


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA PODNIKATELSKÁ
ÚSTAV INFORMATIKY
FACULTY OF BUSINESS AND MANAGEMENT
INSTITUT OF INFORMATICS

VYUŽITÍ UMĚLÉ INTELIGENCE NA FINANČNÍCH TRZÍCH

THE USE OF ARTIFICIAL INTELLIGENCE ON FINANCIAL MARKET

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. JIŘÍ SURYNEK

VEDOUCÍ PRÁCE
SUPERVISOR

Prof. Ing. PETR DOSTÁL, CSc.

BRNO 2013

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Jiří Surynek

Informační management (6209T015)

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

Využití umělé inteligence na finančních trzích

v anglickém jazyce:

The Use of Artificial Intelligence on Financial Market

Pokyny pro vypracování:

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

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

Seznam odborné literatury:

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: Akademické nakladatelství CERM, 2012. 718 s. ISBN 978-80-7204-798-7. e-ISBN 978-80-7204-799-4.

DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: Akademické nakladatelství CERM, 2011. 168 s. ISBN 978-80-7204-747-5.

DOSTÁL, P. a Z. SOJKA. Financial Risk Management. Zlín: UTB 2008. 80 s. ISBN 978-80-7318-772-9.

HANSELMAN, D. a B. LITTLEFIELD. Mastering MATLAB7. Pearson Education International Ltd., 2005. 852 s. ISBN 0-13-185714-2.

MAŘÍK, V., O. ŠTĚPÁNKOVÁ a J. LAŽANSKÝ. Umělá inteligence. ACADEMIA, 2003. 1440 s. ISBN 80-200-0502-1.

REJNUŠ, O. Finanční trhy. Ostrava: Key Publishing, 2008. 559 s. ISBN 978-80-87071-87-8.

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

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



B. Půža

doc. RNDr. Bedřich Půža, CSc.
Ředitel ústavu

J. Škapa

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

V Brně, dne 28.2.2013

Abstrakt

Diplomová práce se zabývá problematikou a následnou aplikací metod umělé inteligence na finančních trzích. Konkrétně se jedná o využití umělých neuronových sítí za účelem predikce hodnoty a určení trendu vývoje vybraného investičního nástroje. Vlastní řešení je vytvořeno ve vývojovém prostředí Matlab.

Abstract

This thesis focuses on the problem and application of artificial intelligence on the financial market. Especially, the use of artificial neural networks to forecast values and determine the trend of the selected investment instrument. Solution is created in the development environment Matlab.

Klíčová slova

Umělé neuronové sítě, technická analýza, predikce, finanční trhy

Key words

Artificial neural networks, technical analysis, forecasting, financial market

Bibliografická citace

SURYNEK, J. *Využití umělé inteligence na finančních trzích*. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2013. 72 s. Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.

Čestné prohlášení

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

V Brně dne 23.května.2013

.....

Bc. Jiří Surynek

Poděkování

Rád bych na tomto místě poděkoval prof. Ing. Petru Dostálovi CSc., za podporu a cenné rady, které mi pomohly při zpracování mé diplomové práce.

Obsah

1	Úvod.....	11
2	Cíle práce	13
3	Popis a historie společnosti.....	14
3.1	Poslání a vize podniku	14
3.2	Historie.....	15
3.3	Popis současného stavu	15
3.4	Důvod založení.....	16
3.5	SWOT	16
3.5.1	Vnitřní prostředí.....	16
3.5.2	Vnější prostředí.....	17
3.5.3	Způsob získání počátečního kapitálu	18
3.6	Průzkum a analýza tržního prostředí - SLEPTE	18
3.6.1	Sociální faktory.....	18
3.6.2	Legislativní faktory.....	18
3.6.3	Ekonomické faktory.....	19
3.6.4	Politické faktory.....	19
3.6.5	Technologické faktory	19
3.6.6	Ekologické faktory.....	20
3.7	Porterův model konkurenčních sil	20
3.7.1	Riziko vstupu potenciálních konkurentů	20
3.7.2	Rivalita mezi stávajícími konkurenty	20
3.7.3	Smluvní síla odběratelů	21
3.7.4	Smluvní síla dodavatelů.....	21
3.7.5	Hrozba substitutů	21
3.7.6	Segmentace trhu zákazníků	21

3.7.7	Odhad velikosti trhu.....	22
4	Teoretická východiska práce	23
4.1	Neuronové sítě	23
4.1.1	Biologická nervová buňka	24
4.1.2	Umělý neuron	26
4.1.3	Technologie neuronových sítí v praxi	27
4.1.4	Prvky neuronových sítí	28
4.1.5	Data	29
4.1.6	Modely neuronových sítí	31
4.1.7	Trénování neuronové sítě.....	35
4.1.8	Obecné schéma práce neuronové sítě	36
4.1.9	Shrnutí.....	37
4.2	Kapitálové trhy.....	37
4.2.1	Vznik a vývoj kapitálových trhů ve světě.....	38
4.2.2	Faktory ovlivňující rozhodování investorů.....	41
4.3	Predikce.....	42
4.3.1	Časové řady a jejich predikce	42
4.3.2	Psychologická analýza.....	45
4.3.3	Technická analýza.....	47
4.4	Výpočetní systém Matlab.....	54
5	Vlastní návrh řešení	56
6	Nelineární autoregresní model (NAR).....	58
6.1	Vyhodnocení NAR modelu.....	63
6.2	Optimalizace NAR modelu	64
6.2.1	Optimalizace vstupních dat.....	64
6.2.2	Optimalizace vlastností a parametrů modelu.....	65

6.2.3	Zhodnocení NAR modelu	66
7	Závěr	67
8	Seznam použité literatury a zdrojů	68
9	Seznam obrázků	70
10	Seznam tabulek	71
11	Seznam příloh	72

1 Úvod

Předpovídání budoucnosti bylo s lidstvem už od nepaměti. Již z dávné minulosti jsou známí různí věštcí, proroci a šamani, kteří se snažili předvídat budoucnost, a to za pomoci nejrozumnějších prostředků. Důvody těchto předpovědí byly různé. Lidé si kladli otázky kdy zasadit úrodu, jak moc se připravit na zimu nebo jakého pohlaví bude jejich potomek.

Z pohledu dnešní vědy se tyto pokusy rozhodně nedají označit jako relevantní. Problém je v tom, že tito dávní proroci neměli k dispozici prostředky, kterými by tyto věštby mohli efektivně provádět. V dnešní době tyto prostředky stále nemáme. Pomáhá nám však výpočetní technika, jejíž rozmach ve druhé polovině dvacátého století velmi dopomohl k zlepšení života jako takového. Pohlaví nenarozeného dítěte určí ultrazvuk, k určení data zasetí úrody je možné použít matematické modely popisující chování počasí atd. Informační technologie lze použít i při predikci vývoje trhu. Důvod tohoto předvídání je jasný. Když budeme znát vývoj na finančních trzích dostatečně do budoucnosti, pak můžeme určit, do jakých komodit investovat tak, aby nám to přineslo zisk a ne ztrátu.

Pro předvídání vývoje na finančních trzích se využívá mnoho technologií a analýz. V této práci budou popisovány podrobněji, je však nutné zmínit například technickou analýzu, která si klade za cíl sledovat historický trend vývoje nejrozumnějších burzovních indexů a z těchto informací se snaží předvídat jejich budoucí vývoj. Dalším nástrojem pro predikování budoucího vývoje je analýza psychologická, která se zaměřuje na chování lidí, kteří s cennými papíry obchodují. V neposlední řadě je nutné zmínit analýzu fundamentální, která se zaměřuje hlavně na činnost a jednání samotné organizace a také sleduje různé faktory a ukazatele v jejím okolí. Toto jsou hlavní nástroje pro predikci burzovního vývoje.

Dvacáté století je stoletím informační revoluce. Od jeho poloviny se stále častěji objevuje výpočetní technika ve všech oblastech lidského snažení. Ke konci 80. let se rapidně rozšiřuje umělá inteligence. Její využití se do dnešní doby rozšiřuje prakticky všude – od počítačových her přes umělé vesmírné sondy, antivirové programy až po

pračky a automobily. Z tohoto důvodu není možné opomíjet využití umělé inteligence i pro predikci vývoje burzovních trendů. V tomto směru se nabízí využití neuronových sítí, které jsou inspirovány přírodou – konkrétně mozkem. Tyto neuronové sítě se na základě poskytnutých dat mohou učit a dokonce vyvozovat vlastní závěry. V této diplomové práci se zaměřím hlavně na neuronové sítě a konkrétně na jejich využití právě pro predikci na burzovních trzích.

2 Cíle práce

Informovat o základních termínech používaných v problematice neuronových sítí, popsat nástroje pro predikci a rozhodování na finančních trzích, popsat fungování a princip neuronových sítí. Vyvinout funkční model neuronové sítě, schopný s dostatečnou přesností predikovat vybraný investiční nástroj. Tento model může být posléze využit pro zhodnocení volných finančních prostředků ve zvolené firmě.

3 Popis a historie společnosti

Právní forma společnosti je společnost s ručením omezeným. Tento typ byl vybrán v návaznosti na možnost podílnictví více osob, s ohledem na působnost business angela jako investora podniku, který poskytl start-up kapitál a své kontakty. [1]

Název: Vronli s.r.o.

Společníci: Vladimír Šandera, Vít Urbanec

Sídlo: Jožky Jabůrkové 695/8, 624 00 Brno

Web: www.vronli.cz

Logo:



Obrázek 1: Logo společnosti Vronli s.r.o.

(Zdroj: webové stránky společnosti Vronli [1])

3.1 Poslání a vize podniku

Společnost Vronli s.r.o. poskytuje nezávislou technickou podporu počítačů, tabletů a mobilních zařízení pro koncové uživatele a malé firmy. Cílem je řešit aktuální technické problémy uživatelů se zabezpečením, nastavením a instalací aplikací. U firem se společnost soustředí na poskytování přidané hodnoty v podobě vzdáleného nastavení a správy firemních procesů jako je fakturování, work-flow management, e-mailů a další. Prioritou je vytvořit image user-friendly společnosti, na kterou se budou moci uživatelé vždy obrátit s dotazem či problémem, na který bude společnost poskytovat okamžitou reakci.

3.2 Historie

Společnost vznikla v návaznosti na úspěšné podnikání na základě živnostenského oprávnění. Společník působí v problematice odvírování a vzdálené správy již bezmála 4. rokem. Vzhledem ke zkušenostem, které čerpal v přední české společnosti v oblasti bezpečnosti a odvírování na pozici Customer support specialist, může svým zákazníkům nabídnout bohaté znalosti, které přispějí k vyřešení problémů s jejich počítači. Podnikání formou živnosti bylo zahájeno 1. 3. 2010 fyzickou osobou Vladimírem Šanderou, který stojí v čele nově založené společnosti Vronli s.r.o.. Společnost s ručením omezeným byla založena v únoru 2012.

3.3 Popis současného stavu

V současné době je poskytováno poradenství a vzdálená správa IT panem Vladimírem Šanderou, který využívá 7 studentů pro vyplnění pracovní doby 8 – 23 h sedm dní v týdnu.

Pro koncové zákazníky jsou dostupné tyto služby:

- Odvírování počítače.
- Oprava počítače.
- Zrychlení počítače.
- Instalace software.
- All-in-one balíček.
- Instalace operačního systému Windows 7 a Windows 8.


Pro firemní zákazníky jsou dostupné balíčky:

- | | | |
|----------------------------|---|--------------------------------|
| • Zabezpečení počítačů. | } | Prováděno technikem online. |
| • Údržba počítačů. | | |
| • Instalace software. | | |
| • Záloha dat. | } | Nutný fyzický zásah technikem. |
| • Nákup počítačů. | | |
| • HW diagnostika a oprava. | | |
| • Re/Instalace Windows. | | |

3.4 Důvod založení

Důvodem založení podniku byla transformace z podnikání, na základě živnostenského oprávnění, kde již byla ověřena životaschopnost projektu. Prvotní důvod pro založení projektu byla existence tržní mezery v oblasti poskytování technických služeb online. Dalším důvodem je poskytování technické podpory domácím uživatelům, bez jakýchkoliv technických znalostí, což je služba, která na našem trhu ještě neexistuje.

3.5 SWOT



Obrázek 2: SWOT analýza společnosti

(Zdroj: vlastní)

3.5.1 Vnitřní prostředí

Společnost se jako první na trhu zaměřila na běžné zákazníky. Do nedávna tyto služby byly poskytovány pouze stálým zákazníkům antivirových společností. Tato skutečnost

pro nás otevřela prostor. Jsme schopni zabezpečit zákazníky bez rozdílu využívaného softwaru či technologií.

Společnost je schopna okamžitě reagovat na požadavek zákazníka a jeho problém ihned začít řešit. Platby jsou vyžadovány až v případě úspěšného zásahu, nejsou vyžadovány žádné platby předem. V případě, že je problém hardwarového typu, je zákazník odkázán na kamenný servis, zákazníkovi nejsou účtovány žádné poplatky. Pro vzdálené připojení k zákazníkům je využívána aplikace LogMeInRescue, která je v současnosti technologicky nejvyspělejší.

V současné době je tato činnost provozována právní formou – společnost s ručením omezeným, jelikož se společnosti podařilo získat investora.

Zaměstnanci jsou zatím studenti, ale se vzděláním v oboru. Nicméně jejich vzdělání a znalosti je potřeba rozvíjet a k tomu v současnosti chybí nějaký systém školení zaměstnanců. Zároveň je potřeba lépe řídit a organizovat většinu firemních procesů, které v současné době nejsou stoprocentně efektivní. Také webová prezentace stále obsahuje drobné chyby, na těch se ale pracuje a společnost se snaží webovou prezentaci nastavit co nejvíce uživatelsky přívětivou.

3.5.2 Vnější prostředí

Jelikož je společnost schopna připojit se na jakýkoliv počítač na světě, který je připojen k internetu, je jedním z hlavních cílů expandovat na zahraniční trhy. Trh koncových uživatelů je sice zajímavý, ale nedostatečně ziskový, v plánu tedy je outsourcovat IT podporu společností, což by společnosti přinášelo větší zisk a jistotu pravidelného příjmu. Jak rostou technologie, roste i portfolio nabízených služeb, v blízké budoucnosti je v plánu vzdálená správa „chytrých“ telefonů.

Již několikrát se zaměstnanci setkali s dotazy zákazníků na samotné softwary, jako je LogMeIn a Microsoft Office, a možnosti jejich zakoupení. Za příležitost je tedy možné pokládat také reselling těchto produktů.

Mnoho zákazníků má nedůvěru k tomuto způsobu vzdáleného připojení, jejich důvěru tedy společnost chce podpořit získáním certifikátu ISO 27001, což je mezinárodní standard, definující požadavky na systém managementu bezpečnosti informací.

Za největší hrozbu je pokládán vstup nových, kapitálově vybavených konkurentů na trh. To je díky velmi nízkým počátečním nákladům dosti pravděpodobné. Další hrozbou by mohl být růst počítačové gramotnosti, nicméně tomuto faktoru není přikládán velký význam.

3.5.3 Způsob získání počátečního kapitálu

Začátky podnikání byly financovány vlastními zdroji. V pozdější fázi se naskytla příležitost v podobě investora, který profinancuje počátky projektu. Další možností je investice na kapitálových trzích, na kterou je zaměřena tato diplomová práce. Pro investici byla vybrána ropa, na kterou bude využita predikce pomocí neuronových sítí. Tyto informace je možné v budoucnu využít i v dalších společnostech.

3.6 Průzkum a analýza tržního prostředí - SLEPTE

3.6.1 Sociální faktory

Služba vzdáleného připojení k technologiím zákazníka je poměrně nová a tak existuje nízké povědomí v očích zákazníka a velmi nízká informovanost o dostupnosti této služby. Dá se očekávat prvotní strach z přístupu cizí osoby do počítače uživatele. Paranoidní přístup uživatelů PC se vyskytuje spíše u věkové kategorie středního věku. V čase se dá očekávat snižování nedůvěry díky předpokládaným dosaženým výsledkům.

3.6.2 Legislativní faktory

Z legislativy v současnosti společnost ovlivňuje Zákon č. 101/2000 Sb., o ochraně osobních údajů a Zákon č. 586/1992 Sb., o daních z příjmů. Samozřejmě je společnost ovlivněna i Zákonem č. 513/1991 Sb., obchodní zákoník a Zákonem č. 40/1964 Sb., občanský zákoník. Všeobecné podmínky ošetřují odpovědnost za způsobenou škodu. Každý zákazník musí odsouhlasit všeobecné podmínky před provedením zákroku technikem. S ohledem na poskytovanou službu firma zákazníkům dává možnost využití záruky v délce 7 dní, která je dle platnosti legislativy ČR. Po transformaci na společnost s ručením omezeným firmu ovlivňují následující zákony:

- Zákon č. 563/1991 Sb., o účetnictví.
- Zákon č. 235/2004 Sb., o dani z přidané hodnoty.

3.6.3 Ekonomické faktory

Podnikání je ovlivněno zejména ekonomickými faktory z oblasti legislativy. V roce 2013 tak např. vzrostla DPH na 21 %, která se nedotkla cen služeb, ale může ovlivnit koupěschopnost našich klientů.

Náklady společnosti by mohl ovlivnit měnový vývoj, apreciace měny prodražuje software, jehož licence jsou nakupovány od společností z USA, jedná se konkrétně o aplikace LogMeIn Rescue a Olark live chat a Desk customer support system.

3.6.4 Politické faktory

Politická situace v zemi nemá v současnosti restriktivní vliv na služby poskytované firmou. Po založení kapitálové obchodní společnosti se situace trochu změnila, jelikož bude mít vliv na podnikání vládnoucí strana tvořící zákony, která může měnit sazbu daně z přidané hodnoty apod. Změny s ekonomickým dopadem na společnost, již byly popsány výše – v ekonomických faktorech. V tomto oboru podnikání dosud nebyla zaznamenána žádná forma politického lobbingu a nelze očekávat změny, ani v nejbližších letech.

3.6.5 Technologické faktory

Pro připojení ke klientovi technik využívá těchto technologických prvků:

- Počítač s připojením k internetu.
- Aplikace pro vzdálenou správu LogMeIn Rescue.
- Telefon.

Dále technici využívají live chat Olark umístěný na webových stránkách pro komunikaci s potenciálními klienty a Desk customer support systém, pro zaznamenání údajů o klientech a prováděné operaci.

Na straně klienta jsou využívány tyto technologie:

- Počítač, kterého se týká zásah s připojením k internetu.
- Telefon.

Klientské připojení k Aplikaci LogMeIn Rescue je podporováno nejpoužívanějšími typy operačních systémů: MS Windows, Mac OS X, Android, iOS.

3.6.6 Ekologické faktory

Podnikání v oblasti vzdálené správy počítačů nemá negativní vliv na prostředí. Do jisté míry lze říci, že existuje pozitivní vliv na životní prostředí, jelikož online technická podpora vytěšňuje běžnou opravu technikem, ke kterému je nutné nejprve zařízení dopravit, nebo naopak dopravit technika k nefunkčnímu zařízení. Touto substitucí produktu nedochází k znečišťování životního prostředí, na rozdíl od přepravy technika (zařízení) dopravním prostředkem, které vypouští zplodiny do ovzduší.

3.7 Porterův model konkurenčních sil

3.7.1 Riziko vstupu potenciálních konkurentů

Nevýhodou poskytované služby jsou nízké náklady na vstup do odvětví. V tomto případě jsou finanční bariéry takřka nulové. Bariéry vstupu však nejsou vždy spojeny jen s finančním zázemím, ale také s know-how. Z tohoto pohledu lze říci, že určitá selektivita vstupu potenciálních konkurentů existuje. Společnost má již základní databázi stálých firemních i běžných zákazníků, kteří jsou zvyklí na komfort, který je jim poskytován. Poskytování online technické podpory představuje nový business model, se kterým firmy na českém trhu nemají zkušenosti. Bariérou pro vstup do odvětví je v současné chvíli neověřený business model, s kterým se pojí větší riziko.

3.7.2 Rivalita mezi stávajícími konkurenty

V tomto sektoru služeb existuje konkurence stejně jako v jiném odvětví. Výhoda společnosti spočívá v tom, že firma byla jedna z prvních na trhu. Někteří konkurenti začali kopírovat „styl“ podnikání společnosti a používají stejné technologické produkty. Avšak kvalitou odvedené práce společnost vyčnívá nad konkurencí, jak potvrzují naši zákazníci. Většina konkurentů vstoupila na trh posledním rokem a doposud se tak seznamují s trhem a možnostmi, jak oslovit potenciální klientelu. Téměř žádný z konkurentů nevyužívá internetovou marketingovou kampaň ve formě PPC reklamy a ani další druhy agresivní marketingové propagace. Lze očekávat, že většina firem se bude snažit ubírat směrem partnerství s již zavedenými společnostmi, z oblasti prodeje IT a vývoje software.

3.7.3 Smluvní síla odběratelů

Vyjednávací síla zákazníků společnosti je poměrně malá, což je dáno i malou konkurencí na trhu. Zákazník může volit mezi online technickou podporou případně odvozem zařízení do kamenné opravny. Tato možnost se ve výsledku prodraží, což je dáno jak cenou, tak oportunitními náklady v podobě cestování a přímých nákladů spojených s přepravou. V budoucnosti, s ohledem na předpokládaný rozmach v oblasti online technické správy můžeme čekat lepší výchozí pozici pro zákazníky a je třeba počítat s online podporou po celých 24 hodin.

3.7.4 Smluvní síla dodavatelů

Společnost není vázána na dodavatele materiálů, jako jsou např. výrobní podniky. Jediným dodavatelem jsou poskytovatelé software pro vzdálené připojení ke klientovi. V této oblasti je však silná konkurence a nákup licencí je prováděn elektronicky, bez osobní komunikace s „dodavatelem“. Používané technologické aplikace jsou od softwarových společností z USA a společnost byla první na trhu, kdo je využívá a tak si udržuje stálý náskok před konkurencí.

3.7.5 Hrozba substitutů

Užívání IT technologií každý den je výdobytkem dnešní doby. Z toho plyne i potřebnost servisu těchto zařízení. Substitutem k online technické podpoře je klasická kamenná opravna. Dnešní doba, ve znamení nedostatku času a pohodlnosti však ukazuje, že lidé substituují kamenné opravny právě za online technickou podporu, pokud je to možné a proveditelné.

3.7.6 Segmentace trhu zákazníků

- Běžní uživatelé bez IT znalostí.
- Drobní živnostníci a malé podniky, kterým se nevyplatí najmout vlastního IT technika.
- Prodejci počítačů, kamenné servisy a softwarové společnosti, kterým společnost dokáže snížit náklady na technickou podporu a zefektivnit proces technické podpory.

3.7.7 Odhad velikosti trhu

Projekt působí v oblasti technické podpory a servisních služeb. Cílová skupina jsou koncoví uživatelé, živnostníci a malé firmy. Každý uživatel nebo firma, která vlastní počítač a připojení k internetu, je náš potenciální zákazník.

V září 2009 bylo k internetu v ČR připojeno 6,8 milionu uživatelů¹. Zhruba polovina připojení z tohoto počtu jsou středně velké a velké firmy. 20% uživatelů PC má dostatečné technické znalosti a nevyhledávají služby technické podpory. V segmentu koncoví uživatelé a malé firmy bez technických znalostí, je tedy po zúžení zákaznické základny přibližně 2,72 milionu potenciálních zákazníků, kteří využívají služeb technické podpory a servisních služeb. [2]

Počet uživatelů PC připojených k internetu se neustále zvyšuje, takže má dobrý potenciál růstu. Vzhledem k tomu, že společnost všechny služby poskytuje online, jsou pro ni dosažitelní zákazníci po celé ČR a také je snadné expandovat s projektem do zahraničí. Dále společnost může do budoucna expandovat na segment mobilních zařízení a tabletů, který je na prudkém vzestupu.

¹ JANOUCH, Viktor. *Internetový marketing : prosad'te se na webu a sociálních sítích*.

4 Teoretická východiska práce

4.1 Neuronové sítě²

Definicí neuronových sítí je velmi mnoho. Uvádí se inspirace biologickými neurony. V terminologii neuronových sítí se většinou nazývají processing units, processing entities, processing elements, neurons, nodes, cells atd. Rovněž se v definicích upozorňuje na vzájemné propojení těchto neuronů a trénink (učení) neuronové sítě.

Příklady definicí neuronových sítí:

„Umělá neuronová síť (ANN) je paradigma zpracování informací, inspirované biologickými neuronovými systémy zpracování informací, jako je mozek. Klíčovým prvkem tohoto paradigmatu je nová struktura systému zpracování informací. Skládá se z velkého počtu vzájemně propojených prvků (neuronů), pracujících společně na řešení specifických úloh. ANN se stejně jako lidé učí z příkladů“³

Steirgiou a Siganos, 1996

„Neuronová síť je vzájemně propojeným souborem jednoduchých prvků (processing elements), jednotek nebo uzlů, jejichž funkčnost je volně založena na nervové buňce. Schopnost sítě zpracovávat data je uložena v silách nebo vahách, získaných procesem přizpůsobování nebo učením z množiny trénovacích dat“⁴

Gurney, 1996

Neuronové sítě je možné chápat jako počítačové systémy vstupu/výstupu s volnými parametry vah a prahových hodnot. Tyto systémy jsou založeny na vzájemném propojení jednotek. Výstupy jsou převážně založeny na učení ze vstupních – trénovacích dat. Je nutné rozlišovat mezi systémy, které jsou založeny převážně na pravidlech (označují se rule based) a systémy, které se učí z datových struktur (example based). Tím není řečeno, že by neuronové sítě nevyužívaly žádné algoritmy – pouze připravují pro danou úlohu pomocí přijatých pravidel algoritmus výpočtu, který je možné využít i v případě podobných úloh.

² FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích.

DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě

³ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 94

⁴ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 94


Principy práce neuronových sítí jsou odlišné od známé John von Neumannovy koncepce zpracování dat počítačovými systémy. Neumannova koncepce je založena na formalizaci problému nebo úlohy ve formě algoritmu. Počítač, v případě této koncepce musí mít ve formě programu k dispozici přesný postup zpracování dat. Výpočetní postup u neuronových sítí spočívá v hledání algoritmu k vyřešení zadané úlohy. Neuronové síť, na rozdíl od von Neumannova stroje, algoritmus řešení zadané úlohy vytváří postupně, s důrazem na to, aby bylo možné tento algoritmus použít i v případě řešení jiných, avšak podobných úloh.

Informace nezbytné pro funkčnost neuronových sítí jsou ukládány do množiny vah. V případě von Neumannova stroje jsou informace pouze součástí programových kroků, jako data postupně transformovaná do výstupu. Z toho plyne velká výhoda neuronových sítí – větší odolnost proti šumu tzn. menší změny na vstupu neovlivňují výstup až tak dramaticky. Neuronové síť mají – na rozdíl od klasických programů – schopnost generalizování struktury vstupních dat.

Finanční a kapitálové trhy jsou většinou chápány jako velmi komplexní systémy. Data a jejich struktura na těchto trzích obsahují jak pravidelnosti, tak nahodilosti. Největší příklad můžeme vidět v časových řadách cen. Vztahy mezi daty kapitálových a podobných trhů obsahují časté nelinearity. Důraz na strukturu dat a nelineární vztahy mezi daty jsou častá témata pro technologii neuronových sítí.

4.1.1 Biologická nervová buňka

Z důvodu pochopení vlastností neuronových sítí je nutné v krátkosti popsat jejich vzor – biologickou nervovou buňku – neuron. Jedná se o základní jednotku nervové soustavy, kterou v roce 1835 objevil Jan Evangelista Purkyně. Jedná se o specializovanou buňku, lišící se od ostatních buněk tím, že z jejího těla vybíhá mnoho větvících se výběžků (1 neurit a dendrity).



Obrázek 3: Biologický neuron

(Zdroj: Neuron [4] - pozměněn)

Její funkce je velmi specifická – tvorba a přenos signálů, které lze registrovat jako elektrické děje. Základním prvkem činnosti neuronů a tím nervového řízení je vlna nervové negativity, šířící se rychlostí 120 - 130 m/s. V lidském těle je přibližně 30 miliard neuronů. Funkcemi neuronu jsou:

- tvorba a přenos nervových signálů – pohyb iontů, označovaný jako elektrický děj
- základní vlastností nervových buněk je jejich dráždivost (schopnost reagovat na určité podněty) a vodivost (schopnost vést vzruchy)
- vzruch (impuls) – akční potenciál, který se z oblasti iniciálního segmentu šíří k jiným neuronům nebo výkonným orgánům
- nervový vzruch je možno vyvolat:
 - přirozeným podnětem (podrážděním smyslových buněk)
 - umělým podnětem (elektrický, mechanický, chemický nebo tepelný podnět nervové buňky)
- molekulární podstata nervových dějů spočívá v otevírání iontových kanálů a pohybu iontů těmito kanály přes plazmatickou membránu [2]


Nervové buňky se od ostatních liší hlavně svou specializací. Jak bylo napsáno výše, nervová buňka se skládá z jednoho neuritu (též zvaného axon) a dendritů – těch může být velmi mnoho – až několik tisíc. Pomocí neuritu se nervové vzruchy přenáší na dendrit dalších nervových buněk.

Spojení jednotlivých neuronů se nazývá synapse. Spojení však není úplné, mezi jednotlivými neurity a dendrity je synaptická mezera. Nervové vzruchy se mezi jednotlivými neurony přenáší vždy jedním směrem. Biologické neurony mají v porovnání s umělými neurony neuronové sítě mnohem složitější strukturu. Srovnání umělých neuronů a biologických je možné pouze z hlediska základních principů jejich fungování.

Neuron vyše vstupní signály dál pouze v případě, jsou-li vstupní signály dostatečně silné, aby mohly aktivovat další nervové buňky. Signál v tomto případě musí překročit prahovou hodnotu k vybuzení buňky k reakci. [3]

4.1.2 Umělý neuron

Umělý neuron je založen na analogických principech, jako neuron biologický. Vstupní informace jsou váženy vahami. Odečítá se prahová hodnota a pomocí aktivační funkce se signál transformuje na výstupní signál, který je předán následujícím umělým neuronům ve skryté – vstupní vrstvě.



Obrázek 4: Činnost umělého neuronu

(Zdroj: FANTA, Psychologie, algoritmy a umělá inteligence na kapitálových trzích.

[3])

Vstupy (A,B,C) jsou váženy (násobeny) vahami (w_1 , w_2 , w_3). Výsledek je sumarizován (sum) a pomocí aktivační funkce AF, která může být lineární nebo nelineární je předán umělým neuronům (D,E,F) ve skryté nebo výstupní vrstvě.⁵

4.1.3 Technologie neuronových sítí v praxi

Neuronové sítě v praxi nabízejí technologii k řešení klasifikačních i predikčních úloh, možnost vytváření modelů závislosti na proměnných a tyto závislosti numericky i graficky zobrazovat atd.

V dnešní době existuje celá řada počítačových softwarů, umožňujících řešit ekonomické úlohy pomocí neuronových sítí. Příklady těchto SW: Statistica Neural Networks, Neural Connection, Neuroshell, Matlab Neural Neural Networks Toolbox atd. Ve většině případů je největší překážkou k pořízení těchto softwarových aplikací jejich cena, která mnohdy překračuje cenu softwarových produktů, běžně užívaných ke statistickým analýzám (např. Excel).

Je důležité zdůraznit, že není možné preferovat užití neuronových sítí oproti jiným technologiím zpracování dat, jako je například statistická analýza. Úspěšnost využití té které analytické metody záleží na řešení úloze. Porovnání výsledků získaných z různých analytických nástrojů je proto nezanedbatelným požadavkem kvalitní analytické práce. Výhoda nasazení neuronových sítí tkví hlavně v možnosti popsání nelineárních vztahů, řešení komplexních a velmi složitých úloh.

V případě neuronových sítí je také nutné dbát na kvalitu vstupních dat. Neuronové sítě jsou sice obecně odolnější, například vůči neúplným časovým řadám, než je tomu u běžných statistických nástrojů, stále však platí fakt, že pokud je kvalita dat dobrá, tj. pokud je zajištěna jejich vysoká validita a reliabilita – výsledky obvykle nevykazují výraznější rozdíly v porovnání s běžnými statistickými nástroji. Stále však platí, že vhodnost užitých prostředků závisí především na řešení úloze.

V porovnání s jinými metodami zpracování dat mají neuronové sítě některé nepříjemné vlastnosti. V první řadě jde o naplnění požadavku identické reprodukovatelnosti výsledků. Různé metody využití neuronových sítí, různé použité softwary a použití různých parametrů pro trénink neuronových sítí nezabezpečují vždy – přes užití

⁵ FANTA, J., Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 97-98

stejných vstupních dat – stejné výsledky. Další nepříjemnou vlastností neuronových sítí vztahující se k vysvětlování příčin jevů je fakt, že stav volných parametrů natrénované neuronové sítě neumožňuje ve většině případů matematicky zachytit vztahy mezi proměnnými. Většinou chybí možnosti pro vyšetření, proč bylo takových výsledků dosaženo. V neposlední řadě se u neuronových sítí vyskytuje problém s novou terminologií. Například statistický pojem reziduum se u neuronových sítí označuje jako chyba (error). Přitom se však jedná o prakticky analogický jev.

Při využití v investování se neuronové sítě používají k odhadům bankrotujících firem, k řízení úvěrové politiky, odhadům rizika finančních operací, k analýzám nejrůznějších typů ekonomických časových řad. Technologie neuronových sítí se často využívá k predikcím cenových pohybů na kapitálových, finančních a jim podobných trzích. Výstupy z různých analytických a predikčních nástrojů technologicko-fundamentálních analýz jsou zde v přímé konfrontaci s novými technologiemi umělé inteligence.

4.1.4 Prvky neuronových sítí

Neuronové sítě se skládají ze tří základních součástí:

1. Umělých neuronů
2. Spojení umělých neuronů
3. Vrstev neuronové sítě

Neurony jsou spolu vzájemně propojeny. Spojení může být realizováno ve stejné vrstvě nebo mezi vrstvami. Síť tak může reprezentovat paralelní zpracování vstupních dat. Uzly jsou pak paměťové buňky. Tyto buňky uchovávají rozpoznávací rámec struktury trénovacích, ověřovacích i testovacích dat. Je tomu tak v případě, kdy síť po tréninku představuje generalizovaný rámec pro řešení podobných úloh s jinými vstupními daty.


Výstup z neuronu je možné popsat pomocí následujícího vztahu:

$$O_j = f(X_j), X_j = O(a_i \cdot w_{ij}) + t_j,$$

Kde O_j je výstup j -tého neuronu ve vrstvě; $f(X)$ je aktivační funkce; a_i je vstup; w_{ij} jsou váhy; t_j je práh.

Všechny prvky neuronové sítě jsou organizovány do vrstev. Ve většině případů jsou tři:

1. Vstupní
2. Skrytá
3. Výstupní



Obrázek 5: MLP neuronová síť 5-6-1

(Zdroj: FANTA, *Psychologie, algoritmy a umělá inteligence na kapitálových trzích*. [3])

Na obr. 5 je architektura sítě typu Multilayer Perceptrons (MLP) se třemi vrstvami. První, vstupní vrstva obsahuje pět umělých neuronů. Ve druhé, skryté vrstvě je celkem šest neuronů, ve třetí výstupní vrstvě je jeden neuron. Uvedenou síť je možné využít například ke klasifikační úloze. Na výstupu je binární dělení typu ANO, NE, které zprostředkovává jeden umělý neuron ve výstupní vrstvě.

4.1.5 Data

Neuronové sítě, podobně jako u jiných počítačových systémů, představují systém vstupu/výstupu. Vývojáři a uživatelé neuronových sítí chápou každou strukturu jako samostatný datový rámeček. Vstupy neuronové sítě obsahují hodnoty vstupních

proměnných. Proměnné mohou být jak numerické tak nenumерické. Některé neuronové sítě mohou mít jako vstupy například i obrázky.

Vstupní data mohou obsahovat:

1. Vstupní i výstupní data vztahující se k úloze
2. Pouze vstupní data

V prvním případě jsou data analogická, jako data vstupující do regresního algoritmu nějakého statistického software. Uživatel statistického software regresní analýzy musí na vstupu do regresního modelu definovat vstupní a výstupní proměnné – nezávislé a závislé proměnné. U neuronových sítí se jedná o analogii. Trénování neuronové sítě s touto datovou strukturou se nazývá řízené učení. Data vyjadřující vztahy mezi proměnnými postupně procházejí uzly neuronové sítě a aktivují umělé neurony ve všech vrstvách – upravují volné parametry neuronové sítě (váhy). Neuronová síť pak hledá optimální vztahy mezi vstupními daty a výstupy. Většina neuronových sítí využívá řízené učení.

Druhý případ je analogií shlukové analýzy ve statistice. Sítě, které používají datové soubory a klasifikují data do skupin se nazývají self-organizing networks. Jako příklad je možné uvést Kohonenovu neuronovou síť (viz níže).

Neuronové sítě kromě řízeného a neřízeného učení využívají další typy trénovacích algoritmů. Příkladem může být:

1. Konkurenční učení
2. Posilovací učení
3. Učení podle Donalda O. Hebba
4. Asociativní učení

Při práci s počítačovými modely neuronových sítí se data dělí do tří skupin:

1. Trénovací data
2. Ověřovací data
3. Testovací data

Největším problémem při učení neuronových sítí je výstup, který by měl splňovat podmínku použitelnosti neuronové sítě pro podobné úlohy s jinými daty. V případě ztráty této použitelnosti pro další úlohy se hovoří o přetrénování neuronové sítě.

Opačným problémem bývá nedotrénování neuronové sítě. V tomto případě je funkce příliš jednoduchá pro zachycení všech nelineárních vztahů mezi vstupními daty.

U všech úloh zpracovávaných pomocí počítačů platí, že kvalita vstupních dat velmi výrazně ovlivňuje kvalitu výstupů. Kvalita výstupů také závisí na volbě typu neuronové sítě, užitém trénovacím algoritmu a také na délce trénování. Ve většině případů jsou neuronové sítě odolnější proti méně kvalitním datům (chybějící údaje, šумы, atd.), v porovnání s užitím klasických statistických metod.

Proměnné, které do neuronových sítí vstupují, mají vlastní rozsah, průměrné hodnoty i variabilitu. Datům s větším rozsahem hodnot odpovídají i větší váhy. Důsledkem je větší vliv dat s větším rozsahem hodnot na model neuronové sítě. K zajištění stejných podmínek pro všechna data vstupující do neuronové sítě se provádí normalizace. Tou nejjednodušší normalizační technikou je určení minimální a maximální hodnoty dat a normalizování hodnot do intervalu mezi 0 a 1.

4.1.6 Modely neuronových sítí

V teorii i v praktické aplikaci existuje velký počet různých typů neuronových sítí. Od jednoduchých lineárních modelů neuronových sítí přes sítě typu MLP, RBF až ke Kohonenovým sítím s neřízeným trénováním. Zde je krátký výčet těch nejzajímavějších:

4.1.6.1 Lineární model

Jedná se o základní jednoduchý model neuronové sítě. Lineární model obsahuje pouze dvě vrstvy. Aktivační funkce je lineární.

4.1.6.2 Multilayer Perceptron – MLP

V současnosti se asi jedná o nejvíce využívaný a také nejznámější model neuronové sítě. Operuje s lineární funkcí a standardně s nelineární aktivační funkcí sigmoid. Někdy se místo funkce sigmoid využívá hyperbolická funkce (tanh), která může vykazovat v některých případech lepší výsledky. MLP je možné použít jak pro kvaziregresní úlohy, tak pro klasifikační úlohy při použití různých typů funkcí a různých


uživatelských úprav. U klasifikačních úloh se MLP používá jak pro jednoduché rozhodování, tak i pro vícenásobnou klasifikaci. MLP sítě jsou kompaktní se širokou škálou aplikací. Znárodnění MLP sítě je na obrázku č. 5.

4.1.6.3 Radial Basis Function – RBF

Jedná se o architekturu, která má vstupní a skrytou vrstvu s radiálními jednotkami (umělými neurony) a obvykle lineární vstupní vrstvou. Vrstva s radiálními jednotkami má většinou exponenciální aktivační funkci. Obecný vzorec pro RBF lze zapsat takto:

$$h(x) = f[(x - c)^T R^{-1}(x - c)]$$

kde f je užitá funkce; c je centrum; R je metrika – většinou euklidovská; výraz $(x - c)^T R^{-1}(x - c)$ je vzdálenost mezi vstupem x a centrem c v metrice definované R .



Obrázek 6: RBF neuronová síť

(Zdroj: FANTA, *Psychologie, algoritmy a umělá inteligence na kapitálových trzích*. [3])

Trénování sítě typu RBF je většinou rychlejší než v případě jiných architektur neuronových sítí. Výsledná RBF síť je však ve většině případů pomalejší v porovnání s řešením analogických úloh pomocí ostatních typů sítí, například MLP. Je to dáno větší velikostí neuronové sítě v porovnání s MLP.

4.1.6.4 Generalized Regression Neural Network - GRNN

Jedná se o model, jehož architektura je určena pro řešení úloh, jejichž vstupní data jsou rozptýlená a řídká a mají kontinuální vstupy. Většinou bývá třívrstvá, aplikační softwaru však většinou pracují se čtyřmi vrstvami:

1. Vstupní
2. Vrstva s radiálními centry
3. Vrstva s regresními jednotkami (umělými neurony)
4. Výstupní

Radiální centra jsou středy shluků dat. Jejich nastavení probíhá před použitím trénovacího algoritmu. Regresní vrstva obsahuje dva druhy lineárních jednotek:

1. Umělé neurony počítající požadovaný regresní výstup pro věty
2. Umělé neurony počítající hustotu pravděpodobnosti

Výstupní funkce užívá speciální funkci, nazývanou division.

4.1.6.5 Pravděpodobnostní model neuronové sítě

Je analogií k GRNN pro klasifikační úlohy. Typická struktura pravděpodobnostní sítě obsahuje tři vrstvy:


1. Vstupní
2. Skrytá vrstva s radiálními prvky
3. Výstupní vrstva lineárních klasifikačních jednotek

Počet umělých neuronů ve skryté vrstvě je minimálně roven počtu trénovacích dat. U tohoto typu sítě je možné definovat ještě čtvrtou vrstvu, nazývanou matice ztrát. Tato vrstva se využívá k vážení pravděpodobností známými náklady nesprávné klasifikace, k dosažení minima rozhodovacích chyb a to tehdy, pokud existuje reálné nebezpečí, že nesprávně klasifikované případy mohou způsobit vážné problémy.

4.1.6.6 Kohonenova neuronová síť

Tato síť bývá také někdy označována jako Self-Organizing Feature Maps (SOFM). Jedná se o model s neřízeným tréninkem. Síť má pouze dvě vrstvy:

1. Vstupní
2. Výstupní s radiálními jednotkami



Obrázek 7: Kohonenova neuronová síť

(Zdroj: FANTA, Psychologie, algoritmy a umělá inteligence na kapitálových trzích. [3])

Sebeorganizující vlastnost Kohonenovy neuronové sítě znamená reakci výstupů, tedy aktivaci umělých neuronů na změny vstupů. Jedná se o velmi podobný princip, jako když se na základě podnětů aktivují jednotlivé části mozku, se specifickými funkcemi (sluchové centrum, zrakové centrum, centrum řeči). Tento neřízený model neuronové sítě soustřeďuje data s určitými vlastnostmi do shluků. Kohonenova neuronová síť funguje analogicky, jako statistická shluková respektive faktorová analýza.

Typ sítě	Výhoda	Nevýhoda
Lineární	Velmi rychlý trénink	Neřeší nelineární úlohy
Probabilistická	Velmi rychlý trénink	Velikost sítě, pomalejší při řešení úloh
GRNN	Velmi rychlý trénink	Velikost sítě, pomalejší při řešení úloh
MLP	Rychlé řešení úloh	Pomalý trénink
RBF	Velmi rychlý trénink	Velikost sítě, pomalejší při řešení úloh

Obrázek 8: Výhody a nevýhody jednotlivých typů neuronových sítí

(Zdroj: FANTA, Psychologie, algoritmy a umělá inteligence na kapitálových trzích. [3])

Kohonenova neuronová síť umožňuje uživateli redukovat velikost vstupního vektoru mapováním do menšího počtu shluků. Využití je v možnosti sloužit k předzpracování dat, k následnému vstupu do jiného modelu neuronové sítě.

4.1.7 Trénování neuronové sítě

Paměť neuronové sítě se vytváří pomocí příkladů. Využívá se při tom nějaký druh učicího algoritmu. Z toho vyplývá, že technologie neuronových sítí není zcela oproštěna od algoritmických struktur. Hlavní cíl tréninku neuronové sítě je nalezení řešení pro daný typ úlohy. Učení je vlastně přizpůsobování vah – vytváří se tak paměť, která je později použitelná pro jiné podobné úlohy.

Existují dva typy učení neuronových sítí:

1. Řízené učení
2. Neřízené učení

V prvním případě je cílem optimalizačního algoritmu nalezení globálního extrému, to znamená globálního minima chyby pro daný parametr. Chyba je v případě tohoto typu učení (tréninku) rozdíl mezi hodnotami vstupní závislé proměnné a vypočítané hodnoty této proměnné.

Neřízené učení je vlastně identifikace shluků dat s minimální vzdáleností od centra shluku. I u tohoto typu učení se jedná o optimalizační úlohu.

Pro učení neuronových sítí bylo vytvořeno velké množství učebních pravidel. Jedná se například o Hebbian learning rule, Hopfield bipolar learning rule, Adaline learning rule, Delta learning rule atd. Delta pravidlo, které vytvořili autoři Widrow a Hoff, a také některá další pravidla se využívají v modelech neuronových sítí všeobecně nazývaných back propagation models. Což jsou známé a často používané modely. Back propagation znamená zpětnou propagaci chyby s následnou úpravou vah spojení umělých neuronů. Delta pravidlo se také někdy označuje jako pravidlo nejmenších čtverců. Změnu váhy (w) v čase t lze popsat následujícím vztahem:


$$\Delta w_{ij}(t) = Le_j o_i + \alpha \Delta w_{ij}(t - 1)$$

Kde L je tempo učení; e_j je lokální gradient chyby; o_i je výstup i -tého neuronu; α je koeficient momentu; e_j je rozdíl mezi očekávaným a aktuální výstupem neuronu j .

Koeficient momentu pomáhá učebnímu algoritmu neuronové sítě vyhnout se lokálnímu minimu chyby. Pomáhá také ke zvýšení výkonu tréninkového algoritmu v případech malé změny chyby. Může nabývat hodnot 0 - 1. Všeobecné doporučení je kombinovat vyšší tempo učení s nižším koeficientem momentu.

Při využití back propagation algoritmu se provádí postupné kroky přibližující chybu k lokálnímu minimu. Optimalizace samotných vah sítě se děje pohybem vypočítané chyby po povrchu hyperboloidu. Globální minimum je pak teoretické řešení reprezentující nejmenší možnou chybu.

4.1.8 Obecné schéma práce neuronové sítě



Obrázek 9: Algoritmus trénování sítě MLP s řízeným učením

(Zdroj: FANTA, Psychologie, algoritmy a umělá inteligence na kapitálových trzích. [3])

Trénování sítě MLP s řízeným učením probíhá následujícím způsobem (viz. obr. 9):

1. Náhodné nastavení vah neuronové sítě
2. Průběh dat sítí (aktivační funkce a přenosová funkce)
3. Výpočet chyby porovnáním aktuálního výstupu s empirickým výstupem
4. Zpětná úprava vah modelu neuronové sítě (učení)
5. Vyhodnocení podmínky zda trénink může skončit
6. ANO – konec
7. NE – opakování kroků 2 - 5

4.1.9 Shrnutí

Neuronové sítě jsou modelem inspirovaným lidským mozkem. Někdy bývají označovány termínem „černá skříňka“, protože není možné detailně znát a popsat vnitřní strukturu systému neuronové sítě. Na tuto strukturu bývá kladeno několik předpokladů, které umožňují popis chování neuronové sítě a popis systému funkcí, které provádí transformaci vstup – výstup.

Neuronové sítě nám pomáhají řešit složité nelineární problémy, na které většinou běžné statistické metody nestačí. Je však nutné vzít v úvahu úskalí, které se mohou v případě použití neuronových sítí vyskytnout. V první řadě je nutné provést dostatečný trénink neuronové sítě na daný typ úlohy. Dále je nutné počítat s nekonzistentností výstupů a výsledků – při prvním výpočtu mohou být výsledky odlišné od dalších výpočtů. V neposlední řadě je také nutné zvolit optimální model neuronové sítě, s ohledem na řešený problém.

4.2 Kapitálové trhy⁶

Kapitálový trh je místo, kde dochází ke směně kapitálu prostřednictvím cenných papírů a jejich derivátů. Můžeme o něm říci, že je podmnožinou finančního trhu. Emitenti, tedy státní a veřejné instituce, finanční instituce a podniky, vydávají cenné papíry a nabízejí je k prodeji na burze. Tímto způsobem získávají zdroje pro financování vlastní činnosti. Cenné papíry kupují investoři. Jsou to banky, podílové nebo penzijní fondy, pojišťovny i fyzické osoby, které tímto způsobem zhodnocují své volné peněžní prostředky.

⁶ PAVLÁT, Vladislav. Kapitálové trhy.

Kapitálový trh zabezpečuje pohyb střednědobého a dlouhodobého kapitálu (splatnost nad jeden rok). [8]

4.2.1 Vznik a vývoj kapitálových trhů ve světě

Podoba dnešních finančních trhů je výsledkem dlouhodobého vývoje, který probíhal po několik staletí. V každé době finanční trhy více či méně odpovídaly charakterem i rozsahem potřebám ekonomiky. V průběhu času sebou ekonomický rozvoj postupně přinášel podněty ke zdokonalování finančních nástrojů i ke zdokonalování finančních trhů jako takových. Objevovaly se nové finanční nástroje a prostředky, nové techniky financování i nové finanční instituce. Během vývoje se z původně úvěrového trhu, postupně vyčlenil segment peněžního a kapitálového trhu. Postupně se vytvářely souvislosti mezi vývojem měny, veřejnými financemi a finančním trhem.

Vývoj finančních trhů neprobíhal ve všech zemích stejným způsobem. Hlavní slovo měly v každé epoše země s nejvyspělejší ekonomikou. Z vývoje v těchto zemích získávaly zkušenosti i další státy. To je také jeden z důvodů, proč je možné setkat se s tak velkým bohatstvím druhů a forem, v nichž finanční trhy v mnohotvárné praxi fungují.

Finanční trhy a jejich vývoj je nejen neodmyslitelnou komponentou ekonomického vývoje, ale je nutno jej chápat také jako neoddělitelnou součást vývoje společenského. Stav na finančních trzích velmi citelně reaguje na sociální, vojenské, politické i přírodní události – vývoj na finančních trzích je těmito událostmi spoluurčován. Vývoj finančních trhů tedy nelze považovat za autonomní.

Vznik středověkých „kapitálových trhů“ lze poměrně přesně spojit s rozvojem obchodu a řemesel. Je možné dohledat zprávy o burzách zboží v italském městě Lucca, dále o peněžních burzách v Benátkách, Janově, Florencii a Paříži už ve 12. století. V souvislosti s prodejem zboží docházelo také k uzavírání nových půjček, kdy hlavním instrumentem byly směnky, používané ke splácení úvěrů v hotových penězích, ke směně mincí v jedné měně, za jinou měnu a podobně.

Samotný název „burza“ vznikl pravděpodobně na středověkém trhu v belgickém městě Bruggy, kam často přijížděli obchodníci a kupci z Benátek a Janova a po příjezdu se shromažďovali před domem bankéře Van der Buerse. To je také doba, kdy bylo město

Bruggy jedno z nejvýznamnějších obchodních center Západní Evropy. Vznik burzy v Bruggách je datován do roku 1409. Další burzy vznikají postupně v Antverpách v roce 1460 a na území Francie v Lyonu v roce 1462. Některé údaje historiků a badatelů se liší a to hlavně z důvodu, že je velmi obtížné v dějinách vysledovat dobu, kdy se tradiční trhy změnily v burzu v dnešním slova smyslu.

Další burzy poté vznikaly v Amsterdamu roku 1530, v Besanconu roku 1552, v Toulouse, Bordeaux, a v Marseille v roce 1595.

V Německu je vznik prvních burz datován na první polovinu 16. století v městech Augsburg a Norimberk. V Hamburku se první burza objevila v roce 1558, v Kolíně nad Rýnem v roce 1566. Následoval vznik dalších burz – v Lübecku v roce 1605, Královci roku 1613, Brémách roku 1614, v Berlíně roku 1716 a ve Vídni roku 1753. Vznik Londýnské burzy „Royal Exchange“ se datuje do druhé poloviny 16. století.

První formy burz byly spíše místem neformálního setkávání obchodníků. Formální organizace na prvních burzách úplně chyběla. Obchodní styky nebyly pravidelné, obchodníci nebyli schopni posoudit předem solventnost svých partnerů a většinou se ani předem neznali. Obchod se odvíjel případ od případu a první burzy se většinou odehrávaly pod širým nebem. Vlivem různých okolností se poté přesouvaly do budov, které byly veřejně přístupné.

Tento přesun do budov lze považovat jako první známku pevné organizace burzy. V této době se také objevují první burzovní kluby a gildy, které opatrovaly peníze na stavbu burzovních budov. Do budov burzy poté mohli vstupovat jen členové těchto spolků, kteří uhradili finanční příspěvek.

Tyto skutečnosti přispěly k vytváření nových racionálních pravidel obchodování na burze. O tato pravidla se staraly burzovní spolky. Tyto spolky také začínají zaznamenávat ceny a kurzy a starají se o obchodní podmínky. Rozhodovaly také o tom, kdo se smí a kdo se nesmí zúčastňovat obchodování na burze. Stát do vlastní činnosti burzy obvykle nezasahoval. Panovník však vždy schválil existenci burzy. Příkladem může být burza v Antverpách, jejíž existenci potvrdil francouzský král Jindřich II. v roce 1549. Burzovní zákonodárství však vznikalo až mnohem později – v průběhu 19. století.

Na středověkých burzách probíhal obchod hlavně se zbožím a koncem středověku také se směnkami. Objevují se také počátky obchodu s cennými papíry a obligacemi. Na burze v Antverpách byly obligace vydány již v prvních letech jejího fungování.

Po založení prvních akciových podniků se také začíná objevovat trh s akciemi. Rapidní rozvoj tohoto druhu obchodování také později přispěl k oddělení trhu s akciemi, od trhu se zbožím. V dalších letech dochází ke specializaci a také ke vzniku jednotlivých druhů burzy tak, jak jsou dnes známy – tedy burzy cenných papírů, devizové burzy, burzy se zbožím a plodinové burzy.

Vznik burz velmi usnadňoval mobilizaci kapitálu, potřebného k rozvoji hospodářství. V novodobých dějinách se burzy staly hybnou silou rozvoje a obchodního a průmyslového kapitalismu.

Vznik novodobých kapitálových trhů byl velmi silně stimulován velkými geografickými objevy v 15. a 16. století. Všechny tehdejší koloniální mocnosti potřebovaly finanční prostředky k financování dopravy zboží a dalších nových nákladů. Tento vývoj výrazně podpořil expanzi úvěru a dalších platebních instrumentů jak je známe dnes. Významnou úlohu zde hrály zejména směnky a různé formy dlužních úpisů panovníků, z nichž se později vyvinuly státní obligace. Tuto dobu lze také považovat za úsvit akciových společností a využití jejich formy. První akciové společnosti byly budovány za účelem financování podnikatelských záměrů. Příkladem může být financování stavby nových plavidel, které měli sloužit k dopravnímu spojení do Indie. Takto vznikla známá Východoindická společnost, která je považována za jednoho z nejdůležitějších předchůdců dnešních akciových společností.

Vývoj kapitálového trhu v jednotlivých evropských zemích probíhal od peněžního trhu, kterému dominoval hlavně lichvářský kapitál přes příležitostní trhy obchodníků a majitelů peněz až po vznik dnešních burz. Vedlejším efektem vzniku burz je tak rostoucí počet nově vznikajících soukromých bank, které se do úvěrových obchodů i obchodů s cennými papíry aktivně zapojují. Banky tedy lze považovat za důležitý faktor rozvoje jak peněžního, tak kapitálového trhu.

V období přelomu středověku a novověku se hlavními finančními středisky stávají Florencie, Benátky a Janov. Na přelomu 17. a 18. století se hlavní těžiště evropských

finančních operací přesouvá do Holandska, kde důležitou roli na kapitálovém trhu hrála Amsterodamská burza. Na začátku 19. století se hlavní část veškerých finančních aktivit v Evropě přesouvá do Anglie, která se stává jedním z nejvýznamnějších světových středisek v oblasti úvěru, obchodování s cennými papíry i mezinárodních měnových transakcí. V roce 1792 vzniká asi nejznámější burza na světě v New Yorku na Wall Street. Od tohoto okamžiku se burzy a kapitálové trhy postupně vyvíjely až do podoby, kterou známe dnes.

4.2.2 Faktory ovlivňující rozhodování investorů

Faktory, které významně ovlivňují chování a rozhodování investorů na kapitálových trzích jsou především likvidita investice, předpokládaný výnos investice a riziko spojené s touto investicí. Úspěšný a racionálně postupující investor většinou postupuje tak, že hledá optimální kombinaci všech výše zmíněných veličin k dosažení předem stanovených cílů.

4.2.2.1 Výnos investice

Výnos investice je možné měřit dvěma způsoby. Častější způsob je měření absolutně ziskem (čistým výnosem) jako rozdílem mezi investovanými prostředky a výnosem. Je nutné také výslednou částku ponížit o příslušné daňové povinnosti.

Druhou možností jak měřit výnos investice je relativní způsob měření. Relativně lze výnos investice vyjádřit jako poměr zisku (čistého výnosu) k celkovým nákladům. Pokud se poté vyjádří výnos investice procentuálně, hovoříme o takzvaném „výnosovém procentu“.

Konkrétním případem zisku je mimo jiné úrok jako odměna za poskytnutí volných finančních prostředků finančnímu zprostředkovateli nebo pro účely podnikání, tedy odměna za zřeknutí se likvidity. V tomto případě je pak míra zisku úrokovou mírou.

Zisk a jeho pohyb není vzhledem k některým parametrům nákladů (vázanost peněžních prostředků, odpisy, časová zpoždění a odklady efektů působících na zisk) stejný s pohybem finančních prostředků. Toto je také důvod, proč je za čistý výnos často brán rozdíl mezi peněžními příjmy a peněžními výdaji za určité období nikoliv samotný zisk. Tento rozdíl bývá nazýván čistým finančním tokem a také se s ním často spojuje

výnosové procento investice. Snadná interpretace je „čistý finanční tok – výnosové procento“ v případě investování do cenných papírů.

4.2.2.2 Riziko investice

Riziko investice lze popsat jako míra nejistoty spojená s očekávaným výnosovým procentem. Stejně hodnoty očekávaných výnosových procent je možné spojit s různou mírou rizika. Rizikovost investice je pak obvykle měřena směrodatnou odchylkou od očekávaného výnosového procenta. V mnoha případech je také možné termín „riziko investice“ nahradit termínem „bezpečnost investice“.

4.2.2.3 Likvidita investice

Likvidita investice je měřena jednoduchým způsobem – rychlostí s jakou lze investici přeměnit zpět v hotové peněžní prostředky.

4.2.2.4 Zlaté pravidlo investování

Výnos investice, riziko investice i její likviditu je nutné posuzovat ve vzájemných vztazích a hodnotit je souhrnně. Není možné dosáhnout současně maximálního výnosu, co nejmenšího rizika a nejrychlejší přeměny v hotové peníze. Je však možné optimalizovat vztahy všech těchto tří aspektů investice. Tento přístup bývá označován jako „zlaté pravidlo investování“.

4.3 Predikce

4.3.1 Časové řady a jejich predikce⁷

„Časovou řadou (někdy chronologickou řadou) rozumíme řadu hodnot určitého ukazatele, uspořádanou z hlediska přirozené časové posloupnosti. Přitom je nutné, aby věcná náplň ukazatele i jeho prostorové vymezení byly shodné v celém sledovaném časovém úseku“⁸

Kropáč, 2007

⁷ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích.

⁷ DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě

⁸ KROPÁČ, J. Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady, s. 114

Statistická data, která popisují ekonomické a společenské jevy v čase, je možné zapisovat pomocí takzvaných časových řad. Tento zápis pomocí časových řad umožňuje provádět nejen kvantitativní analýzu zákonitostí, ale zároveň dává možnost provádět predikci jejich budoucího vývoje.

Časové řady se používají kromě jiného ve společenských vědách například v demografii, kde popisují změny v počtu a složení obyvatelstva. V sociologii například popisují vývoj rozvodovosti. Časové řady v ekonomii se používají například k analýze poptávky po určitém výrobku, k popisu změn v objemu produkce a také k popisu změn ve vývoji směnného kurzu mezi jednotlivými měnami.


Z matematického hlediska je možné popsat predikci časových řad jako posloupnost hodnot $x_1, x_2 \dots x_n$ kde n udává počet hodnot časové řady a prvek x odpovídá hodnotě veličiny v daném čase. Hodnotu v čase $t = 1$ označujeme x_1 v čase $t = 2$ ji označujeme x_2 atd. V čase $t = n$ hodnotu označujeme x_n . Pro potřeby predikce je nutné upřesnit, že hodnota x_n je poslední známou hodnotou časové řady a odpovídá současnosti. Hodnota x_{n+1} je tedy první hodnotou predikce. Je také nutné zdůraznit, že u časových řad je interval mezi jednotlivými měřeními téměř vždy konstantní, takže platí následující vztah:

$$\Delta = t_2 - t_1 = t_3 - t_2 = \dots = t_n - t_{n-1} = konst.$$

Tento interval může být v rozmezí vteřiny, minuty, hodiny, dne, týdne, měsíce, roku a nebo jejich násobcích. Tento interval můžeme označit jako frekvenci. V této souvislosti můžeme říci, že se jedná o velmi vysokou (vteřiny, minuty), vysokou (hodiny), střední (dny), nízkou (týdny) a velmi nízkou (měsíce, roky) frekvenci.

Prvním krokem při využití časových řad obecně je specifikace daného predikčního problému. Dále je také nutné mít už během predikčních prací dostatečně přesnou představu o veličinách predikce, o všech dostupných datech a jejich povaze. Poté je nutné zvolit metodu predikce, časový horizont a jakým způsobem a jestli vůbec budou data upravena pro výpočet. Z důvodu budoucího využití pro rozhodování je také nutné znát povahu predikovaného problému a také mít co možná nejvíce informací o systému, pro který predikci provádíme, v našem případě o finančním trhu.

Časovou řadu je možné představit si jako soubor dvou základních složek, deterministické a stochastické. Dělení těchto složek ukazuje následující obrázek č. 10.



Obrázek 10: Rozdělení složek časových řad

(Zdroj: DOSTÁL, *Pokročilé metody analýz a modelování v podnikatelství a veřejné správě*. [6])

Proces predikce začíná před predikovanou událostí - výpočet predikce, v průběhu události probíhá korekce predikce a po jejím ukončení se provádí její vyhodnocení. Na základě znalostí hodnot predikovaných a skutečných je důležité vyhodnotit kvalitu predikčního modelu. Pro tyto účely se používají různá kritéria, nejčastější je použití střední kvadratické chyby MSE (mean squared error), střední absolutní chyby MAE (mean absolute error) a střední relativní chyby MAPE (mean absolute precentage error), která je vyjádřena v procentech. Zde je výčet vzorců pro tyto veličiny:

$$MSE = \frac{1}{n} \sum_{t=1}^n (x_t - \dot{x}_t)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n |x_t - \dot{x}_t|$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{x_t - \dot{x}_t}{x_t} \right|$$

Kde x_t je naměřená hodnota a $\dot{x}_t$ je hodnota vypočtená predikcí.

4.3.2 Psychologická analýza⁹

Na trzích s aktivy hraje psychika obchodníků významnou roli a to ve dvojím smyslu: jako prvek davové psychózy obchodujících lidí a jako součást obchodního aktu. Stav individuální psychiky obchodníka (investora) má nemalý vliv na obchodní strategii a taktiku i na úspěšnost/neúspěšnost jeho obchodních aktivit. Přes existenci počítačových aplikací a sofistikovaných softwarů usnadňujících obchodní aktivity má vždy konečné slovo člověk. Trh prezentuje autonomní cenový pohyb, který je však výsledkem množství individuálních obchodních rozhodnutí. Při sledování cenového pohybu aktiva i objemu obchodních operací a transakcí probíhají u účastníka trhu emocionální procesy, formované do následující obchodní činnosti. Jak předmět obchodu a sám obchodník tak sociální okolí vytvářejí podmínky pro jeho chování na trhu.

Z historie je známo mnoho případů, které mohou být pro nezávislého pozorovatele těžko pochopitelné. Jedná se například o „spekulativní bubliny“, které vedly ke zruinování velkých skupin lidí. Jako příklad lze uvést tulipánový krach v 17. Století v Holandsku, kdy touha vlastnit tulipánové cibulky způsobila obrovský růst poptávky po této komoditě a logicky i obrovský růst její ceny. Tato „spekulativní bublina“ rostla do nepředstavitelných rozměrů kdy bylo za jedinou cibulku vzácného druhu tulipánů Semper Augustus zapláceno 4600 holandských zlatých plus nový kočár se dvěma šedými hřebci včetně postrojů. Růst se zastavil až v okamžiku, kdy nadhodnocený předmět obchodu už nenašel žádného kupce. Poté nastal prudký pokles provázený

⁹ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích.

⁹ DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě


obchodním vystřízlivěním v roce 1637. Dalším případem přehnaných spekulací může být takzvaná „Jihomořská bublina“. V roce 1611 byla založena Jihomořská společnost (South Sea Company) za účelem obchodování s Amerikou a na podporu rozvoje rybolovu. Brzy tato společnost získala monopol na veškerý obchod s latinskou Amerikou a zakoupila si britské státní dluhopisy v celkové hodnotě téměř 10 milionů tehdejších britských liber. Akcie společnosti časem získávaly čím dál větší hodnotu, někdy byly výkyvy v ceně akcií i v řádech stovek liber v rámci jednoho dne. V roce 1720 zakladatelé společnosti a její předseda prodali veškeré akcie, které vlastnili. Když se tato informace rozšířila, kurz akcií začal pomalu ale neustále klesat. Do konce roku akcie klesly na desetinu své hodnoty a tato skutečnost zapříčinila krach řady bank, které garantovaly své půjčky cennými papíry včetně akcií South Sea Company. Firma byla formálně zrušena až v roce 1855 a za celou dobu své existence nevyvíjela žádnou významnější obchodní aktivitu.

Dnes se takové obchodní postupy řadí do teorie nazývané greater fool theory, tedy teorie většího blázna. Bylo by však mylné se domnívat, že je přehnaný optimismus/pesimismus účastníků trhu jen minulostí. Jedna z možných příčin krachu dne 19. 10. 1987 v Anglii je vysvětlována právě prasknutím spekulativní bubliny.

Psychologové se zamýšlejí nad individuální psychikou účastníků trhu a navrhují různé postupy, jak odstranit některé osobnostní rysy, bránící úspěšným obchodním postupům. Na druhé straně podávají návody, jak využít daného psychického vybavení spekulanta k eliminaci obchodních ztrát. K nejznámějším teoriím patří praktické návody R. N. Elliotta. Praktická aplikace jeho teorie je však kombinace mechanických a psychologických postupů. Jde o sociálně-psychologickou teorii využívající matematickou a geometrickou metodiku. Tato teorie bývá nazývána jako Elliottovy vlny.

Přílivy a odlivy optimismu a pesimismu investorů vytvářejí rozeznatelné rámce při grafickém zobrazení. Tyto rámce lze interpretovat jako impulzní a korekční vlny cenového pohybu. Na základě rozeznání těchto vln je možné určit i budoucí pohyb cen sledovaného instrumentu.

Základní princip Elliottových vln je opakování stejných cenových rámců. Vlny mají hierarchický charakter a kritériem je čas. Hierarchický charakter opakující podobné geometrické obrazce cen vede některé teoretiky k přesvědčení, že jde o fraktálové struktury tržních pohybů. Zájem o tuto teorii budí hlavně historie úspěšných předpovědí cenových pohybů na kapitálových trzích, například předpověď burzovního krachu v roce 1987 atd.



Obrázek 11: Elliottovy vlny

(Zdroj: Google)

4.3.3 Technická analýza¹⁰


Systémy technických analýz využívají při analýzách kapitálových trhů nejrůznějších algoritmů. Mezi tyto algoritmy se například řadí:

1. Indikátory technické analýzy
2. Analytické studie založené na Fibonacciho posloupnosti

¹⁰ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích.

¹⁰ DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě

3. Algoritmy pro výpočet regresní analýzy
4. Algoritmy pro výpočet kovariační analýzy
5. Algoritmy pro výpočet korelační analýzy
6. Výpočetní postupy fundamentální analýzy



Obrázek 12: OHLC graf

(Zdroj: vlastní)

Výhodou těchto systémů je hlavně reprodukovatelnost výstupů. Na rozdíl od neuronových sítí dostaneme při použití stejných dat stejné výsledky v každém případě. Největší slabinou těchto systémů je malý akcent na data vstupující do výpočtu. Předpokladem je, že si uživatel sám zvolí takový výpočetní postup, který je přiměřený vstupním datům. Většinou však nastává situace, že je struktura dat složitá a výběr

odpovídajícího postupu může být pro daný účel neadekvátní. To je také důvod proč práce s těmito nástroji vyžaduje i značnou profesionalitu při interpretaci výstupů. Zpravidla je při využití těchto systému uživateli poskytnut návod, která data jsou vhodná pro vybraný výpočetní postup. V případě lineární regrese je to požadavek linearity, vzájemné nezávislosti proměnných, nezávislost reziduí a vysoký koeficient determinace. Techničtí analytici většinou užívají klouzavé průměry časových řad pro trendující trhy a oscilátory pro postranní typy trhů.

4.3.3.1 Proměnné technické analýzy

Technická analýza bývá definována jako grafická technika, zachycující časové řady dvou proměnných kapitálových trhů: ceny a objemu obchodních transakcí. Na burzách jsou v průběhu obchodování sledovány čtyři typy cen: otevírací (open), nejvyšší (high), nejnižší (low) a uzavírací (close) cena. Pro analytiku nejvyšší význam mají především close ceny. Je to totiž cena, kterou se jednotlivé burzovní seance uzavírají.

Způsobů reprezentace těchto proměnných je mnoho, například OHLC grafy cenový pohyb v průběhu sledování zobrazují jako vertikální čáru s horizontálními liniemi otevíracích (open) a uzavíracích (close) cen. Obrázek č. 11 ukazuje princip tohoto zobrazení.

4.3.3.2 Metody technické analýzy

Technická analýza využívá tři základní metody:

1. Trendové linie
2. Cenové rámce
3. Indikátory

Možnost analyzovat pohyby cen a objemy obchodních transakcí na kapitálových trzích vyplývá z podstaty jejich fungování. Ceny se mohou pohybovat buď vzhůru, dolů nebo mohou v určitém období stagnovat. V případě stagnace jsou rozptyly cen výrazně menší než u stoupajících nebo klesajících cenových pohybů.

Trendové linie umožňují reprodukovat pohyby cen na linie, které zobrazují trend časové řady. Pro výpočet trendových linií jsou používány různé druhy algoritmů. Například regrese (regresní přímky), Fibonacciho studie a specifické nástroje technické analýzy.

Cenové rámce mohou nabývat různých tvarů (trojúhelníky, obdélníky a další geometrické obrazce). Z těchto tvarů mohou techničtí analytici odvodit charakter cenového pohybu a lze z nich odhadnout i budoucí stav.

V případě omezeného množství proměnných je možné definovat velké množství indikátorů, které si může uživatel sám nadefinovat a které mu poté slouží k rozpoznání trendu vývoje cen a které jsou popsány v další podkapitole.

4.3.3.3 Indikátory technické analýzy

Pro různé typy trhů jsou v rámci technické analýzy definovány tři skupiny indikátorů:

1. Pro trendující trhy
2. Pro postraní typy trhů
3. Pro hybridní typy trhů

K indikátorům pro trendující trhy patří:

- Moving Averages – simple, exponential, weighted, triangular, time series, variable, volume adjusted atd
- Price and Volume Trend
- Mike Analysis
- Demand index

K indikátorům pro postraní trhy patří:

- Momentum
- Price Rate of Change (ROC)
- Price Stochastic Oscillators
- Money Flow Index
- Relative Strength Index (RSI)

Pro hybridní trhy se využívají tyto indikátory

- Bollinger bands
- MACD (Moving Average Convergence/Divergence)
- Japanese Candlesticks

Způsobů klasifikace indikátorů je však více – například podle počtu proměnných využívaných při výpočtech atd.

V případě spojení s trendovými liniemi a cenovými rámci využívá technická analýza těchto indikátorů:

- Moving Averages – simple, exponential
- Price Rate of Change (ROC)
- Price Oscillator
- Relative Strenght Index (RSI)
- MACD (Moving Average Convergence/Divergence)

4.3.3.3.1 Klouzavé průměry

Jedním z nejfrekventovanějších nástrojů technické analýzy jsou klouzavé průměry. Využívají se v nejrůznějších kombinacích. Klouzavý průměr (simple) je vlastně prostý aritmetický průměr za dané období. Další výpočty jsou pak posouvány vždy o jedno období dopředu. Při využití indikátoru klouzavého průměru se vlastně linie časové řady vyhladí. Cílem však není jen vyhlazení časové řady (eliminace určitého stupně cenového kolísání) ale také ukázat trend časové řady. Průniky klouzavého průměru časovou řadou zdola dávají technickému analytikovi signál k nákupu. Opačným případem je průnik shora dolů, který slouží jako signál k prodeji.

Klouzavý průměr exponencial (ES) dává možnost nastavit odlišné váhy pro zvolená období. Tato váha daná empirické časové řadě může být stejná nebo různá na rozdíl od té, která je přiřazena časové řadě odhadu. Výsledná hodnota klouzavého průměru je pak součtem hodnot empirické a odhadované řady násobené uživatelem zvolenou vahou. Výpočet se pak provádí podle následujícího vztahu:

$$ES_t = a \cdot X_t + (1 - a) \cdot ES_{t-1}$$

Kde X je empirická hodnota časové řady, ES je klouzavý průměr typu exponential, a je hodnota tzv. Dumping Faktor (DF). Výsledek se pohybuje v rozmezí 0 - 1.

4.3.3.3.2 Price Rate of Change (ROC)

Tento indikátor je oscilátorem. Využívá se k měření hybné síly uzavíracích cen (close) příslušného aktiva. Postup výpočtu indikátoru ROC je v jádru jednoduchý. Dělí se cenový pohyb x časových období cenami před x časovými obdobími. Počet období x zadává uživatel. Výsledkem je procento, které může nabývat kladných i záporných hodnot. Indikátor tedy osciluje kolem nuly.

4.3.3.3.3 Cenový oscilátor

Tento indikátor je založen na rozdílu dvou klouzavých průměrů. Ve většině případů bývá tento rozdíl vyjádřen v procentech nebo bodech. Interpretace cenového oscilátoru vychází z interpretace obou klouzavých průměrů, na kterých je tento indikátor založen. Proniká-li krátkodobý klouzavý průměr zdola dlouhodobější klouzavý průměr, jde v technické analýze o signál k nákupu. Cenový oscilátor zachycuje tyto signály prolínání dvou klouzavých průměrů.

4.3.3.3.4 Relative Strength Index (RSI)

Pro výpočet indikátoru RSI se využívá následující vzorec:

$$RSI = 100 - \left\{ \frac{100}{\left[1 + \left(\frac{U}{D} \right) \right]} \right\}$$

Kde U je průměr kladných změn v ceně za x období. D je poté průměr záporných změn v ceně za x období.


Indikátor RSI se pohybuje v rozmezí 0-100. Nejčastější hodnoty jsou však v rozmezí 30-70. Na těchto dvou hodnotách se také zakreslují linie překoupení (70) a přeprodání (30). V případě, že cena překoná tyto dvě linie, jde o signál překonání tzv. zpětné reakce ceny. Signál k nákupu/prodeji aktiva pak přichází až tehdy, kdy cena stále pokračuje v započatém trendu. Indikátor RSI techničtí analytici užívají společně s klouzavými průměry a trendovými liniemi.

4.3.3.3.5 Moving Average Convergence/Divergence (MACD)

Tento indikátor je složen ze tří klouzavých průměrů. Jedná se o velmi často využívaný indikátor. První linie indikátoru představuje rozdíl mezi šestadvacetidenním a dvanáctidenním klouzavým průměrem. Ve většině případů se jedná o exponenciální klouzavé průměry. Graf indikátoru je pak dále proložen spouštěcí linií (signal line). Tato spouštěcí linie standardně představuje devítidenní klouzavý průměr předchozího rozdílu klouzavých průměrů. Průniky grafu rozdílů klouzavých průměrů se spouštěcí linií pak dávají technickému analytikovi signály k nákupu nebo prodeji.

4.4 Výpočetní systém Matlab

Pro praktickou část diplomové práce byl vybrán program Matlab, který umožňuje vytvářet modely neuronových sítí. Matlab je integrované prostředí pro vědeckotechnické výpočty, modelování, návrhy algoritmů, simulace, analýzu a prezentaci dat, paralelní výpočty, měření a zpracování signálů, návrhy řídicích a komunikačních systémů. Matlab je nástroj jak pro pohodlnou interaktivní práci, tak pro vývoj širokého spektra aplikací.



Obrázek 13: Úvodní obrazovka programu Matlab

(Zdroj: Matlab)

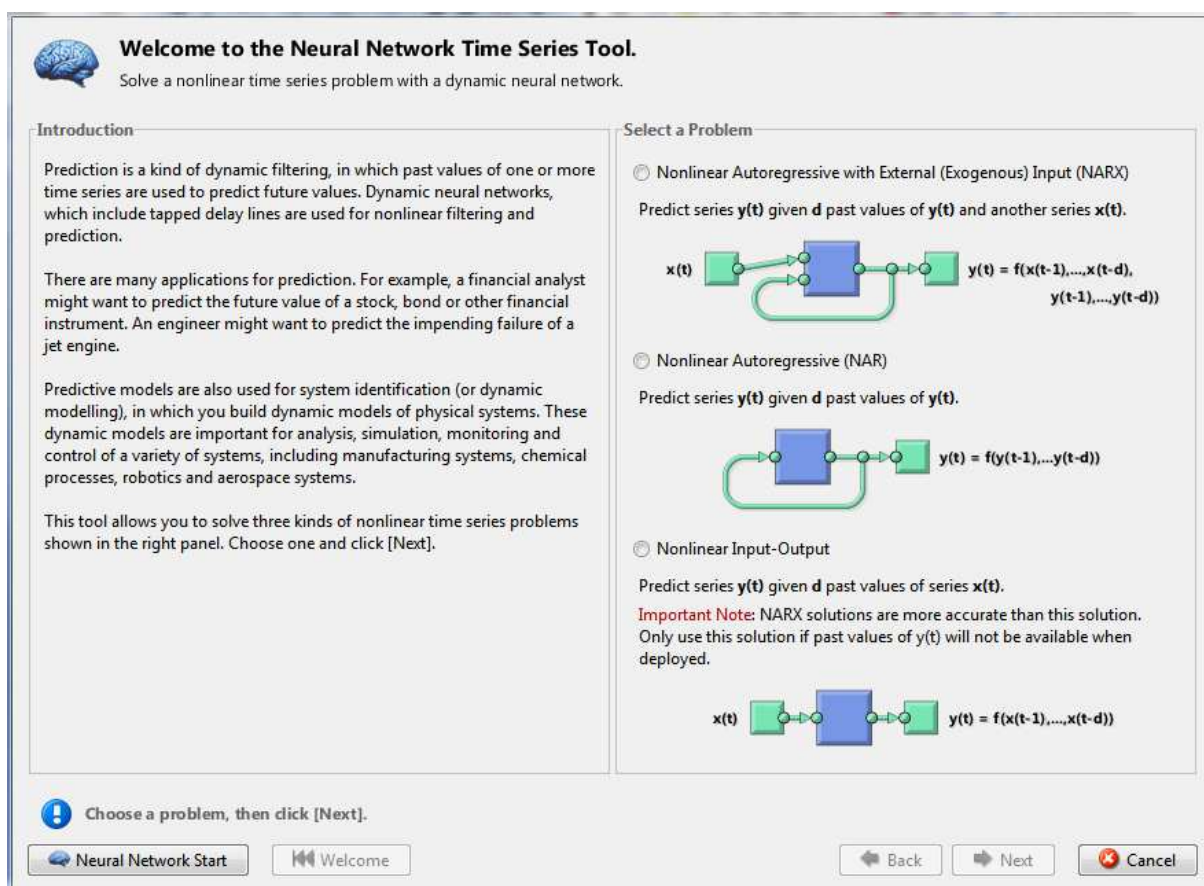
Výpočetní systém Matlab se během uplynulých let stal celosvětovým standardem v oblasti technických výpočtů a simulací ve sféře vědy, výzkumu, průmyslu i v oblasti vzdělávání.

Matlab poskytuje svým uživatelům nejen grafické a výpočetní nástroje, ale i rozsáhlé specializované knihovny funkcí spolu s výkonným programovacím jazykem čtvrté generace. Knihovny jsou svým rozsahem využitelné prakticky ve všech oblastech lidské činnosti.

Díky své architektuře je Matlab určen zejména těm, kteří potřebují řešit početně náročné úlohy a přitom nechtějí nebo nemají čas zkoumat matematickou podstatu problémů. Více než milion uživatelů po celém světě využívá možností jazyka Matlab, který je v mnohém jednodušší než například Fortran nebo C a který skýtá obrovský potenciál produktivity a tvořivosti. Za nejsilnější stránku Matlabu je považováno mimořádně rychlé výpočetní jádro s optimálními algoritmy, které jsou prověřeny léty provozu na špičkových pracovištích po celém světě. Matlab byl implementován na všech významných počítačových platformách (Windows, Linux, Solaris, Mac).

5 Vlastní návrh řešení

Pro vlastní řešení predikční úlohy jsem se rozhodl využít výpočetní systém Matlab, konkrétně toolbox s názvem „Neural network time series tool“. Tento toolbox se spouští příkazem `ntstool` přímo z matlabu.



Obrázek 14: Úvodní obrazovka ntstool

(Zdroj: Matlab)

V tomto nástroji je možné vybrat si z více modelů neuronové sítě. První model, který je možné vybrat je tzv. nelineární autoregresní model s vnějším (exogenním) vstupem (NARX). Tento model se vyznačuje tím, že na jeho vstupu není jen časová řada, ale i nějaký další vstup. Tímto vstupem mohou být podpůrná data například z nástrojů technické analýzy.

Dalším modelem, který je možné využít je tzv. nelineární autoregresní model (NAR). Jedná se o stejný model jako je NARX, jen s tím rozdílem, že se na vstupu nepřidává žádný další vstup. Jedná se tedy o predikci jen z časové řady.

Oba tyto modely využívají data dostupná online na stránce <http://finance.yahoo.com/> . Uživatel si může vybrat komoditu, akcii, index, případně jinou obchodovatelnou položku z velkého množství dostupných. Na této stránce jsou data dostupná i velmi daleko do historie, takže je možné využívat i historická data. Modely většinou k predikci využívají close data. Jedná se o data, která se zaznamenávají každý den na konci obchodování. Je však možné využít i jiná data z OHLC (open, high, low, close) modelu.


Pro samotný predikční model byl vybrán nelineární autoregresní model (NAR).

6 Nelineární autoregresní model (NAR)

Nelineární autoregresní model pracuje jen s hodnotami časové řady – je možné jej na základě historických hodnot jak natrénovat, tak predikovat budoucí vývoj. Na rozdíl od nelineárního autoregresního modelu s exogenním vstupem (NARX) nevyužívá žádná další data. Matematicky je možné nelineární autoregresní model (NAR) popsat takto:

$$y(t) = f(y(t-1), \dots, y(t-d))$$


Kde $y(t)$ je časová řada, d je počet hodnot časové řady. Pokud bychom chtěli nelineární autoregresní model popsat graficky je to možné tímto způsobem:



Obrázek 15: Obecné schéma NAR modelu

(Zdroj: Matlab)

V případě konkrétního modelu neuronové sítě je schéma o poznání složitější. Obrázek č. 16 tento model zobrazuje. Ve schématu je navíc popisem znázorněn počet neuronů ve skryté vrstvě, je znázorněno zpoždění a také je zobrazena transformační funkce jednotlivých vrstev.




Obrázek 16: Schéma konkrétního NAR modelu

(Zdroj: Matlab)

Proces samotného modelování je založen na rozdělení dat historické časové řady vybraného investičního nástroje. Samotná neuronová síť se natrénuje ze 70 procent dat. Dalších 15 procent dat je využito k validaci neuronové sítě, tedy kontrole výsledků natrénované neuronové sítě a to s možností zastavení tréninku v případě, že jsou

výsledky neuronové sítě již na hranici svých možností a výstup se již nijak nezlepšuje. Posledních 15 procent dat se využívá k nezávislému dodatečnému testování neuronové sítě. Rozdělení dat do všech těchto tří skupin probíhá náhodně.

K tréninku neuronové sítě se využívá Levenberg-Marquardt algoritmus, s tím že chyba je měřena metodikou střední kvadratické chyby tedy (MSE).




Obrázek 17: Trénink NAR modelu

(Zdroj: Matlab)

Jak je patrné z obrázku č. 17, testování neuronové sítě proběhlo ve 13-ti iteracích. Dále proběhlo 6 validačních zkoušek.


Na obrázku č. 18 je znázorněn graf validačního výkonu neuronové sítě. Tento graf se využívá ke zjištění zda-li nedošlo k přetrénování neuronové sítě. Jak je na obrázku č. 18 vidět, chybovost neuronové sítě klesala až do sedmé iterace a poté se výpočetní výkon sítě již neměnil.



Obrázek 18: Graf MSE

(Zdroj: Matlab)


Po trénování (a úspěšném natrénování) neuronové sítě následuje samotná predikce hodnot.



Obrázek 19: Schéma NAR modelu po odstranění zpoždění

(Zdroj: Matlab)

Predikce je založena na odstranění zpoždění. Po odstranění zpoždění neuronová síť vrací stejné hodnoty jako neuronová síť se zpožděním, ale tyto hodnoty jsou posunuty o velikost zpoždění směrem doleva. Schéma neuronové sítě bez zpoždění je znázorněno na obrázku č. 19.




Obrázek 20: Odchylka výstupních a požadovaných hodnot

(Zdroj: Matlab)

Úspěšnost predikce je možné vyčíst z grafu v obrázku č. 20. Tento obrázek demonstruje rozdíl mezi výstupní a požadovanou hodnotou při každém kroku predikce a také zobrazuje velikost odchylky v jednotlivých krocích časové řady.

Největší odchylky mezi výstupními a požadovanými hodnotami je možné pozorovat na konci predikce, kdy rozdíl dosahoval vyšších hodnot. Úspěšnost predikce je však možné zhodnotit jako uspokojivou.

Další graf (obr. 21) vzniká překrytím hodnot historické časové řady predikovanými hodnotami. Je možné všimnout si tří hodnot, které se velmi liší, avšak celkový trend se jeví uspokojivě. Tyto rozdíly (chyby) jsou pravděpodobně zapříčiněny prudkými změnami vývoje historické časové řady. Tyto tři chybové hodnoty jsou výrazně znázorněny i v obrázku č. 20 jako vysoké odchylky výstupních a predikovaných hodnot.



Obrázek 21: Srovnání reálných a predikovaných hodnot

(Zdroj: Matlab)

Jak bylo zmíněno již výše, výsledky predikce NAR modelu není možné prakticky nijak ovlivnit jako například u nelineárního autoregresního modelu s vnějším (exogením) vstupem (NARX). Prakticky jediná proměnná, která lze v modelu měnit je počet neuronů ve vnitřní (skryté) vrstvě. Proto byly pro účely porovnání vytvořeny čtyři modely – první model s deseti neurony, další model s dvaceti neurony, poté model s padesáti neurony a nakonec model se sto neurony. Modely se využívaly pro predikci cen ropy v březnu 2013. Výsledky predikce byly srovnány s reálnými hodnotami cen ropy (close ceny).

6.1 Vyhodnocení NAR modelu

Testování NAR modelu probíhalo následovně: byly vytvořeny 4 modely, u kterých se lišil počet neuronů – 10,20,50 a 100 neuronů. Jako testovací období byl vybrán březen 2013. Jako základní investiční kapitál bylo zvoleno \$1000. Tento kapitál se investoval na základě predikce každého ze všech čtyř modelů. V případě, že modely predikovaly změny ceny, proběhla nebo neproběhla investice. V případě úspěchu, se částka připsala zpět k základnímu kapitálu a predikce pokračovala se zvýšeným kapitálem následující den. Tato měření jsou reprezentativní vzorek více pokusů.

Počet neuronů	Odchylka predikce (%)	Úspěšnost (%)	Výsledný stav (\$)
10	0,017 - 2,798	65,23	991,22
20	0,065 - 3,194	57,72	986,76
50	0,056 - 1,403	81,06	1019,65
100	0,059 - 2,634	70,98	1003,92

Tabulka 1: Úspěšnost jednotlivých NAR modelů

(Zdroj: vlastní)

Z tabulky číslo 1 je možné zjistit, že nejúspěšnější predikční model byl s padesáti neurony. Jako další úspěšný model je také model se 100 neurony, kdy počáteční kapitál je skoro o čtyři dolary v plusu. Na rozdíl od modelů s deseti a dvaceti neurony, modely s padesáti a sto neurony správně predikovaly výkyvy ceny na konci sledovaného období. Nejúspěšnější však byl model s padesáti neurony, protože jeho úspěšnost přesáhla osmdesát procent což se dá považovat za velmi dobrý výsledek. V případě

druhého modelu s 20 neurony přesáhla úspěšnost predikce mírně 50%. Tento výsledek je prakticky srovnatelný s házením mince.

6.2 Optimalizace NAR modelu

Optimalizace modelů neuronových sítí je jedním z nejdůležitějších a zároveň nejsložitějších úkolů. Žádný NAR model není optimální pro všechny úlohy, což dává optimalizaci pro daný konkrétní úkol ještě větší důležitost. Možnosti optimalizace ve vývojovém prostředí Matlab jsou široké díky čemuž je optimalizace pro konkrétní úlohu jednodušší. Optimalizace může probíhat dvěma způsoby:

- Optimalizace vstupních dat
- Optimalizace vlastností a parametrů modelu

6.2.1 Optimalizace vstupních dat

Samotný NAR model je založen jen na vstupních historických datech. Data samotná se stahují ze serveru Yahoo!. Model je nastaven tak, aby se stahovala data za posledních 180 dní od data zadaného uživatelem. Po odečtení dnů kdy se neobchoduje (víkendy, statní svátky atd.) tedy dostaneme přibližně 120 close hodnot.

Pro data s nízkou mírou kolísavosti (volatility) se tento počet jeví jako optimální pro natrénování neuronové sítě a získání obstojných výsledků. Pokud by bylo nutné provádět výpočet pro data s vysokou mírou kolísavosti, můžeme zvolit dvě řešení:

- Snížení rozsahu hodnot – míra kolísavosti se také sníží
- Zvýšení rozsahu hodnot – neuronová síť poté bude mít dostatek dat na určení jednotlivých zákonitostí a souvislostí vyplívajících z odvětvové fundamentální analýzy daného investičního nástroje.

Dalším důležitým faktorem je také rozdělení dat pro trénování, validaci a testování. Toto rozdělení může také významným způsobem ovlivnit výsledky predikce. Data se rozdělují těmito způsoby:

- dividerand – data jsou rozdělována do skupin náhodným výběrem (v základním nastavení se využívá tento způsob)

- `divideblock` – data jsou rozdělována do souvislých bloků (data pro trénování tvoří první blok, data pro validaci tvoří druhý a pro testování se vytváří třetí blok dat)
- `divideint` – data jsou automaticky rozdělována do skupin pomocí intervalů
- `divideind` – data jsou rozdělena do skupin pomocí manuálně nastavených intervalů

V případě, že se časový interval i počet neuronů jeví jako dostatečný, ale neuronová síť stále nedosahuje uspokojivých výsledků je také možné měnit velikost trénovacího vektoru – čísla, které určuje jak velká část dat se použije na trénování neuronové sítě.

Je také možné využít funkci `dividetRAIN`, díky které se všechny data uloží do skupiny testovacích dat a obě další skupiny zůstanou prázdné.

6.2.2 Optimalizace vlastností a parametrů modelu

Parametry NAR modelu je možné rozdělit do více skupin:

- Obecné parametry – pojmenování modelu, informace o tomto modelu a další položky týkající se formální stránky modelu
- Parametry zvyšující účinnost modelu – například velikost vyrovnávací paměti pro přepočítávání vstupů atd.
- Parametry týkající se architektury modelu – počet vrstev modelu a jejich typů a také způsobů, jakými jsou tyto vrstvy propojeny
- Funkční parametry – nastavení možností spouštění, tedy inicializace neuronové sítě, způsoby jakými se měří výkonnost sítě, jak se síť adaptuje a trénuje

Jediným způsobem, kterým byl konkrétní model optimalizován, je počet neuronů ve skryté vrstvě sítě. Pokud zvolíme větší počet neuronů, síť poté může vykazovat větší flexibilitu, protože neuronová síť má poté více parametrů, které je možné optimalizovat. Je však nutné vybírat počet neuronů na základě velikosti vstupních dat a také na základě úlohy, kterou má neuronová síť plnit. Větší počet neuronů není vždy zárukou lepších výsledků a samotné řešení dokazuje, že pro daný úkol je neoptimálnější počet padesát neuronů.

V rámci optimalizace neuronové sítě je také důležitý výběr přenosových funkcí a trénovacích algoritmů. Matlab nabízí k výběru 14 přenosových funkcí a 21 trénovacích

algoritmů. Ne všechny jsou však v praxi použitelné a je nutné pečlivě vybírat a testovat jednotlivé kombinace pro zadanou úlohu. V případě nevhodnosti algoritmu Levenberg-Marquardt je možné využít například algoritmus využívající Bayesovu regulizaci (trainbr), který má poměrně dobré výsledky při generalizování neuronové sítě. Míru regulizace je možné nastavit manuálně. Při chybném nastavení však často dochází k přetrénování neuronové sítě.

Zvolený Levenberg-Marquardt algoritmus (trainlm) nabízí také velké množství nastavení různých parametrů:

- `net.trainParam.epochs` – nastavení maximálního počtu iterací
- `net.trainParam.goal` – nastavení výkonnosti neuronové sítě
- `net.trainParam.max_fail` – nastavení maximálního počtu validačních selhání

V neposlední řadě lze také optimalizovat algoritmus pro výpočet chyb. Nejedná se o optimalizaci v pravém slova smyslu, ale spíše o způsob, jak je na chyby nahlíženo. Možnosti jsou následující:

- Sum squared error (sse) – používá se při použití trainbr, výkon je vyjádřen v závislosti na součtu kvadrátů chyb
- Mean absolute error (mae) – průměrná absolutní chyba, výkonnost sítě se měří jako průměr z absolutních chyb
- Mean squared error (mse) – střední průměrná kvadratická chyba – tento nástroj se využívá ve většině případů

6.2.3 Zhodnocení NAR modelu

NAR model poskytuje vhodné nástroje pro predikci libovolného investičního nástroje. Jedná se o velmi rychlý a dobře nastavitelný model. Při dobré optimalizaci modelu a vhodném výběru velikosti vstupných dat a počtu neuronů je možné získat úspěšnost predikce přes 80%. Tento model má však i nevýhody. Například fakt, že využívá jen jeden vstup – tedy řadu historických hodnot. Tento fakt může snížit přesnost výstupu modelu. V případě konkrétní zadané úlohy je však možné hodnotit model nadmíru kladně. Tento model lze doporučit jako nástroj pro predikci vývoje libovolného investičního nástroje.

7 Závěr

Diplomová práce je zaměřena na predikci vývoje na finančních trzích za pomoci prostředků umělé inteligence. V první části se práce zabývá popisem společnosti, která bude výstupy diplomové práce využívat. Teoretická část se zaměřuje na popis prostředků a nástrojů využívaných v souvislosti s predikcí na kapitálových a finančních trzích. Hlavní zaměření je na prostředky umělé inteligence, konkrétně neuronové sítě. Popisuje hlavní typy neuronových sítí, zaměřuje se na prostředky technické, psychologické a fundamentální analýzy. Dalším tématem teoretické části je popis kapitálových a finančních trhů, jejich historie a principů jejich fungování.

V praktické části se práce zaměřuje na model neuronové sítě. Konkrétně je využit nelineární autoregresní model neuronové sítě (NAR). Byly vytvořeny čtyři verze modelu. Tyto čtyři verze se lišily počtem neuronů ve skryté vrstvě. Počet neuronů u jednotlivých modelů byl 10, 20, 50 a 100. Model byl testován na cenách ropy za březen 2013, přičemž se jedná o reprezentativní vzorek více pokusů. Model nepredikuje jen ceny ropy, ale je možné využít i další investiční nástroje například akcie Googlu nebo Microsoftu atd.

Jako nejlepší model po provedení výpočtů a srovnání s reálnými daty se jeví typ s padesáti neurony. Úspěšnost predikce v případě tohoto modelu je přes osmdesát procent, což je velmi slušný výsledek. Nejméně úspěšný model je pak typ s dvaceti neurony, který má úspěšnost méně než šedesát procent. Tento výsledek je prakticky srovnatelný s náhodným tipem, takže jeho využití se nedoporučuje.

Nejvhodnějším modelem pro predikci investičních nástrojů je tedy typ s padesáti neurony, což jej předurčuje k využití firmou pro zhodnocení volných finančních prostředků.

Praktická část se dále zaměřuje na možnosti optimalizace zvoleného modelu za účelem získání ještě lepších výsledků. Optimalizace modelu je možná na více úrovních (datová, parametrická atd.). Po provedení optimalizace by měl model teoreticky dosahovat ještě lepších výsledků.

8 Seznam použité literatury a zdrojů

- [1] VRONLI S.R.O. Vronli: Online technická podpora [online]. [cit. 2013-04-26]. Dostupné z: <http://www.vronli.cz/>
- [2] JANOUGH, Viktor. *Internetový marketing: prosad'te se na webu a sociálních sítích*. Vyd. 1. Brno : Computer Press, 2010. 304 s. ISBN 978-80-251-2795-7
- [3] FANTA, Jiří. *Psychologie, algoritmy a umělá inteligence na kapitálových trzích*. 1. vyd. Praha: Grada, 2001. 167 s. ISBN 80-247-0024-7.
- [4] Biologie člověka: Nervová soustava. [online]. [cit. 2013-04-26]. Dostupné z: http://skolajecna.cz/biologie/Sources/Textbook_Textbook.php?intSectionId=90200
- [5] Wikipedia: Neuron. [online]. [cit. 2013-04-26]. Dostupné z: <http://cs.wikipedia.org/wiki/Neuron>
- [6] DOSTÁL, P. *Pokročilé metody analýz a modelování v podnikatelství a veřejné správě*. 1. vydání. Brno: CERM, 2008. 340 s. ISBN 978-807-2046-058.
- [7] PAVLÁT, Vladislav. *Kapitálové trhy*. 1. vyd. Praha: Professional Publishing, 2005. 318 s. ISBN 80-86419-87-8.
- [8] Kapitálový trh [online]. [cit. 2013-03-11]. Dostupné z WWW: http://cs.wikipedia.org/wiki/Kapit%C3%A1lov%C3%BD_trh
- [9] KROPÁČ, Jiří. *Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady*. 1. vyd. Brno, 2007. 149 s. ISBN 978-80-214-3295-6.
- [10] Matlab - Jazyk pro technické výpočty [online]. [cit. 2013-04-26]. Dostupné z WWW: <http://www.humusoft.cz/produkty/matlab/matlab/>
- [11] DOSTÁL, P. *Pokročilé metody rozhodování v podnikatelství a veřejné správě*. Brno: Akademické nakladatelství CERM, 2012. 718 s. ISBN 978-80-7204-798-7.
- [12] DOSTÁL, P. *Advanced Decision Making in Business and Public Services*. Brno: Akademické nakladatelství CERM, 2011. 168 s. ISBN 978-80-7204-747-5.
- [13] DOSTÁL, P. a Z. SOJKA. *Financial Risk Management*. Zlín: UTB 2008. 80 s. ISBN 978-80-7318-772-9.
- [14] HANSELMAN, D. a B. LITTLEFIELD. *Mastering MATLAB7*. Pearson Education International Ltd., 2005. 852 s. ISBN 0-13-185714-2.

- [15] MAŘÍK, V., O. ŠTĚPÁNKOVÁ a J. LAŽANSKÝ. *Umělá inteligence*. ACADEMIA, 2003. 1440 s. ISBN 80-200-0502-1.
- [16] REJNUŠ, O. *Finanční trhy*. Ostrava: Key Publishing, 2008. 559 s. ISBN 978-80-87071-87-8.
- [17] REJNUŠ, O. *Cenné papíry a burzy*. 1. vydání. Brno: CERM, 2009. 400 s. ISBN 978-80-214-3805-7.

9 Seznam obrázků

Obrázek 1: Logo společnosti Vronli s.r.o.	14
Obrázek 2: SWOT analýza společnosti	16
Obrázek 3: Biologický neuron	25
Obrázek 4: Činnost umělého neuronu	26
Obrázek 5: MLP neuronová síť 5-6-1.....	29
Obrázek 6: RBF neuronová síť	32
Obrázek 7: Kohonenova neuronová síť	34
Obrázek 8: Výhody a nevýhody jednotlivých typů neuronových sítí	34
Obrázek 9: Algoritmus trénování sítě MLP s řízeným učením	36
Obrázek 10: Rozdělení složek časových řad	44
Obrázek 11: Elliotovy vlny	47
Obrázek 12: OHLC graf	48
Obrázek 13: Úvodní obrazovka programu Matlab	54
Obrázek 14: Úvodní obrazovka ntstool	56
Obrázek 15: Obecné schéma NAR modelu	58
Obrázek 16: Schéma konkrétního NAR modelu	58
Obrázek 17: Trénink NAR modelu.....	59
Obrázek 18: Graf MSE	60
Obrázek 19: Schéma NAR modelu po odstranění zpoždění.....	61
Obrázek 20: Odchylka výstupních a požadovaných hodnot.....	61
Obrázek 21: Srovnání reálných a predikovaných hodnot.....	62

10 Seznam tabulek

Tabulka 1: Úspěšnost jednotlivých NAR modelů	63
--	----

11 Seznam příloh

Příloha 1: CD s praktickou aplikací predikčního modelu NAR