 1,2,5,10,15,30 min a více.

² Zdrojem veškerých cenových dat je server <http://www.stockrageous.com>

Z dostupných trhů jsou vybrány tři, z nichž jsou vytvořeny tři trénovací a testovací sady. Jedná se o trhy umožňující obchodovat futures kontrakty, jejichž podkladovým aktivem jsou akciové nebo burzovní indexy. Takové trhy nejlépe splňují první stanovenou podmínku. Akciový resp. burzovní index může být definován jako ukazatel vývoje cen celého balíku akcií resp. trhů z různých tržních segmentů nebo burz. [4] Ekonomickou podstatou indexů se dále tato práce nebude zabývat, důležité je, že tyto trhy většinou nereagují tak prudce na fundamentální vlivy jako trhy jiné a tím jsou snadněji technicky obchodovatelné.

Sada A je vytvořena z akciového indexu „*S&P/TSX Composite Index*“, který je vypočítáván z tržní kapitalizace největších firem kanadské burzy TSX (*Toronto Stock Exchange*). Trh obchodující tento index se nazývá „*S&P/TSX Composite Index Mini Futures*“. V této práci je trh označován zkratkou SPTSX. Cena jednoho kontraktu, který lze nakoupit je uvedena ve specifikaci trhu a je rovna pětinásobku bodů indexu v měně CAD (kanadský dolar).³ Základní údaje sady A shrnuje tabulka 4.1.

Celkem dostupných dat	25. 06. 2010 - 13. 04. 2011	43 328 vzorků (timeframe 2 min)
Trénovací část	25. 06. 2010 - 11. 02. 2011	34 279 vzorků (timeframe 2 min)
Testovací část	14. 02. 2011 - 13. 04. 2011	9 049 vzorků (timeframe 2 min)

Tabulka 4.1 – Rozsahy a počty vzorků sady A.

Sada B je vytvořena z akciového indexu „*NASDAQ-100*“ obchodovaném na americké burze CME (*Chicago Mercantile Exchange*) prostřednictvím trhu s názvem „*NASDAQ-100 Futures*“. V této práci je trh označován zkratkou NDX. Cena jednoho kontraktu je rovna stonásobku bodové hodnoty indexu v měně USD.⁴ Základní údaje sady B shrnuje tabulka 4.2.

Celkem dostupných dat	13. 10. 2010 - 13. 04. 2011	24 767 vzorků (timeframe 2 min)
Trénovací část	13. 10. 2010 - 11. 03. 2011	20 305 vzorků (timeframe 2 min)
Testovací část	14. 03. 2011 - 13. 04. 2011	4 462 vzorků (timeframe 2 min)

Tabulka 4.2 - Rozsahy a počty vzorků sady B.

Sada C je vytvořena z burzovního indexu „*NYSE Composite*“, pokrývajícího nejdůležitější trhy americké burzy NYSE (*New York Stock Exchange*). V této práci je trh označován zkratkou NYA. Cena jednoho futures kontraktu je rovna padesátinásobku bodové hodnoty indexu v měně USD.⁵ Základní údaje sady C shrnuje tabulka 4.3.

Celkem dostupných dat	13. 10. 2010 - 13. 04. 2011	25 827 vzorků (timeframe 2 min)
Trénovací část	13. 10. 2010 - 11. 03. 2011	20 868 vzorků (timeframe 2 min)
Testovací část	14. 03. 2011 - 13. 04. 2011	4 959 vzorků (timeframe 2 min)

Tabulka 4.3 - Rozsahy a počty vzorků sady C.

³ Podle specifikace na <http://www.standardandpoors.com>

⁴ Podle specifikace na <http://www.cmegroup.com>

⁵ Podle specifikace http://www.admis.com.hk/en/pdf/hightower_contract_specs.pdf

Další podrobnější specifika trhů nejsou uvedena, protože nejsou při trénování ani testování systému zahrnuta. Vzájemná korelace všech tří trhů zde také není uvedena, přestože ji lze do určité míry pozorovat. Trhy jsou ale velice odlišné cenou kontraktu, což ve své podstatě znamená, že i stejné pohyby kurzu znamenají jiné cenové rozdíly. Jak bude vidět dále, trhy jsou také jinak volatilní (dravé). Pro veškeré trénování a testování obchodních modelů byl zvolen timeframe 2 minuty (v reálném intradenním obchodování se často používá) hlavně proto, že dodává nejvhodnější hustotu dat pro navržený obchodní systém, což bude vysvětleno v pozdější kapitole.

4.2 Hodnocení systému – skórování

Pro účely porovnání systému s náhodným obchodním modelem a obchodním modelem člověka je provedena simulace obchodování na testovacích sadách dat. Určení úspěšnosti spočívá v porovnání dosažených zisků a ztrát jednotlivých obchodních modelů za testovací období.

Simulace probíhá následujícím způsobem:

- 1) Vynulování stavu peněžního účtu v časovém okamžiku 0 (počátek simulace)
- 2) Průchod testovacích vzorků v chronologickém pořadí od počátku ke konci
- 3) Vstup do pozice na základě podnětu daného obchodního modelu
- 4) Výstup z pozice na základě podnětu daného obchodního modelu
- 5) Výpočet zisku/ztráty, odečtení poplatků za provedení obchodu (tzv. RT), úprava stavu účtu
- 6) Opakování bodů 2 až 5 do konce testovaného období
- 7) Konec simulace

U každé simulace platí následující společná pravidla:

- Krok simulace odpovídá časovému měřítku zdrojových dat
- Peněžní účet je veden měně trhu
- V každém okamžiku je držena maximálně jedna obchodní pozice s jedním kontraktem
- Vstupní hodnota je vypočítána jako cena jednoho kontraktu krát bodová hodnota trhu v okamžiku vstupu do obchodu
- Výstupní hodnota je vypočítána stejně jako vstupní, ale v okamžiku výstupu z obchodu
- Celkový zisk / ztráta z obchodu je rozdíl mezi vstupní a výstupní hodnotou držené pozice po odečtení RT poplatku
- RT poplatek je pevně daný na 5 USD (případně jiné měny trhu), což odpovídá průměrnému poplatku u různých brokerů
- Pozice jsou drženy maximálně v rámci jednoho dne. Pokud bude na konci dne pozice stále otevřena, bude automaticky uzavřena bez ohledu na podněty modelu

Další parametry a nastavení simulací již záleží na daném obchodním modelu, taková nastavení budou uvedena dále u popisu konkrétních modelů.

Simulace je do určité míry zjednodušena a některé skutečnosti reálného obchodování na burze nejsou částečně nebo vůbec zohledněny. Výše bylo zmíněno, že provedení obchodního příkazu se

nemusi vždy provést okamžitě. Tato skutečnost je částečně zajištěna výběrem dostatečně likvidních trhů. Jinak ji není možné uměle vytvořit.

Dále není zohledňována nutná počáteční investice do obchodu, což je u skutečného obchodování jeden z nejpodstatnějších faktů, ovšem při hlubším zamyšlení lze dojít k závěru, že ho lze v případě simulace vypustit. Z celkové částky získané výstupem z reálného obchodu je odečtena počáteční investice, což je potom absolutní zisk nebo ztráta nezávislá na velikosti investice. Rozdíl mezi simulací a realitou pak spočívá pouze v tom, že v případě reálného obchodování nelze po vyčerpání účtu dále obchodovat, simulovat obchody ale lze. Počáteční velikost účtu může být různá, a tedy by bylo nesprávné ukončit simulaci jen proto, že byl k dispozici malý účet, protože v této práci nakonec jde pouze o porovnání celkových zisků a ztrát jednotlivých obchodních modelů za stejné časové období. Společnosti (brokerské), které zprostředkovávají obchody mezi burzou a obchodníkem, navíc poskytují již zmíněné tzv. obchodování na páku, které umožňuje velikost investice rapidně snížit. Velikost páky je u každého brokera určena individuálně, což přispívá k irelevantnosti počátečních investic z pohledu simulace. Z těchto důvodů je tedy účet na počátku simulace vždy nulový a investice pro vstup do obchodů nejsou uvažovány.

Mimo směrodatný výsledek – výše účtu po skončení simulace, jsou v průběhu simulace sledovány i další faktory, jako jsou počty ziskových a ztrátových obchodů, průměrný zisk na obchod a další, což napomáhá interpretaci celkového zhodnocení daného modelu. Je uveden i tzv. „drawdown“⁶, což je velikost největší po sobě jdoucí ztrátové série obchodů za dobu simulace. Grafické znázornění simulace obchodování také přispívá k interpretaci výsledků a k optimalizaci parametrů modelu.

4.3 Náhodný obchodní model

Náhodný obchodní model primárně tvoří spodní hranici pro měření úspěšnosti obchodování. Čím blíže je jiný obchodní systém těmto výsledkům, tím více o něm bude možno říci, že je nefunkční.

Návrh náhodného modelu je následující. Podněty pro vstupy a výstupy z obchodů jsou generovány náhodně, resp. v každém okamžiku s určitou pravděpodobností. Je využito generátoru pseudonáhodných čísel s uniformním rozdělením pravděpodobnosti. Je určena míra pravděpodobnosti, zda je v daný okamžik vygenerován podnět ke vstupu nebo výstupu z obchodu. Tato pravděpodobnost není nijak empiricky určena, pouze ji lze zvolit intuitivně tak, aby v průběhu simulace proběhlo dostatečné množství obchodů pro objektivnější zhodnocení a také tak, aby obchodů neproběhlo příliš mnoho, protože v opačném případě by výsledky byly příliš zkresleny velikostí poplatků za obchody.

Typ pozice k otevření je určen opět pomocí pseudonáhodného generátoru čísel s 50% pravděpodobností otevření pozice na krátkou stranu, v opačném případě je otevřena pozice na dlouhou stranu.

⁶ <http://www.financnik.cz/wiki/drawdown>

Jelikož obchodování probíhá náhodně, jsou i konečné výsledky náhodné. Bylo proto provedeno vždy celkem 1000 simulací na každé testovací sadě a typické výsledky byly vyjádřeny pomocí aritmetického průměru všech pozorování z důvodu následného objektivního porovnávání.

4.3.1 Výsledky simulace náhodného modelu

V prvním kole simulací nebyla použita technika stop-loss, oproti tomu v druhém kole byla využita technika stop-loss. Optimální velikosti hranic SL byly vyzporovány individuálně pro každý trh na trénovacích sadách. Simulace pak probíhaly vždy 1000 krát standardně na testovacích sadách s následujícími průměrnými výsledky:

Testovací sada A	bez stop-loss	stop-loss \$ 2,50
Průměrný počet obchodů celkem	236	351
z toho ziskových obchodů	98	69
z toho ztrátových obchodů	138	282
Průměrný konečný stav účtu	\$ -1 136,20	\$ -85,81
Průměrný celkový zisk	\$ 7 990,00	\$ 5 805,09
Průměrná celková ztráta	\$ -9 126,20	\$ -5 890,90
Průměrná bilance z jednoho obchodu	\$ -4,81	\$ -0,24
Testovací sada B	bez stop-loss	stop-loss \$ 10,00
Průměrný počet obchodů celkem	120	179
z toho ziskových obchodů	58	37
z toho ztrátových obchodů	62	142
Průměrný konečný stav účtu	\$ -1 192,70	\$ -395,02
Průměrný celkový zisk	\$ 21 233,30	\$ 13 388,98
Průměrná celková ztráta	\$ -22 426,00	\$ -13 784,00
Průměrná bilance z jednoho obchodu	\$ -9,94	\$ -2,21
Testovací sada C	bez stop-loss	stop-loss \$ 5,00
Průměrný počet obchodů celkem	121	185
z toho ziskových obchodů	58	37
z toho ztrátových obchodů	63	148
Průměrný konečný stav účtu	\$ -625,23	\$ 1 576,00
Průměrný celkový zisk	\$ 31 960,77	\$ 20 600,00
Průměrná celková ztráta	\$ -32 586,00	\$ -19 024,00
Průměrná bilance z jednoho obchodu	\$ -5,17	\$ 8,52

Tabulka 4.4 - Výsledky simulace náhodného obchodního modelu bez a s použitím stop-loss.

Z výsledků je patrné, že bez použití SL je průměrný obchod ztrátový zhruba ve výši poplatku za obchod. Tento fakt odpovídá předpokladu, že při nekonečném počtu náhodných intradenních

obchodů by si výše zisků i ztrát měla odpovídat. Odchylka jednotlivých pozorování je způsobena tím, že bylo provedeno málo (méně než nekonečno) obchodů. Využití SL potom jednoznačně zvyšuje úspěšnost systému.

4.4 Obchodní model člověka

Úspěšné technické obchodní strategie používané lidmi pro obchodování různých trhů jsou obecně velice propracované modely. Obchodník začátečník, který chce strategii úspěšně využívat, se jí často učí několik měsíců až let, postupně si ji upravuje a ladí podle svých schopností a možností, než ji začne používat pro reálné obchodování.

Takové strategie jsou obtížně naprogramovatelné i proto, že se časem mění podle toho, jak se s dobou mění charakter trhu, ale také právě kvůli své složitosti. Přestože cílem této práce není vytvoření automatického obchodního systému založeného čistě na lidském přístupu k obchodování, pro účely porovnání dále navrženého modelu využívající neuronové sítě byla zvolena, implementována a testována základní jednoduchá strategie. Výsledky tohoto obchodního modelu tak v této práci tvoří horní hranici úspěšnosti obchodování.

4.4.1 Návrh modelu

Navržený model využívá jednoho indikátoru technické analýzy, klouzavého průměru (dále jen zkratka MA), který byl popsán v kapitole 2.4. Pravidla pro vstup do trhu v okamžiku t jsou definována následovně: [14]

- Pokud bodová hodnota trhu (cena trhu) protne MA směrem dolů, je to považováno za signál k nákupu, tedy vstupu do dlouhé pozice. Vstup „*long*“ nastane, pokud platí následující logický výraz:

$$Cena(t - 1) > MA(t - 1) \wedge Cena(t) < MA(t) \quad (4.1)$$

- Pokud bodová hodnotu trhu (cenu trhu) protne MA směrem nahoru, je to považováno za signál k prodeji, tedy vstupu do krátké pozice. Vstup „*short*“ nastane, pokud platí následující logický výraz:

$$Cena(t - 1) < MA(t - 1) \wedge Cena(t) > MA(t) \quad (4.2)$$

Výstup z obchodu je proveden obdobným způsobem:

- je-li otevřena pozice na dlouhou stranu a MA protne cenu trhu směrem nahoru (viz definice vstupu „*short*“)
- je-li otevřena pozice na krátkou stranu a MA protne cenu trhu směrem dolů (viz definice vstupu „*long*“)
- je otevřena pozice na libovolnou stranu a cena trhu protne předem definovanou úroveň stop-loss oproti očekávanému vývoji (pro zamezení výraznější ztráty).

Parametry modelu jsou celkem dva. První, velikost stop-lossu, musí být vhodně zvolen tak, aby zbytečně nezpůsobil výstup z obchodu při sebemenším záchvěvu kurzu (tzv. swingy viz kap. 2.3.1), ale také tak, aby co nejvíce minimalizoval případné ztráty, pokud byl trend trhu předpovězen chybně. Druhým parametrem je počet historických hodnot použitých pro výpočet MA. Oba parametry jsou pro každý trh zvoleny individuálně. Jejich optimální hodnoty jsou předem vyzorovány na trénovacích sadách a poté jsou použity při simulaci, v jejímž průběhu už se nemění ani v závislosti na průběžných výsledcích.

4.4.2 Výsledky simulace

Simulace probíhaly podle standardně definovaného postupu s předem zjištěnými optimálními parametry. Simulace obchodování byla pro každou testovací sadu provedena pouze jednou (se stejnými parametry by dopadla vždy stejně).

Následující tabulka zobrazuje získané výsledky:

Testovací sada	A	B	C
Počet obchodů celkem	497	171	172
z toho ziskových obchodů	117	44	36
z toho ztrátových obchodů	380	127	136
Konečný stav účtu	\$ 6 948,50	\$ 5 841,00	\$ 18 928,00
Celkový zisk	\$ 14 777,60	\$ 21 733,00	\$ 35 265,00
Celková ztráta	\$ -7 829,10	\$-15 892,00	\$-16 337,00
Průměrná bilance z jednoho obchodu	\$ 13,98	\$ 34,16	\$ 110,05
Průměrná absolutní bilance z jednoho obchodu	\$ 45,49	\$ 220,03	\$ 300,01
Drawdown	\$ 372,00	\$ 1 238,00	\$ 5 032,00
Velikost stop-loss v \$	5	100	50
Parametr MA	20	40	50

Tabulka 4.5 - Výsledky simulace obchodního modelu člověka na testovacích částech definovaných sad.

Obchodní model člověka je ve všech testovaných případech ziskový. Za povšimnutí stojí nízký poměr celkových zisků a celkových ztrát. Tento fakt indikuje, že tento obchodní model, přestože je nakonec úspěšný, je zároveň i vysoce riskantní.

4.5 Základní predikční model

V následujících podkapitolách je podrobně popsán navržený predikční systém využívající umělé neuronové sítě popsané v kapitole třetí. Je navržena celková koncepce základního modelu, postup při předzpracování dat, dále jsou detailně vysvětleny vstupy a výstupy neuronové sítě, popsány

veškeré parametry a nakonec je základní predikční systém aplikován v obchodním modelu a jsou uvedeny výsledky simulací na testovacích sadách.

4.5.1 Celková koncepce modelu

V kapitole 3.3 bylo krátce uvedeno několik již vyzkoušených přístupů k predikci kurzu burzy s využitím neuronových sítí. Návrh nového modelu spočívá v určení jak, z jakých dat a co bude systém predikovat.

Vstupem systému jsou výhradně ceny trhu a prvky technické analýzy, tedy indikátory a další ukazatele, jež je možno získat úpravami a výpočty jen a pouze z dostupných historických cen trhu. Jejich kombinací a zvolením vhodného počtu historických hodnot je prostřednictvím trénování systému docíleno toho, že systém je do jisté míry schopný se naučit skryté procesy v trhu a obecnější podstatu vývoje kurzu trhu.

Výstupem základního systému je předpověď průměrné ceny v předem daném časovém rámci. Jedná se tedy o využití neuronové sítě jako nelineárního regresního modelu.

Z podstaty neuronových sítí a obecně řešeného problému není možné přesně určit, jaké konkrétní procesy vývoje kurzu se systém naučí generalizovat. Předpokladem je, že systém bude schopný budoucí hodnoty predikovat na základě podobnosti aktuálních cenových formací (*angl. price patterns*) a formací použitých ukazatelů s dříve viděnými případy z trénovací sady.

4.5.2 Příprava dat - normalizace

Mimo výpočtu ukazatelů technické analýzy, které jsou podrobně definovány v teoretické části, je potřeba samotné historické ceny upravit tak, aby je bylo případně možné prezentovat na vstup systému. Tyto ceny se nejčastěji pohybují v řádech od $1 \cdot 10^2$ do $1 \cdot 10^4$ bodů, pro optimální natrénování NN by však měl být jejich rozsah nejlépe od -1,0 do 1,0. Postupů normalizace dat do daného rozmezí hodnot existuje několik. Důležitější je v tomto případě časový rámec normalizace.

V měřítku celé sady dat jsou odchylky ceny od své průměrné hodnoty příliš velké v poměru k jednomu dni. Proto jsou data normalizována relativně k celé sadě, a to vždy pouze v rámci jednoho obchodního dne. To přináší řadu výhod i nevýhod.

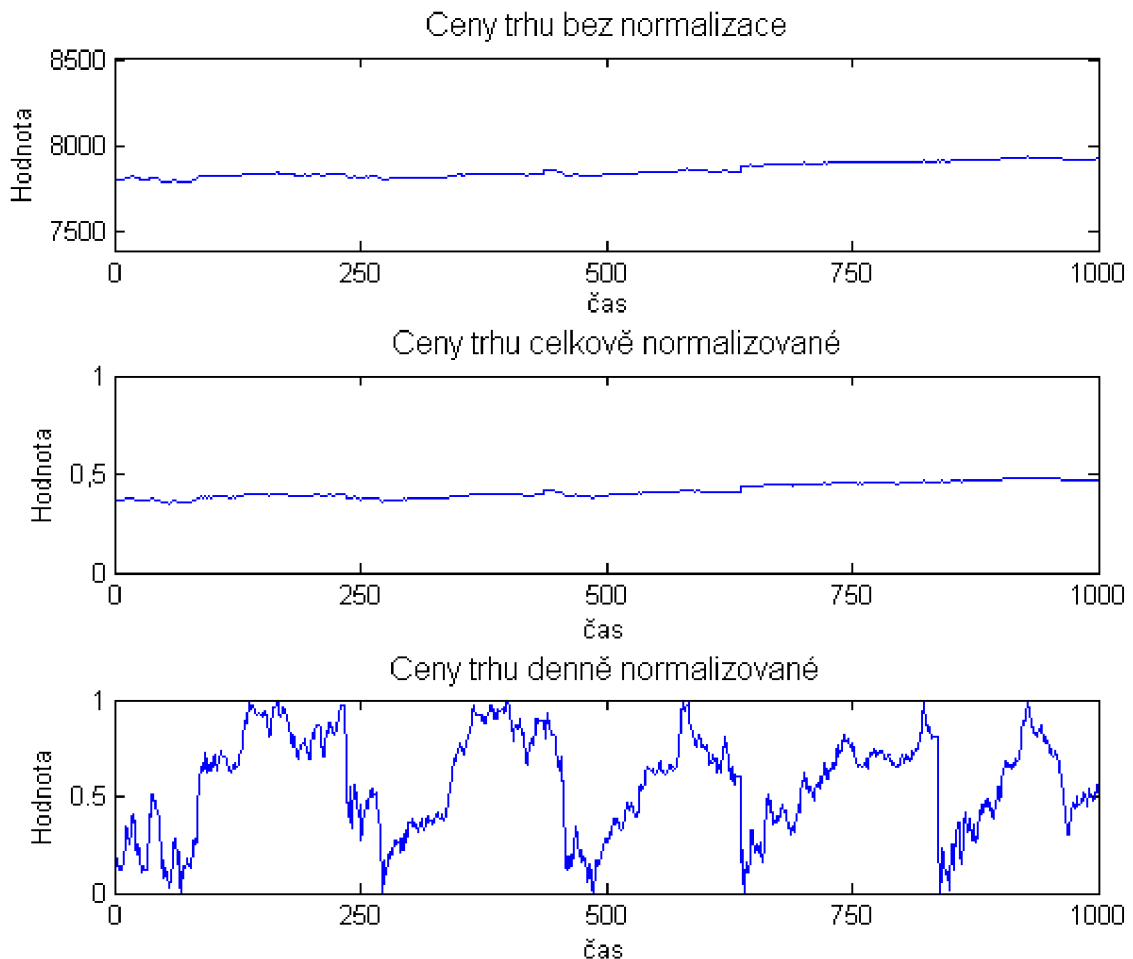
V případě, že by data byla normalizována absolutně na celé sadě, v rámci jednoho obchodního dne by byla variabilita hodnot příliš malá a systém by se pravděpodobně učil rozpoznávat spíše absolutní případy. Z intradenního pohledu na data je denní normalizace výhodnější, protože umožňuje lépe prezentovat i menší krátkodobé pohyby cen, na jejichž základě se intradenně obchoduje. Predikční systém má pak mnohem větší šanci se tyto pohyby naučit predikovat. Na druhou stranu je tímto krokem způsobena ztráta důležité informace o absolutním poměru pohybu ceny v rámci více než jednoho dne. Variabilita normalizovaných hodnot ve dvou různých dnech pak může být velice podobná, přestože se ceny v těchto dvou dnech pohybují v různých rozmezích. Zvolený kompromis použití normalizovaných cen trhů bude nastíněn v následující podkapitole.

Ať se jedná o normalizaci v rámci různých časových období, je vždy použita tzv. „min-max“ normalizace, normalizující dodané hodnoty do rozmezí od 0,0 do 1,0. Tato normalizace je definována následujícím vzorcem:

$$x_n(t) = \frac{x(t) - \min_u^v(x)}{\max_u^v(x) - \min_u^v(x)} \quad (4.3)$$

kde $x(t)$ je hodnota časové řady x v okamžiku t , $x_n(t)$ je její normalizovaná hodnota a $\min_u^v(x)$ resp. $\max_u^v(x)$ jsou minimální resp. maximální hodnoty cenové řady x v časovém rozmezí od u do v . V případě normalizace dále označované jako denní je pak index u prvním okamžikem aktuálního obchodního dne a index v posledním známým okamžikem (viz dále označovaného jako horizont).

Graf 4.1 zobrazuje rozsahy cen části sady před normalizací, po normalizaci v rámci celé sady a po denní normalizaci.



Graf 4.1 – Normalizace dat. Při celkové normalizaci jsou hodnoty v jednotlivých dnech málo variabilní.

Mimo cenové řady jsou pak v modelu použity další normalizované ukazatele. Indikátory technické analýzy RSI a CCI se na celé sadě vždy vyskytují s určitým maximem nezávisle na rozmezí cen. Normalizace indikátoru RSI přes celou sadu je definována vztahem 4.4:

$$RSI_N(t) = \frac{RSI(t)}{abs(max(RSI))} \quad (4.4)$$

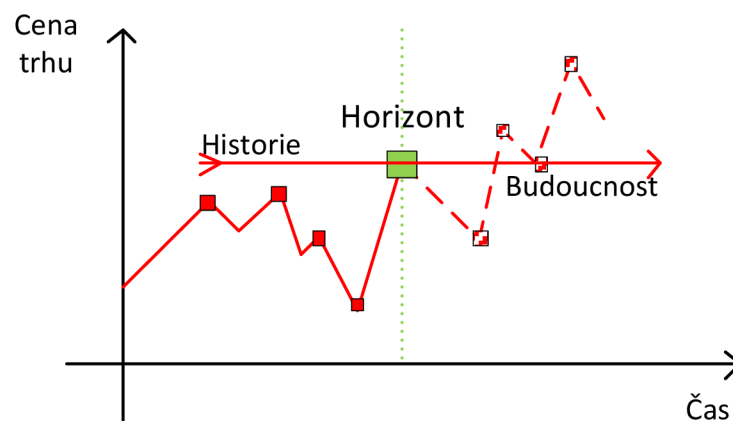
kde $RSI_N(t)$ je normalizovaná hodnota indikátoru RSI v čase t a $abs(max(RSI))$ je maximální absolutní hodnota indikátoru RSI v celém časovém rozsahu sady. Indikátor CCI je normalizován obdobným způsobem.

Další použité indikátory, jako jsou klouzavý průměr (MA), exponenciální klouzavý průměr (EMA) nebo indikátor konvergence a divergence klouzavého průměru (MACD), jsou vytvořeny přímo z denní normalizované ceny, a jsou proto již v požadovaném rozmezí. Důležitou poznámkou je, že stejně jako u denní normalizované ceny, není použití hodnot takových indikátorů dohromady z více než jednoho dne vhodné, protože by si rozsahy použité při normalizaci s velkou pravděpodobností neodpovídaly.

4.5.3 Vstup NN

Vstupní vektory neuronové sítě systému jsou tvořeny kombinací cenových hodnot a vybraných indikátorů technické analýzy.

Výchozí bod, pro který bude systémem prováděna předpověď, bude dále nazýván **horizont**. Horizont je poslední časový okamžik, pro který jsou známy údaje cen a z nich vytvořené indikátory v rámci aktuální předpovědi. Veškeré chronologicky dřívější hodnoty cen od horizontu budou popisovány jako historie a vše od horizontu chronologicky dále bude považováno za budoucnost. Tyto definice ilustruje obrázek 4.1.




Obrázek 4.1 – Horizont je okamžik, který rozděluje čas na historii a budoucnost

Vstupní vektor je tvořen seskládáním různých historických dat za sebou:

- **MACD** – indikátor konvergence a divergence klouzavého průměru (EMA se standardními parametry 12 a 26), normalizován v každém dni zvlášť
- **MA(20)** – klouzavý průměr cen s parametrem 20 hodnot, vzorkovaný po určitých časových skocích. Vektor těchto hodnot je tvořen tak, že často obsahuje hodnoty i z předcházejícího dne. Z tohoto důvodu je normalizován tento vektor jako celek.
- **RSI14** – ukazatel síly trhu, parametr indikátoru 14, standardní normalizace
- **TP** – denně normalizované hodnoty typických cen v nejbližších okamžicích před horizontem

Optimální počet použitých historických hodnot byl stejně tak jako samotná kombinace indikátorů a cen ve vektoru vypořádan experimentálně. Konkrétní údaje, především do jaké historie jednotlivé složky vstupního vektoru sahají, budou uvedeny v části 4.5.5.

Obrázek 4.2 ilustruje, jakým způsobem je vytvořen vstupní vektor z uvedených dat.




Obrázek 4.2 - Tvorba vstupního vektoru. Z cen trhu jsou vytvořeny indikátory technické analýzy v různě dlouhých časových oknech historie (modře a fialově). Vstupní vektor je tvořen kombinací (složením za sebou) takových indikátorů.

4.5.4 Výstup NN

Výstupem NN je predikovaná průměrná hodnota cen trhu ve zvoleném časovém rámci v budoucnosti. Tímto postupem je částečně filtrován šum (swingy), který cenová data přirozeně obsahují. Přestože jsou neuronové sítě schopné dobře se vypořádat se šumem, z pohledu využití systému pro obchodní model není potřeba znát hodnotu ceny v přesně daný budoucí okamžik, ale je mnohem důležitější získat přibližnou predikci směru a síly dalšího vývoje, což může být reprezentováno právě průměrnou hodnotou. Obrázek 4.3 ilustruje výpočet výstupní průměrné hodnoty.

Výstupní hodnota je normalizovaná v rámci aktuálního dne. V případě trénovacích vektorů jsou meze u a v normalizace určeny počátkem dne a posledním okamžikem ve sledovaném období predikce. Toho samozřejmě není možné docílit v případě reálného nasazení systému (při testování), protože rozsah predikovaných hodnot není znám. V takovém případě by reálná průměrná cena

musela být vypočítána dle mezi normalizace vstupních dat (od počátku dne po horizont), ovšem jak bude vysvětleno dále, tato reálná hodnota nebude v navrženém obchodním modelu využita.



Obrázek 4.3 – Výstupní hodnotou je aritmetický průměr hodnot ve sledovaném období.

4.5.5 Parametry a trénování modelu

V předešlých kapitolách bylo uvedeno, jakým způsobem je vytvořen vstupní a výstupní vektor neuronové sítě systému. Z důvodu přehlednosti jsou konkrétní použité parametry uvedeny na jenom místě, v tabulce 4.6.

Optimální hodnoty byly zvoleny průběžným testováním, které probíhalo na malé části trénovací sady. Žádné parametry nejsou přizpůsobeny testovací sadě, takže je zachována objektivnost výsledků.

Predikční systém využívá data s časovým měřítkem (timeframe) 2 minuty. To bylo zvoleno jako nejvhodnější především kvůli množství dostupných dat. S rostoucím měřítkem totiž klesá počet možných trénovacích a testovacích vektorů. Menší timeframe je na druhou stranu příliš podrobný a obtížnější se v něm hledají pohyby trhu vhodné pro intradenní obchodování.

Tabulka 4.6 shrnuje parametry predikčního modelu využité pro všechny definované sady dat. Některé další parametry, zejména parametry obchodního modelu, byly pro každou sadu dat zvoleny individuálně. V takovém případě bude toto nastavení zveřejněno v části s výsledky simulace.

Parametr	Hodnota
Velikost NN	90x20x1 neuronů
Vstupní vektor	Celkem 90 hodnot
Počet hodnot MACD	40 (2 hodiny před horizontem)
Počet hodnot RSI(14)	10 (20 minut před horizontem)
Počet hodnot TP	20 (40 minut před horizontem)
Počet hodnot MA(20)	30 vzorkovaných po 12 minutách (6 hodin)
Výstupní vektor	Celkem 1 hodnota
Počet budoucích hodnot zahrnutých v predikované průměrné ceně	10 (20 minut od horizontu)

Tabulka 4.6 - Parametry základního modelu

Z výše uvedené tabulky vyplývá, že neuronová síť obsahuje neurony ve třech vrstvách. Před počátkem trénování jsou váhy, spojující veškeré neurony vždy sousedních vrstev, inicializovány algoritmem „*Nguyen-Widrow*“. Tímto algoritmem je zvoleno takové počáteční rozložení vah tak, že následné trénování probíhá rychleji a efektivněji, než při zcela náhodném rozložení. Ani v tomto případě však nejsou váhy inicializovány vždy stejně, protože součástí výpočtu dané váhy je i náhodně zvolená konstanta. Váhy skryté vrstvy jsou zvoleny v rozmezí od -1,0 do 1,0 a váhy výstupní vrstvy v intervalu od -0,5 do 0,5. [29]

Aktivační funkcí neuronů ve skryté vrstvě je sigmoidní funkce hyperbolická tangenta, ve výstupní vrstvě je to potom funkce lineární.

Trénovacím algoritmem je „*Conjugate gradient backpropagation with Fletcher-Reeves updates*“. Chyby v jednotlivých vrstvách jsou pro každý trénovací příklad odvozeny zpětnou propagací chyby výstupní vrstvy s ohledem na jednotlivé váhy mezi neurony tak, jak bylo popsáno v kapitole 3. Samotné váhy jsou potom upravovány nejen podle velikosti odvozených chyb, ale také v závislosti na velikosti a směru změn chyb mezi jednotlivými iteracemi trénování. Rychlost učení (učicí faktor) je řízena automaticky podle průběžných validačních výsledků jednotlivých iterací trénování. [30]

Trénovací sady dat jsou rozděleny na trénovací, validační a testovací část v poměru 8:1:1. Trénování probíhá na trénovací části dat, dokud není dosaženo zvoleného maximálního počtu iterací, průběžná změna chyby neklesne pod stanovenou úroveň, nebo dokud se celková chyba validační části trénovací sady zvyšuje během předem daného počtu po sobě jdoucích iterací. V případě této práce je poslední uvedená podmínka nejčastějším podnětem pro zastavení trénování. Testovací část trénovací sady dat je převážně využita pro odladění optimálních parametrů obchodního modelu.

Z trénovacích vektorů jsou vypuštěny ty, které obsahují data ze dvou různých dní právě kvůli odlišné normalizaci. Jedinou výjimkou jsou vzorkované hodnoty MA(20), které jsou normalizovány samostatně. Také jsou vypuštěny vektory, které obsahují vzorky dat, v jejichž čase byla hodnota volume nulová (neprobíhaly žádné obchody).

Jako funkce hodnotící úspěšnost predikce systému je zvolena průměrná kvadratická chyba, tzv. MSE (z angl. *Mean Squarred Error*), které v případě jednoho výstupního neuronu odpovídá následující vzorec.

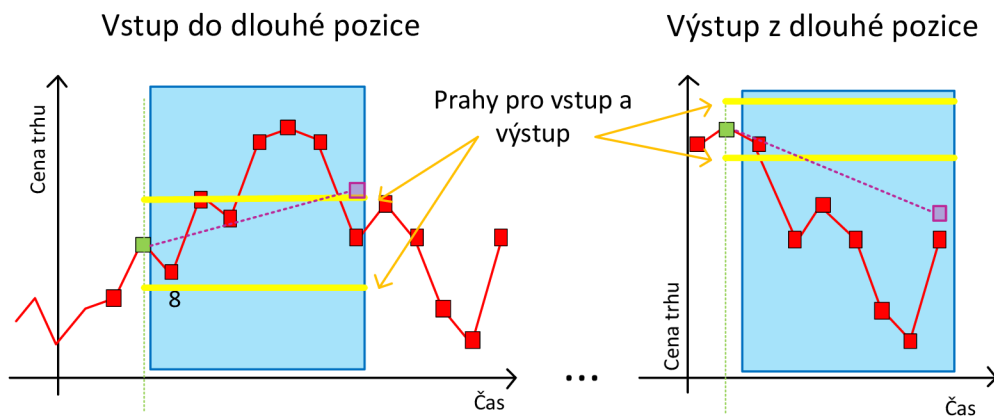
$$MSE = \frac{1}{n} \sum_{i=1}^n (target_i - output_i)^2 \quad (4.5)$$

V rovnici je n je počet trénovacích příkladů, $target_i$ je výstup i . příkladu a $output_i$ je výstup neuronové sítě pro i -tý trénovací příklad. Cílem učení je minimalizace chyby MSE a tím maximalizace úspěšnosti predikce systému.

4.5.6 Využití modelu v obchodním systému

Způsob využití predikce průměrné bodové hodnoty trhu pro obchodní model je podstatnou částí pro celkovou úspěšnost modelu. Jak bylo uvedeno v kapitole 2, obchodní model se skládá ze dvou hlavních částí – určení okamžiku vstupu do trhu a určení okamžiku výstupu z trhu.

Obě části jsou řešeny predikcí neuronové sítě. Ve své podstatě se zde jedná o prahování výstupů neuronové sítě pro daný okamžik. Důležitou roli zde proto hraje vhodná volba prahu, jež je pro vstupy do obchodů jiný (typicky větší) než práh pro určení výstupu. Obchodní model je postaven tak, aby podněcoval spíše méně ziskově výhodnějších vstupů. Větší množství podněcovaných výstupů má způsobit včasný výstup z obchodu z co nejvýhodnější pozice. Prah je sice možné předem určit na základě požadovaných minimálních zisků z jednoho obchodu (obdoba profit-target), ovšem s ohledem na celkovou ziskovost modelu je výhodnější parametry dodatečně odladit na malé testovací části trénovací sady. Výsledkem je, že úspěšnost obchodního modelu není závislá pouze na úspěšnosti neuronové sítě, jež je využita pro predikci. Využití predikce průměrné hodnoty v obchodním modelu zobrazuje obrázek 4.4. Stejně jako v předcházejících ilustracích, i na tomto obrázku je zelenou barvou vyznačen horizont, modrou sledované období v budoucnosti, fialově je průměrná hodnota ceny ve sledovaném období a žlutě jsou navíc zobrazeny prahy pro určení vstupu a výstupu. Oba prahy mají jinou velikost.



Obrázek 4.4 - Využití predikce v obchodním modelu. Pokud predikovaná hodnota překročí zvolený práh (v obrázku žlutě), je to považováno za signál ke vstupu či výstupu z obchodu.

4.5.7 Výsledky simulace

Simulace navrženého obchodního modelu využívajícího neuronové sítě probíhala standardně navrženým způsobem. Výše uvedený princip byl použit pro získání podnětů ke vstupům a výstupům do a z obchodů. Trénování a simulace probíhaly u každé sady pouze jednou. Systém se ukázal jako stabilní při trénování, protože při náhodně inicializovaných vahách neuronové sítě byl počet iterací trénování velice podobný a výsledná validační chyba predikcí byla vždy v nejvyšším řádu stejná.

Následující tabulka zobrazuje získané výsledky simulací obchodování na navržených sadách.

Testovací sada	A	B	C
Počet obchodů celkem	75	45	42
z toho ziskových obchodů	53	28	30
z toho ztrátových obchodů	22	17	12
Konečný stav účtu	\$ 7 827,00	\$ 13 605,00	\$ 12 511,00
Celkový zisk	\$ 10 153,60	\$ 20 446,00	\$ 15 598,50
Celková ztráta	\$ -2 326,60	\$ -6 841,00	\$ -3 087,50
Průměrná bilance z jednoho obchodu	\$ 104,36	\$ 302,33	\$ 297,88
Průměrná absolutní bilance z jednoho obchodu	\$ 166,40	\$ 606,38	\$ 444,90
Drawdown	\$ 313,00	\$ 1 752,00	\$ 496,00
Velikost stop-loss	200	400	400
Chyba NN - MSE	0,0027	0,0042	0,0036
Počet trénovacích vektorů	15 780	10 254	10 705

Tabulka 4.7 - Výsledky základního predikčního modelu

4.6 Upravený predikční model

Hlavní rozdíl upraveného predikčního modelu od základního predikčního modelu spočívá především v koncepci využití neuronové sítě. V základním modelu byla využita jako nelineární regresní model, v upraveném modelu bude neuronová síť využita jako klasifikátor.

Vstupní vektory obsahují naprosto stejná data jako v případě základního modelu. Hodnoty jsou normalizovány i sestaveny ve výsledný vstupní vektor naprosto stejným způsobem. Rozdílem oproti základnímu modelu je formát požadovaného výstupu neuronové sítě, což souvisí s upravenou koncepcí využití NN, a dále také ve využití klasifikace v obchodním modelu.

V následujících podkapitolách budou popsány pouze odlišnosti od základního modelu. V závěru budou zveřejněny výsledky upraveného modelu.

4.6.1 Výstup NN


Výstupem neuronové sítě je třída, do které spadá situace v trhu v následujících okamžicích. Tyto třídy jsou celkem 3 a svými názvy jsou přímo spojeny s obchodním modelem, který tuto předpověď využívá. Každý okamžik (horizont) je systémem klasifikován do jedné z následujících tříd:

- Třída „BUY“ – indikuje, že aktuální okamžik je vhodný pro nákup kontraktu
- Třída „SELL“ – indikuje, že aktuální okamžik je vhodný pro prodej kontraktu
- Třída „HOLD“ – indikuje, že aktuální okamžik není vhodný pro žádnou akci

Třída tedy nepřímou určuje, jakým směrem se kurz trhu v budoucnosti vydá. Bohužel i v tomto modelu je potřeba určité prahování. Bez něj totiž není možné určit, do jaké třídy daný vývoj spadá.

Prahování je aplikováno už při tvorbě trénovacích dat a je jím možné určit minimální požadovanou hodnotu zisku. Výhodou je, že výstupem natrénované sítě je přímo podnět pro obchodní systém a není nutné dodatečně ladit další parametry.

Volba třídy výstupu u trénovacích vektorů je dána maximálním možným ziskem v určitém budoucím časovém rámci, který je dále prahován. Výpočet maximálního zisku v budoucím časovém rámci 7 vzorků ilustruje obrázek 4.5. Žlutou barvou je vyobrazen zvolený práh.



Obrázek 4.5 - Volba třídy pro aktuální okamžik. Pokud maximální hodnota v budoucím sledovaném období překročí zvolený práh (žlutě) směrem nahoru, je zvolena třída BUY.

Z hodnoty maximálního možného zisku je určena třída následujícím způsobem:

$$třída_i = \begin{cases} \text{BUY, když } zisk_i(\text{kratka pozice}) > \text{minimalni zisk} \\ \text{SELL, když } zisk_i(\text{dlouha pozice}) > \text{minimalni zisk} \\ \text{HOLD, když } zisk_i(\text{dlouha pozice} \mid \text{kratka pozice}) < \text{minimalni zisk} \end{cases} \quad (3.1)$$

Index i značí časový okamžik, *minimalni zisk* je požadovaný minimální zisk pro vstup do pozice. Výpočet maximálního zisku je podmíněn typem pozice, ze které je možné zisk získat.

Při tvorbě trénovacích vektorů je výstupní třída reprezentována hodnotou 1,0, ostatní hodnotou 0,0. Například výstupní vektor (BUY; SELL; HOLD) má pro třídu BUY následující podobu (1,0; 0,0; 0,0). Výstupní třídou neuronové sítě je zvolena ta třída, jejíž výstupní hodnota má nejbližší k číslu 1,0.

Hodnotící funkce MSE má v případě tohoto modelu následující vzorec:

$$MSE = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^k (target_{i,j} - output_{i,j})^2 \quad (3.1)$$

V rovnici je proměnná n počet trénovacích příkladů, k reprezentuje počet tříd klasifikace, $target_{i,j}$ je j -tý výstup i -tého příkladu a $output_{i,j}$ je j -tý výstup neuronové sítě pro i -tý trénovací příklad.

4.6.2 Využití modelu v obchodním systému

Klasifikace aktuálního okamžiku je přímo využita jako podnět pro vstup do obchodní pozice, jak bylo uvedeno výše. Podnět k výstupu z pozice, pokud je otevřena, je řízen další neuronovou sítí. Tato další síť je trénovaná stejným způsobem jako neuronová síť pro predikci vstupů. Na rozdíl od vstupních vektorů, které jsou totožné, jsou ale výstupní klasifikace do tříd tvořeny prahováním s jinou hodnotou, typicky nižší. Systém tak méně často podněcuje vstup do obchodů, což slibuje větší zisky, ale na druhou stranu dříve podněcuje výstupy z pozic, pokud obchod začne i málo ztrácet svoji hodnotu. Schéma klasifikace a typy tříd obou klasifikátorů jsou totožné, rozdíl je pouze v hodnotě *minimalní zisk* (viz rovnice 3.1).

Kompletní příklad využití obou klasifikátorů pro zjištění obchodní příležitosti může být následující:

- 1) V čase t predikuje první NN (vstupní příležitosti) vhodnost vstupu na dlouhou stranu (třída BUY). Je proveden vstup do dlouhé pozice (obchodní příkaz BUY).
- 2) V čase $t + 10$ predikuje druhá NN (výstupní příležitosti) vhodnost vstupu na krátkou stranu (třída SELL). Protože je již otevřena opačná pozice, je tato klasifikace interpretována jako příkaz výstupu (obchodní příkaz SELL).

4.6.3 Výsledky simulace

Simulace obchodního modelu využívajícího upravený predikční systém probíhá opět standardně definovaným způsobem. I v tomto případě je trénování obou neuronových sítí stabilní, protože při náhodné inicializaci vah skončí trénování vždy s téměř stejnou chybou. Kombinace dvou neuronových sítí v obchodním modelu už je potom stabilní o něco méně, což je způsobeno právě tím, že obě neuronové sítě se trénují nezávisle na sobě. Celkový výsledek dvou různých simulací i s trénováním na stejné sadě ale zůstává řádově stejný. Tabulky č. 4.8 a č. 4.9 shrnují výsledky a parametry upraveného systému na definovaných testovacích sadách.

Testovací sada	A	B	C
Počet obchodů celkem	248	63	50
z toho ziskových obchodů	145	42	30
z toho ztrátových obchodů	103	21	20
Konečný stav účtu	\$ 10 637,00	\$ 18 283,00	\$ 21 074,00
Celkový zisk	\$ 16 017,40	\$ 24 631,00	\$ 27 632,00
Celková ztráta	\$ -5 380,40	\$ -6 348,00	\$ -6 558,00
Průměrná bilance z jednoho obchodu	\$ 42,89	\$ 290,21	\$ 421,48
Průměrná absolutní bilance z jednoho obchodu	\$ 86,28	\$ 491,73	\$ 683,80
Drawdown	\$ 814,00	\$ 1 003,00	\$ 1 182,00
Velikost stop-loss	\$ 200,00	\$ 400,00	\$ 400,00

Tabulka 4.8 - Výsledky upraveného modelu

Testovací sada	A	B	C
Chyba NN (vstupní příležitosti) - MSE	0,1459	0,1519	0,1569
Chyba NN (výstupní příležitosti) - MSE	0,1158	0,1278	0,1330
Počet trénovacích vektorů	19 308	12 554	13 004

Tabulka 4.9 – Další hodnoty neuronových sítí upraveného modelu

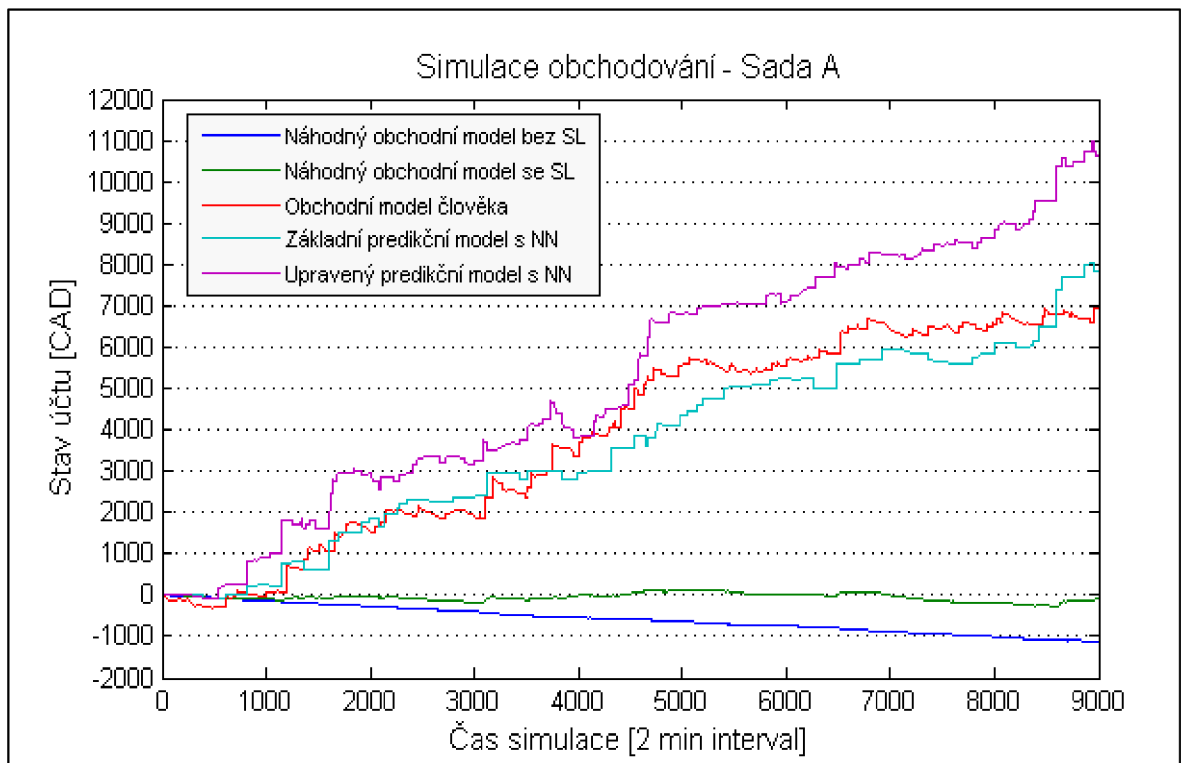
4.7 Porovnání výsledků

Na počátku praktické části této práce byl definován způsob hodnocení predikčního systému simulací obchodování. Bylo také uvedeno, že primárně budou navržené obchodní modely porovnány podle stavu účtu po skončení simulace na definovaných sadách. Následující grafy zobrazují průběžné stavy účtu navržených modelů v závislosti na čase (průběhu simulace). Časové měřítko simulace i následujících grafů je interval 2 minuty, podle zvoleného timeframe zdrojových dat. Účet je veden v měně trhu.

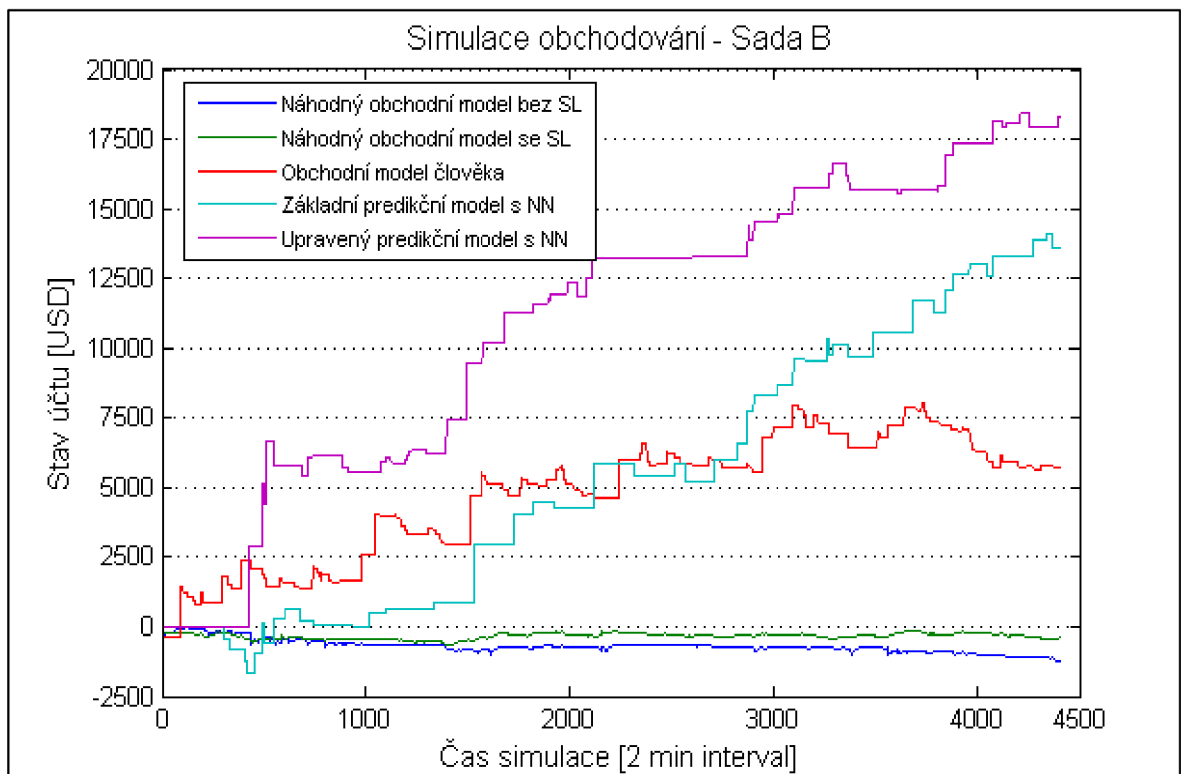
Graf č. 4.2 zobrazuje průběh obchodování sady A. Z výsledků je patrné, že náhodný predikční model bez použití techniky stop-loss je v průměrném případě ztrátový. Oproti tomu, technika stop-loss umožnila udržet výši účtu na téměř stejné úrovni po celou dobu obchodování. Výsledky těchto dvou modelů jsou ovlivněny především velikostí poplatku za obchod a celkovým počtem obchodů. Základní predikční model dosahuje na sadě A podobných výsledků jako obchodní model člověka, jejich rozdíl často spočívá pouze v několika málo ziskových či ztrátových obchodech. Průběžný stav účtu upraveného predikčního modelu má podobný tvar, jako je tomu u obchodního modelu člověka, z čehož lze usoudit, že jsou využity podobné obchodní příležitosti. V některých případech je ale tento model schopný objevit příležitosti více, nebo z nich více vytěžit, a tím překonat lidský model. Trh A je relativně málo dravým trhem, a proto je navyšování stavu účtu téměř plynulé, protože ho lze lépe predikovat.

Graf č. 4.3 zobrazuje průběh obchodování sady B. Tato sada reprezentuje dravější trh, než v případě sady A, a také dražší trh, což dokazují výše zisků u modelů využívajících neuronové sítě. Náhodný obchodní model vykazuje podobné výsledky jako na sadě A. Obchodní model člověka je zpočátku simulace ziskový i přes četné ztráty, které ale na konci simulace způsobí to, že systém postupně ztrácí to, co vydělává. Navržený obchodní model člověka je pro tento trh nevhodný. Na druhou stranu modely využívající neuronové sítě se v tomto trhu jeví jako úspěšné. Upravený model opět již od počátku simulace překonává model základní.

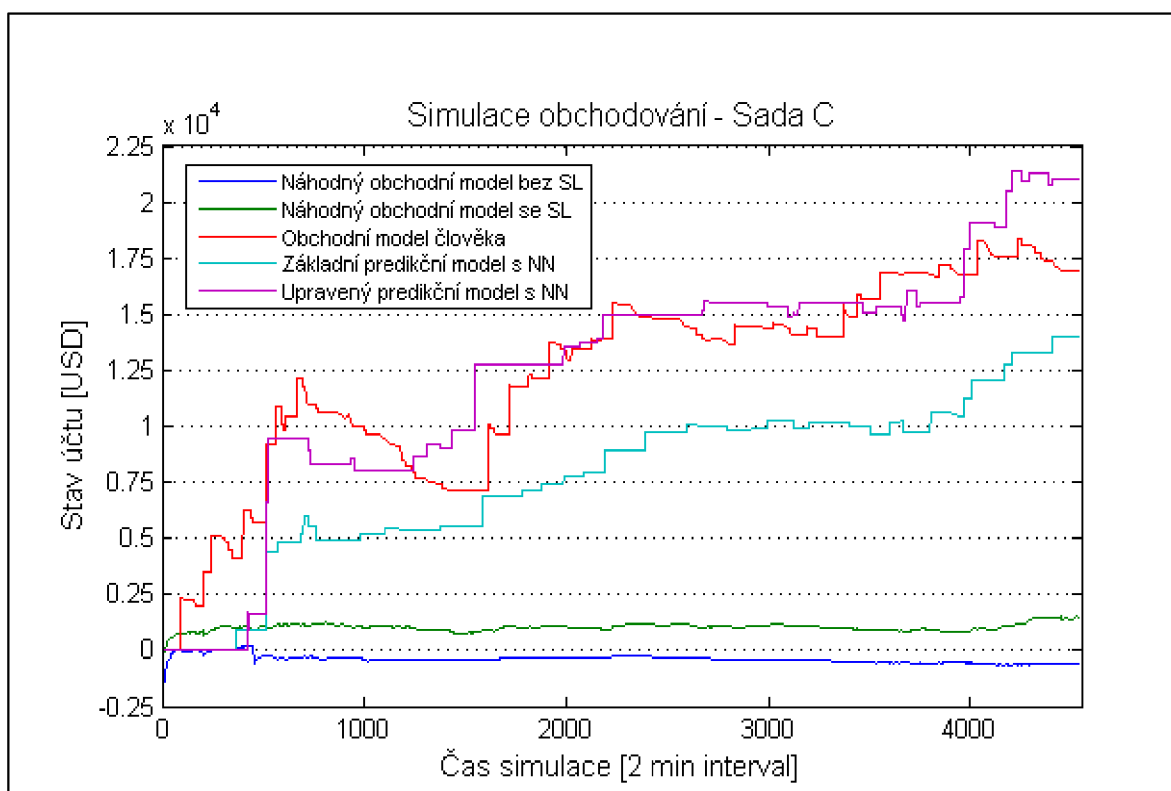
Obchodování asi nejdravějšího trhu použitého v sadě C zobrazuje graf č. 4.4. V tomto trhu je úspěšný navržený lidský model, který i přes dlouhé období ztrát vykazuje velice podobné výsledky jako upravený predikční model. Základní model sice v tomto trhu nevykazuje tak velké zisky v porovnání s ostatními modely, na druhou stranu jsou ale provedené obchody častěji úspěšné, a tím pádem roste křivka zisků plynuleji.



Graf 4.2 - Simulace obchodování sady A



Graf 4.3 - Simulace obchodování sady B



Graf 4.4 - Simulace obchodování sady C

Z uvedených výsledků vyplývá, že nejúspěšnějším modelem při simulacích obchodování byl upravený model využívající neuronové sítě. Základní model je srovnatelný s navrženým lidským obchodním modelem. Výsledky jsou ale v porovnáních nepřímo úměrné charakteru trhu, který podstatně ovlivňuje úspěšnost daného modelu.

Mimo srovnání celkových zisků je pro celkové zhodnocení modelů vhodné porovnat některé další výsledky simulace. Tabulka č. 4.10 obsahuje poměry ztrát k celkovým ziskům z obchodů na jednotlivých sadách i na všech sadách dohromady. Tímto je dokázáno, že navržené modely využívající neuronové sítě obchodují stabilněji, protože ztráty odpovídají zhruba čtvrtině zisků. Oproti tomu ztráty lidského obchodního modelu odpovídají více jak polovině všech zisků. Náhodný model bez SL je v průměru ztrátový, naproti tomu při použití SL se ztráty ziskům téměř rovnají.

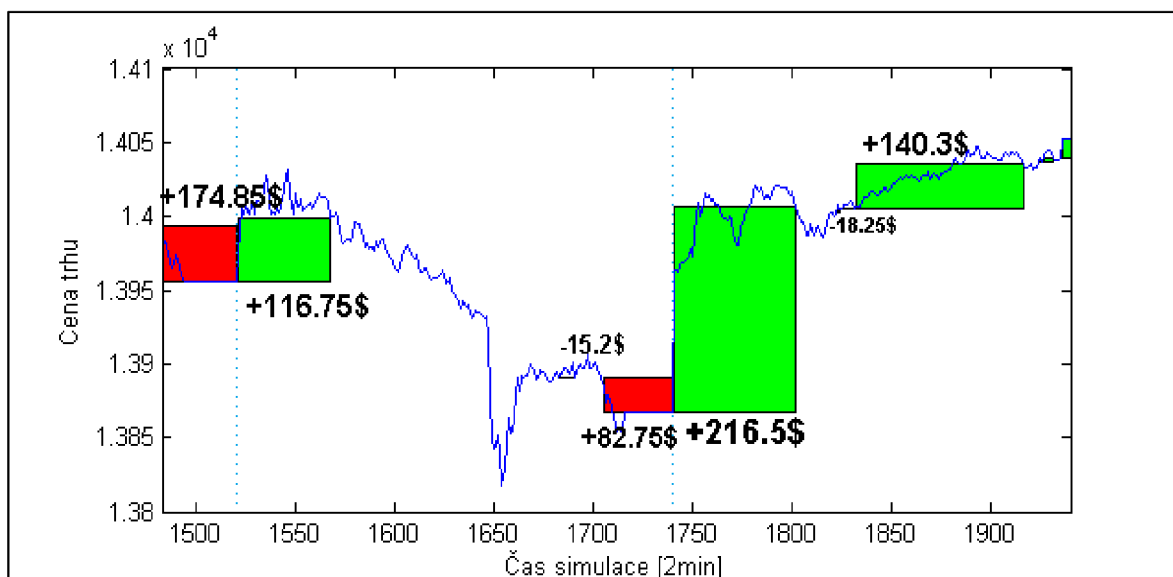
Model/Sada	A	B	C	Celkem
Obchodní model člověka	0,53	0,73	0,46	0,57
Základní model	0,23	0,33	0,18	0,25
Upravený model	0,34	0,26	0,24	0,28
Náhodný model bez SL	1,14	1,06	1,02	1,07
Náhodný model se SL	1,01	1,03	0,92	0,99

Tabulka 4.10 - Poměr ztrát a zisků

Tabulka č. 4.11 obsahuje poměr drawdown k celkovým ziskům. Tato hodnota ukazuje, jak moc je daný obchodní model riskantní z pohledu série po sobě jdoucích ztrát. Uvedení náhodných obchodních modelů nemá žádný další význam, proto jsou tyto modely dále vynechány.

Ze všech uvedených výsledků vyplývá, že nejlepšími výsledky dosahuje upravený predikční model využívající dvě neuronové sítě jako klasifikátory. Základní predikční model potom dosahuje celkově nižších zisků za cenu méně riskantního obchodování. Obchodní model člověka v ojedinělých případech dosahuje největších zisků, ovšem za cenu velkých ztrát a riskantnosti obchodování.

Grafy 4.5, 4.6 a 4.7 ukazují průběhy obchodování jednotlivých modelů na vybrané testovací části sady A. Je zobrazen graf vývoje cen trhu v závislosti na čase, v němž jsou znázorněny jednotlivé obchody uskutečněné při simulaci. Každý obchod je reprezentován obdélníkem, jehož počátek je umístěn v čase vstupu do obchodu a aktuální ceně trhu, konec potom označuje stejným způsobem výstup z obchodu. Zeleně jsou zobrazeny obchody na dlouhou stranu, červeně jsou zobrazeny obchody na krátkou stranu. U jednotlivých obchodů je zobrazen odpovídající zisk (kladné hodnoty) či ztráta (záporné hodnoty). Jednotlivé obchodní dny jsou odděleny svislou přerušovanou čarou.



Graf 4.5 – Ukázka obchodů modelu člověka v průběhu dvou dnů. Červeně jsou zobrazeny obchody na krátkou stranu, zeleně na dlouhou stranu. U každého obchodu je zobrazen odpovídající zisk či ztráta.

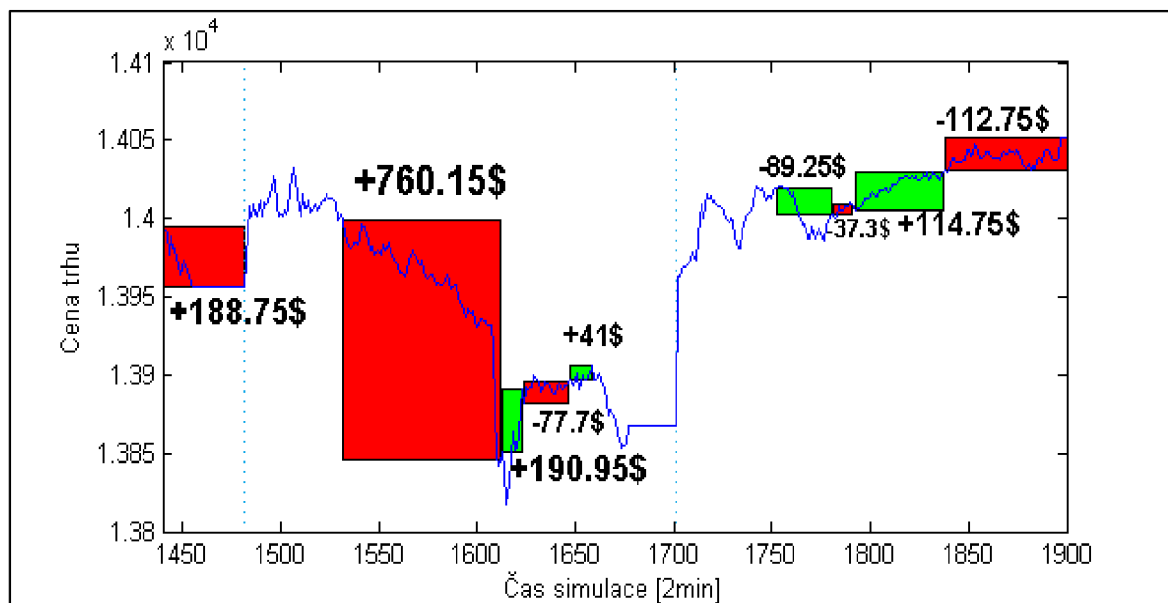
Model/Sada	A	B	C	Celkem
Obchodní model člověka	0,0252	0,0570	0,1427	0,0749
Základní model	0,0308	0,0857	0,0675	0,0614
Upravený model	0,0508	0,0407	0,0428	0,0448

Tabulka 4.11 - Poměr drawdown a zisků

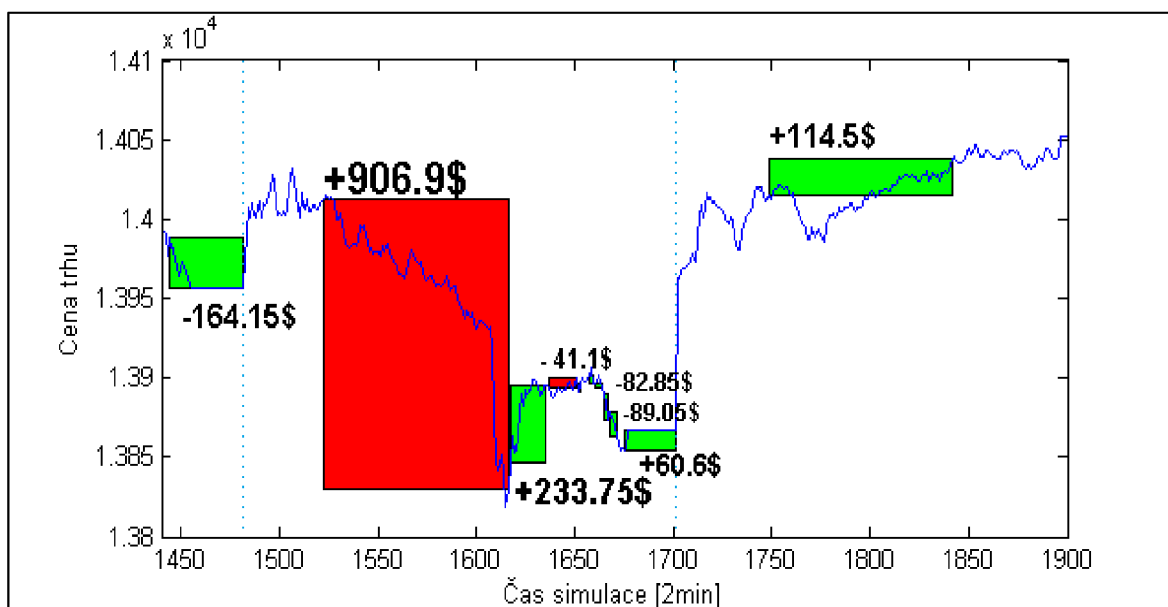
Tabulka 4.12 obsahuje průměrné absolutní bilance z obchodů, tedy to, jak velký je průměrný obchod ať už se jedná o obchod ziskový či ztrátový.

Model/Sada	A	B	C	Celkem
Obchodní model člověka	\$ 45,49	\$ 220,03	\$ 300,01	\$ 188,51
Základní model	\$ 166,40	\$ 606,38	\$ 515,53	\$ 429,44
Upravený model	\$ 86,28	\$ 491,73	\$ 683,80	\$ 420,60

Tabulka 4.12 - Průměrné absolutní bilance obchodů



Graf 4.6 - Ukázka obchodů základního predikčního modelu v průběhu dvou dní.



Graf 4.7 - Ukázka obchodů upraveného predikčního modelu v průběhu dvou dní.

4.8 Varianty modelů a další pozorování

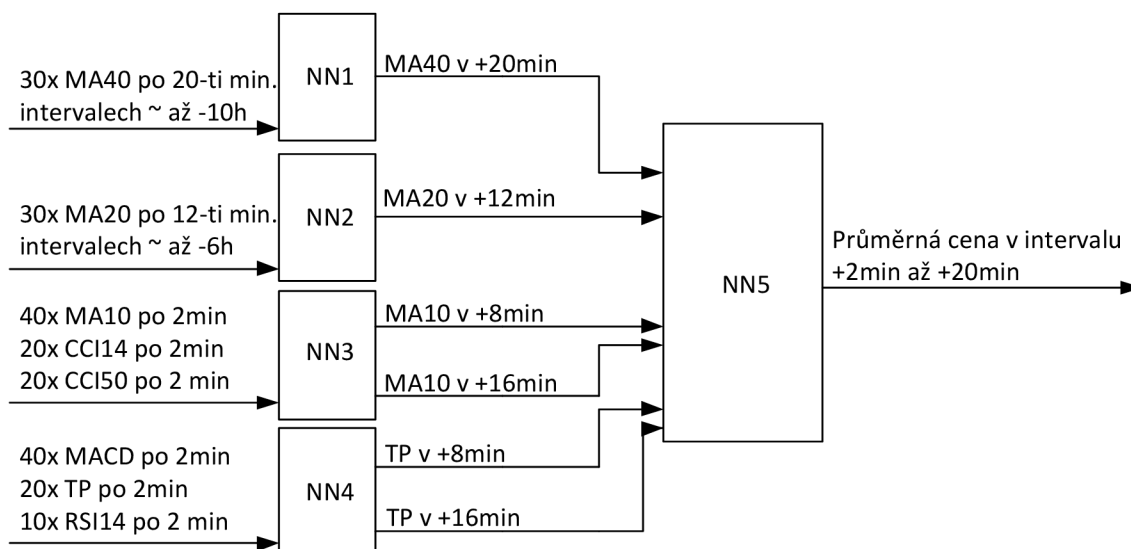
Doposud uvedené modely základního a upraveného systému jsou těmi nejlepšími, které se podařilo vytvořit a natrénovat. Při jejich získávání bylo vyzkoušeno několik dalších variant a nastavení. Rád bych v této části alespoň popsal některé z nich. Opakuji, že svými výsledky nedosahovaly takové kvality, jako dříve uvedené modely, a z tohoto důvodu nejsou konkrétní výsledky ani detailně uvedeny a porovnány jinak, než slovně.

Indikátory technické analýzy, cenové údaje apod. je možné na vstupu do systému zkombinovat mnoha způsoby, některé z nich vynechat nebo upravit délku jejich historie. Vyzkoušeno bylo několik variant. Mimo samotné cenové údaje byly do systému vkládány následující indikátory: klouzavý průměr s parametrem 5, 10, 20, 40, 50 a 100, vytvořený ze zavíracích cen (CLOSE) i z typických cen (TP), exponenciální klouzavý průměr s parametry 12, 34, 26, 204, CCI s parametry 14, 20 a 50, RSI s parametrem 14 nebo indikátor konvergence a divergence klouzavého průměru. Indikátorů existuje i mnoho dalších, tyto byly zvoleny na základě skutečnosti, že se často využívají v některých vybraných obchodních modelech člověka. Délka jejich historie, tedy počet použitých hodnot byl potom zvolen opět na základě zkušeností uváděných v literatuře[4] nebo na základě testů systému. Výběrem parametrů vstupních dat modelu se zabývá následující kapitola o dalších směrech vývoje.

Výstupem základního predikčního systému byla původně normalizovaná cena trhu v pevně daný okamžik. To se ukázalo jako nevýhodné kvůli šumu, který obsahuje cenová řada. V jeden pevně daný okamžik se totiž může například zdát, že trh se vyvíjí určitým směrem, přestože při porovnání sousedních hodnot může být jasně vidět, že trh se dlouhodobě vyvíjí pouze do strany (ani směrem nahoru ani dolů) nebo dokonce směrem opačným. Je možné predikovat více pevně daných časových okamžiků najednou, po sobě jdoucí predikce filtrovat např. klouzavým průměrem nebo filtrovat rovnou hodnoty pro trénování. Ani jedna z variant nebyla úspěšnější než dříve navržené, ovšem to může být zkresleno také způsobem, jakým tyto predikce využíval nadřazený obchodní model.

Velikost sítě, především skryté vrstvy sítě a parametry trénování byly zvoleny na základě praktických testů. Při větších rozměrech sítě dosahovala chyba trénování větších hodnot pravděpodobně z důvodu malého počtu trénovacích vektorů. Zvýšení počtu trénovacích vektorů bylo docíleno kombinací dat z několika různých trhů v jedné sadě. I přes korektní normalizaci takových dat se u upraveného modelu taková sada stala nepoužitelnou, protože data zde jsou vytvářena s ohledem na reálnou cenu obchodu, která je u každého trhu jiná. Základní predikční model nevykazoval na takové sadě zlepšené výsledky pravděpodobně proto, že pohyby kurzu se v každém trhu chovají specifickým způsobem (viz např. volatilita).

Variantou základního predikčního modelu je systém, využívající predikcí několika různě natrénovaných neuronových sítí, jejichž výstupy jsou spojeny další sítí, která je natrénovaná podle těchto vstupů predikovat průměrnou hodnotu ceny v pevně daném budoucím časovém rámci. Tento systém ilustruje obrázek 4.6.



Obrázek 4.6 - Varianta základního systému. Předpovědi čtyř různě trénovaných neuronových sítí jsou zpracovány výstupní neuronovou sítí.

Vstupy sítí v první linii jsou voleny především tak, aby každý obsahoval data různě vzorkovaná z různě dlouhých časových oken historie dat. Výstupy sítí první v linii systému jsou predikce normalizovaných hodnot cen filtrovaných klouzavým průměrem nebo i cen nefiltrovaných (TP) v různých časových okamžicích v budoucnosti. Bylo vyzkoušeno několik variant různých kombinací vstupů a výstupů. Chybu predikce systému z obrázku 4.6 porovnává na testovacích datech se základním predikčním modelem, který predikuje také průměrnou hodnotu ceny ve stejném intervalu, tabulka 4.13.

	MSE NN1	MSE NN2	MSE NN3	MSE NN4	MSE NN5	MSE základního modelu
Sada A	0,0218	0,0386	0,0013	0,0027	0,0129	0,0027
Sada B	0,0210	0,0363	0,0017	0,0044	0,0197	0,0042
Sada C	0,0208	0,0376	0,0016	0,0033	0,0179	0,0036

Tabulka 4.13 - Srovnání chyb jednotlivých neuronových sítí

Z výsledků je patrné, že i přes větší složitost nyní popsaného systému a více kombinací různých vstupních dat, je celková chyba predikce horší než u základního modelu, čemuž odpovídají i výsledky simulace obchodování. Mohlo by se z výsledků dílčích NN3 a NN4 zdát, že NN3 a NN4 jsou úspěšnější než samotná predikce základního modelu. Je to dáno rozdílným výstupem, který je v porovnání se základním modelem méně využitelný v obchodním systému, a tedy z pohledu cíle této práce úspěšnější nejsou. Dále zde lze pozorovat dvě důležité skutečnosti, ze kterých plyne dříve několikrát zmiňovaná stabilita trénování. První je podobnost chyby NN4 a základního modelu, které mají stejné vstupní vektory. Druhou jsou poměry chyb obou predikčních systémů mezi jednotlivými sadami.

4.9 Směry dalšího vývoje

Přestože jsou navržené systémy funkční a většinou i úspěšnější než vybraný obchodní model člověka, stále zůstávají některé významné obchodní příležitosti buď nevyužity vůbec, nebo je jejich potenciál využit jen z části. Systémy také predikují značné množství chybných signálů, což bylo ve výsledcích dokázáno poměrem ztrát a zisků z obchodů. Při zachování stávající základní koncepce obou modelů jsou navržena následující vylepšení a směry dalšího vývoje.

Podstatným problémem, který zatím není zcela vyřešen, je nevhodnější volba a kombinace vstupních dat a další nastavení systému. Pro zopakování se jedná např. o velikosti jednotlivých vrstev NN, nastavení proměnných, prahů či stop-lossů nadřazeného obchodního systému, o velikost použité historie u daného indikátoru nebo samotné cenové řady. Bylo vyzpozorováno, že i malá změna některých parametrů modelu má za následek podstatný rozdíl v celkových výsledcích. Ve výše uvedené práci byly veškeré parametry, výběr dat a jejich podob převážně vyzpozorovány experimentálně nebo na základě zmínek v literatuře. Tímto postupem nebylo zdaleka možno vyzkoušet všechny možné kombinace a pravděpodobně nebylo nalezeno zcela nejefektivnější řešení nastavení systému.

Do systému by mohlo být zahrnuto více známých indikátorů technické analýzy, tím se ale zvýší už tak vysoký počet možných kombinací vstupních dat. Efektivní řešení nabízejí genetické algoritmy (dále jen GA), pomocí kterých by mohly být pomocí simulace přirozeného vývoje zvoleny taková data, jež by systému poskytovala nevhodnější informace pro přesnější určení předpovědi. Takové řešení by mohlo mít podobu vektoru přirozených čísel, kde každý jeho prvek by reprezentoval daný typ dat (cena, upravená cena, nebo indikátor TA) a hodnota tohoto prvku by byla délkou historie takových dat použitých pro vstup systému. Tento vektor se v terminologii GA nazývá chromozóm. Nelezení nevhodnějšího chromozómu spočívá v následujícím algoritmu. Nejprve je vytvořena počáteční populace (množina) různých chromozómů. Po natrénování systémů popsanych populací počátečních chromozómů je provedeno ohodnocení obchodováním testovací sady dat a na základě výsledků jednotlivých systémů je vytvořena nová generace chromozómů selekcí úspěšných jedinců, jež jsou kříženi a/nebo mutováni. Tento postup je opakován, dokud není splněna zastavující podmínka, která může mít podobu maximálního počtu vytvořených populací nebo např. zadané úspěšnosti obchodního systému. Výhodou využití GA algoritmů pro nalezení optimální podoby vstupních dat systému je to, že GA většinou neuváznou v lokálním maximu, a že vždy najdou nějaké řešení. Nevýhodou je v tomto případě velká výpočetní náročnost, která plyne z nutnosti trénování mnoha neuronových sítí.[31]

Další navržený postup spočívá v úpravě trénování NN. Ta by měla být trénována s ohledem na maximalizaci zisku z případného obchodu. Jak bylo uvedeno dříve, zisk závisí nejen na době vstupu do obchodu ale i na době výstupu z obchodu. Tato skutečnost byla do jisté míry implementována v upraveném predikčním modelu tím, že výstupní vektor vznikl prahováním z maximálního možného zisku v daném budoucím období. Problém ale pořád zůstává ve výstupu z obchodu, který byl trénován nezávisle na predikci vstupu. Trénování systému by mělo fungovat jako celek pro predikci vstupů i výstupů. Hodnotící funkce výsledků NN se nyní orientuje na co největší přiblížení

výstupů NN k trénovací sadě. Z pohledu obchodního modelu by takové hodnocení mělo být nahrazeno za hodnocení konkrétních zisků a ztrát z případného vstupu či výstupu z obchodu v dané chvíli.

Další práce na systému by se tedy měla zabývat volbou vstupních dat a návrhem vhodnějšího způsobu trénování neuronové sítě systému.

5 Závěr

Cílem této práce bylo vytvořit predikční systém využívající neuronové sítě, jež by bylo možné použít pro obchodní strategii. Součástí této práce bylo i navržení takovéto obchodní strategie, protože bylo nutné výsledky porovnat se zvoleným, lidmi využívaným, obchodním modelem.

Bylo dokázáno, že neuronové sítě jsou do určité míry schopny naučit se predikovat vývoj kurzu ceny, který už ze své podstaty obsahuje velké množství šumu, nehledě na to, že mezi některými lidmi pořád existuje názor, že vývoj cenového signálu je zcela náhodný, a tedy není ho možno nijak predikovat. Důkazem, že vývoj kurzu není náhodný, se již zabývalo mnoho odborníků, ovšem cílem této práce to nebylo.

Ze statistického hlediska se podařilo dosáhnout uspokojivých výsledků, ve všech případech především ziskových. Při hlubším zkoumání jednotlivých využitých i nevyužitých obchodních příležitostí je ovšem zcela jasně vidět, že trhy v sobě skrývají potenciál mnohonásobně větší, a že navržené obchodní modely jich využívají jen zlomek. Z toho přímo plyne i úspěšnost samotných predikčních systémů, která z tohoto pohledu není velká. Zde přichází v úvahu právě zmíněná náhodnost trhu, která do jisté míry existuje, ale není zcela jasná, jak velká tato míra je, a zda je to opravdu náhoda, která není předpověditelná. Nebo jde jen o ještě komplexnější systém, který predikovat lze, ale o to složitější metodou, což je dle mého názoru pravděpodobnější. Otázkou tedy zůstává, zda opravdu jsou či nejsou neuronové sítě a navržené modely pro predikci cenového signálu vhodné. Jistě je to dáno účelem takového systému, který byl v případě této práce čistě obchodní.

Výsledky náhodných modelů tvoří spodní hranici úspěšnosti v dané oblasti aplikace. Čím více by se jim výsledky navržených modelů přibližovaly, tím spíše by se dalo říci, že jsou navržené modely nefunkční. Horní hranice úspěšnosti byla určena zvoleným lidským obchodním přístupem. Jelikož se podařilo tento přístup překonat, dá se navržený systém považovat z obchodního hlediska (účelu) za úspěšný.

Jak bylo uvedeno v kapitole 4.9, další vývoj projektu by se měl zabývat volbou optimální kombinace vstupních dat a také vhodnějším způsobem trénování neuronové sítě systému.

Literatura

- [1] *Finančník.cz* [online]. 2004, č. 2 [cit 29. 12. 2010]. Co jsou to komodity a jak to funguje – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-jak-to-funguje.html>>
- [2] TOMČIAK, B. *Investiční Web*. [online]. 17. 5. 2010, č. 3 [cit 8. 1. 2011]. Futures kontrakty. Úvod do obchodování s komoditami. Dostupný na WWW: <<http://www.investicniweb.cz/fx-komodity/komodity/2010/5/17/clanky/uvod-do-obchodovani-s-komoditami-3-dil-futures-kontrakty/>>
- [3] *Finančník.cz* [online]. 22. 1. 2009 [cit 8. 1. 2011]. *Futures kontrakt*. Dostupný na WWW: <http://www.financnik.cz/wiki/futures_kontrakt>
- [4] PODHAJSKÝ, P., NESNÍDAL, T.: *Kompletní průvodce úspěšného finančníka*. 1. Praha: Centrum finančního vzdělávání, s.r.o., 2009, 338 s. ISBN 978-80-903874-5-4.
- [5] TOMČIAK, B. *Investiční Web*. [online]. 24. 5. 2010, č. 5 [cit 8. 1. 2011]. Sázka na vzestup a pokles. Úvod do obchodování s komoditami. Dostupný na WWW: <<http://www.investicniweb.cz/fx-komodity/komodity/2010/5/24/clanky/uvod-do-obchodovani-s-komoditami-5-dil-sazka-na-vzestup-na-pokles/>>
- [6] *Finančník.cz* [online]. 2004, č. 6 [cit 29. 12. 2010]. Typy spekulantů – kdo a jak obchoduje – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-spekulanti.html>>
- [7] *Finančník.cz* [online]. 2004, č. 8 [cit 30. 12. 2010]. První krok k výdělkům: technické studium grafů – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-grafy.html>>
- [8] *Finančník.cz* [online]. 28. 6. 2007 [cit 8. 1. 2011]. Alternativní timeframe: volume a tickový graf – Finančník.cz. Dostupný na WWW: <<http://www.financnik.cz/komodity/zkusenosti/volume-graf.html>>
- [9] *Finančník.cz* [online]. 2004, č. 23 [cit 30. 12. 2010]. Více o čtení grafů – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-grafy-zdarma.html>>
- [10] *Finančník.cz* [online]. 2004, č. 10 [cit 8. 1. 2011]. Býci vs. medvědi – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-byci-medvedi.html>>
- [11] *Finančník.cz* [online]. 2004, č. 12 [cit 30. 12. 2010]. Support a resistance – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-support-resistance.html>>
- [12] *Finančník.cz* [online]. 2004, č. 13 [cit 29. 12. 2010]. Dvojitý vrchol/dvojité dno – Finančník.cz. Komodity – manuál zdarma. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-dvojity-vrchol.html>>

- [13] *Online Trading Concepts* [online]. 2009 [cit. 2011-05-09]. Pivot Points. Dostupné z WWW: <<http://www.onlinetradingconcepts.com/TechnicalAnalysis/FloorTraderPivots.html>>.
- [14] *Finančník.cz* [online]. 2004, č. 13 [cit. 29. 12. 2010]. Klouzavé průměry – Finančník.cz. *Komodity – manuál zdarma*. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-klouzave-prumery.html>>
- [15] *Finančník.cz* [online]. 27.05.2006 [cit. 2011-05-09]. Exponential moving average (EMA). Dostupné z WWW: <http://www.financnik.cz/wiki/exponential_moving_average>.
- [16] TUPÝ, Jaroslav. *Investujeme.cz* [online]. 23.4.2008 [cit. 2011-05-09]. MACD: Téměř „svatý grál“. Dostupné z WWW: <<http://www.investujeme.cz/clanky/macd-temer-svaty-gral/>>.
- [17] *Finančník.cz* [online]. 17. 2. 2009 [cit. 8. 1. 2011]. Commodity Channel Index(CCI, Indikátor) – [Finančník]. Dostupné z WWW: <http://www.financnik.cz/wiki/commodity_channel_index>
- [18] HOLOVKA, V.: *Commodity channel index (CCI)* [online]. 15. 7. 2010 [cit. 8. 1. 2011]. Dostupné na WWW: <<http://www.xtb.cz>>
- [19] *StockCharts.com* [online]. 2009 [cit. 2011-05-09]. Relative Strength Index (RSI). Dostupné z WWW: <http://stockcharts.com/school/doku.php?id=chart_school:technical_indicators:relative_strength_index_rsi>.
- [20] *Finančník.cz* [online]. 2004, č. 15 [cit. 8. 1. 2011]. Stop-loss – Finančník.cz. *Komodity – manuál zdarma*. Dostupný na WWW: <<http://www.financnik.cz/komodity/manual/komodity-stop-loss.html>>
- [21] PUTNA, L.: *Predikce deště pomocí meteorologického radaru*. Brno: Vysoké Učení Technické v Brně, Fakulta Informačních Technologií, 2009. Vedoucí bakalářské práce Ing. Igor Szöke.
- [22] DUDA, Richard O.; HART, Peter E.; STORK, David G. *Pattern Classification : Second Edition*. New York : A Wiley-Interscience Publication, 2001. 654 s. ISBN 0-471-05669-3.
- [23] BARBER, S.: *AI : Neural Network for beginners – CodeProject*. [online]. 16.5.2007 [cit. 30. 12. 2010]. Dostupné na WWW: <www.codeproject.com/KB/recipes/NeuralNetwork_1.aspx?msg=2353453>
- [24] GURNEY, Kevin. *Philosophical Transactions of the Royal Society B: Biological Sciences* [online]. The Royal Society, 2007-03-29 [cit. 2011-05-09]. Neural networks for perceptual processing: from simulation tools to theories. Dostupné z WWW: <<http://rstb.royalsocietypublishing.org/content/362/1479/339.full>>. ISSN 0962-8436.
- [25] ZEKIC, M.: *Neural Network Applications in Stock Market Predictions- A Methodology Analysis* [online]. 1998 [cit. 30. 12. 2010]. Dostupné na WWW: <http://oliver.efos.hr/nastavnici/mzekic/radovi/mzekic_varazdin98.pdf>
- [26] EYDEN, R.: *The Application of Neural Networks in the Forecasting of Share Prices*. Finance and Technology Publishing, 1996. ISBN: 978-0965133203

- [27] LAWRENCE, R.: *Using Neural Networks to Forecast Stock Market Prices* [online]. 12. 12. 1997 [cit. 30. 12. 2010]. Dostupné na WWW: <<https://people.ok.ubc.ca/rlawrenc/research/Papers/nn.pdf>>
- [28] TAN, Chong. *Financial Time Series Forecasting Using Improved Wavelet Neural Network*. Århus, 2009. 113 s. Diplomová práce. University of Aarhus.
- [29] ŠKUTOVÁ, Jolana. WEIGHTS INITIALIZATION METHODS FOR MLP NEURAL NETWORKS. *Transactions of the VŠB – Technical University of Ostrava, Mechanical Series*. 2008, 2, článek č. 1636.
- [30] BEALE, Mark Hudson; HAGAN, Martin T.; DEMUTH, Howard B. *Neural Network Toolbox™ 7: User's Guide*. Natick : The MathWorks, Inc., 2010. 951 s.
- [31] VOMLEL, Jiří. *Genetické algoritmy* [online]. 2004. 36 s. Vysoká škola ekonomická Praha. Dostupné z WWW: <<http://staff.utia.cas.cz/vomlel/slides/presentace-ga.pdf>>.
- [32] WILSON, C. L.: Self-organizing neural network system for trading common stocks. *Proc. ICNN'94, Int. Conf. on Neural Networks*, pages 3651–3654, Piscataway, NJ, 1994.

Seznam příloh

Příloha 1.: DVD obsahující veškeré zdrojové kódy, jednoduchý návod na použití zdrojových kódů, předdefinované sady dat a další data vhodná pro predikci, výsledky simulace obchodování popsané v této práci a vybranou literaturu v elektronické podobě (zejména webové zdroje).