


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA PODNIKATELSKÁ
ÚSTAV INFORMATIKY

FACULTY OF BUSINESS AND MANAGEMENT
INSTITUT OF INFORMATICS

VYUŽITÍ UMĚLÉ INTELIGENCE NA FINANČNÍCH TRŽÍCH

THE USE OF ARTIFICIAL INTELLIGENCE ON FINANCIAL MARKET

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

BC. MICHAL HASOŇ

VEDOUCÍ PRÁCE

SUPERVISOR

PROF. ING. PETR DOSTÁL, CSC.

BRNO 2013

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Michal Hasoň

Informační management (6209T015)

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách, Studijním a zkušebním řádem VUT v Brně a Směrnicí děkana pro realizaci bakalářských, magisterských a doktorských studijních programů zadává diplomovou práci s názvem:

Využití umělé inteligence na finančních trzích

v anglickém jazyce:

The Use of Artificial Intelligence on Finacial Market

Pokyny pro vypracování:

Úvod
Vymezení problému a cíle práce
Teoretická východiska práce
Analýza problému a současné situace
Vlastní návrhy řešení, přínos návrhů řešení
Závěr
Seznam použité literatury
Přílohy

Podle § 60 zákona č. 121/2000 Sb. (autorský zákon) v platném znění, je tato práce "Školním dílem". Využití této práce se řídí právním režimem autorského zákona. Citace povoluje Fakulta podnikatelská Vysokého učení technického v Brně. Podmínkou externího využití této práce je uzavření "Licenční smlouvy" dle autorského zákona.

Seznam odborné literatury:

- DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: Akademické nakladatelství CERM, 2012. 718 s. ISBN 978-80-7204-798-7. e-ISBN 978-80-7204-799-4.
- DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: Akademické nakladatelství CERM, 2011. 168 s. ISBN 978-80-7204-747-5.
- DOSTÁL, P. a Z. SOJKA. Financial Risk Management. Zlín: UTB 2008. 80 s. ISBN 978-80-7318-772-9
- HANSELMAN, D. a B. LITTLEFIELD. Mastering MATLAB7. Pearson Education International Ltd., 2005. 852 s. ISBN 0-13-185714-2.
- MARÍK, V., O. ŠTĚPÁNKOVÁ a J. LAŽANSKÝ. Umělá inteligence. ACADEMIA, 2003. 1440 s. ISBN 80-200-0502-1.
- REJNUŠ, O. Finanční trhy. Ostrava: Key Publishing, 2008. 559 s. ISBN 978-80-87071-87-8.

Vedoucí diplomové práce: prof. Ing. Petr Dostál, CSc.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2012/13.



B. Půža

doc. RNDr. Bedřich Půža, CSc.
Ředitel ústavu

Stanislav Škapa

doc. Ing. et Ing. Stanislav Škapa, Ph.D.
Děkan

V Brně, dne 28.2.2013

Abstrakt

Tato diplomová práce je zaměřena na umělou inteligenci a její aplikování v oblasti finančních trhů. Pro predikci hodnoty a trendu vybraných kurzů měn jsou použity umělé neuronové sítě. Umělá neuronová síť je vytvořena v programu Matlab. Toto řešení je následně také zhodnoceno.

Abstract

This diploma thesis is focused on artificial intelligence and its application in financial markets. For the prediction values and trends of selected exchange rates are used artificial neural networks. Artificial neural network is created in Matlab. This solution is subsequently evaluated.

Klíčová slova

umělé neuronové sítě, finanční trhy, predikce.

Keywords

Artificial neural networks, forecasting, financial markets.

Bibliografická citace

HASOŇ, M. *Využití umělé inteligence na finančních trzích*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská 2013. 70 s. Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.

Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem v práci neporušil autorská práva (ve smyslu zákona č. 121/2000 Sb. O právu autorském a o právech souvisejících s právem autorským).

V Brně dne

.....

podpis

Poděkování

Na tomto místě bych rád poděkoval panu prof. Ing. Petru Dostálovi, CSc. za jeho pomoc, ochotu, rady a připomínky v průběhu vypracování této diplomové práce. Dále bych chtěl poděkovat oponentce paní Ing. Monice Raušerové.

Obsah

Úvod	10
1. Cíl práce.....	11
2. Neuronové sítě.....	12
2.1 Biologický neuron	13
2.2 Umělý neuron.....	14
2.3 Aplikace neuronových sítí.....	16
2.4 Druhy neuronových sítí.....	16
2.5 Přenosové funkce neuronů	19
2.6 Proces učení neuronových sítí.....	20
3. Finanční trhy.....	23
3.1 Vznik a vývoj finančních trhů, vznik peněz.....	23
3.2 Členění finančního trhu.....	23
3.3 Trh s cizími měnami.....	24
3.4 Vznik a vývoj burz	25
4. Technická analýza	26
4.1 Technické ukazatele	26
5. Časové řady	29
6. Aplikace Matlab	31
7. Popis a historie společnosti	32
7.1 SLEPT analýza.....	33
7.2 Porterův model pěti konkurenčních sil	34
7.3 SWOT analýza	37
8. Vlastní návrh řešení.....	41
9. Nonlinear Autoregressive model (NAR).....	42
9.1 Vyhodnocení NAR modelu.....	47
9.2 Možnosti optimalizování modelu NAR	48
9.3 Shrnutí a zhodnocení NAR modelu	51
10. Nonlinear Autoregressive Model with External (Exogenous) Input (NARX)	52
10.2 Vyhodnocení NARX modelu	56
10.3 Možnosti optimalizování NARX modelu.....	60
10.4 Shrnutí a zhodnocení NARX modelu.....	62
Závěr.....	63
Použitá literatura.....	64

Seznam obrázků.....	67
Seznam tabulek.....	68
Seznam zkratek.....	69
Přílohy	70

Úvod

Doba, ve které žijeme, je plná změn. Vývoj, rozvoj a nové nejen technické vynálezy a postupy najdeme prakticky ve všech vědeckých disciplínách a ve všech oblastech lidské činnosti. Tento trend způsobuje, že chceme stále nové a lepší zařízení, věci a podobně. Tyto potřeby se snažíme určitými způsoby uspokojovat, k čemuž potřebujeme finanční prostředky. Firma a podniky jsou na tom velice podobně. Často tvoří nadnárodní korporace, a obchodují ve velkém v různých světových regionech a v různých měnách. Tyto transakce probíhají na finančních trzích.

Finanční trhy představují celistvý systém, který se velmi rychle mění a který reaguje na mnoho podnětů. Pro správné rozhodování na tomto trhu je nutné využívat nejrůznější analýzy, které nám rozhodnutí ulehčí. Je třeba si uvědomit, že je velmi důležité, kdy je rozhodnutí na těchto trzích provedeno, protože okamžik provedení ovlivňuje zásadním způsobem výsledek - tedy zda transakce povede k zisku nebo ke ztrátě. Z těchto důvodů jakákoliv firma, která podniká na různých územích a v různých měnách vyhledává nástroje, které jí umožní především minimalizovat riziko ztrát, ale také na těchto transakcích vydělat. Proto firma, která obchoduje a působí na různých národních trzích s různými měnami, by model, který jí usnadní rozhodování a zvýší pravděpodobnost zisku, navrhnutý v této práci, by mohla s úspěchem používat.

1. Cíl práce

Cílem této práce je tvorba modelu (modelů) pro predikci vývoje kurzů a s tím spojené možnosti investic finančních prostředků na finančních trzích nebo zamezení ztrát při transakcích v různých měnách v podniku.

2. Neuronové sítě

Existuje velké množství definic neuronových sítí. Ve většině z nich se uvádí, že vzorem pro umělé neurony byly biologické neurony, definice také upozorňují na vytvoření neuronové sítě propojením umělých neuronů a trénink takto vzniklé sítě.

*"Umělá neuronová síť (ANN) je paradigma zpracování informací, inspirované biologickými nervovými systémy zpracování informací, jako je mozek. Klíčovým prvkem tohoto paradigmatu je nová struktura systému zpracování informací. Skládá se z velkého počtu vzájemně propojených prvků (neuronů), pracujících společně na řešení specifických úloh. ANN se stejně jako lidé učí z příkladů."*¹

(Stergiou a Siganos, 1996)

*"Neuronová síť je vzájemně propojeným souborem jednoduchých prvků (processing elements), jednotek nebo uzlů, jejichž funkčnost je volně založena na zvířecím neuronu. Schopnost sítě zpracovávat data je uložena v silách nebo vahách, získaných procesem přizpůsobování nebo učením z množiny trénovacích dat."*²

(Gurney, 1996)

*"Neuronová síť je orientovaný graf s ohodnocenými hranami kde rozeznáváme uzly vstupní, výstupní a skryté, a kde hrany reprezentují tok signálu. Hrany jsou ohodnoceny parametrem zpracování signálu, který je nazýván vahou."*³

(Soft Noviny, 6/1998)

¹ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 94

² tamtéž, s. 94

³ Purkynka.tk. Neuronové sítě. s.1

2.1 Biologický neuron

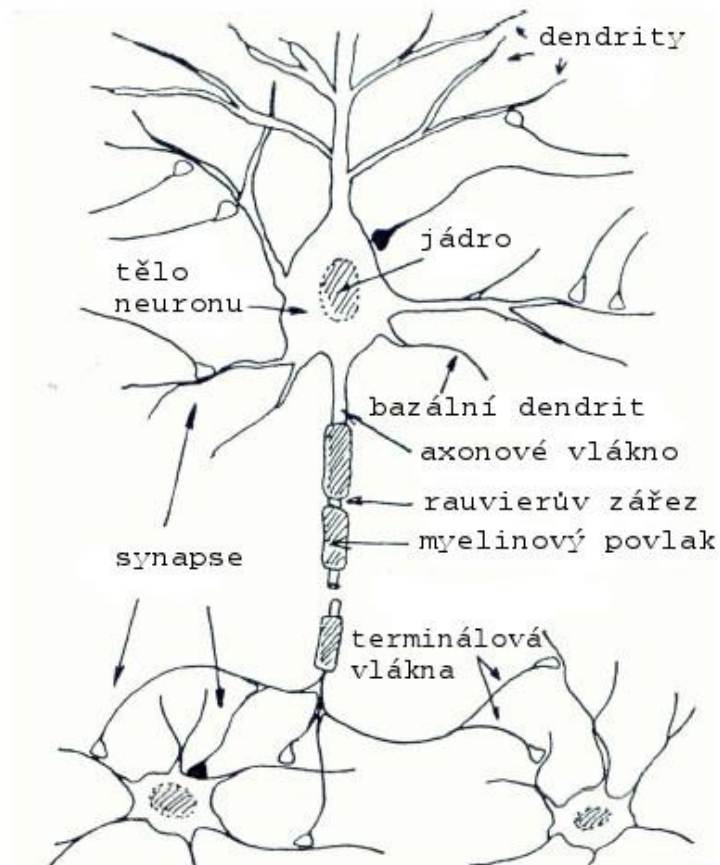
Na objevu biologického neuronu se velkou měrou podílel český vědec Jan Evangelista Purkyně (1787 - 1869). Při svém vědeckém zkoumání buněk objevil a popsal Purkyňovy buňky v malém mozku. Tyto buňky patří k největším v mozku obratlovců a jsou to první neurony, jež byly vědecky zdokumentovány a popsány. Pozdější rozvoj mikroskopické techniky zejména ve 20. století umožnil přesnější popis a detailnější zobrazení těchto buněk.⁽¹⁾

Biologický neuron je vysoce specializovaná buňka, která umožňuje nervové řízení organismu. Jeho vysoká specializace je příčinou toho, že se ve většině případů nervová buňka není schopna dělit a rozmnožovat se. Neuron má velmi atypický tvar, vypadá odlišně od ostatních tělních buněk. Z jeho těla vybíhá množství výběžků, které se nazývají dendrity. Nejdelší výběžek je vždy jeden a nazývá se axon (někdy označovaný jako neurit). Povrch axonu je pokryt dvojitou ochrannou vrstvou (pochvou). Vnitřní pochvu tvoří myelin (tuková hmota), vnější pochvu tvoří Schwanovy buňky. Regeneraci a výživu celého neuronu zajišťují gliové buňky. Odhaduje se, že člověk má těchto neuronů kolem 30 miliard.

Přenos vzruchu mezi buňkami je uskutečňován pomocí synapsí (zápojů). Jedná se o mezery mezi koncem neuritu jednoho neuronu a ukončením dendritu druhého neuronu. Tyto mezery jsou velmi malé, jejich šířka je jen několik mikrometrů. Počet synapsí není přesně znám, ví se, že je jich velké množství (cca stovky bilionů). Každý neurit v sobě obsahuje chemický přenašeč neurotransmitér (umístěný na koncích neuritů ve váčcích). Vzruch procházející neuronem dospěje až na konce neuritů, způsobí prasknutí váčků a neurotransmitér se vyleje do synapse a učiní ji přenosnou pro Na⁺ ionty. Pokud podráždění zmizí, neurotransmitér se velmi rychle rozkládá na enzymy. Protože se váčky nachází jen na neuritech je celý proces přenosu vzruchu jednosměrný. Vzruch samotný prochází neuritem jako elektrický impuls, v synapsi se chemickou cestou přepne zpět na elektrický v dalším neuronu.

¹ PETŘÍK M. Historie objevu neuronu [online].

Základním principem vybuzení (excitace) neuronu je tedy depolarizace. Výše popsaný proces označujeme jako budivý post-synaptický potenciál. Tento proces vyvolávají budivé neurotransmitery (noradrenalin, acetylcholin). Tlumivé neurotransmitery (kyselina γ -aminomáselná) naopak způsobují opačný proces, který se označuje jako hyperpolace, tedy útlum šíření vzruchu.⁽¹⁾



Obrázek 1 - Biologický neuron
(Zdroj: CHURÝ L. *Umělá inteligence, díl 2. - neuronové sítě*).

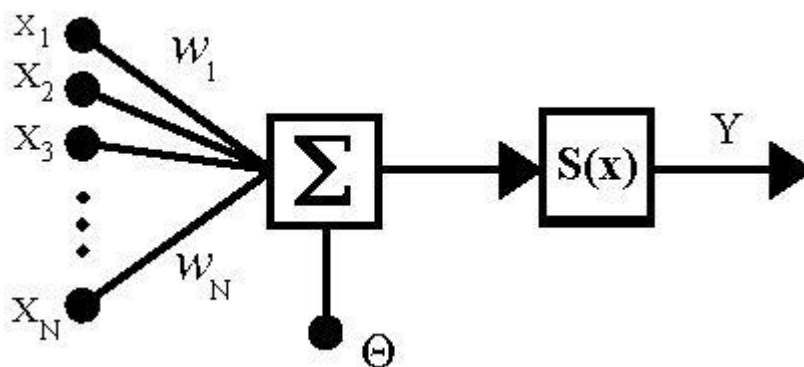
2.2 Umělý neuron

Biologický neuron posloužil jako vzor pro vznik umělého neuronu. Matematicky byl tento umělý neuron popsán v roce 1943 W. McCullochem a W. Pittsem. Dokázali, že díky vzájemnému propojení neuronů je možné realizovat

¹ JELÍNEK, J. ZICHÁČEK, V. *Biologie pro gymnázia*. s.277-285.

libovolnou funkci. Tento jednoduchý neuron byl v dalších desetiletích 20. století postupně zdokonalován a byly navrženy také celé neuronové sítě a algoritmy pro jejich trénink.

Umělý neuron může mít jeden nebo více vstupů, pomocí kterých přicházejí do neuronu informace. Vstupy jsou oceněny určitou váhou. Neuron tyto zpracuje tyto vstupy oceněné vahami, aplikuje aktivační funkci na potenciál. Aktivační signál se přemění na signál výstupní a je předáván neuronům v další vrstvě, případně na výstup.⁽¹⁾ Nejjednodušším modelem umělého neuronu je ten, který vstupy sčítá. Graficky je model tohoto neuronu zachycen na následujícím obrázku.



Obrázek 2 - Schéma umělého neuronu
(Zdroj: Wikipedie. Soubor:Neuron model.jpg)

- $x_1, x_2 \dots x_n$ vstupy neuronu
- $w_1 \dots w_n$ váhy vstupů
- θ prahová hodnota neuronu (citlivost)
- $S(x)$ aktivační funkce
- Y výstup

Matematicky lze tento model neuronu popsat následujícím vztahem:

$$Y = S\left(\sum_{i=1}^N (W_{nj} x_N) + \theta\right)$$

¹ FANTA J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích. s.97-98

2.3 Aplikace neuronových sítí

Pomocí neuronových sítí lze řešit klasifikační a předpovědní úkoly, tvořit závislosti proměnných a to tyto závislosti zachycovat jak graficky tak i početně. Nelze ovšem za všech okolností upřednostňovat pouze neuronové sítě před jinými metodami zpracování dat. Vždy záleží na konkrétním případě a je velmi vhodné kombinovat výsledky z různých metod analyzování dat vhodných na daný případ.

2.3.1 Výhody neuronových sítí

Síla neuronových sítí spočívá v řešení komplexních úloh se složitými vztahy, často nelineárními. Neuronové sítě jsou také odolnější vůči chybám nebo neúplným datům než je tomu u ostatních statistických metod. Nicméně i zde platí, že čím jsou data kvalitnější, tím lepší je výstup z neuronových sítí.

2.3.2 Nevýhody neuronových sítí

Nepříjemnou vlastností neuronových sítí jsou neidentické výsledky. Různé softwary, druhy sítí, doba tréninku, různé parametry pro učení sítě způsobují, že i když použijeme stejná data na vstupu, výstup nemusí být identický. Zároveň chybí možnost vyšetření, proč bylo různých výstupů dosaženo.⁽¹⁾

2.4 Druhy neuronových sítí

V současné době je vyvinuto velké množství modelů neuronových sítí od těch nejjednodušších až po sítě s neřízeným tréninkem

¹ FANTA J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 95-97

2.4.1 Lineární model

Je to nejjednodušší model neuronové sítě. Obsahuje pouze dvě vrstvy, které jsou lineární. Tento model lze použít k filtraci šumu zkreslené informace nebo k extrapolaci (případně interpolaci posloupnosti čísel podle zadaného průběhu).⁽¹⁾

2.4.2 Vícevrstvý perceptronový model

Tento model patří k neznámějším a nepoužívanějším modelům neuronových sítí. Základním prvkem je perceptron, popsáný Frankem Rosenblattem už v roce 1957. Učící algoritmus pro tento model byly navrženy až Rumelhaltem, Hintonem a Williamsem v roce 1986. Síť se skládá z několika vrstev perceptronu (viz obrázek - naskenovat UI4 str 206). Perceptrony jsou propojeny tak, že výstup jakéhokoliv neuronu vede do vstupů všech perceptronů v následující vrstvě. Poslední vrstva se nazývá výstupní vrstva, ostatní vrstvy se nazývají skryté. Síť může obsahovat jednu nebo více skrytých vrstev. Jedná se o jednosměrné dopředné spojení. Počty vrstev a perceptronů v nich se přibližně určují pomocí heuristik. Pokud je počet perceptronů malý, potom síť není schopná zachytit všechny vazby v učících datech. Pokud je jejich počet příliš velký, pak se zvyšuje doba trénování sítě. Navíc může dojít k přeučení, kdy síť není schopná generalizace.⁽²⁾

2.4.3 Hopfieldova síť

Jejími tvůrci jsou "otcové" umělého neuronu W. McCulloch a W. Pitts. Vznikla v roce 1943, ale do podvědomí se zapsala výrazněji až v roce 1982, kdy ji J. Hopfield použil při studiu magnetických minerálů. Zároveň vytvořil energetickou funkci, z které je odvozena většina pravidel pro učení sítě. V dnešní době známe mnoho variací této sítě, které se používají k řešení optimalizačních úloh.⁽³⁾

¹ FANTA, J. Psychologie, algoritmy a umělé inteligence na kapitálových trzích. s.104

² MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. Umělá inteligence (4). s.205-210

³ Tamtéž. s.210-220

2.4.4 Radial Basis Function

Tato síť obsahuje vstupní a skrytou vrstvu a lineární výstupní vrstvu. Výstupní vrstva obsahuje lineární aktivační funkci, ostatní vrstvy exponenciální aktivační funkci. Výhodou této sítě je rychlý trénink. Naopak výsledná síť je pomalejší než u jiných modelů.

2.4.5 Generalized Regression Neural Network

Tato síť může mít tři až čtyři vrstvy: vstupní, výstupní a mezi těmi to vrstvami pak vrstvu s radiálními centry a s regresními jednotkami. Pomocí tohoto typu sítě se řeší úlohy, kde jsou rozptýlená a řídká data, ovšem s kontinuálními výstupy.

2.4.6 Probabilistic Network

Síť obsahuje vrstvu vstupní, skrytou vrstvu s radiálními jednotkami a výstupní lineární vrstvu. Počet neuronů ve skryté vrstvě musí být menší, případně roven počtu trénovacích dat. Tento model někdy obsahuje i čtvrtou vrstvu - matici ztrát. Používá se v případě, kdy je riziko, že špatně ohodnocené případy mohou způsobit vážné ztráty.⁽¹⁾

2.4.7 Kohonenova síť

Tato síť nepotřebuje ke svému učení učitele. Byla navržena T. Kohonenem v roce 1982, ale samotné principy byly popsány mnohem dříve. Inspirována byla vědomostmi a poznatky o fungování mozku obratlovců. Obsahuje dvě vrstvy a to vstupní a výstupní, kde jsou radiální jednotky. Tato síť aproximuje pravděpodobnostní rozdělení na trénovacích datech. Data jsou soustředěna ve shlucích. Tím zmenšuje velikost vstupního vektoru. Používá se například pro prvotní zpracování dat, která jsou poté použita v některém jiném modelu neuronových sítí.⁽²⁾

¹ FANTA, J. Psychologie, algoritmy a umělé inteligence na kapitálových trzích. s.106

² MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. Umělá inteligence (4). s.220-228

2.4.8 Síť ART (Adaptivní rezonanční teorie)

Tato síť odstraňuje nedostatek většiny jiných modelů, kdy se síť není schopná naučit novou informaci bez poškození předchozí uložené informace. Tento problém je dobře patrný například na vícevrstvé perceptronové síti, kdy pro získání nové informace je nutné začít znovu s tréninkem, ovšem starou informaci tím ztratíme. Jedná se opět o síť bez učitele. K dalším výhodám této sítě patří schopnost eliminace špatných informací a citlivost na kontext.⁽¹⁾

2.5 Přenosové funkce neuronů

Přenosová funkce neuronu mění signál vstupní na signál výstupní. V současné době existuje mnoho těchto funkcí. Dají se rozdělit na skokové nebo analogové. Další možné dělení je lineární nebo nelineární. Přenosová funkce je vybírána podle typu úlohy, typu sítě a dalších faktorech. Pro optimalizaci sítě je nutné aby všechny přenosové funkce měly první derivaci spojitou, kromě výstupní vrstvy. Dále jsou uvedeny některé nejpoužívanější přenosové funkce:

- Hardlim

Jedná se o skokovou přenosovou funkci, může tedy nabývat hodnot 0 nebo 1. Tato funkce modifikuje vstupní informace na normovaný výstup. Matematicky lze zapsat tuto funkci následujícím způsobem:

$$a = \text{hardlim}(f(a)) = \begin{cases} f(a) = 0; a < 0 \\ f(a) = 1; a \geq 0 \end{cases}$$

- Purelin

Jde o lineární přenosovou funkci. Opět převádí vstup na výstup. Matematicky lze zapsat takto: $a = \text{purelin}(f(a)) = f(a)$

- Logsig

¹ MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. Umělá inteligence (4). s.229-234

Logaritmická přenosová funkce, jejíž obor hodnot je interval $\langle 0;1 \rangle$. Matematický zápis této funkce: $a = \text{logsig}(f(a)) = \frac{1}{1+e^{-a}}$

- Tansig

Jde o hyperbolickou tangentu - nelineární přenosovou funkci, jejíž oborem hodnot je interval $\langle -1;1 \rangle$. Matematicky lze zapsat vzorcem: $a = \text{tansig}(f(a)) = \frac{e^a - e^{-a}}{e^a + e^{-a}}$

- Sigmoida

Jde o nelineární aktivační funkci, která se používá pro učení neuronových sítí. Matematický zápis je následující: $f(a) = \frac{1}{(1+e^{-\lambda a})}$. ⁽¹⁾

2.6 Proces učení neuronových sítí

Postatou učení je nastavit ("naučit") síť tak, aby dávala správné a relevantní výsledky pro zadaný úkol. Tohoto dosáhneme nastavením vah u jednotlivých vazeb. Tyto hodnoty vah neznáme, ale získáváme je při tréninku sítě. Nastavení těchto vah je nazýváno výukovým zákonem. Tento stav se nazývá adaptabilní, po jeho ukončení přejde síť do vybavovacího režimu.

2.6.1 Učení bez učitele

Při tomto typu učení nedochází k vyhodnocování výstupu. Ten se vytváří na základě zohledněných vstupních vzorů. Výstup sítě je před trénováním neznámý. Při učení bez učitele tedy síť sama zpracovává vstupní informace. Tento typ učení využívá například Kohonenova síť (uzpůsobuje systém vah a svou topologii vstupním podnětům) nebo model ART (roztřídí informace do skupin a každá skupina je poté reprezentována zástupcem).

¹ DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. s. 68-74

2.6.2 Učení s učitelem

Vzor pro tento způsob učení byl získán pozorováním organismů, kde podobný děj také probíhá, jen nemá zřejmého učitele na rozdíl od umělých neuronových sítí. Princip učení můžeme matematicky zapsat následujícím způsobem. Mějme neuronovou síť, se vstupními neurony $x_1 \dots x_m$ a výstupními neurony $o_1 \dots o_n$, můžeme zapsat trénovací množinu jako:

$$T = \{[x^1, y^1], [x^2, y^2], \dots, [x^p, y^p]\},$$

kde x^p je vektor vstupních hodnot a y^p vektor výstupních hodnot p -tého příkladu. T je transformace vstupních hodnot na výstupní p -tého příkladu. Trénovací množina obsahuje P příkladů, potom platí $p \leq P$. Pro vyhodnocení se používá obvykle střední kvadratická odchylka sítě, která je dána vztahem:

$$E = \frac{1}{2} \sum_{p=1}^P (\sum_{k=1}^n (y_k^p - o_k^p)^2),$$

kde E je střední hodnota chyby, rozdíl $y_k^p - o_k^p$ reprezentuje odchylku mezi skutečným a očekávaným výstupem. Chybová funkce závisí na vstupech a vahách uvnitř sítě. Různým nastavením vah je možné velikost chyby minimalizovat.⁽¹⁾

Algoritmů pro učení je dnes známé velké množství. Pro některé typy sítí jsou vhodnější určité učící algoritmy více, jiné méně. Mezi nejznámější patří několik například:

- **Back Propagation** - algoritmus se zpětným řízením. Jedná se o nejdůležitější a nejpoužívanější učící algoritmus. učení probíhá ve třech krocích:
 - 1) Síti je předloženo zadání, po výstupu informací ze sítě se zjistí chyba
 - 2) V této fázi se šíří síti zpětně informace o chybě zpětně, tj od výstupu ke vstupu. Tím se zjistí chyba pro každý neuron.
 - 3) V poslední fázi se tato chyba minimalizuje adaptací vah.

Tento druh učení má i několik nepříjemných vlastností. Chybová funkce je závislá na všech vahách a těch může být velké množství. Tedy existuje i mnoho lokálních minim. Gradientní metoda vede do nejbližšího minima, které nemusí být globální. Druhým problémem je množství parametrů, které

¹Purkynka.tk. Neuronové sítě. s.5-11

nejsou striktně určeny algoritmem, ale přesto ovlivňují celkovou výši chyby.⁽¹⁾

- **Hopfieldův model** - pro učení používá symetrické spoje. Je založen na posilování a oslabování vazeb, to jest nepodstatné informace zapomíná a podstatné si víc pamatuje. Proces trvá tak dlouho, doku zůstanou jen potřebné vazby a nepotřebné jsou odstraněny.⁽²⁾
- **Conjugate Gradient Descent** - metodou postupných kroků se tento algoritmus snaží dosáhnout minima.⁽³⁾
- **Levenberg-Marquardtův algoritmus** - minimalizuje funkci (obvykle nelineární) přes dané parametry funkce.⁽⁴⁾
- **Quick Propagation algoritmus**
- **Quasi-Newtonův algoritmus**, známý také jako **Variable metric methods** opět slouží k nalezení maxim a minim dané funkce. Je založen na Newtonových metodách hledání stacionárních bodů s gradientem 0.⁽⁵⁾

¹ Purkynka.tk. Neuronové sítě. s.8-9

² MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. Umělá inteligence (4). s.210-220

³ Wikipedia. Gradient descent.

⁴ Wikipedia. Levenberg-Marquadt algorithm.

⁵ Wikipedia. Quasi-Newton method.

3. Finanční trhy

V jakékoliv dnešní ekonomice je běžným jevem, že se ekonomické subjekty (domácnosti, firmy, stát, banky, ...) dostávají do situací, kdy mají přebytek nebo naopak nedostatek finančních prostředků. Přemístění peněz od subjektů, které jich mají nadbytek, k subjektům, které jich mají nedostatek se děje právě na finančních trzích. Pomocí finančních operací dochází ke směně peněz za různé druhy finančních služeb a finančních nároků, nákup kapitálových statků, zvyšování produkčních možností ekonomiky a ekonomickému růstu.


3.1 Vznik a vývoj finančních trhů, vznik peněz

Vývoj finančních trhů do dnešní podoby trval velmi dlouho a je úzce spjat s historií a vývojem lidstva. Před vznikem trhu existoval pouze barter, tedy směna zboží za zboží (nicméně se s ním můžeme setkat i dnes). Během vývoje a rozvoje obchodu byla tato směna nepraktická a neefektivní. Bylo nutné stanovit komoditu, která by byla všemi přijímána a která by byla volně směnitelná za zboží. Touto komoditou se staly peníze. Peníze také prošly vývojem:

1. Komoditní peníze - určitý druh zboží všemi přijímaný (látky, ...)
2. Drahé kovy - mají příhodné vlastnosti pro peníze (vzácné, snadno dělitelné, možnost úschovy a přenosu, stálé)
3. Mince - vyrobené z drahých kovů (zlato, stříbro, měď, ...), mince měly určitou hodnotu díky kovu, ze kterého byly vyrobeny
4. Papírové peníze - hodnotu mají symbolickou, stát garantuje jejich hodnotu státním zlatým pokladem
5. Bezhotovostní platby - k jejich provedení se používají šeky, platební karty, bankovní účty, a podobně.

3.2 Členění finančního trhu

Finanční trh lze dále členit do několika segmentů. Toto členění je vidět na následujícím obrázku. Pro tuto práci je důležitý trh z cizími měnami, kterým se tato práce dále zabývá.⁽¹⁾



Obrázek 3 - Členění finančního trhu
(Zdroj: upraveno dle Rejnuš, O. Peněžní ekonomie (Finanční trhy). s.39)

3.3 Trh s cizími měnami

Většina světových ekonomik je otevřených. Jednotlivé státy pak mezi sebou obchodují a potřebují tedy převádět měnu jednoho státu na měnu druhého státu. Důvodem zavedení vlastní měny je kontrola ekonomiky státu a získání nástroje regulace zahraničního obchodu. Měna je tedy peněžní soustava určitého státu, základem každé měny je peněžní jednotka. Měna může být:

1. Nesměnitelná - stát zakazuje držení cizích měn občany, banky získávají monopol této výměny. (příkladem může být československá koruna před rokem 1990).
2. Částečně směnitelná - existují restriktivní pravidla omezující výměnu vlastní měny. (příkladem je česká koruna v letech 1993 - 1995).
3. Plně směnitelná - neexistují žádná omezení při směně měny za jinou (česká koruna od roku 1996).

Trh s cizími měnami je možno rozdělit na:

a) trhy devizové

- devizy = pohledávky znějící na cizí měnu (cenné papíry v cizí měně)
- jde o trhy s bezhotovostními formami cizích měn, dochází zde k směňování měn a tvorbě jejich kurzů

¹ REJNUŠ O. Finanční trhy. s.38-40

- obchodování zde má spíše velkoobchodní charakter

b) trhy valutové

- valuty = bankovky a mince cizího státu
- jedná se o trhy s hotovostními formami cizích měn, obchodují se za valutové kurzy
- obchodování zde má maloobchodní charakter

3.4 Vznik a vývoj burz

Známe více teorií, které popisují, jakým způsobem vzniklo slovo burza. Nejprozaičtější říká, že vzniklo z latinského slova "*bursa*", jež znamená měšec, pytlík s penězi. Další teorie popisuje, že slovo vzniklo v Bruggách u domu vážené rodiny van der Burse, jejichž znak obsahoval tři měšce. Samotné slovo burza se dnes používá téměř ve všech jazycích vyjma angličtiny, kde najdeme termín "The Exchange". Za první burzu na světě je považovaná burzovní budova v Antverpách postavená roku 1531, kde hlavním předmětem obchodu byly mince a směnky. V tomto období vznikají burzy především ve Francii, Německu a Anglii (namátkou jmenujme burzu v Lyonu roku 1546, v Toulouse roku 1549, v Rouvenu roku 1556, v Hamburku roku 1558, v Paříži roku 1563, v Londýně roku 1571). V dalších stoletích vznikaly burzy postupně po celém světě, za všechny jmenujme burzu v New Yorku na Wall Street roku 1792. Pražská burza vznikla roku 1871.

Díky rychlému rozvoji výpočetní techniky ve 20. století se obchody postupně přesouvají na automatizované zpracování. Klesá význam národních burz, naopak na vzestupu jsou mezinárodní burzy.⁽¹⁾

¹ Referáty10.com. Vznik a vývoj burz, podstat burz.

4. Technická analýza

Technická analýza se používá k určení pohybu cen v budoucnosti na základě historických dat. Tímto se velmi liší od fundamentální analýzy, kterou zároveň vhodně doplňuje. Největším problémem fundamentálních analýz je obtížnost a věrohodnost získaných dat. Fundamentální analýza také není schopná stanovit nejlepší okamžik pro nákup nebo prodej cenných papírů, měn,...

Hlavní cíl technické analýzy spočívá v určení budoucího vývoje cen, určení trendu, tedy jeho konce a případného otočení trendu. Předpovědi získané technickou analýzou nejsou nikdy stoprocentní, nicméně procento omylu lze správným použitím velmi silně zredukovat.

4.1 Technické ukazatele

Metodou technické analýzy je studium grafů. Grafy mohou mít různou grafickou podobu, nejčastěji se používá liniový, schodový nebo svícnový graf. K nejvýznamnějším technickým ukazatelům se řadí :

1) Klouzavé průměry (Moving Average)

Počítají se jako průměr stejného počtu za sebou jdoucích období. Používá se několik typů klouzavých průměrů:

- Jednoduché klouzavé průměry
- Vážený klouzavý průměr
- Exponenciální klouzavý průměr
- Vyhlazený klouzavý průměr

2) MACD (Moving Average Convergence Divergence)

Tento indikátor představuje rozdíl mezi dvěma klouzavými průměry. Většinou se jedná o rozdíl mezi 12 a 26 denním exponenciálním klouzavým průměrem. Čárou

stanovení obchodních signálů je 9 denní exponenciální klouzavý průměr. Tyto klouzavé průměry mohou být upraveny v závislosti na potřebách analytika a analyzovaného kurzu.

3) ROC (Rate of Change)

Tento index je v praxi velmi používaný zejména díky jeho jednoduchosti. Popisuje sílu a rychlost trendu. Nicméně má tento index několik nedostatků. Pro výpočet hodnot je třeba dlouhých časových řad, není jasné, kdy je optimální doba na nákup a prodej a hodnoty jsou často ovlivňovány vývojem minulých dat, která jsou součástí výpočtu.⁽¹⁾

4) Index relativní síly (Relative Strength Index)

Tento index relativní síly měří vnitřní sílu akcie. Počítá se: $RSI = 100 - (100/(1+RS))$, kde RS je podíl součtu kladných změn ceny za dobu n a součtu záporných změn ceny za dobu n. Index relativní síly určuje, zda je trh překoupený nebo přeprodaný. Ze vzorce je patrné, že nabývá hodnot z intervalu $\langle 0;100 \rangle$. Pokud se hodnota indexu pohybuje v intervalu $\langle 0;30 \rangle$, pak se jedná o přeprodaný trh, je tedy možnost růstu kurzu. Pokud hodnota indexu náleží do intervalu $\langle 70;100 \rangle$, pak se jedná o překoupený trh a kurz bude pravděpodobně klesat.

5) Stochastik

Indikátor popisuje polohu uzavírací ceny ve vztahu k rozpětí mezi nejvyšší a nejnižší cenou v daném období (obvykle 5 - 21 dnů). Indikátor se podobně jako předchozí Index relativní síly používá k určení trhu přeprodaného nebo překoupeného. Nabývá opět hodnot v intervalu $\langle 0;100 \rangle$. Největší pravděpodobnost optimálního času pro nákup a prodej, nastane v době, kdy má indikátor hodnotu z intervalu $\langle 0;20 \rangle$ pro nákup a $\langle 80;100 \rangle$ pro prodej ovšem nemusí to být vždy pravidlem.⁽²⁾

¹ ŘÍHA J. Technická analýza cenných papírů s. 60-63

² Tamtéž. s.65-74

6) Williams %R

Tento indikátor využívá algoritmus, jež využívá hodnoty z několika posledních obchodních dnů. Standardně se nastavuje na hodnotu 14, tedy 14 obchodních dnů). Někdy se používá i jeho dvojnásobná hodnota (zejména pro dlouhé periody). Tento indikátor nabývá hodnot 0 - 100, kde interval 0-20 znamená přeprodanost trhu a hodnoty 80-100 překoupenost trhu. ⁽¹⁾

¹ FOREX. Obchodujeme FOREX (XI): technická analýza (3).

5. Časové řady

Časové řady nám umožňují zápis ekonomických a společenských údajů v průběhu času. Tento zápis nám dává také možnost vytvořit prognózu jejich vývoje v budoucnosti. V ekonomii pomocí časových řad zachycujeme například vývoj kurzů mezi jednotlivými měnami, poptávku po určitém výrobku za časový úsek, vývoj účetních ukazatelů a podobně. Časové řady se dělí na dvě základní skupiny:

- a) intervalové - charakterizují počet jevů, událostí, nastalo (nenastalo, zaniklo) v určitém časovém úseku
- b) okamžikové - charakterizují počet jevů v určitém časovém okamžiku

Matematicky lze časovou řadu vyjádřit posloupností hodnot $x_1, x_2, x_3, \dots, x_n$, kde x je hodnota sledované veličiny v čase a index n určující pořadí a počet prvků dané časové řady. Časovou řadu lze dekomponovat na 4 základní složky - trendovou, sezonní, cyklickou a náhodnou. Trendová složka popisuje tendenci dlouhodobého vývoje, sezonní složka vyjadřuje takové změny sledované veličiny, které se cyklicky za určité období opakují, cyklická složka určuje tzv. fluktuace kolem trendu, kde se střídá fáze růstu a poklesu za působení vnějších příčin a jevů. Náhodná složka časové řady je vše ostatní, co zůstane po odstranění tří výše uvedených složek. Je tvořena výkyvy, které jsou náhodné a které nemají rozpoznatelný původ ani charakter. Do této složky patří také nejružnější chyby, které vznikají při práci s časovou řadou (chyby v zaokrouhlování, chyby měření, apod.). Některé časové řady mohou obsahovat pouze některé z těchto složek. Protože pouhým součtem těchto složek dostaneme původní časovou řadu, jedná se o tzv. aditivní dekompozici.

Prognóza nebo také predikce časových řad (samotné slovo predikce pochází z latinských slov *prae* - oproti, ve srovnání s a *dicere* - říct) popisuje předpověď dalšího vývoje. Tato předpověď je postavená na teoriích, faktech a hypotézách, které vychází z experimentů nebo ze zjištěných skutečností. Budoucí hodnotu můžeme předpovědět buď tzv. interpolací (z latiny *inter-polare*, vylepšení

vložení), kdy se zjišťuje hodnota sledované veličiny na základě předchozích známých hodnot v určitém intervalu. Většinou se používá tzv. extrapolace, která se od interpolace liší tím, že hodnota funkce, kterou se snažíme nalézt leží mimo interval známých hodnot.

K predikci můžeme také využít pokročilejší techniky, jednou z nich jsou neuronové sítě. Výhodou neuronových sítí je schopnost trénovat a učit se na minulých datech, nevýhodou je že nelze nijak zjistit velikost chyby. Další nevýhodou je pak nutnost sestavení modelu "na míru", neexistuje totiž žádný univerzální model.⁽¹⁾

¹ KROPÁČ, J. Statistika B. s. 115-125

6. Aplikace Matlab

Historie aplikace Matlab se začala psát v roce 1984. Tehdy Matlab fungoval v prostředí MS DOS. Během vývoje se z jednoduchého programu stala výkonná vědecká a matematická aplikace s mnoha funkcemi. Samotné jádro programu je rozšiřitelné o další části - toolboxy a moduly, čímž se z Matlabu stává komplexní nástroj pro řešení nejrůznějších úloh ve vědecké, matematické a mnoha dalších sférách. Uživatelům je také k dispozici grafická interpretace výsledků. Velmi oceňovaná je i možnost rozšíření programu o vlastnoručně napsané funkce v m-souborech.

Program nachází využití v mnoha oblastech vědy a výzkumu, například v ekonomii, elektrotechnice, strojírenství a mnoha dalších oborech. Léta praxe spolu s rychlým a výkonným jádrem dělá z Matlabu jeden z nejlepších a nejkompaktnějších programů na trhu. K vypracování praktické části této práce byl použit Matlab R2010b, verze 7.11.584 (64-bit).

7. Popis a historie společnosti

Společnost Hanácká kyselka s.r.o. (dále jen společnost nebo firma) byla založena 22.6.1992. Nicméně základy, na kterých dnes staví společnost, sahají až do poloviny 19. století, kdy byl při hledání ložisek uhlí nalezen léčivý pramen. Do roku 1948 byly prameny a budovy ve vlastnictví fyzických osob (rodina Pospíšilová). Po převratu v roce 1948 došlo ke znárodnění. V současné době je společnost vlastněna jednou právnickou osobou a několika fyzickými osobami (dědici rodiny Pospíšilů).⁽¹⁾

V současnosti má společnost významné postavení na českém trhu v oblasti těžby, úpravy stáčení a výroby minerálních vod. Dále svoje produkty vyváží do zahraničí, například na Slovensko nebo do USA.

Produkty společnosti jsou minerální vody. Dají se rozdělit do několika základních skupin:

I. Přírodní minerální vody

- patří sem produkt Hanácká přírodní, která je jedním ze stěžejních produktů společnosti. Těší se dlouholeté oblibě u zákazníků.

II. Ochucené minerální vody

- Ochucené minerální vody zahrnují více než desítku nejrůznějších příchutí, přičemž pravidelně přibývají další.
- Nejdůležitější příchutí je Citron, který se těší více než 15-leté oblibě i zákazníků a dosahuje největších objemů prodeje.
- Mezi další příchutě patří pomeranč, višně, limetka, grapefruit, aloe, malina, jahoda, ananas, borůvka, čer bez, alpské byliny, white cola.

III. BIO minerální vody

¹ Obchodní rejstřík a sbírka listin. Sbírk listin Hanácká kyselka s.r.o.

- tyto produkty se od ostatních liší použitím doplňujících látek s označením Bio (typicky bio cukru)
- existují dvě příchutě těchto minerálních vod, a to citron a hruška⁽¹⁾

7.1 SLEPT analýza

7.1.1 Sociální faktory

Průměrný stav populace v ČR se mírně zvyšuje díky přistěhovalectví. Zároveň ale dochází ke stárnutí populace, zvyšuje se průměrný věk obyvatelstva. To samo o sobě je pro společnost víceméně příznivá zpráva, protože tím pádem má společnost více potenciálních zákazníků. Na druhou stranu se za poslední rok zvýšila nezaměstnanost a tedy hrozí pokles koupěschopnosti obyvatelstva, což by mělo za následek možné snížení objemu odbytů.

7.1.2 Legislativní faktory

Sazba DPH rozhodným způsobem ovlivňuje cenovou hladinu produktů. V posledních několika letech došlo k jejímu zvýšení. Toto zvyšování DPH s sebou přináší velkou pravděpodobnost zdražení potravin, které se projevilo v tržbách obchodníků. Spotřebitelé totiž omezili nejen nákup např. alkoholu nebo tabáku, ale také jídla a nápojů. Díky vyšší DPH také vzrostly společností náklady na běžný provoz a fixní náklady.

7.1.3 Ekonomické faktory

Pro společnost, která působí na zahraničních trzích v EU a USA je velmi důležité sledovat kurz koruny vůči euru a také dolaru, případně kurz dolaru vůči euru. Vzhledem k faktu, že ekonomické krize v Evropě pravděpodobně v dohledné době neskončí a tedy nedojde k výraznému oživení poptávky, je třeba, aby společnost udržovala stabilní objem prodeje. Společnost také využívá peníze z ESF

¹ Hanácká kyselka. Produkty.

fondy na projekt "Péče o lidské zdroje = péče o budoucnost podniku Hanácká kyselka s.r.o." Projekt je zaměřen na rozvoj profesních schopností a zvýšení vzdělání zaměstnanců a týká se všech pracovníků.⁽¹⁾

7.1.4 Politické faktory

Politické faktory nepatří mezi faktory, které by na společnost měly významný vliv (vyjma už popsané změny DPH a s tím spojené kupní síly obyvatelstva). Vláda je i přes nedávné politické problémy jeví jako celkem stabilní a nadále provádí reformy, její chování a předpoklad budoucího směřování je poměrně předvídatelný. Politická situace v EU je vypjatá, zejména díky ekonomické situaci v Řecku, Španělsku, Itálii a některých dalších zemích, přesto to společnost zatím nijak neovlivňuje, protože na trzích těchto států nepůsobí. Státy jako Slovensko, Německo či USA (tedy kde společnost dodává produkty) se jeví jako poměrně stabilní.

7.1.5 Technologické faktory

Tyto faktory se vztahují především k získávání, úpravě a stáčení vody do lahví. Společnost využívá především stávající technologie a zatím neplánuje zařazení nových technologií do výrobního procesu.

7.2 Porterův model pěti konkurenčních sil

7.2.1 Riziko vstupu potenciálních konkurentů

Toto riziko je dáno velikostí a množstvím bariér, které brání vstupu nového konkurenta do určitého odvětví. Většina bariér je zejména náročná po finanční stránce, konkurent by tedy musel mít k dispozici značný vstupní kapitál.

Další bariéry vstupu do odvětví:

- Vybudovaná síť zákazníků, zavedené dobré jméno značky a tradice značky

¹ Evropský sociální fond v ČR. Péče o lidské zdroje, péče o budoucnost podniku Hanácká kyselka.

- Výběr dodavatelů, vznik vazeb, hledání nových dodavatelů → tímto vznikají další dodatečné náklady. Stávající firmy se snaží neměnit smluvní partnery, protože jim to vyhovuje po finanční stránce.
- Nový konkurent je nucen vynaložit extra náklady na uvedení na trh, rozjezd firmy a také musí počítat s tím, že bude chvíli trvat než si najde okruh zákazníků. Prvních několik let tedy nemusí být konkurent v zisku a bude nucen ze svých zdrojů provoz dotovat.
- Konkurent také potřebuje vlastnit nějaký vhodný pramen, který bude využívat pro výrobu vlastních minerálních vod. Tento pramen ale může být velmi obtížné, ne-li nemožné nalézt.

V současnosti nehrozí vstup nových konkurentů na trh také z důvodu ekonomické situace v EU a v ČR. Je to dáno ekonomickou krizí, kdy se snižuje poptávka, klesá kupní síla obyvatelstva a většina firem i jednotlivců se snaží snižovat náklady, tedy šetřit. O něco vyšší riziko vstupu konkurenta do odvětví je v případě, že zvolí výrobu levného produktu s nízkou kvalitou. Tím by část zákazníků s nižší kupní silou mohl přetáhnout stávajícím firmám.

7.2.2 Rivalita mezi stávajícími konkurenty

Většina společností má vybraného konkurenta, kterého se snaží dohnat nebo ještě lépe předčit. Proto je důležité a vhodné konkurenty znát a sledovat jaké kroky udělali, jaké mají cíle, jakou vyznávají strategii, a podobně.

Mezi nejvýznamnější konkurenty společnosti patří:

- Poděbradka a.s.
- Karlovarské minerální vody a.s.
- Coca Cola Company

Rivalita firem v tomto segmentu trhů je poměrně velká, žádná firma nemá výrazně vyšší podíl než ostatní. Růst v odvětví je minimální, spíš dochází ke stagnaci. Trh je v současnosti nasycen.

7.2.3 Smluvní síla kupujících

Zákazníci společnosti se dají rozdělit do dvou skupin:

Obchodní organizace:

- a. maloobchodní řetězce (Kaufland, Ahold, Billa, ...) - podíl 44 % z obrátu a roste
- b. spotřební družstva jednoty COOP - podíl z obrátu cca 15 %
- c. nezávislí odběratelé (velkoobchody, maloobchody, podniky,...) - podíl z obrátu 40,5 %

Koneční spotřebitelé, to jsou koneční konzumenti produktů společnosti, které zakupují na různých prodejních místech.

Pozice a vyjednávací síla zejména obchodních řetězců je poměrně značná, protože odebírají skoro polovinu produkce společnosti. Díky této pozici je společnost nucena prodávat svoje produkty těmto řetězcům poměrně levně, což se negativně podepisuje na finanční situaci společnosti.

7.2.4 Smluvní síla dodavatelů

Zde nelze očekávat výrazné změny, společnost spolupracuje s osvědčenými dodavateli, proto jejich vyjednávací síla je dána dlouhodobě a nijak se nemění. Ke změně dodavatelů může dojít při změně výrobní technologie, kterou dodají na trh jiní než stávající dodavatelé. Další vynucenou změnou může být zánik dodavatele. Společnosti se tohle stalo s dodavatelem jejich reklamních spotů, který skončil v exekuci. Při dobré platební morálce společnosti je také s tradičními dodavateli vyjednat systém slev a bonusů a to zejména při pravidelných odběrech.

7.2.5 Hrozby substitučních výrobků

Na trhu existuje poměrně velké množství homogenních produktů od konkurenčních firem. Všechny produkty jsou si velmi podobné, takže nemálo zákazníků se rozhoduje podle ceny při koupi těchto produktů. Mezi další konkurenční výrobky patří v podstatě veškeré nealkoholické nápoje, různé džusy,

sirupy ředitelné vodou, limonády a další podobné produkty. Dalším substitutem může být i obyčejná pitná voda, ke které má přístup každá domácnost a která stojí jen zlomek ceny oproti minerální vodě. V součtu se jedná o největší hrozbu a konkurenční sílu pro společnost.

7.3 SWOT analýza

SWOT analýza je zaměřená na rozbor současného stavu firmy (vnitřní prostředí) a vnějšího okolí firmy. Ve vnitřním prostředí jsou identifikovány silné a slabé stránky společnosti, ve vnějším prostředí potom příležitosti a hrozby.

Silné stránky (strengths)	Slabé stránky (weaknesses)
široká nabídka produktů různé objemy použitých lahví používání skleněných vratných lahví tradiční a zavedená značka povědomí o značce v široké veřejnosti řada minerálních vod BIO vysoká grafická úroveň etiket řada ocenění (Klasa, Zlatý pramen)	nevyřešená finanční situace problémy s odběrateli pokles objemu prodeje a tržeb slabší marketing a reklama
Příležitosti (Opportunities)	Hrozby (threats)
nové příchutě růst ekonomiky rozvoj značek BIO	nová konkurence korupce změna (zvýšení) daní finanční válka největších firem odklon spotřebitelů od tradičních příchutí odchod velkých řetězců z ČR

Tabulka 1 - SWOT analýza společnosti Hanácká kyselka s.r.o.
(zdroj: vlastní)

7.3.1 Silné stránky

Široká nabídka produktů je dána především snahou společnosti držet krok s konkurenty a také tím, aby si každý zákazník mohl vybrat produkt, který nejlépe

odpovídá jeho potřebám. Roli také hraje udržování konkurenceschopnosti a reagování na požadavky obchodních partnerů a koncových zákazníků.

Společnost minerální vody plní **do lahví o různých objemech** z důvodu větší konkurenceschopnosti. Tradičně největší procento minerální vody je plněno do lahví o objemu 1,5 litru. Společnost však používá lahve od objemu 0,33 litru až po již uvedený objem 1,5 litru. Na přání obchodního partnera je také schopna zajistit stáčení minerální vody do KEG sudů.

Vzhledem k poptávce některých firem po minerálních **vodách stáčených do skleněných lahvích** společnost tyto lahve využívá. V tomto segmentu trhu má největší postavení. Pravidelnými odběrateli těchto produktů jsou například Třinecké železárny.

Společnost těží ze zavedené a **všeobecně známé značky** Hanácká kyselka, která na trhu působí už poměrně dlouhou dobu. Díky této značce je společnost **pevně zakořeněná v povědomí veřejnosti**.

Vzhledem k požadavku obchodních partnerů byla v roce 2010 uvedena na trh nová **řada minerálních vod s označením BIO**. Společnost tímto reaguje na všeobecně se zvyšující poptávku po těchto produktech. Vzhledem k faktu, že byla s touto řadou na trhu první, měla konkurenční výhodu před konkurencí. Tato výhoda částečně trvá až do současnosti.

Pro společnost jsou velmi významná **udělená ocenění** od odborné veřejnosti na potravinářských veletrzích Salima. Část spotřebitelů nakupuje i podle toho, zda výrobek má udělenou cenu Klasa, která by měla být zárukou kvality produktu. Mezi další získaná ocenění patří pravidelné čelní pozice v každoročně udělovaném ocenění Zlatý Pramen.

7.3.2 Slabé stránky

Společnost si je vědoma svých slabých stránek, které se snaží minimalizovat. Nejvýznamnějším problémem je **neuspokojivá finanční situace** ve společnosti. Díky tomu se společnost nemůže plně rozvíjet.

Společnost také řeší **problémy s odběrateli**, kdy se stává, že díky jejich nezvládnuté logistice si zákazníci stěžují přímo společnosti, která s tím ovšem

nemůže nic dělat. Hrozí tak poškození dobrého jména společnosti. Druhým problémem je velká prodleva mezi dodáním produktů a jejich úhradou od obchodních řetězců. V konečném důsledku to opět zhoršuje finanční situaci podniku. Díky vyjednávací síle těchto odběratelů s tím však společnost mnoho dělat nemůže.

Za posledních několik let dochází k postupnému **snižování objemů prodeje a tedy i tržeb**. Snahou společnosti je tento propad zastavit. Jednou z cest je i dodávání produktu na zahraniční trhy.

Protože společnost nemá mnoho prostředků na **podporu marketingu a reklamy**, vsází především na tradiční značku a všeobecném povědomí široké veřejnosti o společnosti. Přesto by bylo vhodné převzít záštitu, případně sponzorovat některé menší lokální akce, které nejsou tolik nákladné.

7.3.3 Příležitosti

Příležitostí je bezesporu další **rozšiřování produktové řady** o nové produkty. Může se jednat o nové příchutě nebo o zcela novou produktovou řadu, která by mohla společnosti přilákat nové zákazníky.

Signály, které mohou naznačovat **růst ekonomiky**, jsou pro společnost vodítkem, že by mohl v příštích letech dojít k oživení poptávky a růstu tržeb společnosti. Aktuálně je nízká míra nezaměstnanosti, nicméně HDP stagnuje.

Zavedení **produktové řady BIO** se ukazuje jako dobrý krok. Společnost tedy může tuto řadu dále rozvíjet a obohacovat o další příchutě.

7.3.4 Hrozby

Hrozbou může být **vstup nové konkurence**, která se bude orientovat na produkty s nízkou kvalitou a cenou. Díky současné krizi a zvyšování daní je nižší koupěschopnost obyvatelstva, které by se mohlo přiklonit k těmto produktům, což by znamenalo další propad tržeb.

Druhou hrozbou je **korupce**. I přes programové prohlášení a snahu vlády o potírání korupce, je u nás korupce poměrně rozšířená.

Změna soustavy daní, zejména **zvyšování daňové zátěže** ovlivňuje nejenom zvýšení ceny surovin, ale také cenou hladinu a tvorbu cen.

Velkou hrozbou by mohla být **cenová válka** největších producentů. I když je krize a všichni se snaží snižovat náklady, mohlo by dojít k cenovému boji s ohledem na možné zvýšení podílu na trhu.

Velkou hrozbou je **odklon zákazníků od tradičních příchutí** citron a pomeranč, protože tyto dva produkty jsou pro drtivou většinu firem v této oblasti klíčové. Tvoří základ prodeje, na kterých staví nejenom společnost, ale také téměř všichni její konkurenti.

Poslední hrozbou by mohl být **odchod některých velkých řetězců** z ČR (např. v minulosti odešel Julius Meinl). Došlo by opět ke snížení objemu prodeje.

8. Vlastní návrh řešení


Pro praktickou část této diplomové práce je použit program MATLAB, konkrétně jeden z jeho mnoha toolboxů. Nazývá se ntstool → "Neural network time series tool". Tento toolbox je určen pro řešení dynamických neuronových sítí s možností predikce časových řad. Obsahuje celkem tři modely, a to Nonlinear Autoregressive with External (Exogenous) Input (NARX), Nonlinear Autoregressive (NAR) a Nonlinear Input-Output. V této práci jsou využité ze tří dostupných pouze dva modely → NAR a NARX.

Nejprve je využit model NAR, který je schopný predikce na základě historických hodnot časové řady, poté model NARX, který k těmto hodnotám přidává další exogenní (vnější) vstupy.

Oba dva modely (NAR a NARX) používají data o kurzech měn z internetu (finance.yahoo.com), kde jsou uvedené kurzy měn i několik let zpětně. Data použitá k predikci jsou historické hodnoty kurzu české koruny vůči americkému dolaru.

9. Nonlinear Autoregressive model (NAR)


Nonlinear Autoregressive model (česky nelineární auto-regresní model) umí trénovat neuronovou síť pomocí historických hodnot vybraného kurzu. Pomocí těchto hodnot také dokáže předpovědět budoucí hodnoty časové řady zvoleného kurzu. Základní schéma modelu je zobrazeno na následujícím obrázku.



Obrázek 4 - Základní schéma modelu NAR

(Zdroj: program Matlab, toolbox ntstool)

Mějme časovou řadu $y(t)$ s počtem hodnot d , pak lze model popsat následujícím vztahem $y(t) = f(y(t-1), \dots, y(t-d))$. Tento model je graficky zachycen na obrázku 4. Pro dané konkrétní případy je vhodné tento základní model zobrazit podrobněji (viz Obrázek 5).



Obrázek 5 - NAR model s 10 neurony

(Zdroj: program Matlab, toolbox ntstool)

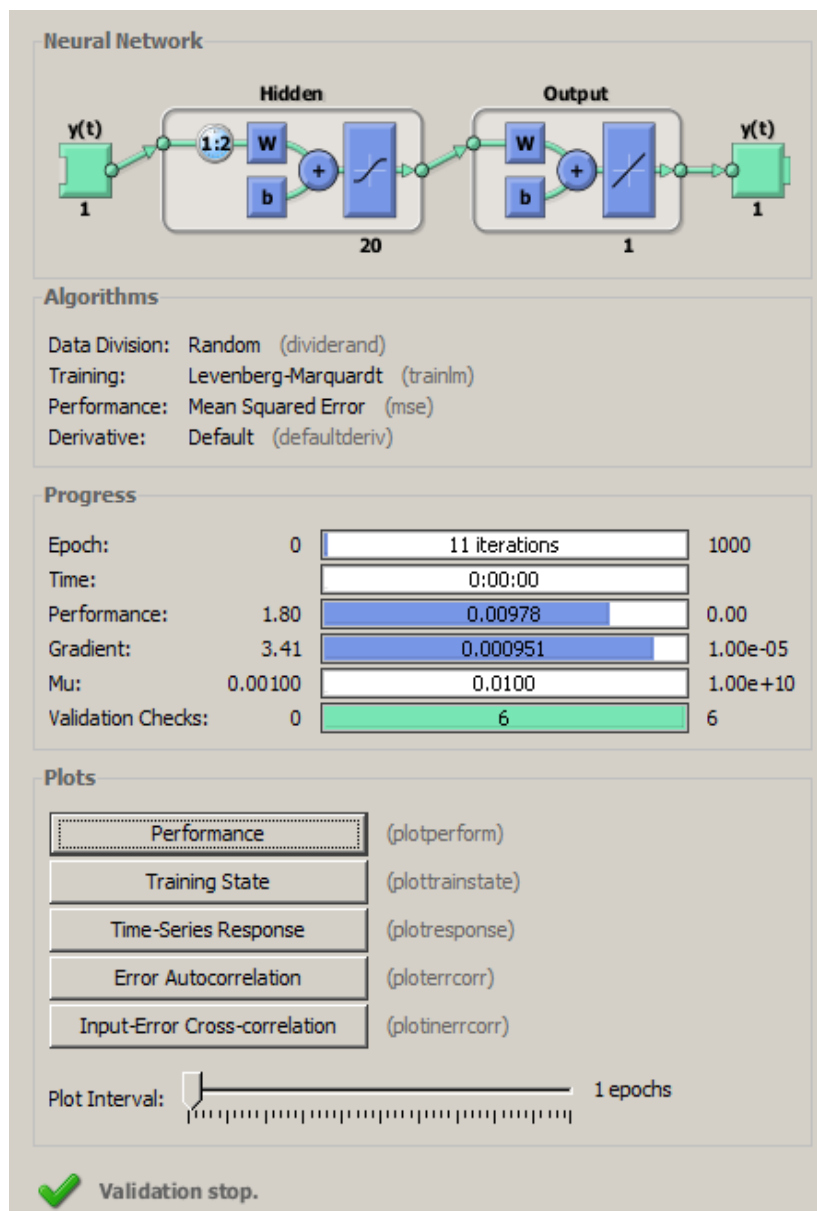
Na obrázku 5 je zobrazeno nastavení zpoždění, počet neuronů ve skryté vrstvě, výstupní vrstva a typy transformačních funkcí jednotlivých vrstev a samozřejmě vstup a výstup.

Samotný proces modelování probíhá v několika krocích. Množina dat je rozdělena náhodným výběrem na 3 skupiny. 70 procent dat slouží k natrénování

sítě, 15 procent dat slouží k validaci, která kontroluje generalizaci sítě a v případě, že se model dále nevylepší, pak může trénink sítě zastavit, a zbylých 15 procent dat slouží k nezávislému testování neuronové sítě. Dále je možné nastavit delay (zpoždění), kde si síť může ukládat stanovený počet předchozích hodnot.


Pro trénink sítě je využit jeden z nejpoužívanějších algoritmů - Levenberg-Marquardt algoritmus. Chyba je měřena středními kvadratickými chybami (anglicky MSE - Mean Squared Error).

Na následujícím obrázku (obrázek 6) je ukázáno samotné trénování sítě. V tomto případě se testování ukončilo v jedenácté iteraci, jelikož nebyla snížena chyba při validaci pod šest iterací (položka Validation Check). Na obrázku je také vidět jakým stylem byla rozdělena data (Data Division), délka tréninku (Time) a je zde možno zobrazit další grafy.




Obrázek 6 - Trénink neuronové sítě u modelu NAR
(Zdroj: program Matlab, toolbox ntstool)

Na dalším obrázku (Obrázek 7) je vykreslený graf, který ukazuje, zda nedošlo k přetrénování neuronové sítě. Střední kvadratická odchylka u validace, tréninku i testování postupně klesala až do páté iterace, a protože se nijak výrazně nezvýšila ani u jedné z křivek v dalších iteracích, lze tvrdit, že nedošlo k přetrénování neuronové sítě.



Obrázek 7 - Graf střední kvadratické chyby (MSE)
(Zdroj: program Matlab, toolbox ntstool)

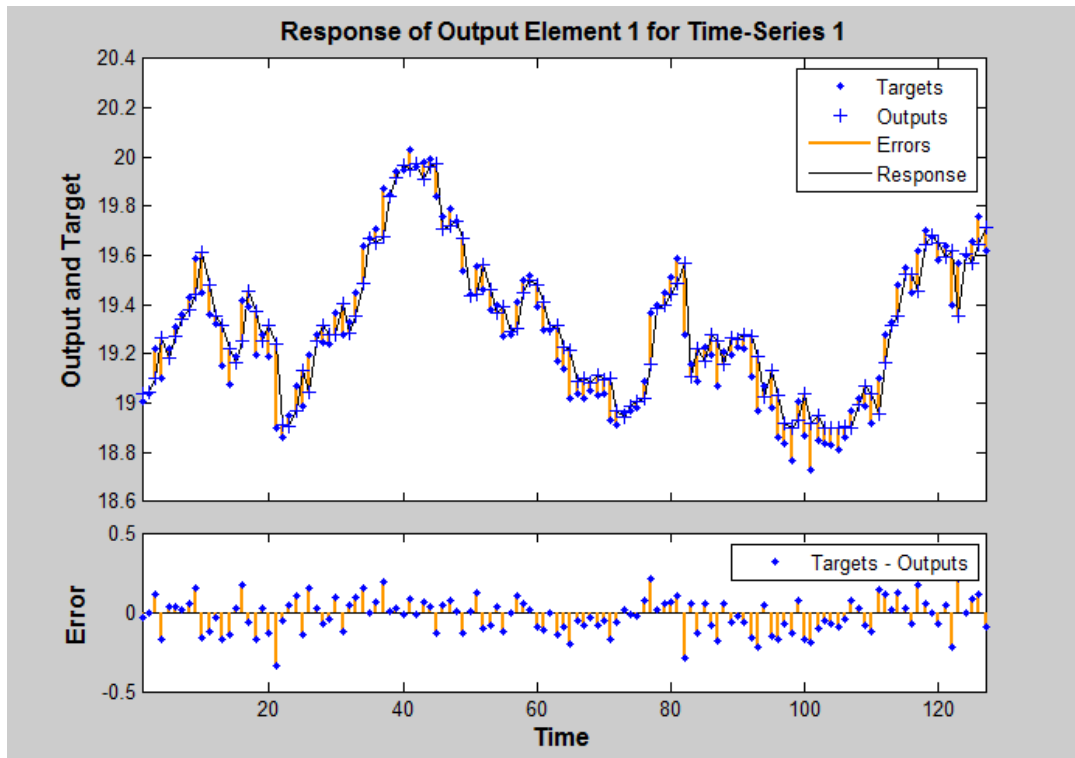
Dalším krokem je samotná predikce, bylo tedy odstraněno zpoždění. Tato "nově" vytvořená neuronová síť dává totožné hodnoty jako předchozí síť. U předchozí sítě byly hodnoty posunuty podle velikosti zpoždění směrem doleva. Graficky predikční neuronovou síť zachycuje následující obrázek.



Obrázek 8 - Schéma predikčního modelu NAR s 20 neurony
(Zdroj: program Matlab, toolbox ntstool)

Výslednou predikční funkci neuronové sítě zachycuje graf na obrázku 9. Je zde zachycena velikost rozdílu mezi skutečnými a predikovanými hodnotami na

celém průběhu funkce. Ve spodní části obrázku je pak ukázána velikost chyby v jednotlivých bodech predikce.



Obrázek 9 - Korelace hodnot časové řady a hodnot predikce u NAR modelu
(Zdroj: program Matlab, toolbox nstool)

V příkazovém okně programu Matlab (Command Window) je zobrazen slovní výstup modelu (obrázek 10).

```
PREDIKOVANI UZIVATELEM ZVOLENEHO KURZU

Zkratky jednotlivych ukazatelu jsou k dispozici na webové adrese Finance Yahoo.com.
Například:
CZK=X - Kurs ceske koruny k americkemu dolaru
a podobne

Zadej zkratku ukazatele, se kterym se bude pracovat a stiskni klávesu ENTER: CZK=X
Zadej den, pro který se bude predikovat hodnota! Datum zadej ve formátu MM-DD-RRRR a stiskni klávesu ENTER:04-02-2013

Hodnota je predikována k (datum, zvoleny ukazatel, hodnota ukazatele):
'03-Apr-2013' 'CZK=X' [20.0745]
```

Obrázek 10 - Slovní výstup modelu NAR
(Zdroj: program Matlab)

K tréninku neuronové sítě byla použita data z yahoo. Konkrétně se jednalo o vývoj kurzu české koruny k americkému dolaru. Predikován byl vývoj tohoto kurzu za celý měsíc březen roku 2013. Jediný parametr sítě, který se měnil, byl počet neuronů ve skryté vrstvě. Bylo zvoleno 10, 20, 50 a 100 neuronů, z toho tedy vyplývá, že byly porovnávány 4 různé NAR modely.

9.1 Vyhodnocení NAR modelu

Ve skutečnosti není vytvořen žádný univerzální NAR model, který by dosahoval nejlepších výsledků při predikci zvoleného finančního nástroje. Proto se nabízí možnost optimalizování modelu pro odhad vývoje kurzu měn (či dalších finančních nástrojů).

Samotné vyhodnocení probíhalo následujícím způsobem. Byly vytvořeny 4 NAR modely, každý z nich obsahoval jiný počet neuronů ve skryté vrstvě, konkrétně 10, 20, 50 a 100 neuronů. U každého modelu byla provedena predikce vývoje kurzu české koruny (CZK) vůči americkému dolaru (USD) každý obchodní den v měsíci březnu roku 2013. Potřebná historická data pro predikci jsou k dispozici na serveru Yahoo.

Na začátku měsíce března měl každý model k dispozici na virtuálním účtu \$1000. V průběhu měsíce se při predikci rostoucího kurzu dolary směnily za koruny, naopak při predikci poklesu kurzu se dolary směnily zpět na koruny. Pokud poslední den zůstaly na účtu české koruny, byly převedeny na dolary podle kurzu posledního dne.

Získané predikované hodnoty kurzu byly také porovnány s hodnotami reálného kurzu v daný den. Dále byla zjišťována odchylka mezi predikovanými a reálnými hodnotami. Výsledky byly souhrnně vyneseny do následující tabulky.

Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,105 - 1,848	42,86	1002,58
20	0,215 - 2,127	42,86	1016,38
50	0,136 - 3,976	66,67	993,45
100	0,056 - 5,044	61,91	1002,86

Tabulka 2- Vyhodnocení modelu NAR

Z tabulky 2 je patrné, že nejlepšího výsledku dosáhl model s 20 neurony i přes poměrně nízkou úspěšnost predikce. Je to způsobeno tím, že model dokázal predikovat největší ztráty a nárůsty kurzu během března. Naopak ve dnech kdy se kurz příliš neměnil, predikoval opačný trend. Proto si nepřipsal příliš velké ztráty. Naopak model s nejvyšší úspěšností predikce (50 neuronů), predikoval ve dnech největšího růstu a poklesu kurzu opačný trend, čímž si připsal ztrátu. Zbylé dva modely jsou jen mírně ziskové.

Pokud by byly srovnány výsledky modelů s pasivní investicí, pak by byly všechny modely lepší. Pasivní investice vykázala na konci měsíce hodnotu cca \$983.

9.2 Možnosti optimalizování modelu NAR

Jelikož není definován žádný NAR model, který by byl nejvhodnější, nejlepší nebo všestranně použitelný pro všechny situace, nabízí se použití optimalizace. Program Matlab disponuje množstvím funkcí a nastavení, kterými lze model modifikovat. Je silně doporučeno brát na zřetel fakt, že se všechna nastavení, vlastnosti, výhody a nevýhody jednotlivých funkcí mohou na výsledku projevit nejen žádoucím, ale i nežádoucím způsobem.

Je možné optimalizovat:

- a) model
- b) použitá data

9.2.1 Možnosti optimalizace vlastností modelu

- Architektura - zde můžeme nastavit počet vrstev, jejich typy (skryté, ...) a způsob jejich vzájemného propojení
- Funkce - říkají, jak se model adaptuje, trénuje nebo spouští a také jak se měří výkonnost modelu
- Účinnost - sem patří nastavení paměti, jednou z nich je například vyrovnávací paměť, která počítá zpožděné vstupy.
- Obecná rovina- sem patří název modelu neuronové sítě, informace o něm a podobně.

Během testování modelu NAR byla využita pouze jedna možnost optimalizace modelu, a tou bylo nastavení počtu neuronů ve skryté vrstvě. Vyšší množství neuronů zlepšuje u modelu pružnost, díky většímu počtu neuronů má síť k dispozici více parametrů, které lze optimalizovat. Ovšem je nutné přihlížet i k množině dat, počet dat by mělo být v určitém poměru k počtu neuronů. Pokud by byl větší počet neuronů než dat, dávala by síť na výstupu zkreslené výsledky. Síť by nastavovala a optimalizovala více parametrů než by bylo samotných dat. Naopak pokud by bylo neuronů malé množství oproti velkému množství dat, pak by síť neměla dostatek parametrů k optimalizaci a výsledky by byly opět nepřesné.

V teoretické části bylo zmíněno několik přenosových funkcí (kapitola 3.5). Programové prostředí MATLAB ale disponuje širším spektrem těchto přenosových funkcí. Ne všechny z těchto funkcí jsou ale univerzálněji použitelné a některé se téměř nepoužívají. V případě algoritmů určených pro trénink neuronových sítí je situace obdobná. Program MATLAB jich má k dispozici více než 20, ale nejvíce se používá Lavenberg-Marquardt algoritmus (používá backpropagation). Pokud je tento algoritmus nevyhovující, je možné použít samozřejmě některý další, například Batch training, který upravuje nastavení vah. kromě automatického nastavení paramterů (vah), je samozřejmě možné nastavit váhy a parametry výkonu sítě manuálně, ovšem v případě nevhodného nastavení může docházet k přeučení sítě. Obecně je proto jednodušší, výhodnější a vhodnější využít některý z algoritmů.

Při ponechání defaultního nastavení trénování sítě je zvolen Lavenberg-Marquardt algoritmus (označení `trainlm` v nápovědě MATLABu). Jedná se o jeden z nejrychlejších backpropagation algoritmů, ve kterém je možné nastavit více než 10 parametrů. Mezi nejdůležitější patří:

- `net.trainParam.epochs` - maximální počet iterací (defaultně 100)
- `net.trainParam.max_fail` - maximální počet chyb při validaci (defaultně 5)
- `net.trainParam.time` - maximální čas pro trénink sítě
- `net.trainParam.goal` - cílový výkon sítě

Nahlížení na chyby

Sice se nejedná o přímo o optimalizaci modelu, ale je vhodné vědět, že program Matlab nabízí několik způsobů, jak pohlížet na chyby. U některých algoritmů je měření chyb rozdílné než u jiných. Nejčastěji se používají následující způsoby:

- Průměrná střední kvadratická chyba (Mean Squared Error MSE)
- Průměrná absolutní chyba (Mean Absolute Error MAE)

9.2.2 Možnosti optimalizace použitých dat

NAR model používá jenom historická data ekonomický, investičních, finančních a dalších nástrojů. Z toho plyne, že záleží především na počtu použitých dat a jejich trendu. Data, která jsou použita v modelech, jsou stažena ze serveru yahoo.com a jedná se o data za cca polovinu roku. Ve výsledku se tedy jedná o data za zhruba 130 obchodních dnů.

Počet dat určených k trénování sítě vyplynul z tvorby mého modelu. Kurzy nemají relativně příliš vysoké kolísání hodnot, proto je vhodné vzít data ze zhruba středně dlouhého časového úseku. Pokud by byla zpracovávána data s velkým kolísáním hodnot, je možné snížit délku časového úseku (a tím i počet dat) tak, aby na tomto daném časovém úseku hodnoty dat příliš nekolísaly. Druhou možností je naopak "vzít" data určená k tréninku neuronové sítě z dlouhého časového úseku, kde je možné odhalení souvislostí a zákonitostí, které vyplývají přímo z analýzy daného odvětví, neboli jsou pro dané odvětví typické a běžné a tomu přizpůsobit předpověď budoucího vývoje.

Samotná data, která jsou získána z určitého časového období, se rozdělí při tvorbě neuronové do tří skupin:

- a. data určená pro trénink
- b. data určená pro validaci
- c. data určená pro testování

V mém případě jsem ponechal defaultní nastavení Matlabu, tedy 70 procent dat pro trénink a shodně po 15 procentech pro validaci a testování. Matlab umožňuje několik možností, jak data do těchto skupin rozdělit:

- dividerand - nejpoužívanější způsob, data jsou rozdělována do skupin náhodným výběrem
- divideint - data jsou do jednotlivých skupin rozdělována intervalově automaticky
- divideind - data jsou do jednotlivých skupin rozdělována manuálně dle nastavených intervalů
- divideblock - data jsou dělena do souvislých bloků (první blok dat je určen pro trénování sítě, druhý blok dat je určen pro validaci a třetí blok dat je určen pro testování)

9.3 Shrnutí a zhodnocení NAR modelu

Predikční NAR model je velmi rychlý a elegantní nástroj pro odhad vývoje trendu zvoleného finančního nástroje. I přesto, že je poměrně jednoduchý, existuje velké množství možností, jak upravit jeho kód nebo použité algoritmy a funkce. Tyto změny by měly být prováděny tak, aby vedly ke zlepšení a zpřesnění odhadu vývoje. Hledání takového ideálního nastavení je však velmi časově náročné, zejména díky velkému množství různých kombinací.

Mezi nevýhody modelu patří skutečnost, že NAR model umí pracovat jen s omezenou délkou dat, která pro určité typy finančních ukazatelů a nástrojů nemusí stačit. Model tedy nedokáže zachytit například sezónní vlivy nebo vlivy, kterými se zabývá fundamentální analýza. Model, optimalizovaný pro určitý finanční nástroj, by měl být jedním z několika prostředků a zdrojů informací, které budou využity pro rozhodování.


Vlastní kód modelu je uveden v příloze. Je v něm množství poznámek, které umožňují zkušenějšímu uživateli provést případné změny v modelu. Jedná se například o stanovení vlastního počtu neuronů ve skryté vrstvě, zobrazení dalších grafů, změna rozdělení dat určených pro testování, validaci a trénink sítě, změna tréninkového algoritmu a další úpravy.

10. Nonlinear Autoregressive Model with External (Exogenous) Input (NARX)

Nonlinear Autoregressive Model with External (Exogenous) Input (česky Nelineární auto-regresní model s vnějšími vstupy) je dokonalejší podoba předchozího modelu NAR. Vyšší přesnosti se zde dosahuje pomocí vnějšího vstupu(vstupů). Mezi používané exogenní vstupy se používají prostředky technické analýzy, které jsou uvedené a podrobněji popsány v příslušné kapitole v této práci. Zde uvádím pro připomenutí jejich výčet:

- Klouzavé průměry (Moving average)
- MACD (Moving Average Convergence Divergence)
- ROC (Rate of Change)
- Relative Strength Index (RSI)
- Stochastik
- WilliamsR


Model NARX se dá popsat matematicky popsat následujícím způsobem. Mějme časovou řadu $y(t)$, a jinou časovou řadu $x(t)$, jež je vnějším vstupem, přičemž výsledný počet označíme d , pak můžeme matematicky zapsat: $y(t) = f(x(t-1) \dots x(t-d), y(t-1) \dots y(t-d))$. Graficky je model znázorněn na následujícím obrázku.



Obrázek 11 - Schéma NARX modelu
(Zdroj: program Matlab, toolbox ntstool)

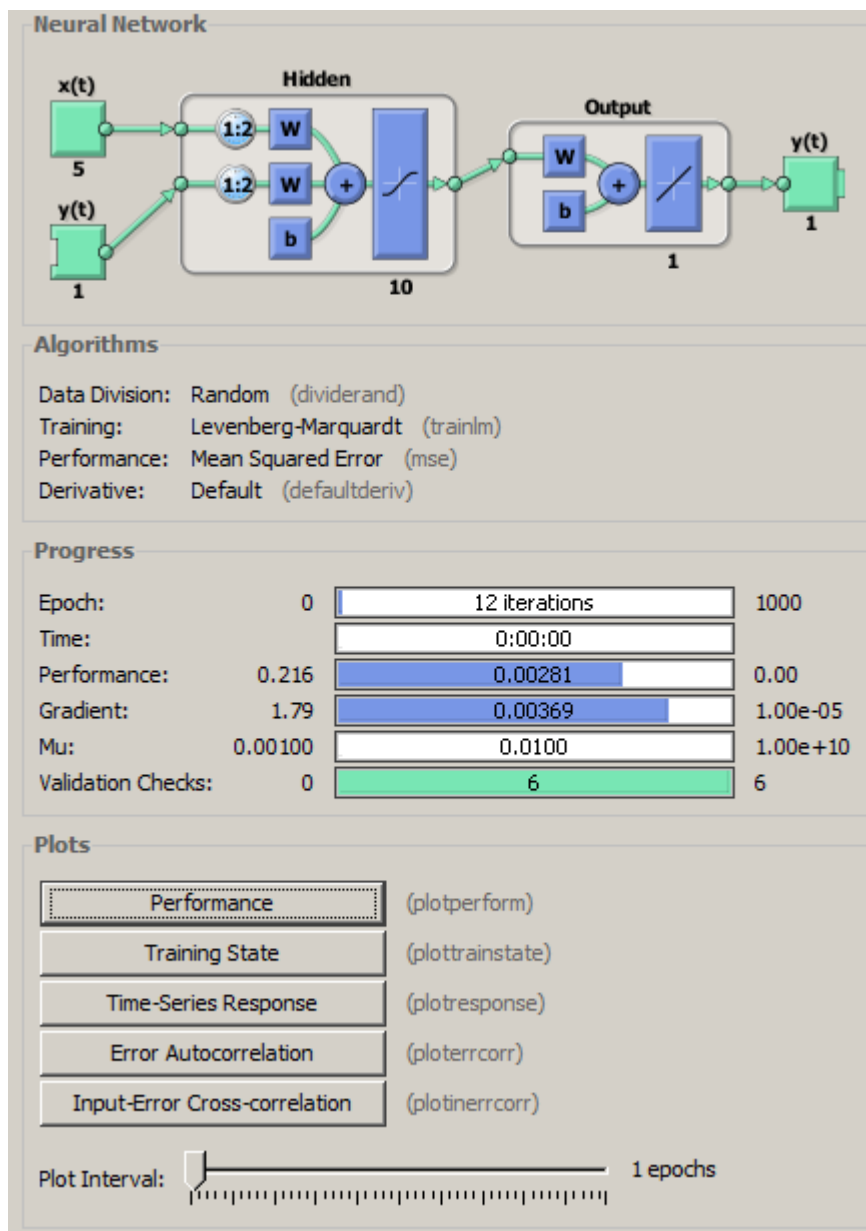
Stejně jako u modelů NAR se v daných případech rozšířené grafické schéma od základního liší. Rozšířené grafické schéma je detailnější a přesnější. Stejně jako

u modelů NAR zobrazuje nastavení zpoždění, počet neuronů ve skryté vrstvě a transformační funkce neuronů v jednotlivých vrstvách. Navíc zobrazuje počet exogenních vstupů, se kterými neuronová síť dále pracuje (obrázek 11).




Obrázek 12 - Model NARX s 20 neurony a 5 exogenními vstupy
(Zdroj: program Matlab, toolbox ntstool)

Tvorba neuronové sítě je stejná jako u modelu NAR. Samotná data jsou rozdělena náhodným výběrem tak, že 70 % dat je určeno k tréninku sítě, 15 % dat k validaci sítě a zbylých 15 % dat k testování sítě. Algoritmus pro trénink sítě byl vybrán Levenberg-Marquardt, velikost chyby je určena metodikou MSE. Velikost zpoždění je nastavena také stejně jako u modelu NAR, a to na 2 kroky.



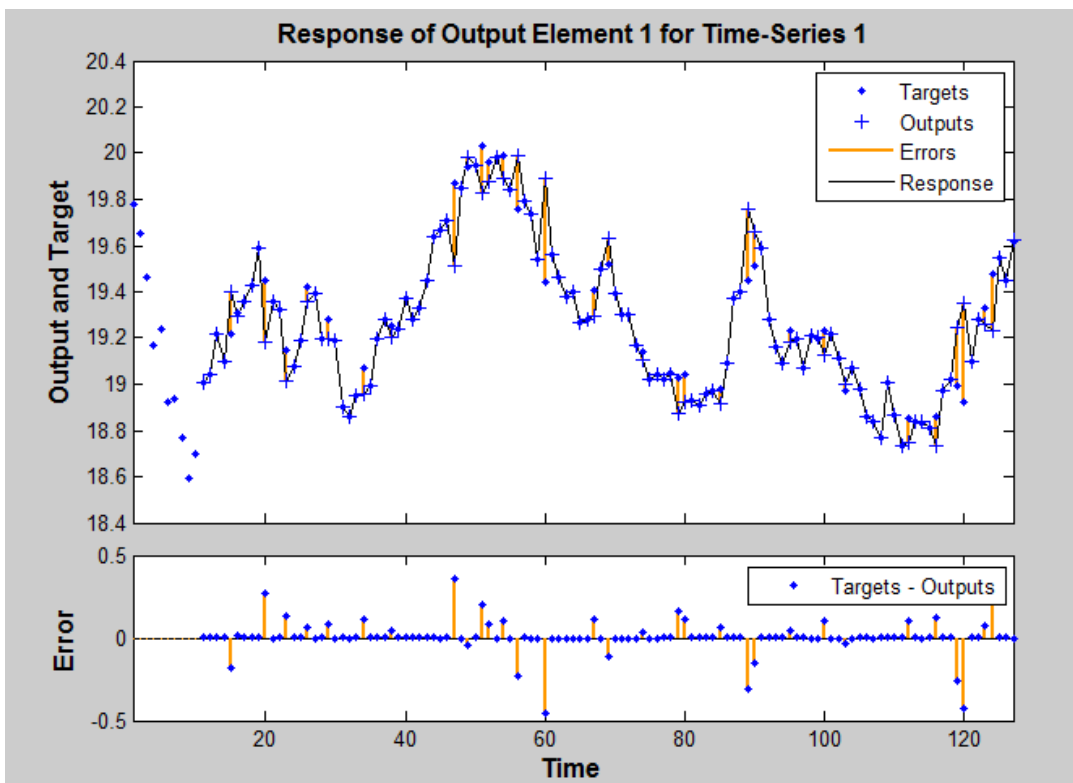
Obrázek 13 - Trénink neuronové sítě u modelu NARX
(Zdroj: program Matlab, toolbox nstool)

Následně je zobrazen graf, který ukazuje zda nedošlo k přetrénování sítě. Pak následuje samotné predikování, schéma neuronové sítě pro predikci je zobrazeno na dalším obrázku.



Obrázek 14 - Schéma predikčního modelu NARX
(Zdroj: program Matlab, toolbox ntstool)

Další obrázek ukazuje graf, kde jsou vyneseny skutečné a predikované hodnoty časové řady. Ve spodním okně jsou zobrazeny chyby predikce a jejich velikost. Na rozdíl od podobného obrázku u modelu NAR nejsou vyneseny predikované hodnoty v levé části grafu. To je způsobeno nedostupností hodnot z technické analýzy. Není to tedy chyba.



Obrázek 15 - Korelace hodnot časové řady a hodnot predikce u NARX modelu
(Zdroj: program Matlab, toolbox ntstool)

Poslední obrázek zachycuje slovní popis k predikci. Slovní popis je vložen ze stejných důvodů jako u NAR modelu - přehlednost, číselný podklad.

```
PREDIKOVANI UZIVATELEM VYBRANEHO KURZU

Zkratky jednotlivych ukazatelu jsou k dispozici na webové adrese Finance Yahoo.com.
Například:
CZK=X - Kurs české koruny k americkému dolaru
a podobně

Zadej zkratku ukazatele, se kterým se bude pracovat a stiskni klávesu ENTER: CZK=X
Zadej den, pro který se bude predikovat hodnota! Datum zadej ve formátu MM-DD-RRRR a stiskni klávesu ENTER:03-01-2013

Hodnota je predikována k (datum, zvoleny ukazatel, hodnota ukazatele):
'02-Mar-2013' 'CZK=X' [19.5565]
```

Obrázek 16 - Slovní popis modelu NARX

10.2 Vyhodnocení NARX modelu

Ani v případě NARX modelu neexistuje žádný univerzální model. Proto je vhodné stejně jako u předešlého NAR modelu provést optimalizaci tohoto modelu.

Vyhodnocení jednotlivých typů modelu NARX probíhalo v podstatě stejně jako u NAR modelu. Hodnotily se 4 páry modelů, které měly různě nastavené exogenní vstupy. Modely se stejnými vstupy měly navíc různé počty neuronů ve skryté vrstvě - 10, 20 a 50. U každého modelu byla provedena predikce vývoje kurzu české koruny (CZK) vůči americkému dolaru (USD) každý obchodní den v měsíci březnu roku 2013. Potřebná historická data byla opět získána ze serveru Yahoo. Na začátku března měl každý model k dispozici \$1000 a na základě predikce byly prováděny prodeje a nákupy amerických dolarů a českých korun při dodržování stejných pravidel jak v případě NAR modelu. Výsledky predikce byly porovnány s reálným kurzem. Pro porovnání je třeba následující hodnota:

- Pokud by byla provedena jen pasivně vedená investice, pak by na konci měsíce bylo na virtuálním účtu cca \$983.

Jako exogenní vstupy byly vždy u každého modelu připojeny i další dostupné hodnoty kurzu z jednotlivých dní - Open, High a Low hodnoty, ostatní exogenní vstupy technické analýzy jsou u jednotlivých dvojic tabulek různé.

Dvojice tabulek mají vždy stejné exogenní vstupy, jen s rozdílem kroku 5 a 10 u ukazatelů technické analýzy.

Jako první byly testovány modely se čtyřmi vstupy technické analýzy, především byly použity klouzavé průměry. Výsledky zobrazuje následující dvojice tabulek.

Vstupy technické analýzy: MA5, MACD, ROC5 RSI5			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,015 - 2,137	71,43	1000,28
20	0,015 - 2,577	66,67	994,85
50	0,005 - 2,014	61,91	969,7

Tabulka 3 - NARX model se dvěma indikátory technické analýzy

Vstupy technické analýzy: MA10, MACD, ROC10, RSI10			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,005 - 3,404	61,91	994,57
20	0,085 - 3,606	61,91	996,44
50	0,045 - 2,121	61,91	1001,51

Tabulka 4 - NARX model se dvěma indikátory technické analýzy

Všechny modely z tabulek 3 a 4 mají poměrně vysokou úspěšnost predikce. Nejhoršího výsledku dosáhl model z tabulky 3 s 50 neurony. Tento model predikoval špatný trend ve dnech s nejvyšším kolísáním kurzu, proto si připsal vysokou ztrátu, jednu z nejvyšších ze všech modelů. Tato ztráta může být způsobena vyšším počtem neuronů, kdy síť svoje výsledky generalizovala. Celkově ovšem ani jeden model nedosáhl dobrého výsledku a proto se příliš nehodí ani k případné další optimalizaci.

Další dvě tabulky ukazují výsledky modelů se vstupy klouzavých průměrů, exponenciálních klouzavých průměrů, MACD, RSI indexu, Stochastiku a Williams%R indikátoru.

Vstupy technické analýzy: MA5, ExMA5, MACD, Williams%5, Stoch, RSI5			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,005 - 2,119	57,14	1016,61
20	0,07 - 1,806	57,14	1009,89
50	0,041 - 4,141	66,67	981,55

Tabulka 5 - NARX model se vstupy MA5, ExMA5, MACD, Williams %R5, Stoch, RSI5

Vstupy technické analýzy: MA10, ExMA10, MACD, Williams%R10, Stoch, RSI10			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,041 - 2,579	47,62	967,56
20	0,102 - 1,792	61,91	1002,17
50	0,081 - 2,150	80,95	1005,7

Tabulka 6 - NARX model se vstupy MA10, ExMA10, MACD, Williams %R10, Stoch, RSI10

Nejlepšího výsledku dosáhl model s 10 neurony a krokem 5 u indikátorů technické analýzy (tabulka 5). Tento model nemá příliš velkou úspěšnost predikce, nicméně dokázal předpovědět správný trend vývoje kurzu pro dny, kdy se kurz výrazněji (skokově) změnil. Ztráty utrpěl převážně ve dnech kdy se kurz měnil jen minimálně. Je dobře patrné, že s vyšším počtem neuronů klesala výnosnost, přičemž míra úspěšnosti se příliš nezměnila.

V tabulce 6 je situace opačná. Největších ztrát dosáhl kurz s 10 neurony, kterou pravděpodobně způsobil malý počet neuronů. Tento model má míru úspěšnosti predikce pod 50 procenty, naopak model s 50 neurony má úspěšnost predikce jednu z nejvyšších ze všech modelů - více než 80 %. Přesto si připsal dvě citelné ztráty, proto má na svou vysokou úspěšnost poměrně malý výnos. Optimalizace obou modelů by mohla spočívat např. ve změně parametrů klouzavých průměrů, nebo případně vyřazením jedné z OHLC hodnot.

Následující dvě tabulky ukazují výsledky modelů, kde jsou využity zejména oscilátory.

Vstupy technické analýzy: ExMA5, RSI5, Williams%R5, Stoch			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,035 - 2,104	61,91	979,42
20	0,12 - 2,906	71,43	988,56
50	0 - 2,85	61,91	994,72

Tabulka 7 - NARX model se vstupy ExMA5, RSI5, Williams %R5, Stoch

Vstupy technické analýzy: ExMA10, RSI10, Williams%R10, Stoch			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,076 - 1,766	71,43	1001,82
20	0,035 - 2,261	66,67	995,55
50	0,015 - 2,289	80,96	1015,64

Tabulka 8 - NARX model se vstupy ExMA10, RSI10, Williams %R10, Stoch

Modely s indikátory technické analýzy s krokem 5 uvedené v tabulce 7 jsou poměrně ztrátové, i přes poměrně úspěšnou predikci. Ztráty přinesly, stejně jako u některých předchozích modelů, špatné predikce na dny s největším kolísáním kurzu. Důvodem může být použití především oscilátorů.

U tabulky 8 je situace opačná, kromě modelu s 20 neurony, který je ztrátový. Zbylé dva modely mají vysokou úspěšnost predikce a oba jsou ziskové. Model s 50 neurony dosáhl jednoho z nejlepších výsledků ze všech modelů a byl označen za optimální model. Jeho případná optimalizace by mohla spočívat v nastavení jiného indikátoru klouzavých průměrů.

Poslední dvě tabulky zobrazují výsledky modelů jen se dvěma indikátory technické analýzy - ExMA a ROC.

Vstupy technické analýzy: ExMA5, ROC5			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,050 - 1,913	71,43	981,25
20	0,035 - 1,931	61,91	978,73
50	0,081 - 1,408	66,67	1013,55

Tabulka 9 - NARX model se vstupy ExMA5, ROC5

Vstupy technické analýzy: ExMA10, ROC10			
Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,081 - 2,216	52,38	984,23
20	0,071 - 2,625	52,38	987,59
50	0,329 - 3,310	47,62	994,74

Tabulka 10 - NARX model se vstupy ExMA10, ROC10

První dva modely z tabulky 9 jsou ztrátové, přestože mají dobrou míru úspěšnosti predikce. Největší ztráty modely zaznamenaly na konci měsíce, kde byla

soustředěna chybovost predikce. Může za to pravděpodobně malý počet neuronů, vzhledem k výsledku třetího modelu s 50 neurony, který dosáhl vysokého zisku. Jeho optimalizace by mohla spočívat v přidání dalšího ukazatele technické analýzy na exogenní vstup.

Modely z tabulky 10 vykazují všechny ztrátu a úspěšnost se pohybuje pouze kolem 50 procent. Je to způsobeno patrně krokem indikátorů technické analýzy.

10.3 Možnosti optimalizování NARX modelu

Možnosti optimalizace modelu NARX jsou podobné jako u modelu NAR. Optimalizována tedy mohou vstupní data a také nastavení samotného modelu. Výstupní nastavení po optimalizaci je ovšem možné použít jen na stejný konkrétní nástroj pro který byl model optimalizován. Optimalizaci je vhodné provést i díky neexistence žádného univerzálního modelu.

10.3.1. Možnosti optimalizace modelu

Stejně jako u NAR modelu lze NARX model optimalizovat ve dvou úrovních:

- Nastavení paměti - náročnost výpočtu stoupá s délkou použitých časových řad, proto je vhodné při dlouhých časových řadách (mnoho hodnot) toto nastavení provést
- Nastavení architektury sítě - je možné nastavit počet neuronů ve skryté vrstvě, samotný počet vrstev, aktivační a tréninkové funkce, algoritmus sítě, rozdělení dat, nebo třeba měření chyb.

10.3.2 Možnosti optimalizace vstupních dat

Jednou z možností, jak optimalizovat vstupní data, je počet těchto dat. Počet dat a tedy délka časové řady záleží na tom, pro který nástroj je model optimalizován. Velikost intervalu se odvíjí od volatility zvoleného nástroje. Pokud

je nástroj velmi volatilní je vhodné buď prodloužit délku intervalu, aby neuronová síť měla k dispozici větší množství dat a nebo naopak dlouhou časovou řadu rozdělit na několik kratších intervalů a s nimi dále pracovat. Pro nástroje, kde je volatilita poměrně nízká, stačí použít historická data za posledních několik měsíců.

Další možností, kterou model NARX nabízí, je využít optimalizace vstupních indikátorů technické analýzy. Tyto indikátory jsou přivedeny na exogenní vstup neuronové sítě a měly by se vztahovat k dané časové řadě, resp. měly z ní vycházet. Indikátorů technické analýzy existuje několik, proto existuje velké množství nejrůznějších kombinací těchto indikátorů, u kterých je navíc možnost nastavení dalších parametrů. Díky tomu je velmi obtížné a časově nesmírně náročné dospět k nějakému nejideálnějšímu modelu. Parametry, které lze nastavit u indikátorů technické analýzy:

- Klouzavé průměry (MA, MACD, ...) - lze zvolit několik typů klouzavých průměrů (jednoduché, exponenciální,...), s parametrem nastavení zpoždění (prodlevy), který určuje počet předchozích dat, ze kterých se průměr následně počítá
- Index relativní síly (RSI) - lze nastavit hodnotu periody použití datových bodů
- Míra změny (ROC) - lze nastavit změnu počtu předchozích datových bodů, hodí se zejména pro dlouhé časové řady
- Stochastické oscilátory - dělí se na dva druhy, první druh (Fast) využívá nejvyšší hodnotu (High) a druhý (Slow) naopak nejnižší (Low). U každé je dále možné nastavit doby použití datových bodů a způsob získání klouzavých průměrů.

Tyto indikátory technické analýzy se v MATLABU nachází pod Financial toolboxem. Tento toolbox také obsahuje mnoho funkcí pro výpočet těchto indikátorů. Díky tomu ale silně vzrůstá obtížnost a náročnost optimalizací, protože existuje velké množství potenciálních kombinací. Indikátory technické analýzy jsou si navíc podobné. Je tedy nutné brát na zřetel jakou kombinaci zvolit, protože špatná kombinace nebo větší počet těchto indikátorů může negativním způsobem ovlivnit predikci.

10.4 Shrnutí a zhodnocení NARX modelu

NARX model je poměrně rychlý algoritmus, který je schopen dosáhnout velké úspěšnosti při predikci trendu vybraného nástroje. Hodnota úspěšnosti může přesáhnout i 80 %, ovšem k jejímu dosažení je nutné model vhodně optimalizovat a ani tak tato úspěšnost není zaručena.

Pokud srovnáme úspěšnost a profitabilitu modelů, tak je zřejmé, že pokud je úspěšnost vyšší, pak je dosažení zisku velmi pravděpodobné, což znamená, že není nutné mít model s extrémně vysokou úspěšností odhadu. Ztrátové výsledky u modelů s úspěšností kolem 60 % mohou být způsobeny i náhodnými jevy, např. rozdělením dat a následným tréninkem a validací sítě.

Z tabulek jednotlivých modelů lze vypočítat i poměrně přesné odhady skutečných hodnot, v jednom případě dokonce model přesně "trefil" kurz následujícího dne. Nicméně ani vyšší odchylky nepopisují přímo chybovost modelu, neuronová síť zjistila růstový nebo poklesový trend.

K výhodám tohoto modelu patří jednoznačně poměrně snadné nastavení vstupů, jejich parametrů a parametrů neuronové sítě.

Asi největší nevýhodou modelu je absence univerzálního nastavení modelu v kombinaci s velkým množstvím indikátorů technické analýzy, které navíc mívají často několik parametrů. Indikátory technické analýzy se navíc mohou různě kombinovat, díky tomu je k dispozici velké množství variant. Proto je sestavení optimálního modelu pro daný nástroj velmi časově náročné a občas se optimální řešení nalézt nepodaří.

Závěr

Tato diplomová práce je zaměřena na predikci ukazatelů na finančních trzích. Konkrétně zde byl použit kurz české koruny vůči americkému dolaru.

V teoretické části je popsán neuron jako základní stavební kámen neuronových sítí. Dále následují kapitoly zaměřené na neuronové sítě (jejich druhy, metody učení,...). Další kapitoly se věnují technické analýze, časovým řadám a aplikaci MATLAB, ve které byly modely sestaveny. Samostatná část je pak věnována firmě.

V praktické části byly sestaveny a testovány dva modely NAR a NARX, u kterých byla provedena optimalizace a vyhodnocení dosažených výsledků.

U modelu NAR, který používá k predikování pouze historické hodnoty, byl dosažen nejlepší výsledek při nastavení 20 neuronů ve skryté vrstvě. Tento model se hodí spíše pro určování trendu vývoje (vzhledem k použití časové řady sestavené z historických hodnot), ale i tak je díky němu možné dosáhnout zisku.

U modelu NARX, který používá i exogenní vstupy indikátorů technické analýzy pro dosažení co nejlepších výsledků predikce, bylo dosaženo více než 80% úspěšnosti odhadu trendu zvoleného nástroje. Díky optimalizaci je model možno použít i pro případné investice.

Výhodou obou modelů je jejich rychlost a také jednoduchost a třeba i možnost nechat si vygenerovat množství podpůrných grafů.

Nevýhodou modelů je nutnost optimalizace, bez které podávají zkreslené výsledky, které se nehodí pro další využití. Optimalizaci je navíc velmi vhodné provést na několika stupních, zejména na datech, parametrech neuronové sítě a u modelu NARX navíc i u vstupních indikátorů technické analýzy. Nutno dodat, že samotná optimalizace je velmi časově náročná. Další nevýhodou by mohlo pro některé uživatele být to, že je potřeba koupit uživatelskou licenci aplikace MATLAB.

Použitá literatura

- [1] DOSTÁL, P. *Pokročilé metody rozhodování v podnikatelství a veřejné správě*. Brno: Akademické nakladatelství CERM, 2012. 719 s. ISBN 978-80-7204-799-4.
- [2] Evropský sociální fond v ČR. Péče o lidské zdroje, péče o budoucnost podniku Hanácká kyselka. *esfcr.cz*. [online]. ©2010-2012 [cit. 2013-03-29]. Dostupné z: <<http://www.esfcr.cz/projekty/pece-o-lidske-zdroje-pece-o-budoucnost-podniku-hanacka>>
- [3] FANTA, J. *Psychologie, algoritmy a umělé inteligence na kapitálových trzích*. Praha: Grada Publishing, 2001. 168 s. ISBN 80-247-0024-7.
- [4] FOREX. Obchodujeme FOREX (XI): Technická analýza (3). *financnik.cz* [online]. ©2009. [cit. 2013-03-30]. Dostupné z: <<http://www.financnik.cz/komodity/zkusenosti/forex-RSI-RMI.html>>.
- [5] Hanácká kyselka. Produkty. *hanackakyselka.cz*. [online]. ©2011. [cit. 2013-03-30]. Dostupné z: <<http://www.hanackakyselka.cz/rozcestnik/>>
- [6] CHURÝ L. Umělá inteligence, díl 2. - neuronové sítě. *programujte.com*. [online]. ©2005. [cit. 2013-03-30]. Dostupné z: <<http://programujte.com/clanek/2005061201-umela-inteligence-dil-2neuronove-site/>>
- [7] JELÍNEK, J. ZICHÁČEK, V. *Biologie pro gymnázia*. Olomouc 2003. 576 s. ISBN: 80-7182-159-4.
- [8] JLS. Biologický neuron a neuronové sítě. *jlswebs.wordpress.com* [online]. [cit. 2013-03-29]. ©2008-2012 Dostupné z: <<http://jlswebs.wordpress.com/2009/07/09/biologicky-neuron-a-neuronove-site/>>.
- [9] KROPÁČ, J. *Statistika B*. Brno 2007. 150 s. ISBN 80-214-3295-0.
- [10] MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. *Umělá inteligence (4)*. Academia Praha 2003. 476 s. ISBN 80-200-1044-0.
- [11] Obchodní rejstřík a sbírka listin. Sbírká listin Hanácká kyselka s.r.o. *justice.cz*. [online]. Ministerstvo spravedlnosti ČR 2012. [cit. 2013-03-30].

- Dostupné z: <https://or.justice.cz/ias/ui/vypis-sl?subjektId=isor%3a156761&klic=doo5if>
- [12] PETŘÍK M. Historie objevu neuronu. *petrik.bigblogger.lidovky.cz* [online]. Mafra a.s. 2013. [cit. 2013-03-29]. Dostupné z: <http://petrik.bigblogger.lidovky.cz/c/111708/Historie-objevu-neuronu.html>.
- [13] Purkynka.tk. Neuronové sítě. *iss.unas.cz*. [online]. ©2006. [cit. 2013-03-29]. Dostupné z: iss.unas.cz/NEURON-site-vyuka2.DOC.
- [14] Referáty10.com. Vznik a vývoj burz, podstat burz. *referaty10.com*. [online]. Slezská univerzita Opava 2011. [cit. 2013-03-30]. Dostupné z: <http://www.referaty10.com/referat/Finance/3/tema-3-5-Finance.php>
- [15] REJNUŠ O. *Peněžní ekonomie (Finanční trhy)*. Brno: Akademické nakladatelství CERM 2010. 354 s. ISBN: 978-80-214-4044-9.
- [16] ŘÍHA, J. *Technická analýza cenných papírů*. Comenia Nova 1994. ISBN 80-901784-0-5.
- [17] Wikipedia. Gradient descent. *en.wikipedia.org*. [online]. © 2001-2013 [cit. 2013-03-29]. Dostupné z: http://en.wikipedia.org/wiki/Gradient_descent.
- [18] Wikipedia. Levenberg-Marquadt algorithm. *en.wikipedia.org*. [online]. ©2001-2013 [cit. 2013-03-29]. Dostupné z: http://en.wikipedia.org/wiki/Levenberg%E2%80%93Marquardt_algorithm
- [19] Wikipedie. Neuron. *cs.wikipedia.org*. ©2001-2013 [online]. [cit. 2013-03-30]. Dostupné z: <http://cs.wikipedia.org/wiki/Neuron>
- [20] Wikipedie. Neuronová síť. *cs.wikipedia.org*. [online]. ©2001 - 2013. [cit. 2013-03-29]. Dostupné z: http://cs.wikipedia.org/wiki/Neuronov%C3%A1_s%C3%AD%C5%A5
- [21] Wikipedia. Quasi-Newton method. *en.wikipedia.org*. [online]. ©2001 - 2013 [cit. 2013-03-30]. Dostupné z: http://en.wikipedia.org/wiki/Quasi-Newton_method.

[22] Wikipedie. Soubor:Neuron model.jpg. *cs.wikipedia.org*. [online]. ©2001-2013 [cit. 2013-03-29]. Dostupné z: <http://cs.wikipedia.org/wiki/Soubor:NeuronModel.jpg>

Seznam obrázků

Obrázek 1 - Biologický neuron	14
Obrázek 2 - Schéma umělého neuronu.....	15
Obrázek 3 - Členění finančního trhu	24
Obrázek 4 - Základní schéma modelu NAR.....	42
Obrázek 5 - NAR model s 10 neurony	42
Obrázek 6 - Trénink neuronové sítě u modelu NAR.....	44
Obrázek 7 - Graf střední kvadratické chyby (MSE).....	45
Obrázek 8 - Schéma predikčního modelu NAR s 20 neurony	45
Obrázek 9 - Korelace hodnot časové řady a hodnot predikce u NAR modelu.....	46
Obrázek 10 - Slovní výstup modelu NAR.....	46
Obrázek 11 - Schéma NARX modelu	52
Obrázek 12 - Model NARX s 20 neurony a 5 exogenními vstupy	53
Obrázek 13 - Trénink neuronové sítě u modelu NARX.....	54
Obrázek 14 - Schéma predikčního modelu NARX	55
Obrázek 15 - Korelace hodnot časové řady a hodnot predikce u NARX modelu...	55
Obrázek 16 - Slovní popis modelu NARX.....	56

Seznam tabulek

Tabulka 1 - SWOT analýza společnosti Hanácká kyselka s.r.o.	37
Tabulka 2- Vyhodnocení modelu NAR.....	47
Tabulka 3 - NARX model se dvěma indikátory technické analýzy	57
Tabulka 4 - NARX model se dvěma indikátory technické analýzy	57
Tabulka 5 - NARX model se vstupy MA5, ExMA5, MACD, Williams %R5, Stoch, RSI5	58
Tabulka 6 - NARX model se vstupy MA10, ExMA10, MACD, Williams %R10, Stoch, RSI10.....	58
Tabulka 7 - NARX model se vstupy ExMA5, RSI5, Williams %R5, Stoch	58
Tabulka 8 - NARX model se vstupy ExMA10, RSI10, Williams %R10, Stoch	59
Tabulka 9 - NARX model se vstupy ExMA5, ROC5	59
Tabulka 10 - NARX model se vstupy ExMA10, ROC10	59

Seznam zkratek

fce	funkce
např.	například
tzv.	takzvaný

Přílohy

Zdrojové kódy obou modelů jsou k dispozici na CD ve vsádce na deskách diplomové práce.