


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA PODNIKATELSKÁ
ÚSTAV MANAGEMENTU

FACULTY OF BUSINESS AND MANAGEMENT
INSTITUTE OF MANAGEMENT

VYUŽITÍ PROSTŘEDKŮ UMĚLÉ INTELIGENCE NA KAPITÁLOVÝCH TRZÍCH

THE USE OF MEANS OF ARTIFICIAL INTELLIGENCE FOR THE DECISION MAKING SUPPORT
ON STOCK MARKET

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. JAN VAŠKO

VEDOUCÍ PRÁCE
SUPERVISOR

prof. Ing. PETR DOSTÁL, CSc.

BRNO 2011

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Jan Vaško

Řízení a ekonomika podniku (6208T097)

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 a magisterských studijních programů zadává diplomovou práci s názvem:

Využití prostředků umělé inteligence na kapitálových trzích

v anglickém jazyce:

The Use of Means of Artificial Intelligence for the Decision Making Support on Stock 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 analýz a modelování v podnikatelství a veřejné správě. Brno : CERM, 2009. 342 s. ISBN 978-80-7204-605-8.
- DOSTÁL, P. Advanced Economic Analyses. Brno : CERM, 2008. 80 s. ISBN 978-80-214-3564-3.
- REJNUŠ, O. Cenné papíry a burzy. 1. vyd. Brno: Vysoké učení technické v Brně. Fakulta podnikatelská, 2009. 400 s. ISBN 978-80-214-3805-7
- DOSTÁL, P., SOJKA, Z. Financial risk management. UTB 2008. ISBN: 978-80-7318-772-9.
- FANTA, J. Technologie umělé inteligence na kapitálových trzích. 1. vyd. Praha: Karolinum, 1999. 89 s. ISBN 80-7184-866-2.
- MARÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J. Umělá inteligence (4). 1. vyd. Praha : Academia, 2003. 470 s. ISBN 80-200-1044-0


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

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2010/11.





PhDr. Martina Rašticová, Ph.D.
Ředitel ústavu



doc. RNDr. Anna Putnová, Ph.D., MBA
Děkanka

V Brně, dne 25.3.2011

Anotace

Diplomová práce se zabývá analyzováním možnosti využití umělé inteligence, konkrétně umělých neuronových sítí a fuzzy logiky, na kapitálových trzích jako podpůrný nástroj v rozhodování podniku. K tomu je využito programové prostředí MATLABU. Práce je rozdělena do tří částí. V první se věnuji teoretickým poznatkům, ve druhé stručnému popisu současné situace a ve třetí části aplikuji tyto teoretická východiska do systému.

Annotation

Diploma thesis deals with analyzing the possibility of using artificial intelligence, specifically artificial neural networks and fuzzy logic, on the capital markets as a tool to support decision making in business. The MATLAB software is used for this purpose. The work is divided into three parts. The first part deals with theoretical knowledge, brief description of the current situation is covered in a second part and the theoretical solutions are applied to the system in the third section.

Klíčová slova

Fuzzy logika, umělé neuronové sítě, umělá inteligence, index S&P 500, MATLAB, neural network toolbox, NARX, Feed-forward back propagation, money management, klouzavý průměr, směrodatná odchylka, MACD, RSI.

Key words

Fuzzy logic, neural network, artificial intelligence, index S&P 500, MATLAB, neural network toolbox, NARX, Feed-forward back propagation, money management, moving average, standard deviation, MACD, RSI.

Bibliografická citace práce:

VAŠKO, J. Využití prostředků umělé inteligence na kapitálových trzích. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2011. 86s. Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.

Čestné prohlášení

Prohlašuji, že jsem diplomovou práci na téma „Využití prostředků umělé inteligence na kapitálových trzích“ vypracoval samostatně pod vedením svého vedoucího Prof. Ing. Petra Dostála, CSc. a že v seznamu literatury byli uvedeny veškeré použité zdroje.

V Brně, dne 20. Května 2011

.....

Podpis

Poděkování

Děkuji vedoucímu mé diplomové práce panu Prof. Ing. Petru Dostálovi, CSc. a všem ostatním za cenné rady poskytnuté během zpracovávání diplomové práce.

Obsah

Úvod.....	11
1 Vymezení problému a cílů práce	12
2 Teoretická východiska diplomové práce.....	13
2.1 Fundamentální analýza	13
2.2 Psychologická analýza	15
2.3 Technická analýza.....	16
2.3.1 Downova teorie.....	16
2.3.2 Základní zobrazení cen na časovém grafu	17
2.3.3 Grafické formace	19
2.3.4 Technické ukazatele.....	21
2.4 Money management.....	23
2.5 Agentura Standard's & Poor's	24
2.6 Akciový index S&P 500	24
2.6.1 Historie.....	25
2.6.2 Váha jednotlivých společností v indexu	25
2.6.3 Největší společnosti v indexu	26
2.7 Fuzzy logika.....	27
2.7.1 Obecně k metodě	27
2.7.2 Použití fuzzy logiky na kapitálových trzích	30
2.8 Neuronové sítě	31
2.8.1 Biologický základ	31
2.8.2 Vlastnosti umělých neuronů	32
2.8.3 Neuronové sítě	33
2.8.4 Modely neuronových sítí	34
2.8.5 Topologie neuronových sítí	35
2.8.6 Pravděpodobnostní neuronové sítě	40
2.8.7 Proces učení	41
2.9 Program MATLAB a jeho moduly	43
2.9.1 Fuzzy logic toolbox	43
2.9.2 Neural network toolbox	44

2.10	Analýza časových řad	45
3	Analýza problému a současné situace	47
3.1	Vývoj akciového indexu	47
3.2	Společnosti IFE-CR, a.s.....	47
3.3	SWOT analýza.....	47
3.4	Portrova analýza	48
3.5	Společnosti XTB.....	49
3.5.1	Otevření účtu.....	50
4	Vlastní návrhy řešení, přínos návrhů řešení	52
4.1	Data pro predikci	52
4.1.1	Stažení z X-Trade brokera	52
4.1.2	Výpočet indikátorů	53
4.2	Predikce metodou NARX	53
4.2.1	Predikce Close pomocí Hodnot Open, High, low, close, volume ..	54
4.2.2	Predikce pomocí indikátorů MACD, MA, Standard dev. a RSI.....	59
4.3	Predikce za pomocí Nonlinear Input-Output	63
4.3.1	Predikce Close pomocí Hodnot Open, High, low, volume.....	64
4.3.2	Predikce pomocí indikátorů MACD, MA, Standard dev. a RSI.....	68
4.4	Predikce metodou Nonlinear Autoregressive with external Input.....	70
4.5	Srovnání metod	70
4.6	Systém pro rozhodování	72
4.6.1	Trend.....	72
4.6.2	Příležitost	74
4.7	Velikost obchodu	75
4.8	Zhodnocení vytvořeného systému a využití pro společnost	76
5	Závěr	77
6	Seznam použité literatury	78
7	Seznam grafů.....	81
8	Seznam tabulek	82
9	Seznam obrázků.....	83

10 Seznam vzorců.....	85
11 Seznam příloh.....	86

Úvod

V dnešní době, kdy celosvětová finanční krize odeznívá, se společnosti vrací do původních, zasetých kolejí a opouští strategie šetření, kdy hlavním cílem jakékoliv společnosti bylo přežít na trhu. Tak jak se posiluje schopnost nakupujících kupovat dodatečné zboží, které za finanční krize nekupovali, rostou i zisky společností a ty se rozhodují jak s nimi naloží.

Ve finančním světě platí jedno jednoduché pravidlo a to „Peníze se musí otáčet, aby vydělávali“. Toto pravidlo platí pro jakoukoliv společnost, instituci, či byť obyčejného živnostníka. Díky dostupnějším kapitálovým trhům, prostřednictvím mimoburzovních brokerů, jako jsou X-Trade broker, Colloseum, Cyrrus, Fio a dalším, se dynamicky uvažujícím společnostem otevírá nový prostor, jak zhodnotit své volné kapitálové prostředky. Společnost by je neměla nechat volně ležet na firemním účtu. Ruku v ruce s možnými kolosálními zisky na kapitálovém trhu jde i riziko spojené s obchodováním. Toto riziko se investor snaží snížit různými metodami. Jsou jimi fundamentální, psychologická a technická analýza, dále money management a v neposlední řadě právě inteligentní systémy fuzzy logiky, neuronových sítí, genetických algoritmů a teorie chaosu.

Použití výše zmíněných metod umělé inteligence má nespočet využití. Rád bych jich pár jmenoval např.: optimalizace procesů, podpora rozhodovacích procesů, odhad cen nemovitostí, hodnocení rizika poskytované hypotéky a v neposlední řadě predikce vývoje cen akcií, komodit a akciových indexů. Posledně zmíněnému se věnuji v této diplomové práci.

1 Vymezení problému a cílů práce

V této diplomové práci budu analyzovat možnosti použití umělých neuronových sítí na kapitálových trzích, konkrétně na akciovém indexu S&P 500 a zkoumat jejich možnosti uplatnění výsledků vytvořeného systému ve společnostech, jako je příkladně společnost IFE-CR, a.s.. Toto všechno v prostředí programu MATLAB a jeho toolboxů. Konkrétně se jedná o Neural network toolbox, nástroje Neural time series tool a modelů Nonlinear autoregressive with external input (NARX), nonlinear autoregressive (NAR) a nonlinear input-output a fuzzy-logic toolbox.

Cílem této práce je analyzovat, zda je GUI prostředí neuronových sítí a fuzzy logiky softwaru MATLAB vyhovující pro využití ve firmách jako je výše zmíněná IFE-CR, a.s. a zda by systém vytvořený v tomto prostředí mohl dávat dobré informace pro podporu v rozhodování o investicích volného kapitálu společnosti.

2 Teoretická východiska diplomové práce

Teoretická východiska jsou rozdělena do deseti částí, které popisuje jednotlivé použitelné metody pro vytvoření expertního systému, sloužícího pro predikci ceny akciového indexu S&P500 za použití umělé inteligence. Konkrétně Fuzzy logiky a umělých neuronových sítí.

2.1 Fundamentální analýza

Fundamentální analýza je analýzou jdoucí nejhluběji. Snaží se najít vnitřní hodnotu akcie (potažmo akciového indexu), cílem je zjistit jestli je cena akcie (akciového indexu) nadhodnocená, nebo podhodnocená. Díky ekonomickým údajům, veřejně dostupným, jako jsou DPH, cena ropy, kurzy měn, inflace, nezaměstnanost, peněžní zásoba a vývoj úrokových měr. Následující odrážky popisují vztahy mezi vybranými instrumenty a cenou akcie.

Makroekonomická fundamentální analýza

- **Peněžní zásoba** – Růst peněžní nabídky ovlivňuje vývoj na akciových trzích vždy kladně. Zvýší-li centrální banka peněžní nabídku, pak se předpokládá, že část peněz skončí na akciových trzích. Známí efekt likvidity říká, že Zvýší-li se peněžní zásoba, tak ve velmi krátkém období všichni pocítují nadbytek peněz a tím část investují do akcií a tím zvyšují jejich cenu.
- **Inflace** – vývoj akciových kurzů a inflace je mírně negativně závislý až skoro nepatrný. Díky síle této závislosti nedoporučuji tento ekonomický parametr zahrnout do dalšího zkoumání.
- **Vývoj úrokových měr** – vývoj úrokových měr a ceny akcií je spojen negativním pojítkem. To znamená roste-li míra úrokových měr, klesá vývoj akciových cen a naopak. Pro tento vztah existuje několik vysvětlení:
 - a) Jelikož je úroková míra zakomponována jako odúročitel ve výpočtu diskontované úrokové sazby ceny akcie, tak její nárůst ovlivňuje zvýšený požadované výnosové míry akcie a tím snižuje její cenu

- b) Trh dluhopisů se vyvíjí v opačně než trh akcií. Když roste úroková míra akcionáři přesouvají svůj kapitál na instrumenty s vyšší mírou zhodnocení tzn., do dluhopisů. K tomuto efektu většinou dochází na konci hospodářského cyklu, kdy se banky zvedáním úrokových sazeb snaží mírnit dopady inflace.

Díky těmto důvodům můžeme využít vyhlazeného ukazatele vývoje úrokových měr pro potvrzení trendu vývoje na akciovém trhu.

- **HDP** – je známo že mezi cenou akcie (akciového indexu) a HDP je kladný vztah. Je ale důležité si uvědomit, že vývoj cen akcií předbíhá vývoj HDP o zhruba 3 až 9 měsíců. Tím můžeme vyloučit započítání vývoje HDP do predikčního modelu sestavovaného v této práci.

Každému investorovi je jasné že jakékoliv šoky (krize, přírodní pohromy, války atd.) ovlivňují akciové indexy (potažmo samotné akcie) negativně, ale mohou i pozitivně. Za zmínku stojí útoky z 11. září 2001 z New Yorku, kde se po uzavření burzy akciový index dostal na svou původní hodnotu již 25. září, hypoteční krize USA a z nedávné doby i přírodní katastrofa v Japonsku a následné problémy s jadernou elektrárnou, která způsobila propad Japonského indexu o více jak 25% a stále se nedostal na svoji původní úroveň.

Odvětvová fundamentální analýza

- **Citlivost odvětví na hospodářský cyklus** – akcie firem obsažených v indexu jsou ovlivněny i tím jak jsou jednotlivé firmy ovlivněny hospodářským cyklem. Můžeme říci, že některé obory jsou v období expanze žádanější (luxusní oblečení, elektronika atd.) a v období recese méně (luxusní oblečení, elektronika atd.).
- **Tržní struktura odvětví** – je důležité vědět v jakém prostředí se firmy pohybují, tím se investorovi otevrou dveře a on může vytvářet předpoklady o budoucím vývoji jednotlivých firem. Tržní struktura se dělí na monopolní, oligopolní a konkurenční.

- **Způsoby státní regulace odvětví** – je dalším významným faktorem, který ovlivňuje cenu akcie. V této práci se jím ale zabývat nebudeme, protože by to bylo nad rámec této diplomové práce.
- **Perspektivy budoucího vývoje odvětví**

Fundamentální analýza je druhou, ale neméně důležitou, analýzou, kterou investor při zvažování zda investovat, nebo ne používá. V této práci se, ale věnujeme spíše umělé inteligenci, která získává data z minulého vývoje. Jako užitečný instrument, který je dobrý sledovat, jsem shledal vývoj peněžní zásoby a úrokových měr.

2.2 Psychologická analýza ¹

„Psychologická analýza vychází z předpokladu, že akciové trhy jsou pod silným vlivem masové psychologie burzovního publika, jež tím, že působí na účastníky trhu, ovlivňuje úroveň kurzů. Jinými slovy to znamená, že budoucí vývoj kurzů akcií závisí na impulzech, které ovlivňují chování davu, jenž je jimi veden buď k nákupům, nebo k prodejm.

Význam masové psychologie dokládá všeobecně známý názor Keynese, který již ve své době tvrdil, že **„nemá žádného smyslu zaplatit 25 peněžních jednotek, za investici, o níž podle jejího perspektivního výnosu důvodně soudíte, že má sice hodnotu 30, avšak předpokládáte, že za tři měsíce ji trh ocení pouze na 20“**. Z toho vyplývá, že investor musí věnovat značnou pozornost předvídání budoucích změn v atmosféře psychologie trhu a vhodným způsobem využívat svých odhadů.

Psychologická analýza zahrnuje celou řadu různých teoretických koncepcí zabývajících se vlivem masové psychologie na kurzy akcií, z nichž za nejvýznamnější jsou považovány.

- Keynesova spekulativní rovnovážná hypotéza
- Kostolanyho burzovní psychologie
- Teorie spekulativních bublin“

¹ REJNUŠ, O. *Cenné papíry a burzy*. 1. vyd. Brno: Vysoké učení technické v Brně. Fakulta podnikatelská, 2009. 400 s. ISBN 978-80-214-3805-7

2.3 Technická analýza

Technická analýza akcií, komodit, měn se používá k určení budoucího vývoje ceny daného instrumentu na základě časové analýzy dat. Jsou jimi vývoj ceny instrumentu a objem obchodování.

Technický analytik se rozhoduje na základě grafických formací, které reprezentují chování investorů. Tyto formace se v čase opakují a mají podobný vývoj na každém trhu. Investor tyto formace vyhledává a tím snižuje riziko vstupu do ztrátové pozice. Níže jsou popsány způsoby, formace a další údaje, které techničtí investoři využívají.

2.3.1 Downova teorie

Je první teorií, kterou historie uznala, která určuje trendy vývoje na trzích. Jejím zakladatelem je Charlese H. Dow. Uceleně ji zformovali až jeho následovníci z Dowových článků a poznámek. Předpokladem se stala skutečnost, že při poklesu většiny akcií v trhu se trh pohybuje směrem dolů a naopak. Při růstu cen většiny akcií v trhu se trh bude pohybovat směrem nahoru.

Dow popsal dvě hlediska ze kterých lze hodnotit trendy (vývoj) akciových indexů. Tyto hlediska použil na indexy, které sám sestrojil „Dow Jones Industrial Average“ a „Dow Jones Transportation Average“.

A. Z hlediska délky jejich trvání

- Primární trend – jedná se o dlouhodobý, v délce trvání od jednoho roku po několik let, klesající, nebo rostoucí trend
- Sekundární trend – jedná se o cenové pohyby trvající několik týdnů až měsíců
- Terciální trend – doba trvání terciálního trendu by neměla přesáhnout 3 týdny, tomuto trendu Charlese H. Dow přikládal nejmenší váhu


B. Z hlediska směru průběhu vývoje cen

- Rostoucí – cenový vývoj indexu v čase je rostoucí (jako většina v něm obsažených titulů)
- Klesající – cenový vývoj indexu v čase je klesající (jako většina v něm obsažených titulů)

- Postranní – cenový vývoj indexu v čase má horizontální charakter (jako většina v něm obsažených titulů)

2.3.2 Základní zobrazení cen na časovém grafu

- Sloupcové



Obr. 1 - Sloupcové zobrazení cen (Zdroj: NESNÍDAL, T. – PODHAJSKÝ(16))

Horní obrázek znázorňuje jednu obchodní seanci a několik důležitých údajů:

- OPEN – cena za kterou bylo v určité seanci otevřeno (první údaj)
- HIGH – nejvyšší cena v rámci obchodní seance
- LOW – nejnižší cena v rámci obchodní seance
- CLOSE – cena za kterou bylo v určité seanci zavřeno (poslední údaj)
- Rozpětí cen HIGH, LOW – rozpětí cen v jejímž rámci se za daný časový interval v seanci obchodovalo. Výpočet: $Rozpětí = HIGH - LOW$

- Svíčkové

Svíčkové grafy jsou obdobným zobrazením grafů sloupcových. Rostoucí trend je naznačen prázdným tělem svíčky a otevírací cena je základna těla svíčky, oproti tomu při klesajícím trendu je základna uzavírací cena.

- Čárové

Čárové grafy jsou přímky protínající ceny stejného druhu. Tudíž jen OPEN/HIGH/LOW/CLOSE.

A. Hladina podpory a odporu

- Hladina podpory

Cenová hladina, kterou cena po několik seancí nemůže prorazit se jmenuje hladina podpory.

- Hladina odporu

Jde o cenovou hladinu přes kterou se cena instrumentu v průběhu několika seancí nemůže dostat, prorazit. Jedná se spíše o psychologickou hranici, tak jako u hladiny podpory, než o fakt založený na fundamentálních faktech. Dobrým příkladem mohou být ceny 100, 1000 10 000 atd. Tyto příklady platí i u hladiny podpory.

B. Trendové linie a kanály

„Trendovou linii lze charakterizovat jako přímku spojující „sérii“ minimálních hodnot (lokálních minim), či maximálních hodnot (lokálních maxim) akcie, akciového indexu, komodity, či jiných instrumentů během určitého období.“ (18)

Z předešlého popisu je patrné, že při rostoucím trendu je linie (přímka, většina softwaru má k dispozici tento nástroj technické analýzy) přímky, linií podpory a naopak při klesající ceně instrumentu se trendová linie stává hladinou odporu.

C. Volume

Indikátor Volume je technický indikátor, který vyjadřuje počet změn na daném trhu. Je užitečný při změnách trendu. Obchodování na základě tohoto indikátoru se dělá tak, že když objem klesá (klesá zájem současných uživatelů o obchodování) a tím se zpomaluje i cenový pohyb a čeká se změna trendu. Obchodníci vstupují do pozice až když se změna trendu potvrdí zvýšením objemu obchodování a tedy i novým trendem. Za velmi silné potvrzení se považuje, když v době zvýšení objemu obchodů se protrhne hladina podpory, nebo odporu (trendová linie).

D. Mezery (GAPS)


Jsou to „hluchá místa“ v cenovém grafu, jinými slovy jsou to oblasti, ve kterých nedošlo k žádnému obchodu, tedy objem obchodů byl 0. K nejznámějším patří:

- Běžná mezera
- Prolamující mezera
- Padající mezera
- Mezera z vyčerpání
- Ostrov zvratu

2.3.3 Grafické formace


Grafické formace jsou spolehlivým indikátorem změny, nebo potvrzení trendu vývoje cenového grafu. Vždy se musí poměřovat s hodnotou volume, aby byla změna potvrzena a reverzní formace se obchodují až na konci trendů.

- **Vrchol a dno** – tato formace se vyskytuje na trzích prakticky každý den. Ať již se jedná o intradenní obchodování, nebo poziční, je prostě všude a díky tomu se z této formace stává téměř nevyužitelná formace. Jde o nejběžnější reverzní formaci.
- **Dvojitý vrchol a dvojitě dno** – Tato formace je již mnohem spolehlivějším ukazatelem reverzního trendu na trzích. Nevyskytuje se tak často jako jednoduchý vrchol, jednoduché dno a proto se na tuto formaci obchodníci mohou spolehnout. U této formace obchodník nevyhodnocuje pouze cenovou úroveň lokálních maxim, či minim, ale i vzdálenost těchto minim, maxim od sebe, což záleží na časovém zobrazení grafu na obchodní platformě. Dále existují formace jako je trojitý vrchol, trojitě dno, nebo vícenásobný vrchol, vícenásobné dno, ty pak mohou tvořit trendový kanál.




Obr. 2 - Cenová formace Dvojitý vrchol, dvojité dno (Zdroj: REJNUŠ(18))

- **Hlava a ramena** – Grafická formace hlava a ramena je odvozená od vzhledu lidského těla, obzvláště jeho horní poloviny (ramenou a hlavy). Může se vyskytovat na konci rostoucího trendu, kde signalizuje ukončení růstu, nebo na konci klesajícího trendu, kde signalizuje ukončení padání ceny. Princip je zobrazen na následujícím obrázku. Vše musí být potvrzeno ukazatelem objemu obchodování.



Obr. 3 - Cenová formace hlava ramena (Zdroj: REJNUŠ(18))

- **Diamant** – tato formace nepatří k těm velmi častým, vyskytuje se pouze u extrémů, kdy kurz instrumentu vzroste, nebo klesne na nebývalou hodnotu. Je tvořen dvěma trojúhelníky. V prvním se cenové rozpětí rozšiřuje a v druhém se zmenšuje. To vše je doplněno rostoucím objemem obchodů v prvním trojúhelníku a velmi nízkým objemem obchodů v druhém trojúhelníku.



Obr. 4 - Cenová formace diamant (Zdroj: REJNUŠ(18))

- **Reverzní obdélník** – jde o formaci, která na určitou dobu zpomaluje, nebo obrací trend. Jde tedy o cenový pohyb mezi dvěma trendovými liniemi (kanál), kde většina prodejních příkazů je u hranice odporu a většina nákupních příkazů je u hranice podpory. Vývoj objemu obchodů je v rámci obdelníku neprůkazný a investor by se měl soustředit až na objem obchodu posledního trendu (růst, pokles) před prolomením hranice podpory, nebo odporu.
- **Vlajky** – formace vlajka je velmi podobná formaci reverzní obdelník, kdy cena instrumentu se pohybuje mezi dvěma trendovými liniemi. Jediný rozdíl je v objemu obchodů, kdy ve formaci vlajka je objem obchodů nižší než na počátku(vniku do formace) a konci (výstupu z formace)
- **Praporek (trojúhelník)** – jde o podobnou formaci jako u konsolidačních obdelníků. Zde se přímky podpory a odporu sbíhají. Praporek rozdělujeme na dva druhy, praporek v rostoucím trendu a praporek v klesajícím trendu. U objemu obchodování platí stejné pravidlo jako u obdelníků, kdy průběhu praporku jsou objemy obchodů nižší než na začátku a konci.

2.3.4 Technické ukazatele

Tato kapitola popisuje 4 technické ukazatele, které jsou ve finančním světě hojně využívány a v této práci budou použity jako vstupy do neuronové sítě.

2.3.4.1 Moving average (MA)

„Klouzavý průměr je technický indikátor, který ukazuje průměrnou cenu instrumentu za určité časové období. Jak se cena instrumentu v čase mění, mění se také klouzavý průměr, neboli roste či klesá. Zjednodušeně řečeno klouzavý průměr vyhlazuje průběh ceny finančního instrumentu a díky tomu můžeme lépe pozorovat trend.“(26)

2.3.4.2 MACD

„MACD je trendový technický indikátor. Vypočítá se jako rozdíl mezi dvěma exponenciálními klouzavými průměry s délkou 12 a 26 období. Ukazuje se že MACD je nejefektivnější v široce „tendujících“ trzích.“(27)

2.3.4.3 RSI

„Technický indikátor Relative Streight Index (RSI) je oscilátor, který sleduje kurz finančního instrumentu a nabývá hodnot od 0 do 100. Hodnota vyšší než 70 znamená, že je trh „překoupen“, hodnota pod 30 znamená, že je trh „předprodán“. Překonání těchto hodnot může znamenat, že brzy dojde ke změně trendu.“ (28)

Vzorec 1 - RSI

$$RSI = 100 - \frac{100}{1 + \frac{U}{D}}$$

U ...průměrný počet pozitivních cenových změn

D ...průměrný počet negativních cenových změn

2.3.4.4 *Relative streight index* Standard Deviation (StdDev)

„Směrodatná odchylka měří volatilitu (proměnlivost, kolísavost) dané proměnné (kurzu finančního instrumentu). Volatilita měřená směrodatnou odchylkou je ve finančním světě často ztotožňována s rizikem daného finančního instrumentu. Čím vyšší volatilita, tím větší pravděpodobnost že vývoj kurzu daného instrumentu půjde opačným směrem , než jsme předpokládaly.“(31)

Vzorec 2 - Standard deviation

$$S_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$$

x_i ... i-tá hodnota (cena) instrumentu

$\bar{x}$...průměr hodnot v dané časové periodě

n ...časová perioda

2.4 Money management

Money management patří k důležitým prvkům investování. Investor může mít vynikající technickou analýzu podpořenou fundamentálními prvky, ale když nebude vědět kolik do obchodu vložit peněz, nikdy nebude profitabilní.

Money management se zabývá peněžní stránkou obchodů na trzích. Jednou z nejkritičtějších součástí money managementu je „Position sizing“.

Position sizing je matematická metoda, která investorovi říká kolik kontraktů (potažmo za jakou cenu) má investor obchodovat. Pokud se investorovi daří a vydělává position sizing investorovi radí aby kupoval více. Naopak, pokud se investorovi nedaří, tak metoda radí ubírat počet kontraktů.

K nejpopulárnějším metodám position sizingu patří metoda „Fixed fraction“. Metoda dobře funguje pro velké i malé účty. Metoda je velmi jednoduchá, jak již bylo popsáno v odstavci výše, říká nám jaký počet kontraktů má investor koupit v budoucím obchodě. Určující prvky metody:

- **Maximální velikost risku investora na jeden obchod** – Není nic jiného než počet peněz které je investor ochoten ztratit z jednoho obchodu.
 - **Př.:** pokud je stoloss investora stanoven na 20\$ (ať již by byl vývoj ceny instrumentu jakýkoliv, investor se rozhodnul ztratit maximálně 20\$, tato částka platí pro každý obchod), bude maximální velikost risku na jeden obchod právě 20\$
- **Maximální procento riskovaného kapitálu** – vyjadřuje poměrnou částku kterou je investorovi, podle metody, povoleno riskovat z celkové výše kapitálu na obchodním účtu. Nováčkům se doporučuje riskovat 1 – 3 %, pokročilým investorům 3 – 5 %.

- **Př.:** Maximální procento riskovaného kapitálu = 1%

Maximální velikost risku na 1 obchod = 20\$

Velikost účtu = 2 000\$

Pokud by v tuto chvíli investor prodělal riskovaných 20\$ a chtěl by si ponechat riziko na 1% musel by upravit velikost maximálního risku na jeden obchod.

Velikost účtu = 1 980\$

Maximální procento riskovaného kapitálu = 1%

Maximální velikost risku na 1 obchod = 19,80\$

Vzorec 3 - Fixed fraction

$$K = A_c * \frac{\left(\frac{P_r}{100}\right)}{R1_{max}}$$

A_c ...velikost účtu investora (př: 2 000\$)

P_r ...procento riskovaného kapitálu (př: 1%)

$R1_{max}$...maximální velikost risku na jeden obchod (př: 20\$)

2.5 Agentura Standard's & Poor's

Standard's & Poor's je americká společnost poskytující finanční služby, je součástí The McGraw-Hill Companies, které poskytují finanční výzkum a analýzy akcií a dluhopisů. Zároveň je Standard's & Poor's známá pro akciové indexy: S&P 100, S&P 500, S&P 600, S&P 1000. V této diplomové práci se budeme věnovat pouze akciovému indexu S&P 500.

2.6 Akciový index S&P 500

Index S&P 500 patří k těm nejvíce sledovaným indexům na Americkém trhu. Jak již název napovídá obsahuje 500 nejúspěšnějších Amerických společností, které musí splňovat následující kritéria, aby byli přijaty do indexu. Jelikož kritéria nejsou pro vypracování této diplomové práce velmi důležitá, stačí vyjmenovat pouze některé z nich:

- Americká společnost – společnost musí být domácí Americkou společností
- Tržní kapitalizace – musí přesahovat 4 miliardy dolarů.

- “Public float” – aspoň 50% akcií musí být veřejně obchodovatelných
- Finanční životaschopnost – společnosti musí mít aspoň 4 po sobě jdoucí čtvrtletí kladný hospodářský výsledek (počítán podle metodiky US GAAP).

2.6.1 Historie

Akciový index byl založen firmou Standard's & Poor's a od roku 1957 se počítá v jeho současné podobě. V roce 2000 dosáhl historického maxima v denim obchodování 1552,87 bodů a o dva roky později, po dlouhém pádu indexu, byl na minimu 768,63 bodů.

2.6.2 Váha jednotlivých společností v indexu


Pro výpočet vah se používá metoda „floated weigh“, znamená to, že váha je určena množstvím akcií pro veřejnou nabídku. Ve spodním grafu je znázorněn vah jednotlivých odvětví. Zastoupení odvětví a jejich váhy ukazují na rozložení Amerického trhu, nebo by měli poukazovat na toto rozložení.

Nevýhodou tohoto indexu je, že přikládá větší váhu na malý počet akcií velkých společností, tím potažmo reflektuje vývoj akcií největších společností obsažených v indexu.

Tab. 1 - Ekonomická odvětví zastoupená v indexu(Zdroj: *STANDARD&POOR'S(28)*)

Tabulka odvětví zastoupených v indexu²
Consumer Discretionary
Consumer Staples
Energy
Financials
Health Care
Industrials
Information Technology
Material
Telecommunications Services
Utilities

² Tabulka vytvořena k datu 27.3.2011



Graf 1 - Procentní poměr odvětví v indexu

2.6.3 Největší společnosti v indexu

Tab. 2 - Seznam 10 společností s největší vahou v indexu (Zdroj: *STANDARD&POOR'S Fact sheet* (29))³

Company	Float adjusted market cap (milinon \$)	Index weight	Sector weight	Investable weight factor	Sector
Exxon Mobil Corp	431 289,9	3,57%	27,18%	1	Energy
Apple Inc.	324 002,0	2,68%	14,39%	1	Information technology
General Electric Co	222 896,7	1,84%	16,63%	1	Industrials
Chevron Corp	208 789,4	1,73%	13,16%	1	Energy
Intl business Machines Corp	201 113,4	1,66%	8,93%	1	Information technology
Microsoft Corp	200 117,1	1,65%	8,89%	0,88	Information technology

³ Tabulka vytvořena k datu 27.3.2011

JP Morgan Chase & Co	182 518,7	1,51%	9,42%	1	Financials
Procter & Gamble	176489,1	1,46%	14,43%	1	Consumer staples
Wells Fargo & Co	169 324,9	1,40%	8,74%	1	Financials
Johnson & Johnson	168 729,8	1,39%	12,84%	1	Health care

2.7 Fuzzy logika

2.7.1 Obecně k metodě

Teorii neostrých množin vytvořil v roce 1965 L. Zadech, který poprvé vyslovil pravidlo: jak moc prvek do množiny patří, jeho jistotu / nejistotu. Jinými slovy příslušnost prvku X do množiny μ je definována v rozmezí $<0;1>$ tzv. šedá množina mezi prvky 0 a 1.

„Teorie fuzzy množin představuje matematický aparát svou podstatou mimořádně vhodný pro řešení úloh vícekritériálního hodnocení, kdy vstupní hodnoty i hodnoty funkce mají často neurčitý charakter.“(20)


Metoda fuzzy logiky je již delší dobu často používána jako účinná metoda řízení firem.

Pojem množina (tzv. univerzum) lze popsat několika způsoby. Mějme množinu U (univerzum) do které patří fuzzy množina A , pak matematický zápis je následující:

Vzorec 4 - Množina

$$\mu_A: U \rightarrow <0;1>$$

Z předchozího vztahu je patrné že pokud prvek X do množiny zcela patří pak $\mu_A: X = 1$. Opačně pokud prvek X do množiny A zcela nepatří, pak platí vztah $\mu_A: X = 0$. Již tedy nemůžeme říci, že prvek X do množiny A buď zcela patří, nebo zcela nepatří.



Obr. 5 - Fuzzy množina (Zdroj: DOSTÁL(1))

Jak je vidět na obrázku 5 prvek „1“ do množiny nepatří, čili $\mu_A: 1 = 0$. Prvek „6“ do množiny zcela patří $\mu_A: 6 = 1$. Prvky v intervalu (4;5) a (8;9) mají funkci členství do množiny A následující $\mu_A: (4; 5) \cup (8; 9) \rightarrow < 0; 1 >$.

Mezi základní operace které lze s množinami provádět počítejme:

Součet: $[A,B]+[C,D] \rightarrow [A+C,B+D]$


Rozdíl: $[A,B]-[C,D] \rightarrow [A-D,B-D]$

Násobení: $[A,B]*[C,D] \rightarrow [\min(AC,AD,BC,BD),\max(AC,AD,BC,BD)]$

Dělení: $[A,B]:[C,D] \rightarrow [\min(A/C,A/D,B/C,B/D),\max(A/C,A/D,B/C,B/D)]$

2.7.1.1 Schéma fuzzy systémů

„Schéma fuzzy systému je překvapivě jednoduché. Obsahuje pouze tři kroky: fuzzifikaci, fuzzy inferenci a defuzzifikaci. Obr. 3.12 zobrazuje tyto tři algoritmické kroky.“(6)



Obr. 6 - Proces Fuzzy logiky

2.7.1.2 Fuzzifikace

Fuzzifikace je proces přeměny matematických proměnných na lingvistické. V našem případě kdy sledujeme cenové grafy akciového indexu S&P 500 je matematickou proměnnou cena. Převedením reálné proměnné cena na lingvistickou proměnnou cena, které bude náležet několik atributů (stagnace, vzestup, pokles ...). V ideálním případě přesně 5 – 7. V případě 2 – 4 se může zdát rozdělení atributů příliš hrubé a tím se ztratí některé informace. V případě 8 – více se jedná o nadbytečný počet

atributů v mnohém více zvyšující nároky znalosti programátora systému a znalosti expertů, než přínosy z tohoto rozdělení. V některých případech je menší počet žádán př: pohlaví.

V tomto kroku určujeme i stupeň členství μ pro jednotlivé lingvistické proměnné na vstupu i pro výstupní proměnnou. Funkce členství dané lingvistické proměnné se překrývají (jsou zamlžené). Na těchto intervalech je pro investora, spekulanta, nebo kohokoliv jiného, rozhodujícího se podle fuzzy systému, pohyb matematické proměnné nedůležitý.

2.7.1.3 Fuzzi interference

Pomocí pravidel typu podmínkových vět KDYŽ, POTOM, S VÁHOU se definuje druhý krok fuzzy systému. Tyto podmínkové věty se objevují ve velkém množství programů, můžeme jmenovat DELPHI, skriptovací jazyk VBA a spousta dalších. Podmínky vytváří samostatný uživatel systému, jsou to jeho znalosti, moudra. Tudíž jak pečlivě uživatel zadá jednotlivé podmínky a stupně podpory, tak kvalitní systém vytvoří. V průběhu testování systému lze pravidla i stupně podpory měnit. Konečná pravidla systému tvoří tzv. Znalostní systém. V některých programech lze k vytvořeným pravidlům definovat i stupeň podpory tzv. DoS (degree of support).

„Fuzzy interference umožňuje definovat i složené podmínky, spojené logickými spojkami Jejich interpretace je však odlišná od logických spojek AND, OR, NOT klasické logiky. V tabulce níže jsou uvedena vyhodnocovací pravidla tří typů logických spojek.“(6)

Tab. 3 - Pravidla fuzzy interference(Zdroj: DOSTÁL(1))

AND	$\mu_{x \wedge y} = MIN(\mu_x, \mu_y)$
OR	$\mu_{x \vee y} = MAX(\mu_x, \mu_y)$
NOT	$\mu_{\bar{x}} = 1 - \mu_x$

2.7.1.4 Defuzifikace

Poslední operací je defuzzifikace, která převede výsledky procesu fuzzy interference na reálné hodnoty. Existuje několik postupů převodu lingvistické proměnné na reálnou. Za zmínku rozhodně stojí „Center of maximum“.

„Jde o přístup, při kterém se přiřazuje výstupní lingvistické proměnné hodnotu reálné proměnné v závislosti na váze vstupní lingvistické proměnné a definovaných pravidel v kroku fuzzy interference.“(6)

Musíme si určit typickou hodnotu pro výstupní reálnou proměnnou reprezentující výstupní lingvistickou proměnnou, která byla zvolena v kroku fuzzy interference. Při předpokladu nevyužití Dos (stupeň podpory v procesu fuzzy interference) počítáme výstupní reálnou proměnnou podle následujícího vzorce.

Vzorec 5 - Výstupní reálná proměnná

$$y = \frac{\sum_{i=1}^n (y_i * \mu_{x_i})}{\sum_{i=1}^n \mu_{x_i}}$$


Kde y_i je zvolená hodnota výstupní lingvistické proměnné za předpokladu že $\mu_{y_i} = 1$ a μ_{x_i} je váha vstupní lingvistické proměnné.

2.7.2 Použití fuzzy logiky na kapitálových trzích

Jakýkoliv kapitálový trh je v současné době spjat s nespočetným množstvím informací, které více, či méně ovlivňují rozhodování investorů o koupi, nebo prodeji. Tyto informace s sebou nesou jistou míru chaotičnosti, nebo řekněme mlhavosti v rozhodování. Společně s neuronovými sítěmi a ostatními metodami umělé inteligence, fuzzy logika tvoří to nejlepší, co se v dnešní době nechá účinně použít.

Díky fuzzy logice můžeme hodnotit formace jako jsou Jitřenka, Večernice atd. Tyto cenové formace nejsou teoreticky popsány v této práci, ale mohou být obsaženy v praktické části. Pro nastudování těchto cenových formací odkazují na literaturu: REJNUŠ (18).

Fuzzy logika se na kapitálovém trhu může využívat k rozhodování zda obchod uskutečnit, nebo ne. Systém predikce na kapitálovém trhu můžeme doplnit o systém rozhodování podle smluvních podmínek brokera (marže, úroková sazba), aktuálních finančních možností společnosti, rizika, fundamentálních zpráv, formace a další.



Obr. 7 - Fuzzy systém

2.8 Neuronové sítě

V současné době je sepsáno hned několik definic neuronových sítí. Níže uvádím jednu z nich:


„Neuronová síť je vzájemně propojeným souborem jednoduchých prvků (processing elements), jednotek nebo uzlů, jejichž funkčnost je založena silách nebo vahách, získaných procesem přizpůsobování nebo učením z množiny trénovaných dat.“

Gurney, 1996

Říkáme, že neuronové sítě mají „černou skříňku“, nemůžeme detailně znát jejich vnitřní uspořádání. Neuronové sítě se používají tam kde deterministické závislosti jsou příliš provázané.

2.8.1 Biologický základ

Biologická struktura mozku dala základ k začátku a rozvoji zkoumání umělých neuronů. Ač v současné době došlo k velkému pokroku v zkoumání umělých neuronů, tak právě tyto umělé neurony stále hluboce zaostávají za těmi biologickými Obr. 7. Biologický i umělý neuron je systém mající vstupní část a výstupní část. U biologického neuronu rozpoznáváme dendrit (výběžek nervových buněk a vede vzruch směrem do buňky), axon (výstup z nervové buňky), synapse (spojení buněk nervovými vlákny), soma (tělo biologického neuronu). Na obrázku níže vede do/z těla neuronu pouze pár spojení, ve skutečnosti jich jsou tisíce.




Obr. 8 - Biologický neuron

2.8.2 Vlastnosti umělých neuronů

Historie umělých neuronů se datuje do doby první poloviny 20. Století. V té době W. S. McCulloch, W. Pitts a F. Rosenblatt vypracovali první práce. Od té doby se začali neuronové sítě vrstvit a vznikali první vícevrstvé neuronové sítě. Dále po objevení učícího algoritmu „backpropagation“ došlo k masivnímu rozšíření této metody klasifikace, optimalizace a predikce.

„Umělý neuron je založen na analogických principech. Vstupní informace jsou váženými vahami (weights). Odečítá se prahová hodnota (threshold) a pomocí aktivační funkce (activation function, transfer function) se signál transformuje na výstupní signál, který je předán následujícím umělým neuronům ve skryté (hidden) , resp. Výstupní vrstvě.“(6)

Každý neuron počítá vážený průměr všech vstupů, tím pro dva vstupy vzniká rovnice přímky, pro 3 vstupy vzniká rovnice roviny, pro 4 vstupy dostaneme rovnici prostoru. Tímto způsobem můžeme pokračovat i nadále.



Obr. 9 - Umělý neuron (Zdroj: MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J(14))

Vzorec 6 - Součet vstupů a prahové hodnoty

$$\varepsilon = \sum_{i=1}^n w_i * x_i + b$$

ε ... hodnota součtu vstupních hodnot a prahové hodnoty

b ... prahová hodnota

x ... i-vstupní hodnota

w_i ... i-vstupní váha

Aktivační funkce

- Hardlim – hodnota výstupní proměnné (n) je 0, nebo 1. Normování výstupních hodnot je smyslem použití této funkce.

Matematické vyjádření: $n = 0$ pro $a < 0$; $n = 1$ pro $a \geq 0$


- Purelin – je aktivační funkcí přenášející hodnotu a na výstup. Matematické vyjádření: $n = a$

- Logsig – aktivační funkce přenášející vstupní hodnoty na hodnoty v intervalu 0 až 1. Matematické vyjádření: $n = \frac{1}{1+e^{-a}}$

- Tansig - aktivační funkce přenášející vstupní hodnoty na výstupní hodnoty v intervalu -1 až 1. Matematické vyjádření: $n = \frac{e^a - e^{-a}}{e^a + e^{-a}}$

2.8.3 Neuronové sítě

Na spodním obrázku je naznačena obecná struktura vícevrstvé neuronové sítě, kde je znázorněna 4-3-2-1 neuronová síť. Toto značení vypovídá o počtu neuronů ve vstupní vrstvě (4), počtu neuronů ve dvou skrytých vrstvách (3-2) a o počtu neuronů ve výstupní vrstvě (1).




Obr. 10 - Obecné schéma neuronové sítě (Zdroj: DOSTÁL(1))

Vstupní vrstva – je vrstvou přes kterou do systému umělé inteligence vstupují prvotní data.

Vnitřní vrstva/y – je/ jsou to vrstvy do kterých data přicházejí ze vstupní vrstvy a daty vycházejí do vrstvy výstupní.

Výstupní vrstva – je vrstvou ze které data vycházejí, z této vrstvy dostáváme informace, které jsme chtěli získat.



Obr. 11 – Globální chyba

Cílem neuronových sítí je nalezení globálního minima, jak je naznačeno v obrázku nahoře, chyby. Chyba je parametr, můžeme říci ukazatel, úspěšnosti umělé neuronové sítě. Chybu značíme písmenem „E“ a vzorec pro vypočítání je následující.

Vzorec 7 - Chyba

$$E = \sum (n_i - o_i)^2,$$

n_i ...i-tá hodnota na výstupu

o_i ... i-tá očekávaná hodnota (je nám známá v průběhu testování).

Proces učení je rozveden níže v kapitole 2.7.5.

2.8.4 Modely neuronových sítí

- **Lineární model** – jedná se o nejjednodušší model neuronových sítí.
- **Generalized Regression Neural Network** – jde o model neuronové sítě, který řeší úlohy klasifikačního charakteru. Může být použit pro shlukovou analýzu, kde vstupní vrstva je považována za vstupní, pak obsahuje tzv. Radiální vrstvu. Ta obsahuje neurony (centroids), které reprezentují středy shluků (nastavují se před tréninkem). Regresní vrstvu, obsahující neurony,

které a) počítají regresní výstup pro věty a b) hustotu pravděpodobnosti. Výstupní vrstva obě regresní spojuje.

- **Pravděpodobnostní moden neuronové sítě** – jde o analogii k modelu neuronových sítí Generalized Regression Neural Network.
- **Radial basis function** – má výstupní lineární funkci, a vstupní a skrytou vrstvu s radiálními jednotkami
- **Multi layer perceptron** – obsahuje nelineární aktivační funkci sigmoid, a lineární PSP funkcí.

Tab. 4 - Výhody a nevýhody jednotlivých druhů sítí (Zdroj: MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. – LAŽANSKÝ(14))


Model sítě	Výhoda	Nevýhoda
Lineární	Velmi rychlý trénink	Neřeší nelineární úlohy
Probabilistická	Velmi rychlý trénink	Velikost sítě, je pomalejší při řešení úloh
Generalized Regression Neural Network	Velmi rychlý trénink	Velikost sítě, je pomalejší při řešení úloh
MLP	Rychlé řešení úloh	Pomalý trénink
Radial basis function	Velmi rychlý trénink	Velikost sítě, je pomalejší při řešení úloh

2.8.5 Topologie neuronových sítí

2.8.5.1 Vícevrstvá perceptronová síť (MLP)

„Vícevrstvá perceptronová síť (Multilayer Perceptron Neural Network - MLP) patří mezi nejznámější a nejpoužívanější neuronové sítě.“(14)


„Vícevrstvá perceptronová síť je síť s učitelem, tj. trénovací vzory musí kromě vstupních hodnot obsahovat i hodnoty příslušných odpovídajících výstupů. Vzhledem ke svému všeobecnému rozšíření existuje více variant vícevrstvé perceptronové sítě, které se snaží odstranit její nedostatky.“(14)



Obr. 12 - Schéma vícevrstvé neuronové sítě (Zdroj: MAŘÍK(14))

Struktura vícevrstvé perceptronové sítě je v zásadě jednoduchá. Skládá se z několika perceptronů poskládaných ve vrstvách, jak je vidět na předešlém obrázku. Každý neuron vrstvy následující má vstupy z každého neuronu vrstvy předcházející. Tomuto uspořádání se říká bipartitní graf. Tuto podmínku splňují i data vstupující do vstupní vrstvy, jsou tedy distribuovány do všech neuronů této vrstvy. Volba počtu skrytých vazeb v praxi je závislá na povaze úlohy, kterou bude umělá neuronová síť počítat.

Jak vícevrstvá perceptronová síť funguje ukazují na následujícím obrázku. Z něj je patrné, že použití pouze jednoho perceptronu přímkou rozděluje základní prostor na dvě části. Použitím dvou perceptronů v jedné skryté vrstvě dostaneme dvě přímky, které základní prostor rozdělí na 3, nebo 4 části (podle toho zda se protínají, nebo ne).



Obr. 13 - Princip fungování sítě (Zdroj: MAŘÍK(14))

Společně s MLP mluvíme o tzv. Vybavovací fázi. Proces vybavování je procesem práce umělé neuronové sítě. Na vstup přiložíme hodnoty a ty se v několika krocích transformují na výslednou proměnnou / proměnné (v závislosti na počtu perceptronů výstupní vrstvy).

Aby síť byla efektivní, musí zprvu projít procesem učení. Proces učení není nic jiného, než nastavování vah w_i a minimalizování chyby „E“.

Vzorec 8 – Chyba E

$$E = \sum_k E_k$$

E_k je chyba rovna k-tému trénovacímu vzoru a její výpočet je následující

Vzorec 9 - Chyba E_k

$$E_k = \frac{1}{2} \sum_j (y_j - d_{kj})$$

d_{kj} je element chtěného výstupu k-tého trénovacího cyklu. Pro optimalizaci se nastavují vstupní hodnoty i prahové hodnoty, nastavují na náhodná čísla, nejlépe z intervalu $< -\frac{2}{s}; \frac{2}{s} >$, kde „s“ označuje počet synapsí vstupujících do neuronu. Po průchodu všech trénovacích dat se váhy jednotlivých neuronů v trénovacím cyklu (t+1) nastavují podle následujícího vzorce.

Vzorec 10 - Váha synapse

$$w_{ij}(t + 1) = w_{ij}(t) + \Delta w_{ij}$$

$w_{ij}(t + 1)$...váha synapse ij v následujícím kroku, $w_{ij}(t)$... předchozí váha synapse a Δw_{ij} ... změna váhy synapse. Změna váhy synapse se počítá podle následujícího vzorce.

Vzorec 11 - Změna váhy synapse

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}$$


η ...je parametr učení náležící intervalu $<0;1>$, $\frac{\partial E}{\partial w_{ij}}$... je parciální derivace chyby (E) podle vah (w_{ij}).

Tento základní proces učení se jmenuje akumulované učení a váhy jsou nastaveny až po průchodu posledního trénovacího vzoru. Další procesy jsou popsány v níže v této práci.

2.8.5.2 Hopfieldova síť

Obecné schéma Hopfieldovi sítě je znázorněno na dalším obrázku, ze kterého je patrné, že Hopfieldova síť má tolik perceptronů kolik má vstupů, nebo výstupů. Každý neuron má jeden externí vstup a jeden externí výstup. Výstup z každého neuronu dalším vstupem pro další neurony, samozřejmě jde o vážený vstup (váha w_i).

Hopfieldova neuronová síť se využívá jako autoasociativní paměť. Toto použití v sobě skrývá dvě úskalí. První z nich je omezená kapacita paměti, neboli počtu věcí které je Hopfieldova síť schopna zapamatovat. Obecně platí že počet neuronů použitý v síti by se měl vypočítat podle následujícího vzorce $s \leq 0,138n$, kde s je počet vzorů a n je počet neuronů. Druhým úskalím je podobnost zapamatovaných vzorů. Ty by jsi měli být co nejméně podobné tzn. Měli by mít maximální Hamingovu vzdálenost.



Obr. 14 - Schéma Hopfieldovi sítě (Zdroj: MAŘÍK(14))

Zavedeme-li pojem energetická funkce Hopfieldovi neuronové sítě, zjistíme, že tato funkce popisuje proces vybavování a hlavně učení. Jinými slovy energetická funkce nám umožňuje lépe poznat chování Hopfieldovi neuronové sítě. Vztah pro výpočet funkce je následující:

Vzorec 12 - Energetická funkce

$$E = -\frac{1}{2} \sum_i \sum_{j \neq i} w_{ij} x_i x_j$$

Výsledkem vypočtené funkce je trojrozměrný graf mající konvexní a konkávní body. Naším úkolem je dostat se do globálního minima, tedy do minima energetické funkce. V tomto bodě se nachází předpoklad nejlépe si zapamatujícího vzoru.

Proces učení sítě je založen na vytváření si nových vzorů. U Hopfieldovi neuronové sítě musíme počítat i s již minulými naučenými vzory, neboť ty budou ovlivňovat hodnotu váhy w_i . Následující energetická funkce je rozepsána do součtu dvou částí. První část (obsahuje index „k“) je energetickou funkcí (E_k) nově naučeného vzoru a druhá část (obsahuje index „*“) je tzv. Šum (E'). Šum představuje minulé naučené vzory. Úkolem procesu učení je zadat vzory takovým způsobem, aby je šum co nejméně ovlivňoval.


Vzorec 13 - Energetická funkce rozepsání

$$E = -\frac{1}{2} \sum_i \sum_{j \neq i} w_{ij}^k x_{ki} x_{kj} - \frac{1}{2} \sum_i \sum_{j \neq i} w_{ij}^* x_i x_j = E_k + E'$$

Po procesu učení, kde jsme Hopfieldovu síť naučili potřebný počet vzorů, přichází na řadu proces vybavování. Proces vybavování je procesem, ve kterém získáváme ze vstupních dat (vstupní vzor) vzor naučený. Tento proces je dobře popsán v literatuře: MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J(14).

2.8.5.3 Kohonenova síť

„Kohonenova síť (Kohonenova samoorganizační mapa) je síť, která nepotřebují k učení učitele (Kohonen 1982 a další). Kohonenova síť provádí vektorovou kvantizaci, tj. snaží se aproximovat pravděpodobnostní rozdělení v předkládaných trénovacích datech.“(14)



Obr. 15 - Schéma Kohonenovi sítě (Zdroj: MAŘÍK(14))

Model Kohonenovi sítě je klasifikační model, jenž vytváří shluky. Jde o analogii se statistickou shlukovou analýzou.

Kohonenova síť nahodile vybere centra shluků a nahodile určí váhy. Algoritmus začíná testovat sousední body (neighbors) a přiřazuje je k nejbližšímu centru. V dalším

kroku jsou toto centrum a sousedé upravovány, tak aby odpovídaly zadané trénovací větě.

2.8.5.4 ART síť

Síť ART je síť, která je schopná se naučit nový vzor aniž by poškodila vzory předchozí. Tento efekt se jmenuje „problém proměnné stability“ a je způsoben změnami vah w_i mezi neurony. Naproti ostatním výše popsaným, je síť ART dobře vybavena proti tomuto problému. Vzhledem k tomu, že v praktické části této práce se síť ART zabývat nebudu, odkazuji na literaturu: MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J.(14).

2.8.6 Pravděpodobnostní neuronové sítě

„Na rozdíl od standardních metod nepředpokládá pravděpodobnostní přístup k neuronovým sítím a priori žádný model neuronu. Problém návrhu pravděpodobnostní neuronové sítě (PNS, probabilistic neural network) je formulován jako jedno z možných řešení obecného statistického rozhodovacího problému, které je založeno na aproximaci podmíněných rozložení pravděpodobnosti pomocí konečných distribučních směsí s komponentami součinného typu.“(14)

„Pravděpodobnostní přístup umožňuje sekvenční návrh vícevrstevných vzestupných neuronových struktur. Konkrétní návrh PSN spočívá v opakovaném řešení problému aproximace neznámých podmíněných rozložení pravděpodobnosti pomocí distribučních směsí s využitím EM algoritmu.“(14)

2.8.6.1 Podmíněná pravděpodobnost


Jako podmíněnou pravděpodobnost označujeme pravděpodobnost jevu označeného A vztahujícího se k standardním podmínkám daného pokusu, doplněného podmínkou B. Označení $P(A|B)$. Tohoto teoretického základu se využívá v pravděpodobnostních neuronových sítích.

Doc. RNDr. Jiří Kropáč, CSc. ve své publikaci uvádí: „Uvažujeme-li pokus, k němuž sestrojíme základní prostor Ω . Necht' jevy A a B jsou podmnožiny Ω . Jestliže k systému podmínek vymezující daný pokus přidáme další podmínku. A to, že nastal jev B, pak pravděpodobnost uskutečnění jevu α za této podmínky nazýváme pravděpodobností jevu A podmíněnou jevem B.“(10)

$$P(A|B) = \frac{P(A \cap B)}{P(B)}, \text{ pokud } P(B) > 0.$$

2.8.7 Proces učení

Učení s učitelem – proces učení s učitelem probíhá tak, že neuronová síť porovnává aktuální výstup s výstupem zadaným (učitel) a následně upravuje váhy u vstupů do neuronů. Při tomto způsobu učení se neuronové síti předkládají data z minulosti a ta se na nich učí. Pro zlepšení výsledků se neuronové síti mohou poskytnout i data z intervenčních proměnných, tedy proměnných, které se nacházejí mimo predikovanou oblast (v našem případě cenový vývoj akciového indexu S&P 500). Mohou jimi být signály z technické analýzy (ukazatele, klouzavých průměrů, MACD), nebo vývoj cenového ukazatele jiného instrumentu, který může mít na vývoj indexu svou váhu (Cena ropy, kurz USD/EUR).



Obr. 16 - Vazba časové řady a intervenční řady (Zdroj: *Učení neuronové sítě(31)*)

Učení bez učitele – probíhá tak, aby neuronová síť poskytovala konzistentní výstup při podobných vstupních datech.

Delta pravidlo – pravidlo nejmenších čtverců

Řízené učení – Globální extrém chybové funkce je předmětem řízeného učení.

Neřízené učení – jak uvádí FANTA „jde o identifikaci shluků dat s minimální vzdáleností od centra shluku. Je rovněž optimalizační úlohou.“(6)

2.8.7.1 Modely učení

- Základní model D.O. Hebb

Tento základní model učení byl popsán v kapitole: 2.8.5.1. Vícevrstvá perceptronová síť (MLP).

- Backpropagation

Jelikož je model backpropagation nejrozšířenějším učícím algoritmem u vícevrstevných dovedných sítí, budu se mu i více věnovat.

Obecný postup je následující. V prvním kroku se hodnoty vah nastaví na náhodnou hodnotu. Následně proběhne proces přenosu signálu a ve vstupní, skrytých a výstupní vrstvě. Obecně se výstup z každého neuronu spočítá jako součtu vážených vstupů a přepočítá se výstup z každého neuronu přes aktivační funkci. Při průchodu výstupní vrstvou se počítá odchylka od vypočítané hodnoty od skutečné. Tato odchylka je následně zpětně distribuována a v celé neuronové síti se přepočítávají váhy u jednotlivých neuronů. Tuto skutečnost dobře demonstruje následující příklad:

- Levenbergův-Marquardův učící algoritmus

Protože se při výpočtu chybové funkce vystavujeme nebezpečí, že se chyba ustálí v lokálním minimu a tudíž síť se nenaprogramuje s minimální chybou, bylo rozpracováno několik metod pro zlepšení učení sítě.

- **Velikost parametru učení** – doporučuje se zprvu nastavit parametr učení malý (při tom chyba klesá jen pomalu) a postupně jej zvyšovat (při vysokém parametru, chyba klesá rychleji, ale může divergovat)

- **Moment** – Do rovnice rozdílu váhy v kroku „t“ se přidá rozdíl váhy v kroku (t - 1) s parametrem momentu α , který náleží intervalu $\langle 0;1 \rangle$ a volí se blízky hodnotě „1“. To způsobuje tížený efekt dostání se přes lokální minimum. Tato metoda patří k nepoužívanějším optimalizačním metodám.

Vzorec 15 - Změna váhy synapse + Moment

$$\Delta w_{ij}(t) = -\eta \frac{\partial E}{\partial w_{ij}} + \alpha \Delta w_{ij}(t - 1)$$

- **Šum** – patří k dalším optimalizačním metodám
- **Přidání neuronů**

2.9 Program MATLAB a jeho moduly

Program MATLAB je vysoce výkonným nástrojem pro technické, matematické a jiné výpočty, vizualizace a programování v uživatelsky příjemném kabátu. Příklady typických použití:

- Matematika
- Vývoj algoritmů
- Sběr dat
- Modelování, simulace
- Analýza dat, průzkum a vizualizace
- Vědecké a technické grafy
- Vývoj aplikací

V následujících dvou odstavcích jsou krátce popsány dva nástroje, které v této práci použiji nejvíce.

2.9.1 Fuzzy logic toolbox


Fuzzy logic toolbox je efektivním nástrojem matematického prostředí MATLABU pro tvorbu fuzzy systémů. V MATLABU se fuzzy systém může vytvořit, editovat a nebo uživatel může integrovat svůj systém do prostředí MATLABU za použití Simulink. Navíc MATLAB umožňuje uživateli si vytvořit vlastní program založený na jazyce C. Fuzzy logic toolbox se do značné míry opírá o uživatelské prostředí „GUI“, které je uživatelsky více příjemné, než je práce na příkazovém řádku.

Fuzzy logic toolbox poskytuje tři druhy nástrojů

- Příkazový řádek
- Interaktivní grafické prostředí
- Simulink bloky a příklady

Do první skupiny patří funkce, které si uživatel může volat z příkazového řádku, nebo z vlastní aplikace. Většina těchto funkcí se ukládá do souboru s koncovkou „.m“

Za druhé nástroje interaktivního prostředí GUI umožňují uživateli přístup k mnoha funkcím a poskytují výborné prostředí pro tvorbu fuzzy systémů i jejich aplikaci a analýzu.




Obr. 17 - Grafické prostředí Fuzzylogic toolboxu v MATLABU

Do třetí skupiny patří sada nástrojů, bloků sloužících pro použití v prostředí Simulink.


2.9.2 Neural network toolbox

Neural network toolbox je skvělý nástroj pro navrhování, provádění, vizualizaci, simulaci neuronových sítí. Tento nástroj obsahuje příkazový řádek a grafické prostředí pro vytváření, školení, trénování a provozování neuronových sítí. Grafické prostředí zjednodušuje vytváření těchto sítí pro analýzu časových řad, rozpoznávání a clustering.

Po vytvoření neuronové sítě v grafickém prostředí si uživatel může nechat vygenerovat kód. Prostředí Neural network toolbox umožňuje použití všech výše uvedených architektur, metod učení a trénování popsanych v dřívější kapitole. Níže přikládám printscreeny tohoto toolboxu pro grafickou ilustraci.



Obr. 18 - Neural network fitting tool




Obr. 19 - Neural network clustering tool

2.10 Analýza časových řad

V této práci se ve 4. Kapitole zabývám vytvořením kvalitního systému pro predikci vývoje akciového indexu S&P 500, kde cenový graf je časovou řadou, nesmí v teoretické části chybět aspoň krátká zmínka o tom co je to časová řada.

Časová řada je posloupnost hodnot v závislosti na čas (ten se většinou v grafu zobrazuje na ose „x“). Jedná se tedy o vektor hodnot $x = (x_1; x_2; x_3 \dots x_n)$, kde n značí celkový počet hodnot časové řady.

„Časovou řadu si lze představit tak, jako by byla složena ze dvou základních složek, a to deterministické a stochastické. Deterministickou složku řady lze dále dělit na složku lineární, periodickou a chaotickou.“⁽¹⁾



Obr. 20 - Složky časové řady (Zdroj: DOSTÁL(1))

3 Analýza problému a současné situace

3.1 Vývoj akciového indexu

V týdnu od 21.2.2011 – 25.2.2011 byl vývoj akciového indexu ovlivněn jak býky tak medvědy. Velmi důležitou cenovou hladinu je 1294, což je nejnižší hladina a 1344 nejvyšší hladina.

3.2 Společnosti IFE-CR, a.s.

„IFE-CR, a.s. je celosvětově vedoucím výrobcem automatických dveřích systémů pro kolejová vozidla. Více jak 60 let se uplatňuje základní princip společnosti "úspěch skrz kvalitu a vývoj", který je hnacím motorem pro celou společnost.“(25)

společnost IFE-CR, a.s. je zařazena do koncernu Knorr-Bremse, kde figuruje jako samostatná jednotka, tak sama rozhoduje o svých ziscích. Za posledních 6 let (čítaje do roku 2009) měla společnost jen dvakrát záporný výsledek hospodaření a to v letech 2008 a 2005. V ostatních letech společnost dosahuje zisků v řádech milionů až desítek milionů.

„Cíly podniku již po mnoho let je minimálně udržení si tržního postavení, neustálé zlepšování jakosti svých výrobků, zvyšování odbornosti svých pracovníků a zlepšení klíčových ukazatelů ve všech oblastech.“(25)

3.3 SWOT analýza⁴

„Silné stránky společnosti – Strenths (S)

- Kvalita výrobku
- Technologie
- Propracovaný výrobní systém
- Propracovaný personální systém
- Specialisté v oboru
- Kolektiv pracovníků
- Silná IT podpora
- Součástí silné skupiny Knorr-Bremse

⁴ VAŠKO, J. *Hodnocení finanční situace podniku a návrhy na její zlepšení*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. 73s. Vedoucí bakalářské práce Ing. Vojtěch Bartoš, Ph.D.

- Dobře zvládnutá obchodní strategie společnosti

Slabé stránky společnosti – Weaknesses (W)

- Vysoké náklady výroby
- Vysoký tlak vedení na kontinuální zvyšování kvality výroby

Příležitosti – Opportunities (O)

- Rozvíjení technologie
- Nové trhy na východu

Hrozby – Treats (T)

- Konkurence v Číně
- Finanční světová krize
- Odchod nenahraditelných specialistů“ (25)

3.4 Portrova analýza⁵

„Riziko vstupu konkurentů

Na českém trhu je firma IFE-CR, a.s. jedinou firmou vyrábějící vstupní systémy. Společnost vyrábí zakázkově, a vytvoření stálých partnerů pro nově vznikající společnost by bylo velmi obtížné. Výroba vstupních systémů je nákladný a technologicky špatně zvládatelný proces, který firma IFE-CR, a.s. již zvládla. Je tedy malá pravděpodobnost příchodu konkurentů na český trh.

Rivalita mezi konkurenty

Na českém trhu není žádný konkurent, ale ve světovém měřítku začíná v Číně vyrůstat nová společnost zabývající se vstupními systémy. Jmenuje se IFE Victall Railway Vehicle Door System, Quingdao CO. Ltd, China. Tato firma nejenže vyrábí stejný produkt, ale dostala se svými náklady níže a tedy prodává levněji. Mezi touto společností a IFE-CR, a.s. jistě v budoucnu bude velká rivalita. Stávajícími hlavními soupeři IFE-CR, a. s. jsou britská firma Faiveley a německá Bode.

⁵ VAŠKO, J. *Hodnocení finanční situace podniku a návrhy na její zlepšení*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. 73s. Vedoucí bakalářské práce Ing. Vojtěch Bartoš, Ph.D.

Smluvní síla odběratelů

Jelikož se jedná o zakázkovou výrobu IFE-CR, a.s. nemá problémy s nacházením odběratelů. Společnost má 5 největších, stálých odběratelů, kterých se krize zatím nedotkla. Jediný problém může nastat se státními zakázkami, kdy si odběratel kvůli platební neschopnosti, nebo z jiných důvodů, může posunout termín dodání a tak způsobit držení kapitálu společnosti IFE-CR, a.s. v zásobách. Smluvní sílu odběratelů hodnotím jako přiměřenou.

Smluvní síla dodavatelů

Společnost IFE-CR, a.s. má zhruba 200 dodavatelů, přitom ke každé komponentě má 2 až 3 dodavatele. Každý z dodavatelů je pro společnost něčím výhodnější, jeden má lepší cenu a druhy kvalitu. Dělení dodavatelů tímto způsobem zapříčiňuje to, že IFE-CR, a.s. nemá kritického dodavatele a tudíž smluvní síla všech dodavatelů je malá. Díky celosvětové krizi, koncern Knor-Bremse hledá cestu, jak pomoci svým dodavatelům, aby nezkrachovali.

Hrozba substitutů

Jelikož se jedná o komplexně řešené vstupní systémy, nemyslím si a také nevím o jiném substitutu, který by mohl být použit na úkor vstupních systémů od IFE-CR, a.s.“ (25)

společnost IFE-CR,a.s., nebo kterákoliv jiná společnost může daný expertní systém využívat pro investování svého volného kapitálu, případně na určení vývoje cen vstupních komodit, které se odvíjí od cen komodit, které využívají dodavatelé.

3.5 Společnosti XTB

Společnost X-Trade Brokers je polskou společností obchodující s cennými papíry zajišťující mimoburzovní obchodování na derivátovém tzv. OTC trhu v rámci Evropské unie. Její pobočka X-Trade Broker je zapsána na městském soudu v Praze v oddílu A, vložka č. 56720 a zajišťuje obchodování na území české republiky.

Společnost využívá pro obchodování několik obchodních systémů:

- XTB-Trader
- XTB-Trader Mobile – jde o zúženou verzi programu XTB-Trader umožňující sledování/obchodování na trhu přes mobilní telefon

- XTB-Trade Multiterminal
- XTB-Option trader

Společnost využívá softwaru Metatrader ve verzi 4⁶ pro XTB-Trader . Ta umožňuje pohodlné sledování cenových grafů. Je dodávána bezplatně, v českém jazyce, s velkým počtem technických indikátorů. Další rozhodujícím prvkem je informační modul, který investora informuje o aktuálních datech ze světa a to díky AFX a analytikům společnosti.

Díky DDE servru může uživatel využívat real-time data a importovat je do programu MetaServer RT, který umožňuje real time přenos informací, nebo do dalších softwarů jako jsou MS excel, nebo Open Office. Postup jak DDE zapnout a data importovat je na stránkách společnosti X-Trade Broker.

MQL4 je programovací jazyk, díky kterému je možné naprogramovat si vlastní cenový ukazatel, který se zobrazuje přímo v cenovém grafu, či mimo něj, nebo celkovou obchodní strategii, či automatický obchodní systém

Díky všem výše zmíněným výhodám jsem se pro stahování dat rozhodl použít data ze systému XTB-Broker společnosti X-Trade Broker.

Ukazatele obchodní platformy XTB-Trader:

Acceleration/Deceleration Oscillator, Accumulation/Distribution, Alligator, Average firectional movement index, Average true range, Awesome oscillator, Bears power, Bollinger bands, Bulls power, Commodity chanel index, DeMarker, **Envelopes**, Fibonacci retracement, Force index, **Fractals**, Gator oscillator, Ichimoku Kinko Hyo, Market facilitation index, **Momentum**, Money flow index, Movind average, **MACD**, Moving average of oscillator, **On balance volume**, Parabolic SAR, Relative streight index, Relative vigor index, **Standard deviation**, Stochastic oscillator, **Volumes**, Williams' percent range

3.5.1 Otevření účtu

Veškeré dokumenty nutné k otevření účtu jsou obsaženy v příloze (smlouva, obchodní podmínky, investiční dotazník, identifikační karta zákazníka, prohlášení o vědomí investičního rizika, informace týkající se zajištění vkladů klientů, , žádost o

⁶ Aktuální ssoftware ke dni 30.4.2011

výplatu finančních prostředků, plná moc a informace o zdanění derivátů), případně jsou volně stažitelné z internetových stránek společnosti X-Trade broker www.xtb.cz.

4 Vlastní návrhy řešení, přínos návrhů řešení

4.1 Data pro predikci

Vlastní data je potřeba nejprve stáhnout a pak nahrát do programu MATLAB. Stahování dat se věnuji v další kapitole.

Nejjednodušším způsobem jak nahrát připravená data do MATLABU je přes GUI prostředí, příkladně GUI prostředí Neural network toolboxu a jakékoliv z modelů. Tím se vytvoří proměnná, kterou je potřeba uložit do externího.m souboru. Pro tuto práci jsem vytvořil několik proměnných (data_Input_All, data_Input_Indicators, data_Input_Values, data_Target_1day, data_Target_2day, data_Target_3day, data_Target_4day, data_Target_5day, data_Target_Theday, , data_Test_All, data_Test_Values, data_Test_Indicators a k nim příslušné tagreg data)

Tabulka s daty je v příloze.

4.1.1 Stažení z X-Trade broker

Všechna potřebná data jsou k dispozici na obchodní platformě X-Trade broker v záložce Nástroje – Centrum historie. Zde jsem vybral skupinu indikátorů Index FIS a v ní konkrétně index US.500, který reprezentuje historický vývoj akciového indexu S&P 500. Obrázek níže znázorňuje centrum historie obchodní platformy X- Trader.

Centrum historie: US.500,Daily

Symboly: Indices FIX

- DE.30
- EU.50
- FRA.40
- ITA.40
- SPA.35
- UK.100
- US.100
- US.30
- US.500
- 1 minuta (M1)
- 5 minut (M5)
- 15 minut (M15)
- 30 minut (M30)
- 1 hodina (H1)
- 4 hodiny (H4)
- Denní (D1)
- Týdenní (T1)
- Měsíční (Měs)
- W.20
- Commodity

Databáze: 1060 zápisy

Čas	Otevřít	Maximum	Minimum	Zavřít	Objem
2011.04.29 00:00	1354.1	1360.6	1352.4	1359.4	8308
2011.04.28 00:00	1351.6	1358.1	1346.4	1354.4	9941
2011.04.27 00:00	1341.4	1353.9	1340.1	1351.1	9109
2011.04.26 00:00	1332.9	1345.6	1327.6	1341.6	10028
2011.04.25 00:00	1329.6	1334.9	1326.9	1332.6	6792
2011.04.21 00:00	1334.4	1337.4	1328.4	1332.6	9085
2011.04.20 00:00	1312.9	1334.4	1311.1	1333.9	10942
2011.04.19 00:00	1298.9	1313.6	1293.9	1313.1	10505
2011.04.18 00:00	1316.6	1317.6	1290.1	1298.6	11312
2011.04.15 00:00	1311.6	1318.9	1305.4	1315.6	9563
2011.04.14 00:00	1308.4	1312.9	1297.9	1310.9	11573
2011.04.13 00:00	1309.1	1318.4	1304.6	1308.1	10715
2011.04.12 00:00	1317.4	1318.1	1305.1	1309.4	11196
2011.04.11 00:00	1326.9	1329.6	1316.9	1317.1	9188
2011.04.08 00:00	1329.1	1335.4	1318.4	1323.6	9985
2011.04.07 00:00	1329.1	1334.6	1322.1	1328.6	9793
2011.04.06 00:00	1327.1	1336.1	1326.4	1328.9	10691

Stáhnout Přidat Editovat Odstranit Exportovat Importovat Zavřít

Obr. 21 - Centrum historie

Data jsem pro svou práci stáhl za období dvou let a dvou měsíců. Konkrétně od 20.5.2009 – 28.2.2011. Tyto data jsou použita pro natrénování, validaci a testování neuronové sítě. Toto období představuje 465 obchodních dnů a v každém obchodním dnu byl stažen kompletní soubor informací o tomto dnu, tedy hodnoty open, high, low, close a volume. Dodatečná data akciového indexu od 1.3.2011 do 22.3.2011 jsou používána na dodatečný test již natrénované neuronové sítě. Zde jde o 18 obchodních dnů. I za toto období byl stažen kompletní soubor informací obchodního dnu. Všechna data jsem uložil do tabulkového programu excel ve verzi 2007.

4.1.2 Výpočet indikátorů

- a) Klouzavý průměr – pro výpočet tohoto technického indikátoru jsem využil tabulkový program Excel, ve kterém jsou uložena data stažená data z X-Tradera. Pro klouzavý průměr (SMA9) jsem využil sumu 9-ti denních minulých hodnot a podělil jsem ji součtem dnů. Jedná se tedy o jednoduchý devítidenní klouzavý průměr. Stejný postup byl využit pro SMA14, zde jsem využil periodu 14 předchozích obchodních dnů.
- b) RSI – i v případě indikátoru „Relative streight index“ byl využit výpočet v prostředí excelu. Tento index byl vypočítán a přiřazen ke každému obchodnímu dni podle vzorce $1 - RSI$. Pro výpočet jsem použil 14 denní rámeček, tak jak jej doporučil p. Wilder, když tento index sestavoval.
- c) Směrodatná odchylka – pro výpočet tohoto technického indexu byla použita přímo integrovaná funkce excelu „STDEV“ za 10-ti denní časový rámeček.
- d) MACD – Indikátor MACD byl vypočítán jako rozdíl exponenciálního klouzavého průměru za 26 obchodních dnů od exponenciálního klouzavého průměru za 12 obchodních dnů. Veškerý propočet byl vytvořen v Excelu.

4.2 Predikce metodou NARX

V celé této kapitole, používám původní nastavení MATLABU:

- Rozdělení dat – random (dividerand)
- Trénovací funkce: Levenberg-Marguard (trainlm)
- Měření výkonu: Mean squared error (mse)
- Derivative: Default (defaultderiv)

Pro testování modelu NARX jsem vybral 4 druhy síťové architektury s ohledem na propočtový výkon PC. První architektura je implicitně nastavenou architekturou MATLABU, jedná se o síť s 10 neurony a zpožděním 2 období výstupní hodnoty. Jako druhou architekturu jsem zvolil architekturu o 20 neuronech a 10 dobách zpoždění výstupu. V třetí architektuře jsem ponechal počet neuronů, ale zvýšil jsem počet zpoždění na 17, tak aby tato síť umožnila porovnat výsledky s předchozí. Poslední síť jsem zkonstruoval jako nejrobustnější o 30 neuronech a časové zpoždění ponechal na 17. V celé práci používám maximální časové zpoždění zpětného kanálu neuronových sítí maximálně 17 a to z důvodu dodatečných testovacích dat, které obsahují 18 obchodních dnů. Při definování neuronové sítě, konkrétně časového zpoždění, nejde na počítači, na kterém byl pokus prováděn, definovat větší než 50 násobné časové zpoždění a to z důvodů nedostatku paměti počítače⁷.

Každá trojice řádků zobrazuje rozdělení dat do skupin učících se dat „learning“, ověřovacích „validation“ a testovacích „testing“. V celé práci používám rozdělení „90 5 5“, „30 35 35“ a „60 25 15“. V prvním případě je většina dat určena pro naučení neuronové sítě a jen minimum z nich je pro validaci a testování. Druhé rozdělení dat reprezentuje rovnoměrné rozložení vstupních dat do všech 3 skupin a ve 3 rozdělení dat se ponechává 60% dat pro naučení neuronové sítě, 25% dat na validaci a pouze 15% dat pro testování.

Každou síťovou architekturu jsem zároveň testoval pro 5 obchodních dnů.

4.2.1 Predikce Close pomocí Hodnot Open, High, low, close, volume

V této kapitole se věnuji predikci hodnoty close za pomoci vstupních hodnot cenového grafu, tedy hodnot Open, High, Low, Close a objemu obchodů Volume.

Následující tabulky jsou seřazeny podle síťové architektury. V každé tabulce, pro každou síťovou architekturu, bylo provedeno 15 testů (tzn. 60 testů pro metodu NARX a pro vstupní hodnoty stažené z platformy X-Trader). Vyhodnocování bylo uskutečněno za pomoci metody MSE „Mean square error“ v českém překladu „metodou nejmenších čtverců“. Dále byla propočtena predikční chyba MAPE, o které píšu v kapitole 4.5 Srovnání metod.

⁷ V době provádění testu 4 GB RAM, 1066 MHz

Za nejlépe naučenou síť byla považována ta síť, které neměla jen nejmenší chybu MSE⁸ v jedné, či dvou částech rozdělování dat, ale ta, která měla nejkonzistentnější rozdělení chyby (tzn. MSE byla pro fáze učení, validaci a testování přibližně stejná) a zároveň s požadavkem na co nejmenší hodnoty MSE. Tyto skupiny dat jsou vyznačeny v tabulkách.

Tab. 5 - NARX, Síť (10 2), Values

		Síť (neurons:10, delay:2)				
MSE	%	1 den	2 den	3 den	4 den	5 den
Learning	90	128	142	125	146	129
Validation	5	168	145	268	159	131
Testing	5	153	269	141	307	185
Learning	30	125	79	99	86	60
Validation	35	227	464	261	206	280
Testing	35	226	514	531	310	245
Learning	60	114	125	96	93	117
Validation	25	224	163	272	192	182
Testing	15	359	238	178	154	274

Tab. 6 - NARX, Síť (20 10), Values

		Síť (neurons:20, delay:10)				
MSE	%	1 den	2 den	3 den	4 den	5 den
Learning	90	223	13	195	76	55
Validation	5	198	347	614	98	312
Testing	5	374	585	504	305	528
Learning	30	76	94	1	0.004	28
Validation	35	1225	677	978	624	507
Testing	35	2046	543	1391	1103	350
Learning	60	59	196	224	0.2	85
Validation	25	247	914	710	545	233
Testing	15	207	755	528	518	584

⁸ MSE je kritériem výkonu, funkce MATLABU pro grafický výstup „plotperform“, všechny vybrané sítě mají graf výkonu v příloze Výsledky.zip

Tab. 7 - NARX, Sít' (20 17), Values


		Sít' (neurons:20, delay:17)				
MSE	%	1 den	2 den	3 den	4 den	5 den
Learning	90	0.005	76	177	93	47
Validation	5	374	272	493	240	95
Testing	5	408	111	703	367	336
Learning	30	0.0029	12	4	19	2.8
Validation	35	728	528	584	691	574
Testing	35	623	472	486	911	746
Learning	60	0.000009	5	3.9E-19	70	87
Validation	25	491	77	689	538	374
Testing	15	566	273	586	483	461

Tab. 8 - NARX, Sít' (30 17), Values


		Sít' (neurons:30, delay:17)				
MSE	%	1 den	2 den	3 den	4 den	5 den
Learning	90	30	54	2	0.7	4E-10
Validation	5	578	631	217	732	472
Testing	5	718	274	487	915	414
Learning	30	2	1.9	4	0.0008	5E-15
Validation	35	830	448	709	569	918
Testing	35	585	1330	596	659	1298
Learning	60	1	9E-15	4	0.4	41
Validation	25	882	640	662	465	1248
Testing	15	670	689	738	687	482

4.2.1.1 Popis vybraných sítí


Nejlepší srovnání vybraných metod za jednotlivé obchodní dny nabízí tzv. Error histogram, na kterém je vidět rozložení chyb v predikci. Následující pětice obrázků, seřazená podle dnů tuto chybu dobře dokresluje. Z rozložení hodnot na histogramu je patrné, že v prvních 3 dnech byla vybrána síť s rozložením dat „60 25 15“ a pro 4. a 5. den síť s rozložením „90 5 5“




Obr. 22 - Error histogram, NARX, Values, 1. Den




Obr. 23 - Error histogram, NARX, Values, 2. Den



Obr. 24 Error histogram, NARX, Values, 3. Den




Obr. 25 - Error histogram, NARX, Values, 4. den



Obr. 26 - Error histogram, NARX, Values, 5. den


Z rozložení chyby je patrné, že síťová architektura má velký vliv. Při zvyšování počtu neuronů se chyba v testovacích datech zmenšuje, to ale na úkor dat validace a testování.

Jiný pohled na rozložení chyby poskytuje časový graf za všech 5 obchodních dnů. Error1 reprezentuje chybu 1 dne, Error2 chybu 2 dne atd. Z něj je zřejmé, ve kterém pásu se většina chyb pohybuje. Podobné znázornění poskytnou grafy „Time-response“ programu MATLAB. Ty jsou uloženy v příloženém souboru Výsledky.zip



Graf 2 - NARX, Časové rozložení chyby

Nejzajímavější výsledky jsme dostali v 5. obchodním dnu, kdy měla neuronová síť chyby pouze: Learning = 47, Validation = 95 a mírně zhoršený Testing = 336. Následující obrázek regrese tento fakt dokládá.



Obr. 27 - Regrese, NARX, Values, 5. Den

Skript z 5. obchodního dne je obsažen v příloze.

Vybrané neuronové sítě predikující maximálně 5 dnů z vstupních dat Open, High, Low, Close a Volume predikovali s průměrnou chybou v rozmezí -20 až 20, počítáno v absolutních hodnotách. V méně volatilních dnech měli neuronové sítě lepší výsledky než ve dnech se zvýšenou volatilitou. To je patrné z grafu na předešlé stránce. Kde mezi 250 až zhruba 350 obchodním dnem byla zvýšená volatilita.

4.2.2 Predikce pomocí indikátorů MACD, MA, Standard dev. a RSI

Druhým způsobem, jak predikovat budoucí vývoj akciového indexu je predikce za pomoci technických ukazatelů. I zde jsou následující tabulky seřazeny podle architektury. I zde jsem využil 4 architektury. Můžeme říci, že v této kapitole bylo použito stejných kritérií jako v předchozí kapitole, jen s ohledem na vstupní data.

Tab. 9 - NARX, Sít' (10 2), Ukazatele

		Sít' (neurons:10, delay:2)				
	%	1 den	2 den	3 den	4 den	5 den
Learning	90	92	94	105	131	81
Validation	5	162	104	310	133	253
Testing	5	121	123	175	207	394
Learning	30	66	124	127	117	120
Validation	35	339	168	260	237	234
Testing	35	210	181	221	260	155
Learning	60	80	112	108	107	104
Validation	25	230	208	182	206	135
Testing	15	260	176	172	186	256

Tab. 10 - NARX, Sít' (20 10), Ukazatele

		Sít' (neurons:20, delay:10)				
	%	1 den	2 den	3 den	4 den	5 den
Learning	90	99	9	18	100	136
Validation	5	167	252	323	606	484
Testing	5	281	449	250	289	574
Learning	30	199	292	8	2	7
Validation	35	725	903	603	426	774
Testing	35	747	1022	753	616	681
Learning	60	26	0.3	39	3	0.02
Validation	25	602	468	463	587	484
Testing	15	477	408	546	761	622

Tab. 11 - NARX, Sít' (20 17), Ukazatele

		Sít' (neurons:20, delay:17)				
	%	1 den	2 den	3 den	4 den	5 den
Learning	90	0.00001	16	426	2E-21	5
Validation	5	424	151	460	267	392
Testing	5	539	385	878	463	328
Learning	30	0.084	0.08	7	0.006	0.0006
Validation	35	890	1105	647	524	470
Testing	35	856	1127	706	546	547
Learning	60	8	0.003	0.009	0.01	0.4
Validation	25	455	321	330	285	384
Testing	15	483	306	405	353	350


Tab. 12 - NARX, Síť (30 17), Ukazatele

		Síť (neurons:30, delay:17)				
	%	1 den	2 den	3 den	4 den	5 den
Learning	90	45	0.00001	64	1E-20	0.5
Validation	5	602	175	290	203	259
Testing	5	237	198	433	319	290
Learning	30	13	0.0000007	2E-26	49	0.2
Validation	35	727	517	930	603	549
Testing	35	777	679	1002	383	652
Learning	60	1	20	1E-16	0.00000001	1E-20
Validation	25	413	417	447	385	414
Testing	15	504	693	392	446	362


Z tabulek vyplívá, že pro predikci vývoje za použití zvolených technických indikátorů je nejvhodnější sítíovou architekturou implicitně zvolené programem MATLAB. Až na predikci 2. dne kde skvělých výsledků dosáhla síť o 30 neuronech a 17 denním zpoždění.

4.2.2.1 Popis vybraných sítí


Stejně jako v předešlé kapitole, je pro popis vybraných sítí nejlepší Error histogram.



Obr. 28 - Error histogram, NARX, Ukazatele, 1. Den Obr. 29 - Error histogram, NARX, Ukazatele, 2. Den




Obr. 30 - Error histogram, NARX, Ukazatele, 3. Den Obr. 31 - Error histogram, NARX, Ukazatele, 4. Den



Obr. 32 - Error histogram, NARX, Ukazatele, 5. den

Je na první pohled patrné, že při zvyšování počtu neuronů a zpoždění, se neuronová síť lépe učí. V predikci 2. obchodního dne byla dokonce lepší i ve validaci a testování. V porovnání s prvním obchodním dnem se hodnoty chyby pohybují ve stejném celkovém intervalu, ale většina z nich je soustředěna kolem 0. Dokonce v porovnání se 3., 4. a 5. obchodním dnem, je rozložení celkového intervalu chyby druhého dne menší.



Obr. 33 - - Regrese, NARX, Ukazatele, 2. Den

Skript z 2. obchodního dne je obsažen v příloze.

4.3 Predikce za pomoci Nonlinear Input-Output

V této kapitole se věnuji predikci hodnoty close za pomoci vstupních hodnot indikátorů, tedy MACD, SMA9, SMA14, Standard deviation a RSI, zároveň používám původní nastavení MATLABU:

- Rozdělení dat – random (dividerand)
- Trénovací funkce: Levenberg-Marguard (trainlm)
- Měření výkonu: Mean squared error (mse)
- Derivative: Default (defaultderiv)

I zde jsem vybral takovou síťovou architekturu, abych jí mohl srovnávat s ostatními metodami. Jedná se o architekturu 10 neuronů a zpoždění 2, dále 20 neuronů a 10 denního zpoždění a jako poslední jsem vybral architekturu čítající 30 neuronů a 17 dnů zpoždění.

Rozdělení dat bylo přesně v korespondenci s rozdělením dat u metody NARX. Znova z důvodů poměření výkonnosti obou metod. Data byla rozdělena v poměru, který rozepsán v tabulce.

Tab. 13 - Input-Output, rozdělení dat

	1. rozdělení	2. rozdělení	3. rozdělení
Learning	90%	30%	60%
Validarion	5%	35%	25%
TEsting	5%	35%	15%

4.3.1 Predikce Close pomocí Hodnot Open, High, low, volume

Metoda Nonlinear Input-Output predikuje výstup, bez zpětné vazby, to znamená, že v této kapitole, kde jsem určoval hodnotu Close cenového grafu akciového indexu S&P 500, se hodnota Close ceny nepoužívá jako vstup.

Tab. 14 - Input-Output, Sít' (10 2), Values

		Sít' (neurons:10, delay:2)				
MSE	%	1day	2 day	3 day	4 day	5 day
Learning	90	164	238	316	374	467
Validation	5	116	408	295	285	341
Testing	5	60	279	296	414	569
Learning	30	232	200	178	327	334
Validation	35	333	622	791	616	855
Testing	35	357	467	9551	1345	1572
Learning	60	112	261	276	443	541
Validation	25	199	315	498	535	1053
Testing	15	454	303	567	462	505

Tab. 15 - Input-Output, Sít' (20 10), Values


		Sít' (neurons:20, delay:10)				
MSE	%	1day	2 day	3 day	4 day	5 day
Learning	90	38	137	165	488	233
Validation	5	407	253	339	268	541
Testing	5	444	233	740	563	765
Learning	30	23	161	313	200	194
Validation	35	655	900	836	713	819
Testing	35	681	763	1065	724	871
Learning	60	59	624	92	368	183
Validation	25	432	981	927	567	786
Testing	15	442	1695	1192	731	1160

Tab. 16 - Input-Output, Síť (30 17), Values


MSE	%	Síť (neurons:30, delay:17)				
		1day	2 day	3 day	4 day	5 day
Learning	90	135	127	37	16	222
Validation	5	365	1898	493	362	821
Testing	5	643	2494	243	1144	307
Learning	30	0.00002	187	8E-26	6	0.0000002
Validation	35	487	952	1874	1624	2168
Testing	35	997	1584	1905	1521	1608
Learning	60	3	0.0007	61	24	102
Validation	25	365	1201	706	1894	1116
Testing	15	727	1833	1314	760	2074

Tabulky ukazují sílu jednoduchých neuronových sítí, které dosahují lepších výsledků než ty složitější, až na výjimku z predikce 3. obchodního dne.


Při této metodě, dopadl zajímavým způsobem graf „Error autocorrelation“.




Obr. 34 - Error autocorrelation, Input-Output, Ukazatele, 1. den




Obr. 35 - Error autocorrelation, Input-Output, Ukazatele, 2. den



Obr. 36 - Error autocorrelation, Input-Output, Ukazatele, 3. den




Obr. 37 - Error autocorrelation, Input-Output, Ukazatele, 4. den



Obr. 38 - Error autocorrelation, Input-Output, Ukazatele, 5. den


Chyba, která je zobrazená na error histogramu⁹ je nejčastější v intervalu od -20 do 20.

Významně dobrých hodnot se mi podařilo naměřit za použití sítě (10 2), tedy implicitně nastavené, rozložení dat 90: Learning, 5: Validation a 5: Testing pro predikci 1 obchodního dne. Pro tuto metodu jsem provedl dodatečný test. Výsledky jsou znázorněny níže na obrázku časové odezvy a histogramu chyby.



Obr. 39 - Test time response, Input-Output, Values, 1. den

⁹ Dostupný z příloženého souboru Výsledky.zip



Obr. 40 - Test error histogram, Input-Output, Values, 1. den

Rozložení chyby je v dodatečném testu nerovnoměrně rozřazeno, většina hodnot se nachází pod nulovou linií, to znamená, že neuronová síť odhaduje nižší cenu než je target a to v poměru 12:5.

4.3.2 Predikce pomocí indikátorů MACD, MA, Standard dev. a RSI

Předposlední metodou predikce ceny close akciového indexu S&P 500 je metoda Nonlinear Input-Output se vstupními hodnotami vypočítaných technických indikátorů. Výsledky úspěšnosti/neúspěšnosti zobrazují tři následující tabulky.

Tab. 17 - Input-Output, Síť (10 2), Ukazatele

		Síť (neurons:10, delay:2)				
MSE	%	1day	2 day	3 day	4 day	5 day
Learning	90	138	211	315	433	376
Validation	5	207	250	349	401	356
Testing	5	200	253	314	408	785
Learning	30	321	142	101	329	141
Validation	35	381	402	999	819	832
Testing	35	372	367	908	778	904
Learning	60	139	213	259	174	237
Validation	25	276	300	516	454	617
Testing	15	299	345	480	542	450


Tab. 18 - Input-Output, Síť (20 10), Ukazatele

		Síť (neurons:20, delay:10)				
MSE	%	1day	2 day	3 day	4 day	5 day
Learning	90	48	10	201	8	526
Validation	5	338	226	190	253	556
Testing	5	303	283	635	329	609
Learning	30	29	2	4	128	4
Validation	35	634	861	817	1164	1192
Testing	35	556	633	1193	953	1360
Learning	60	21	0.00004	46	215	335
Validation	25	605	839	748	988	804
Testing	15	473	895	716	765	815

Tab. 19 - Input-Output, Síť (30 17), Ukazatele

		Síť (neurons:30, delay:17)				
MSE	%	1day	2 day	3 day	4 day	5 day
Learning	90	0.0000002	0.0004	4E-22	2	5
Validation	5	237	200	562	385	527
Testing	5	670	627	364	482	451
Learning	30	0.06	2E-26	9E-10	1	0.03
Validation	35	912	702	806	1296	1612
Testing	35	741	717	894	1411	1933
Learning	60	0.002	0.9	70	5	0.0004
Validation	25	604	640	591	513	459
Testing	15	409	574	771	573	475

Všimněme si, že MSE se ve všech obchodních dnech pohybuje kolem hodnoty 300 a někdy i mnohem více. Tyto vysoké hodnoty dobře graficky zobrazuje regresní přímka predikce třetího obchodního dne, kde jsou hodnoty MSE pro učení, validaci a testování nejbližší.



Obr. 41 - Regrese, Input-Output, Ukazatele, 3. den

4.4 Predikce metodou Nonlinear Autoregressive with external Input

Jelikož se jedná o metodu, které predikuje budoucí vývoj, pouze na základě předešlých hodnot výstupu, není tedy komplexní, je tato metoda podle výsledků měření MSE v predikci horší, než výše popsaná metoda NARX.

Za zmínku stojí jen to, že pokud byla většina vstupních hodnot ponechána na učení, pak se neuronová Síť svými výsledky přibližovala metodě NARX.

4.5 Srovnání metod

V průběhu zpracovávání predikce neuronovými sítěmi jsem se dostal k celé řadě zajímavých výsledků od naprosté nenaučenosti sítě přes dokonalou naučenost na učicích se datech a velmi slabou na datech pro validaci a testování, až po řekněme systémy, které byli konzistentní v celém rozsahu. Tyto systémy jsem vybral a popsal v předešlých kapitolách. Celkem bylo testováno 222 neuronových sítí, za použití 4 architektur a 3 metod.

Zhodnotím-li cenový graf indexu, tak za zvolenou periodu se vystřídalo rostoucí, klesající i stagnující období, období s mírnou volatilitou i se zvýšenou. Neuronové sítě nejlépe předpovídali budoucnost v mírně volatilním dnu a při rostoucím trendu. Naopak při velmi volatilních obchodních seancích, měli všechny architektury všech modelů problémy s určením budoucího vývoje.

V následujících tabulkách jsou zapsány průměrné predikční chyby MAPE a správně/chybně odhadnutý směr vývoje cenového grafu.

Tab. 20 - Výsledky, NARX, Values

<u>NARX</u>	Values				
	1 day	2 day	3 day	4 day	5 day
MAPE [%]	0.78	0.804	0.801	0.63	0.52
Dobře	245	232	237	279	291
Špatně	209	230	225	175	156

Tab. 21 - Výsledky, NARX, Ukazatele

<u>NARX</u>	Ukazatel				
	1 day	2 day	3 day	4 day	5 day
MAPE [%]	0.67	0.1	0.76	0.8	0.85
Dobře	273	413	244	231	234
Špatně	189	34	218	231	228

Tab. 22 - Výsledky, Input-Output, Values

<u>Input-Output</u>	Values				
	1 day	2 day	3 day	4 day	5 day
MAPE [%]	0.86	1.16	0.48	1.34	1.53
Dobře	235	245	324	248	271
Špatně	228	218	124	215	192

Tab. 23 - Výsledky, Input-Output, Ukazatele

<u>Input-Output</u>	Ukazatel				
	1 day	2 day	3 day	4 day	5 day
MAPE [%]	1.02	0.3	1.22	0.28	0.6
Dobře	235	363	252	365	329
Špatně	228	92	211	90	119

Pro predikci budoucího vývoje se podle výsledků zdá být nejlepší metoda Input-Output za použití technických ukazatelů jako vstupů. Tato metoda vykazuje nejlepší odhady směru budoucích hodnot, ale nezapomeňme, že pro 2., 3. a 4. obchodní den byla použita architektura, které se vyznačuje velmi dobrými odhady na učicích se datech, ale již horšími na datech pro validaci a testování.

Proto jako nejkonzistentnější metoda pro predikci budoucího vývoje se z 222 pokusů jeví metoda NARX za použití vstupních hodnot cen indexu, která vykazuje relativně stálou predikční chybu, pohybující se kolem hodnoty 0.7%.

4.6 Systém pro rozhodování

V této kapitole se věnuji vytvoření expertního rozhodovacího systému, který se bude uživateli radit, zda do obchodu vstoupit, či nikoliv a s jak velkou částkou. Toto rozhodování bude prováděno z dat klouzavých průměrů 14-ti denního a 9-ti denního, které určují trend. Trend společně s průběhem, resp. chybou minulého obchodního dne budou určovat příležitost, tedy skutečnost, zda do obchodu vstoupit, či nikoliv.

4.6.1 Trend

Trend vychází z rozdílových hodnot současného a předchozího obchodního dne technických ukazatelů SMA9 a SMA14. Rozpětí jakého tyto hodnoty mohou nabývat bylo dosaženo tak, že jsem vypočítal rozdíly dvou obchodních dnů na grafickém vyjádření bodového grafu jsem určil hranice ve kterých se tyto rozdíly pohybují. Pro SMA9 to je minimum – 50,-5,-2.5,2.5,5,50. Pro SMA14 to je -100,-4,-1.5,1.5,4,100.

SMA9

- Silně klesající
- Mírně klesající
- Stagnující
- Mírně rostoucí
- Silně rostoucí
- Naměřené maximum: 9.98
- Naměřené minimum: -11.20

SMA14

- Silně klesající
- Mírně klesající
- Stagnující
- Mírně rostoucí
- Silně rostoucí
- Naměřené maximum: 7.61
- Naměřené minimum: -8.46


Horní a spodní hranice byly záměrně nastaveny vysoké, aby nedošlo ke zkolabování system. Výsledný trend skládajících se z poměřování, těchto dvou trendových ukazatelů má též 5 atributů, jsou jimi:

Trend

- Silně rostoucí
- Mírně rostoucí
- Stagnující
- Mírně klesající
- Silně klesající

Výsledné hodnoty jsem normalizoval do intervalu $<-1 ; 1>$ to z důvodů následného využití v určování příležitostí.

Výsledné grafické zobrazení proměně trend je na následujícím obrázku:



Obr. 42 - Výstup proměnné Trend, Fuzzy logika

4.6.2 Příležitost

Příležitost pro obchodování nastává tehdy, pokud trend není stagnující a neuronová síť je dobře naučená a tedy z výsledků minulého vývoje vyplívá malá chyba. I zde jsem stejnou metodou jako u klouzavých průměrů stanovil hranice mezi lingvistickými poměny. Hranice jsou -150,-7,-4,4,-7,150. Nastavení vstupů:

Průběh

- Špatný
- Možný
- Příznivý
- Možný
- Špatný

Trend

- Silně rostoucí
- Mírně rostoucí
- Stagnující
- Mírně klesající


- Silně klesající

Výstupem je příležitost doporučení do vstupu do pozice, může se jednat o nákup či prodej. Pro ukončení pozice doporučuji využít inteligentní příkaz platformy Stop loss.

Příležitost

- Buy
- No action
- Sell

Výsledné grafické zobrazení pro příležitost je zobrazeno na následujícím obrázku:



Obr. 43 - Výstup proměně Příležitost, Fuzzi logika

4.7 Velikost obchodu

Velikost obchodovaného kontraktu se určuje podle pravidel Possition sizingu, podle vzorce uvedeného v kapitole 2.4. Toto nastavení je díky jednoduchosti nelepší vytvořit v programu excel, který je pro tento účel dostačující.

4.8 Zhodnocení vytvořeného systému a využití pro společnost

Systém predikce je budoucího vývoje je založen na neuronových sítích. Tyto sítě jsou považovány spíše jako černá skříňka, do které uživatel, potažmo ani programátor, nevidí. Podle predikčních chyby MAPE byl vybrán systém, který tuto chybu měl v průměru kolem hodnoty 0,7%. Tento systém byl vybrán jako nejkonzistentnější. Jeho predikční schopnost byly změřeny podle správného odhadu směru. NARX systém byl úspěšný „pouze“ v 57%.

Systém pro rozhodování, byl vytvořen za pomoci fuzzy logiky. Jeho hlavním cílem je pomoci investorovi v rozhodování zda do obchodu vstoupit a nebo ne. Je rozdělen na trendovou složku, která díky klouzavým průměrům sleduje trend trhu a rozhodovací složky, která díky aktuální chybě v predikci neuronové sítě napovídá, zda je síť dobře natrénována a investor může do obchodu vstoupit, nebo zda je síť pro daný moment natrénována hůře a tento systém doporučuje do obchodu nestupovat.

V obchodování na trzích platí jedno pravidlo a to, že investorovi stačí pouze 51% úspěšnost v odhadování směru trhu a už může být ziskový (+ musíme připočítat marži za obchodování). Tedy tento systém je o plných 6% lepší, než jiný ziskový systém. Při dodržení striktních pravidel money managementu, hlavně poměru zisku a riziku, může tento systém dávat investorům více než zajímavé výsledky.

Ve většině společností je investování na kapitálových trzích spojeno s vysokým až nepřiměřeným rizikem. Firmy využívající prostředí MATBAU mohou jednoduše díky neural network toolboxu a síťové architektury NARX využít tento predikční systém, který jim bude dávat uspokojivé výsledky a riziko z obchodování snižovat. Díky rozhodujícímu systému budou vědět, kdy do trhu vstoupit a kdy ne.

Systémové prostředí GUI neural network toolboxu z prostředků MATLABU je pro uživatele tou nejschůdnější cestou jak se dopracovat k výsledku. Je intuitivní a zároveň do určité míry komplexní s možností výběru několika parametrů. Systémové prostředí GUI má i své nevýhody, jmenujme jeho komplexnost, která pokročilejším uživatelům nemusí stačit. Pro ty je tu nástroj zvaný nntool, který dovoluje uživateli širší možnosti nastavení.

5 Závěr

Diplomovou práci na téma „Využití prostředků umělé inteligence na kapitálových trzích“ jsem rozdělil do 3 částí začínající druhou kapitolou, ve které se věnuji teoretickým východiskům této práce. Třetí kapitola se věnuje aktuální situaci akciového indexu, stručnému popisu společností IFE-CR, a.s. a X-Trade broker. Čtvrtá kapitola diplomové práce je zaměřena na vlastní řešení stanoveného cíle.

Cílem diplomové práce bylo zjistit zda je GUI prostředí programu MATLAB neural network toolboxu vhodné pro predikci a vytvořit systém, který se bude na základě minulého vývoje ceny akciového indexu a trendu rozhodovat, zda to trhu vstoupit, či nikoliv. Neuronovou síť byla s určitou přesností spočítána predikce budoucího vývoje akciového indexu a to denní až pětidenní. Za pomoci fuzzy logiky byl vytvořen rozhodující systém, který doporučuje index nakoupit, prodat, nebo nevynakládat žádnou akci.

Cíle určené na začátku diplomové práce považuji za splněné. Výsledky diplomové práce budou společnosti IFE-CR, a.s. k dispozici, samozřejmě záleží na zvážení managementu, jakým způsobem je využijí. Před použitím tohoto systému doporučuji jakékoliv společnosti dobře promyslet její finanční možnosti a také zhodnotit rizika možné ztráty těchto peněz na hlavní činnost podniku. Zároveň doporučuji prostudovat literatury, internet, nebo další zdroje informací o obchodování na kapitálových trzích před samotným obchodováním. Věřím že výsledky práce budou ku prospěchu společnosti.

6 Seznam použité literatury

Knihy:

- 1) DOSTÁL, P. *Pokročilé metody analýz a modelování v podnikatelství a veřejné správě*. 1. vyd. Brno: Akademické nakladatelství CERM, 2008. 340 s. ISBN 978-80-7204-605-8
- 2) DOSTÁL, P. *Pokročilé metody rozhodování v managementu a ekonomii*. 1.vyd. Brno: VUTUM, 2010. 24 s. ISBN 978-214-4034-0
- 3) DOSTÁL, P. – RAIS, K. – SOJKA, Z. *Pokročilé metody manažerského rozhodování: Pro manažery, specialisty, podnikatele a studenty: Konkrétní příklady využití metod v praxi*. 1. vyd. Praha: Grada, 2005. 166 s. ISBN 80-247-1338-1
- 4) FANTA, J. *Neuronové sítě ve společenských vědách*. 1. vyd. Praha: Karolinum, 2000. 165 s. ISBN: 80-246-0175-3
- 5) FANTA, J. *Počítačové technologie: Na kapitálových trzích*. 1. vyd. Praha: Computer press, 1998. 225 s. ISBN 80-7226-073-1
- 6) FANTA, J. *Psychologie, algoritmy a umělá inteligence na kapitálových trzích*. 1.vyd. Praha: Grada Publishing, 2001. 168 s. ISBN 80-247-0024-7
- 7) FANTA, J. *Technologie uměl inteligence na kapitálových trzích*. 1. vyd. Praha: Karolinum, 1999. 89 s. ISBN 80-7184-866-2
- 8) FINAL. *Burza cenných papírů Praha a obchodování s cennými papíry*. 1. vyd. Praha: DTP system, 1996. 64 s. ISBN [2-1018.435](#)
- 9) GLADIŠ, D. *Naučte se investovat*. 2. vyd. Praha: GRADA, 2005. 176 s. ISBN 80-247-1205-9
- 10) KROPÁČ, J. *Statistika A: Náhodné jevy, Náhodné veličiny, Náhodné vektory, Indexní analýza, Rozhodování za rizika*. 2. vyd. Brno: Vysoké učení technické v Brně. Fakulta podnikatelská, 2007. 157 s. ISBN 978-80-214-3194-6
- 11) KROPÁČ, J. *Statistika B: Jednorozměrné a dvourozměrné datové soubory, Regresní analýza, Časové řady*. 1. vyd. Brno: Vysoké učení technické v Brně. Fakulta podnikatelská, 2007. 155 s. ISBN 80-214-3295-0
- 12) KŘUPKA, J – KAŠPAROVÁ, M. *Modelování v kostce pro Matlab a Simulin*. 1. vyd. Pardubice: Univerzita Pardubice, 2009. 72 s. ISBN: 978-80-7395-162-7

- 13) MARČEK, D. *Neuronové sítě a fuzzy časové řady s aplikacemi v ekonomice*. 1. vyd. Opava: Slezská univerzita, 2002. 151 s. ISBN: 80-7248-157-6
- 14) MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J. *Umělá inteligence (4)*. 1. vyd. Praha : Academia, 2003. 470 s. ISBN 80-200-1044-0
- 15) NERUDA, R. *Teoretické otázky neuronových sítí*. 1. Vyd. Praha: Matfyzpress, 1996. 390 s. ISBN 80-85863-18-9
- 16) NESNÍDAL, T. – PODHAJSKÝ, P. *Obchodování na komoditních trzích: průvodce spekulanta*. Praha: GRADA, 2007. 200 s. ISBN 80-247-1851-0
- 17) NOVÁK, V. *Základy fuzzy modelování*. 1. vyd. Praha : BEN, 2000. 175 s. ISBN 80-730-0009-1
- 18) REJNUŠ, O. *Cenné papíry a burzy*. 1. vyd. Brno: Vysoké učení technické v Brně. Fakulta podnikatelská, 2009. 400 s. ISBN 978-80-214-3805-7
- 19) SYROVÝ, P. *Investování pro začátečníky*. 1. vyd. Praha: GRADA, 2005. 108 s. ISBN 80-247-1366-7
- 20) TALAŠOVÁ, J. *Fuzzy metody: vícekritériálního hodnocení a rozhodování*. 1. vyd. Olomouc: Univerzita Palackého, 2003. 179s. ISBN 80-244-0614-4
- 21) ZAPLATÍLEK, K. – DOŇAR, B. *Matlab: tvorba uživatelských aplikací*. 1. vyd. Praha: BEN, 2005. 216 s. ISBN 80-7300-133-0
- 22) ZAPLATÍLEK, K. – DOŇAR, B. *Matlab: pro začátečníky*. 2. vyd. Praha: BEN, 2005. 152 s. ISBN 80-7300-175-6
- 23) ZELINKA, I., aj. *Evoluční výpočetní techniky: principy a aplikace*. 1.vyd. Praha: BEN, 2008. 536 s. ISBN 978-80-7300-218-3
- 24) ZELINKA, I. *Umělá inteligence 1: Neuronové sítě genetické algoritmy*. 1. vyd. Brno: VUTÍUM, 1998. 126 s. ISBN 80-214-1163-5

Diplomové práce:

- 25) VAŠKO, J. *Hodnocení finanční situace podniku a návrhy na její zlepšení*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. 73s. Vedoucí bakalářské práce Ing. Vojtěch Bartoš, Ph.D.

Elektronické zdroje:

- 26) *Moving average* [online]. [citováno 30. Dubna 2011]. Dostupné z: http://www.xtb.cz/vzdelani/zaklady_investovani_na_financnich_trzich/technicka_analyza/technicke_ukazatele/
- 27) *Moving average Convergence/Divergence* [online]. [citováno 30. Dubna 2011]. Dostupné z: http://www.xtb.cz/vzdelani/zaklady_investovani_na_financnich_trzich/technicka_analyza/technicke_ukazatele/
- 28) *Relative streight index* [online]. [citováno 30. dubna 2011]. Dostupné z: http://www.xtb.cz/vzdelani/zaklady_investovani_na_financnich_trzich/technicka_analyza/technicke_ukazatele/
- 29) *STANDARD&POOR'S* [online]. [citováno 30. Dubna 2011]. Dostupné z: <http://www.standardandpoors.com/indices/sp-500/en/us/?indexId=spusa-500-usdof--p-us-l-->
- 30) *STANDARD&POOR'S Fact sheet* [online]. [citováno 30. Dubna 2011]. Dostupné z: <http://www.standardandpoors.com/indices/sp-500/en/us/?indexId=spusa-500-usdof--p-us-l-->
- 31) *Standard Deviation* [online]. [citováno 30. dubna 2011]. Dostupné z: http://www.xtb.cz/vzdelani/zaklady_investovani_na_financnich_trzich/technicka_analyza/technicke_ukazatele/
- 32) *Učení neuronové sítě* [online]. [citováno 30.4.2011]. Dostupné z: <http://obitko.com/tutorials/predpovidani-neuronovou-siti/uceni-neuronove-site.html>

7 Seznam grafů

GRAF 1 - PROCENTNÍ POMĚR ODVĚTVÍ V INDEXU	26
GRAF 2 - NARX, ČASOVÉ ROZLOŽENÍ CHYBY	58

8 Seznam tabulek

TAB. 1 - EKONOMICKÁ ODVĚTVÍ ZASTOUPENÁ V INDEXU(ZDROJ: <i>STANDARD&POOR'S(28)</i>)	25
TAB. 2 - SEZNAM 10 SPOLEČNOSTÍ S NEJVĚTŠÍ VÁHOU V INDEXU(ZDROJ: <i>STANDARD&POOR'S FACT SHEET (29)</i>)	26
TAB. 3 - PRAVIDLA FUZZY INTERFERENCE(ZDROJ: DOSTÁL(1))	29
TAB. 4 - VÝHODY A NEVÝHODY JEDNOTLIVÝCH DRUHŮ SÍTÍ(ZDROJ:MAŘÍK, V. – ŠTĚPÁNKOVÁ, O. – LAŽANSKÝ(14))	35
TAB. 5 - NARX, Síť (10 2), VALUES	55
TAB. 6 - NARX, Síť (20 10), VALUES	55
TAB. 7 - NARX, Síť (20 17), VALUES	56
TAB. 8 - NARX, Síť (30 17), VALUES	56
TAB. 9 - NARX, Síť (10 2), UKAZATELE	60
TAB. 10 - NARX, Síť (20 10), UKAZATELE	60
TAB. 11 - NARX, Síť (20 17), UKAZATELE	60
TAB. 12 - NARX, Síť (30 17), UKAZATELE	61
TAB. 13 - INPUT-OUTPUT, ROZDĚLENÍ DAT	64
TAB. 14 - INPUT-OUTPUT, Síť (10 2), VALUES	64
TAB. 15 - INPUT-OUTPUT, Síť (20 10), VALUES	64
TAB. 16 - INPUT-OUTPUT, Síť (30 17), VALUES	65
TAB. 17 - INPUT-OUTPUT, Síť (10 2), UKAZATELE	68
TAB. 18 - INPUT-OUTPUT, Síť (20 10), UKAZATELE	69
TAB. 19 - INPUT-OUTPUT, Síť (30 17), UKAZATELE	69
TAB. 20 - VÝSLEDKY, NARX, VALUES	71
TAB. 21 - VÝSLEDKY, NARX, UKAZATELE	71
TAB. 22 - VÝSLEDKY, INPUT-OUTPUT, VALUES	71
TAB. 23 - VÝSLEDKY, INPUT-OUTPUT, UKAZATELE	71

9 Seznam obrázků

OBR. 1 - SLOUPCOVÉ ZOBRAZENÍ CEN (ZDROJ: NESNÍDAL, T. – PODHAJSKÝ(16)).....	17
OBR. 2 - CENOVÁ FORMACE DVOJITÝ VRCHOL, DVOJITÉ DNO (ZDROJ: REJNUŠ(18))	20
OBR. 3 - CENOVÁ FORMACE HLAVA RAMENA (ZDROJ: REJNUŠ(18)).....	20
OBR. 4 - CENOVÁ FORMACE DIAMANT (ZDROJ: REJNUŠ(18)).....	21
OBR. 5 - FUZZY MNOŽINA (ZDROJ: DOSTÁL(1))	27
OBR. 6 - PROCES FUZZY LOGIKY	28
OBR. 7 - FUZZY SYSTÉM	30
OBR. 8 - BIOLOGICKÝ NEURON.....	31
OBR. 9 - UMĚLÝ NEURON (ZDROJ: MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J(14))...	32
OBR. 10 - OBECNÉ SCHÉMA NEURONOVÉ SÍTĚ (ZDROJ: DOSTÁL(1)).....	33
OBR. 11 – GLOBÁLNÍ CHYBA.....	34
OBR. 12 - SCHÉMA VÍCEVRSTVÉ NEURONOVÉ SÍTĚ (ZDROJ: MAŘÍK(14)).....	36
OBR. 13 - PRINCIP FUNGOVÁNÍ SÍTĚ (ZDROJ: MAŘÍK(14)).....	36
OBR. 14 - SCHÉMA HOPFIELDOVI SÍTĚ (ZDROJ: MAŘÍK(14))	38
OBR. 15 - SCHÉMA KOHONENNOVI SÍTĚ (ZDROJ: MAŘÍK(14)).....	39
OBR. 16 - VAZBA ČASOVÉ ŘADY A INTERVENČNÍ ŘADY (ZDROJ: <i>UČENÍ NEURONOVÉ SÍTĚ(31)</i>)	41
OBR. 17 - GRAFICKÉ PROSTŘEDÍ FUZZYLOGIC TOOLBOXU V MATLABU	44
OBR. 18 - NEURAL NETWORK FITTING TOOL	45
OBR. 19 - NEURAL NETWORK CLUSTERING TOOL	45
OBR. 20 - SLOŽKY ČASOVÉ ŘADY (ZDROJ: DOSTÁL(1))	46
OBR. 21 - CENTRUM HISTORIE.....	52
OBR. 22 - ERROR HISTOGRAM, NARX, VALUES, 1. DEN	57
OBR. 23 - ERROR HISTOGRAM, NARX, VALUES, 2. DEN	57
OBR. 24 ERROR HISTOGRAM, NARX, VALUES, 3. DEN	57
OBR. 25 - ERROR HISTOGRAM, NARX, VALUES, 4. DEN.....	57
OBR. 26 - ERROR HISTOGRAM, NARX, VALUES, 5. DEN.....	57
OBR. 27 - REGRESE, NARX, VALUES, 5. DEN.....	59
OBR. 28 - ERROR HISTOGRAM, NARX, UKAZATELE, 1. DEN.....	61
OBR. 29 - ERROR HISTOGRAM, NARX, UKAZATELE, 2. DEN.....	61
OBR. 30 - ERROR HISTOGRAM, NARX, UKAZATELE, 3. DEN.....	62
OBR. 31 - ERROR HISTOGRAM, NARX, UKAZATELE, 4. DEN.....	62
OBR. 32 - ERROR HISTOGRAM, NARX, UKAZATELE, 5. DEN	62
OBR. 33 - - REGRESE, NARX, UKAZATELE, 2. DEN	63
OBR. 34 - ERROR AUTOCORRELATION, INPUT-OUTPUT, UKAZATELE, 1. DEN	65

OBR. 35 - ERROR AUTOCORRELATION, INPUT-OUTPUT, UKAZATELE, 2. DEN	66
OBR. 36 - ERROR AUTOCORRELATION, INPUT-OUTPUT, UKAZATELE, 3. DEN	66
OBR. 37 - ERROR AUTOCORRELATION, INPUT-OUTPUT, UKAZATELE, 4. DEN	66
OBR. 38 - ERROR AUTOCORRELATION, INPUT-OUTPUT, UKAZATELE, 5. DEN	67
OBR. 39 - TEST TIME RESPONSE, INPUT-OUTPUT, VALUES, 1. DEN.....	67
OBR. 40 - TEST ERROR HISTOGRAM, INPUT-OUTPUT, VALUES, 1. DEN.....	68
OBR. 41 - REGRESE, INPUT-OUTPUT, UKAZATELE, 3. DEN	70
OBR. 42 - VÝSTUP PROMĚNNÉ TREND, FUZZY LOGIKA.....	74
OBR. 43 - VÝSTUP PROMĚNĚ PŘÍLEŽITOST, FUZZI LOGIKA	75

10 Seznam vzorců

VZOREC 1 - RSI	22
VZOREC 2 - STANDARD DEVIATION.....	23
VZOREC 3 - FIXED FRACTION	24
VZOREC 4 - MNOŽINA	27
VZOREC 5 - VÝSTUPNÍ REÁLNÁ PROMĚNNÁ.....	30
VZOREC 6 - SOUČET VSTUPŮ A PRAHOVÉ HODNOTY	32
VZOREC 7 - CHYBA.....	34
VZOREC 8 – CHYBA E.....	37
VZOREC 9 - CHYBA EK.....	37
VZOREC 10 - VÁHA SYNAPSE	37
VZOREC 11 - ZMĚNA VÁHY SYNAPSE.....	37
VZOREC 12 - ENERGETICKÁ FUNKCE	38
VZOREC 13 - ENERGETICKÁ FUNKCE ROZEPSÁNÍ.....	39
VZOREC 14 - PODMÍNĚNÁ PRAVDĚPODOBNOST	41
VZOREC 15 - ZMĚNA VÁHY SYNAPSE + MONENT	43

11 Seznam příloh

Příloha č. 1 – Skript 5. Obchodního dne modelu NARX (Input - Values)

Příloha č. 2 - Skript 2. obchodního dne modelu NARX (Input - Indicators)

Příloha č. 1 – Skript 5. obchodního dne modelu NARX (Input - Values)

```
% Solve an Autoregression Problem with External Input with a NARX Neural Network
% Script generated by NTSTOOL
% Created Wed May 11 14:34:34 CEST 2011
%
% This script assumes these variables are defined:
%
%   data_Input_Values - input time series.
%   data_Target_5day - feedback time series.

inputSeries = tonndata(data_Input_Values,false,false);
targetSeries = tonndata(data_Target_5day,false,false);

% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:17;
feedbackDelays = 1:17;
hiddenLayerSize = 20;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares timeseries data for a particular network,
% shifting time by the minimum amount to fill input states and layer states.
% Using PREPARETS allows you to keep your original time series data unchanged, while
% easily customizing it for networks with differing numbers of delays, with
% open loop or closed loop feedback modes.
[inputs,inputStates,layerStates,targets] = preparets(net,inputSeries,{},targetSeries);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 90/100;
net.divideParam.valRatio = 5/100;
net.divideParam.testRatio = 5/100;

% Train the Network
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, plotregression(targets,outputs)
%figure, plotresponse(targets,outputs)
%figure, ploterrcorr(errors)
%figure, plotinerrcorr(inputs,errors)

% Closed Loop Network
% Use this network to do multi-step prediction.
% The function CLOSELOOP replaces the feedback input with a direct
% connection from the output layer.
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,inputSeries,{},targetSeries);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(netc,tc,yc)

% Early Prediction Network
% For some applications it helps to get the prediction a timestep early.
% The original network returns predicted y(t+1) at the same time it is given y(t+1).
% For some applications such as decision making, it would help to have predicted
% y(t+1) once y(t) is available, but before the actual y(t+1) occurs.
% The network can be made to return its output a timestep early by removing one delay
% so that its minimal tap delay is now 0 instead of 1. The new network returns the
% same outputs as the original network, but outputs are shifted left one timestep.
nets = removedelay(net);
```

```
nets.name = [net.name ' - Predict One Step Ahead'];  
view(nets)  
[xs,xis,ais,ts] = preparets(nets,inputSeries,{},targetSeries);  
ys = nets(xs,xis,ais);  
earlyPredictPerformance = perform(nets,ts,ys)
```


Příloha č. 2 – Skript 2. obchodního dne modelu NARX (Input - Indicators)

```
% Solve an Autoregression Problem with External Input with a NARX Neural Network
% Script generated by NTSTOOL
% Created Wed May 11 21:09:03 CEST 2011
%
% This script assumes these variables are defined:
%
%   data_Input_Indicators - input time series.
%   data_Target_2day - feedback time series.

inputSeries = tonndata(data_Input_Indicators,false,false);
targetSeries = tonndata(data_Target_2day,false,false);

% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:17;
feedbackDelays = 1:17;
hiddenLayerSize = 30;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares timeseries data for a particular network,
% shifting time by the minimum amount to fill input states and layer states.
% Using PREPARETS allows you to keep your original time series data unchanged, while
% easily customizing it for networks with differing numbers of delays, with
% open loop or closed loop feedback modes.
[inputs,inputStates,layerStates,targets] = preparets(net,inputSeries,{},targetSeries);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 90/100;
net.divideParam.valRatio = 5/100;
net.divideParam.testRatio = 5/100;

% Train the Network
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, plotregression(targets,outputs)
%figure, plotresponse(targets,outputs)
%figure, ploterrcorr(errors)
%figure, plotinerrcorr(inputs,errors)

% Closed Loop Network
% Use this network to do multi-step prediction.
% The function CLOSELOOP replaces the feedback input with a direct
% connection from the outout layer.
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,inputSeries,{},targetSeries);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(netc,tc,yc)

% Early Prediction Network
% For some applications it helps to get the prediction a timestep early.
% The original network returns predicted y(t+1) at the same time it is given y(t+1).
% For some applications such as decision making, it would help to have predicted
% y(t+1) once y(t) is available, but before the actual y(t+1) occurs.
% The network can be made to return its output a timestep early by removing one delay
% so that its minimal tap delay is now 0 instead of 1. The new network returns the
% same outputs as the original network, but outputs are shifted left one timestep.
nets = removedelay(net);
```

```
nets.name = [net.name ' - Predict One Step Ahead'];  
view(nets)  
[xs,xis,ais,ts] = preparets(nets,inputSeries,{},targetSeries);  
ys = nets(xs,xis,ais);  
earlyPredictPerformance = perform(nets,ts,ys)
```