


ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA STROJNÍ

ÚSTAV PŘÍSTROJOVÉ A ŘÍDICÍ TECHNIKY



**STUDIE VYUŽITÍ NEURONOVÝCH SÍTÍ A ADAPTIVNÍHO
MONITOROVÁNÍ PRO ALGO-TRADING**

Diplomová práce

ZADÁNÍ DIPLOMOVÉ PRÁCE

pro:

Bc. Filipa MOLČÍKA

obor: Přístrojová a řídicí technika

Název tématu:

Studie využití neuronových sítí a adaptivního monitorování pro algo-trading

Název anglicky:

Neural Networks and Adaptive Monitoring Study for Algo-Trading

Zásady pro zpracování

Cílem práce je navrhnout a otestovat metodu sledování a vyhodnocování trendů v dynamice složitého dynamického systému, zde tržních veličin s otestováním různých typů neuronových modelů.

1. Proveďte rešerši metod zpracování dat a ukazatelů se zaměřením na využití pro algo-trading.
2. Pro zvolená data (např. FOREX), navrhňte a proveďte analýzy závislostí dat (viz. rešerše + prostá predikovatelnost neuronovým modelem LNU, QNU, MLP, algoritmus L-M)
3. Pro stejná data, navrhňte a otestujte neuronovou síť typu RBF pro predikci.
4. Pro stejná data, navrhňte síť typu ELM (Extreme Learning Machine) zde s jednou skrytou vrstvou a porovnejte její výkon s ostatními neuronovými modely v závislosti na volbě počtu skrytých neuronů.
5. Navrhňte metodu monitorování a vyhodnocování dynamiky dostupných ekonomických veličin pro okamžité vyhodnocování trendu veličiny a implementujte řešení (Python nebo Matlab).
6. Ověřte funkčnost na umělých datech a proveďte studii pro reálná historická data (např. FOREX)
7. Zdokumentujte řešení a vyhodnoťte teoretické i praktické poznatky.

Rozsah grafických prací: max. 50 %

Rozsah průvodní zprávy: min. 50 stran + přílohy

Seznam odborné literatury:

- [1] MELOUN, M. a Jiří MILITKÝ. *Statistická analýza experimentálních dat*. Vyd. 2., upravené a rozšířené. Praha: Academia, 2004. ISBN 978-80-200-1254-8.
- [2] GUPTA, Madan M, Noriyasu HOMMA, Zeng-Guang HOU, MG SOLO a Ivo BUKOVSKY. Higher order neural networks: fundamental theory and applications. *Artificial Higher Order Neural Networks for Computer Science and Engineering: Trends for Emerging Applications*. 2010, s. 397–422.
- [3] HUANG, Guang-Bin, Qin-Yu ZHU a Chee-Kheong SIEW. Extreme learning machine: Theory and applications. *Neurocomputing* [online]. 2006, roč. 70, č. 1–3, Neural Networks Selected Papers from the 7th Brazilian Symposium on Neural Networks (SBRN '04) 7th Brazilian Symposium on Neural Networks, s. 489–501. ISSN 0925-2312. Dostupné z: doi:10.1016/j.neucom.2005.12.126
- [4] EVANS, Cain, Konstantinos PAPPAS a Fatos XHAFI. Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation. *Mathematical and Computer Modelling* [online]. 2013, roč. 58, č. 5–6, The Measurement of Undesirable Outputs: Models Development and Empirical Analyses and Advances in mobile, ubiquitous and cognitive computing, s. 1249–1266. ISSN 0895-7177. Dostupné z: doi:10.1016/j.mcm.2013.02.002
- [5] Další podle provedené rešerše a doporučení vedoucího

Vedoucí diplomové práce: doc. Ing. Ivo Bukovský, Ph.D.

Datum zadání diplomové práce: 12. 4. 2016

Termin odevzdání diplomové práce: 15. 6. 2016

u-2 JCh

doc. Ing. Jan Chyský, CSc.
vedoucí ústavu



Michael Valášek

prof. Ing. Michael Valášek, DrSc.
děkan fakulty

V Praze dne: 5. 4. 2016

PROHLÁŠENÍ

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně s tím, že její výsledky mohou být dále použity podle uvážení vedoucího diplomové práce jako jejího spoluautora. Souhlasím také s případnou publikací výsledků diplomové práce nebo její podstatné části, pokud budu uveden jako její spoluautor.

Podepsán: _____

Datum: _____

Bc. Filip Molčík

ANOTACE

V této práci je provedena studie využití neuronových sítí pro algoritmické obchodování. Je zde představen trh cizích měn FOREX. Jsou zde uvedeny základní postupy využívané pro algoritmické obchodování. Dále je shrnut současný stav využití neuronových sítí pro obchodování. V dalších částech je navržen experiment na základě provedené rešerše pro využití neuronových sítí pro obchodování. Pro tento experiment je vytvořeno 5 neuronových modelů v prostředí MATLAB, které jsou otestovány na umělých datech a poté srovnána jejich výkonnost pro prostou predikci na historických datech. V experimentu je využito dat z FOREXu za období leden 2012 až leden 2016 v 15 minutových sloupcích pro 8 měnových párů. Pro nejvýkonnější neuronovou síť je poté navržena metoda pro okamžité monitorování trendu založená na klouzavých průměrech, která dosahuje za testované období o 5,2 vyšší procento profitabilních obchodů oproti jednoduchým klouzavým průměrům. V závěru jsou shrnuty výsledky a také nastíněn další možný vývoj.

ABSTRACT

Aim of this work is study of artificial neural networks for algorithmic trading usage. Foreign exchange market, state of art for algo-tading and artificial neural networks for trading is introduced in this paper. In next part, the experiment is presented based on methods of artificial neural networks for trading chapter. In this experiment, five artificial neural networks were designed in MATLAB enviroment. These five neural models are tested on generated data and then their performance is compared for simple prediction of historical data. In this experiment, data from the foreign exchange market are used in period from January 2012 to January 2016 in 15 minute bars. These data consists of 8 currency pairs. The neural model with best performance from the experiment is used in the proposed method of trend monitoring. This new method is based on moving average utilizing neural network approach, and it achieves 5,2 points better percent of profitable trades in comparison to the simple moving averages. In conclusion, the results are summarized and proposals for future work are discussed.

PODĚKOVÁNÍ

Tímto bych chtěl poděkovat mému vedoucímu Doc. Ing. Ivo Bukovskému, Ph.D. za trpělivost, cenné rady a připomínky k vypracování této práce. Dále bych chtěl poděkovat Ing. Viktoru Plačkovi, Ph.D. za poskytnutá data a čas, který si na mě našel. Poděkování patří též mé rodině a přítelkyni za pomoc a podporu během studia.

OBSAH

1 ÚVOD	1
2 FOREX	3
2.1 OBCHODNÍ CENTRA	3
2.2 MĚNOVÉ PÁRY	3
2.3 PÁKOVÝ EFEKT	4
3 POPIS METOD	5
3.1 ALGORITMICKÉ OBCHODOVÁNÍ	5
3.1.1 <i>Money management</i>	6
3.1.2 <i>Testování</i>	6
3.1.3 <i>Hodnocení výsledků</i>	7
3.2 TECHNICKÁ ANALÝZA	7
3.2.1 <i>Grafické metody</i>	8
3.2.2 <i>Technické indikátory</i>	9
3.3 NEURONOVÉ SÍTĚ	9
3.3.1 <i>Topologie neuronové sítě</i>	11
3.3.2 <i>Neuron</i>	11
3.3.3 <i>Základní neuronové architektury</i>	12
3.3.4 <i>Učení (trénování)</i>	14
3.3.5 <i>Testování</i>	15
3.4 NEURONOVÉ SÍTĚ PRO FINANČNÍ ČASOVÉ ŘADY	15
3.5 ANALÝZA ZÁVISLOSTÍ VE FINANČNÍCH ČASOVÝCH ŘADÁCH	19
3.5.1 <i>Pearsonův korelační koeficient</i>	19
3.5.2 <i>Autokorelační funkce</i>	21
3.5.3 <i>Vzájemná informace (Mutual Information)</i>	21
4 EXPERIMENTÁLNÍ STUDIE NEURONOVÝCH MODELŮ PRO PREDIKCI FINANČNÍCH ČASOVÝCH ŘAD	22
4.1 POPIS EXPERIMENTU	23
4.2 LNU	25
4.2.1 <i>Ověření funkčnosti neuronového modelu</i>	25
4.2.2 <i>Experiment</i>	26
4.3 QNU	29
4.3.1 <i>Ověření funkčnosti neuronového modelu</i>	29
4.3.2 <i>Experiment</i>	30
4.4 MLP	33

4.4.1	<i>Ověření funkčnosti neuronového modelu.....</i>	<i>33</i>
4.4.2	<i>Experiment.....</i>	<i>34</i>
4.5	RBF.....	37
4.5.1	<i>Ověření funkčnosti neuronového modelu.....</i>	<i>37</i>
4.5.2	<i>Experiment.....</i>	<i>38</i>
4.6	MLP-ELM.....	41
4.6.1	<i>Ověření funkčnosti neuronového modelu.....</i>	<i>41</i>
4.6.2	<i>Experiment.....</i>	<i>42</i>
4.7	VÝSLEDKY.....	46
5	NÁVRH METODY PRO OKAMŽITÉ VYHODNOCOVÁNÍ TRENDU.....	48
5.1	POPIS METODY.....	48
5.2	JEDNODUCHÝ KLOUZAVÝ PRŮMĚR PRO PREDIKOVANÁ DATA.....	50
5.3	VÝSLEDKY.....	54
	ZÁVĚR.....	55

SEZNAM TABULEK

Tab. 1: Matematické detaily základních neuronových architektur [12].....	14
Tab. 2: Základní učící algoritmy neuronových architektur [12].....	15
Tab. 3: Tabulka výsledků pro testování LNU neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných Logistickou funkcí (19).....	26
Tab. 4: Tabulka výkonnosti LNU neuronového modelu pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce LNU hůře jak u srovnávací strategie buy & hold.....	27
Tab. 5: Tabulka výsledků pro testování QNU neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných logistickou funkcí (19).....	29
Tab. 6: Tabulka výkonnosti QNU neuronového modelu pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce QNU hůře jak u srovnávací strategie buy & hold.....	31
Tab. 7: Tabulka výsledků pro testování MLP neuronového modelu na umělých data generovaná lineární funkcí (18), náhodných datech a logistickou funkcí (19).....	33
Tab. 8: Tabulka výkonnosti MLP sítě pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce MLP sítě lépe jak u srovnávací strategie buy & hold.....	35
Tab. 9: Tabulka výsledků pro testování RBF neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných Logistickou funkcí (19).....	37
Tab. 10: Tabulka výkonnosti RBF sítě pro jednotlivé měnové páry během 159 dní – celkově dopadá investování podle predikce RBF sítě lépe jak u srovnávací strategie buy & hold.....	39
Tab. 11: Tabulka výsledků pro testování MLP-ELM neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných logistickou funkcí (19).....	41
Tab. 12: Srovnání výkonosti MLP-ELM sítě pro predikci všech 8 měnových párů podle počtu neuronů ve skryté vrstvě – nejlépe dopadá vrstva se 100 skrytými neurony.....	43

Tab. 13: Tabulka výkonnosti MLP-ELM sítě pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce MLP-ELM sítě lépe jak u srovnávací strategie buy & hold.....	44
Tab. 14: Srovnání výsledků 5 neuronových architektur pro provedené testování na historických datech - RBF neuronová síť dopadá nejlépe.....	46
Tab. 15: Srovnání výkonnosti klouzavých průměrů seřazených podle délky periody za 159 dnů na 8 měnových párech.....	51
Tab. 16: Srovnání výkonnosti klouzavých průměrů využívajících predikci RBF neuronového modelu seřazených podle délky periody za 159 dnů na 8 měnových párech.....	52

SEZNAM OBRÁZKŮ

Fig. 1: Náčrt biologického neuronu podle [36] vytv. autor.....	10
Fig. 2: matematický model biologického neuronu vytv. autor.....	12
Fig. 3: Průběh predikce a skutečné ceny z práce [18] - predikována je zavírací cena SGD/AUD v období 65 týdnů (str. 6).....	16
Fig. 4: MLP síť s vstupními daty v podobě klouzavých průměrů [24] (str. 91)..	17
Fig. 5: Predikce a skutečná data pro filtrovaná data v práci [27] (str. 29).....	18
Fig. 6: Korelační koeficient plovoucího okna mezi veličinami GBP/USD a EUR/USD - z obrázku je patrné, že hodnota korelačního koeficientu se v čase mění, $dT=6\text{hod}$, $dt=15\text{min}$, $\text{lag}=0$	20
Fig. 7: Průběh predikce Logistické funkce (19) jednotkou LNU (1),(11) a (12) – lineární model není schopen predikovat nelineární dynamiku.....	26
Fig. 8: Výřez z průběhu skutečné a predikované ceny podle LNU neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)...	28
Fig. 9: Výřez z průběhu nákupů a prodejů podle predikce pomocí LNU neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej).....	28
Fig. 10: Průběh stavu účtu během backtestingu pro predikci podle LNU neuronového modelu.....	29
Fig. 11: Průběh predikce logistické funkce (19) jednotkou QNU – kvadratický model je schopen predikovat nelineární dynamiku (červená predikovaná a modrá skutečná se překrývají).....	30
Fig. 12: Výřez z průběhu skutečné a predikované ceny podle QNU neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)...	32
Fig. 13: Výřez z průběhu nákupů a prodejů podle predikce pomocí QNU neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej).....	32
Fig. 14: Průběh stavu účtu během backtestingu pro predikci podle QNU neuronového modelu.....	33

Fig. 15: Průběh predikce logistické funkce (19) MLP neuronovým modelem – MLP model je schopen predikovat nelineární dynamiku s NMSE 0,94 (červená - predikovaná, modrá - skutečná).....	34
Fig. 16: Výřez z průběhu skutečné a predikované ceny podle MLP neuronového modelu (modrá – predikovaná závírací cena, červená skutečná závírací cena)...	36
Fig. 17: Výřez z průběhu nákupů a prodejů podle predikce pomocí MLP neuronového modelu během backtestingu (modrá – závírací cena, zelené kolečko nákup, červené kolečko prodej).....	36
Fig. 18: Průběh stavu účtu během backtestingu pro predikci podle MLP neuronového modelu.....	37
Fig. 19: Průběh predikce logistické funkce (19) RBF neuronovým modelem – MLP RBF model je schopen predikovat nelineární dynamiku s NMSE 0,999 (červená – predikovaná a modrá - skutečná se téměř překrývají).....	38
Fig. 20: Výřez z průběhu skutečné a predikované ceny podle RBF neuronového modelu (modrá – predikovaná závírací cena, červená skutečná závírací cena)...	40
Fig. 21: Výřez z průběhu nákupů a prodejů podle predikce pomocí RBF neuronového modelu během backtestingu (modrá – závírací cena, zelené kolečko nákup, červené kolečko prodej).....	40
Fig. 22: Průběh stavu účtu během backtestingu pro predikci podle RBF neuronového modelu.....	41
Fig. 23: Průběh predikce Logistické funkce (19) neuronovým modelem MLP-ELM – tento neuronový model je schopen predikovat nelineární dynamiku s NMSE 0,94 (červená predikovaná a modrá skutečná se překrývají).....	42
Fig. 24: Výřez z průběhu skutečné a predikované ceny podle MLP-ELM neuronového modelu (modrá – predikovaná závírací cena, červená skutečná závírací cena).....	45
Fig. 25: Výřez z průběhu nákupů a produjů podle predikce pomocí MLP-ELM neuronového modelu během backtestingu (modrá – závírací cena, zelené kolečko nákup, červené kolečko prodej).....	45
Fig. 26: Průběh stavu účtu během backtestingu pro predikci podle MLP-ELM neuronového modelu.....	46
Fig. 27: Výřez z průběhu backtestingu - Srovnání klouzavých průměru s predikcí (a, b) a bez predikce (c,d), překřížení průběhu závírací ceny s MA(10) je signálem pro vstup/výstup, plným kroužkem jsou vyznačena místa, kde si	

klouzavé průměry s predikcí vedly lépe, čárkovaným kroužkem, kde si vedly hůře
.....53

Fig. 28: Porovnání klouzavých průměrů využívajících predikci RBF neuronového modelu (červená) s konvenčními klouzavými průměry (modrá) pro metriku PPT (procento profitabilních obchodů) a metriku profitu – klouzavé průměry využívající predikci dopadají ve všech variantách lépe.....54

NOMENKALTURA

ANN	Umělé neuronové sítě	Artificial Neural Network
API	Rozhraní pro programování aplikace	Application Programming Interface
AR	Roční návratnost	Annualized Return
ARIMA	Autoregresní integrovaný model klouzavých průměrů	Autoregressive Integrated Moving Average
AT	Automatizované obchodování	Algo-Trading
ATS	Automatický obchodní systém	Automated Trading Systems
AUD/USD	Měnový pár australský dolar/americký dolar	
BP	Algoritmus zpětného šíření chyby	Back Propagation
EUR/USD	Měnový pár euro/americký dolar	
FOREX	Směny cizích měn	Foreign Exchange
FX	Směny cizích měn	Foreign Exchange
GBP/USD	Měnový pár libra / americký dolar	
IBCO		Improved Bacterial Chemotaxis Optimization
LNU	Lineární neuronová jednotka	Linear Neural Unit
Lot	Jednotka standardního objemu obchodu	
MA	Klouzavý průměr	Moving Average
MDA	Klasifikační vícerozměrná statistická analýza	Multiple Discriminant Analysis
MLP	Více vrstvá neuronová síť	Multi Layer Perceptron
MLP-ELM	Více vrstvá neuronová síť v konfiguraci extrémního učení	Multi Layer Perceptron – Extreme Learning Machine
MM	Management peněz	Money Management
NMSE	Fit funkce využívající normalizovanou průměrnou kvadratickou chybu	Normalized Mean Square Error

NZD/USD	Měnový pár novozélandský dolar/ americký dolar	
Pip	Nejmenší standardní jednotka pohybu kurzu	Price Interest Point
PPT	Procento profitabilních obchodů	Percent of Profitable Trades
PT	Cílový zisk	Profit Target
QNU	Kvadratická neuronová jednotka	Quadratic Neural Unit
RBF	Neuronový model s Radialními bázovými funkcemi	Radial Basis Functions Neural Network
SL	Uzavření ztrát	Stop Loss
USD/CAD	Měnový pár americký dolar/kanadský dolar	
USD/CHF	Měnový pár americký dolar/ švýcarský frank	
USD/JPY	Měnový pár americký dolar/japonský jen	
UTC	Koordinovaný světový čas	Coordinated Universal Time
XAU/USD	Měnový pár zlato/americký dolar	

1 ÚVOD

Algoritmické obchodování je obchodování, kdy je exekvováno během jednoho dne velké množství obchodů, které by byly člověkem jen těžko prováděny. Při tomto druhu obchodování je profitováno na malých pohybech ceny v rámci jednoho dne při velkých objemech obchodů. Typickým trhem pro algoritmické obchodování je trh cizích měn FOREX, který je charakteristický svou vysokou likviditou a nízkými poplatky.

V současné době existují především dvě školy zabývající se předpovídáním finančních časových řad. Fundamentální analýza a technická analýza. Fundamentální analýza pracuje s kurzotvornými informacemi, tedy makroekonomickými daty a podle nich se snaží odhadnout správnou vnitřní cenu finančního instrumentu. Tato analýza je zaměřena na dlouhodobé predikce. Naproti tomu technická analýza využívá pouze historických dat a na základě empirických vztahů odhaduje kdy vstupovat či vystupovat z pozice. Je vhodná pro krátkodobé spekulace a pro algoritmické obchodování je využíváno výhradně technické analýzy.

Využití neuronových sítí pro finanční časové řady je důležitým tématem, o kterém bylo napsáno velké množství článků např.: [26], [20] a [24] s převážně pozitivními výsledky. V těchto pracích jsou využívány neuronové sítě v nejrůznějších konfiguracích, vždy se však jedná o více vrstvou neuronovou síť (**MLP**, Multi Layer Perceptron [13]).

Hlavním cílem této práce je porovnat další neuronové architektury, konkrétně lineární neuronovou jednotku (**LNU**, Linear Neural Unit) a kvadratickou neuronovou jednotku (**QNU**, Quadratic Neural Unit [10] - [12]), více vrstvou neuronovou síť **MLP**, síť s radiální bázovou funkcí (**RBF**, Radial Basis Function [13]) a více vrstvou neuronovou síť v konfiguraci extrémního učení **MLP-ELM** (**ELM**, Extreme Learning Machine)[16]. Pro splnění tohoto cíle budou naprogramovány a otestovány jednotlivé neuronové modely, podle provedené rešerše pro využití neuronových sítí pro finanční časové řady navržen experiment pro krátkodobou predikci, založenou pouze na historických cenách dané finanční časové řady, tedy jakousi autonomní predikci. Ze získaných poznatků bude poté navržena metoda pro monitorování trendu.

Tato práce má následující strukturu. V kapitole 2 je představen trh cizích měn FOREX. V kapitole 3 jsou představeny metody využívané pro algoritmické obchodování a také neuronové sítě včetně přehledu literatury pro neuronové sítě využívané pro obchodování a predikci finančních časových řad. Dále je zde zmíněna analýza závislostí pro finanční časové řady. V kapitole 4 je navržen a proveden experiment pro porovnání výkonností jednotlivých neuronových modelů. V kapitole 5 je navržena metoda pro okamžité monitorování trendu. V závěru jsou shrnuty výsledky a také nastíněny možnosti navázání na tuto práci.

2 FOREX

Je trh na kterém účastníci mohou nakupovat, prodávat, směňovat a spekulovat na cizích měnách. Od toho je odvozen i název trhu tedy *FOREign EXchange Market* označován zkratkou FOREX, nebo FX. Na Forexovém trhu [5] obchodují banky, komerční společnosti, centrální banky, investiční společnosti, hedgeové fondy, retailoví brokeři a investoři. Forexový trh je považován za největší¹ a nejlikvidnější finanční trh na světě.

2.1 Obchodní centra

Obchodování probíhá kontinuálně 24 hodin denně 5 dní v týdnu. Neexistuje však žádný centrální trh, ale během dne se obchodní hodiny překrývají v jednotlivých obchodních centrech. Hlavní seance probíhají následovně [6] :

- Sydney (22:00 UTC – 7:00 UTC)
- Tokio (0:00 UTC – 9:00 UTC)
- Londýn (8:00 UTC – 17:00 UTC)
- New York (13:00 UTC – 22:00 UTC).

Mezi další velká obchodní centra patří Zürich, Frankfurt, Paříž, Hong Kong, Singapur, Wellington aj. Obchodování začíná v neděli v Australii ve 22:00 UTC a končí v pátek v New Yorku ve 22:00 UTC. Největších objemů je dosahováno mezi 13:00 UTC a 17:00 UTC, kdy se současně obchoduje v Londýně a New Yorku.

2.2 Měnové páry

Na Forexu se měnové kurzy uvádí ve tvaru *základní měna/kótovací měna* např.: EUR/USD, kde základní měnou je euro a kótovací dolar. Pokud budeme tedy měnový pár obchodovat, měnový kurz nám říká, kolik budeme muset zaplatit za jednotku základní měny. Pro EUR/USD tedy, kolik musí obchodník zaplatit dolarů, aby nakoupil 1 euro. Samotná cena měnového kurzu je pak dána ještě nabídkou (*bid*), to je, za kolik nám je obchodník ochoten základní měnu prodat

¹ Denní obchodovaný objem přesahuje hodnotu \$1 900 000 000 000 [5]

a poptávkou (*ask*), to je, za kolik je od nás obchodník ochoten základní měnu koupit. Rozdíl mezi nabídkou a poptávkou je cenové rozpětí (*spread*).

Spread je transakčním nákladem každého obchodu. Běžně se uvádí v jednotce pip (*price interest point*). 1 pip² je nejmenším standartním pohybem kurzu měnového páru. U měnových párů zobrazovaných na 4 desetinná místa je tedy 1 pip roven 0.0001 ceny. U měnových párů, kde je základní měnou jen (JPY), je kurz uváděn na 2 desetinná místa a 1 pip je tedy roven 0.01 ceny. Pip slouží jako základní jednotka na Forexových trzích.

Kromě pipu se také používá standardizovaná jednotka obchodu 1 lot³ neboli 1 kontrakt. 1 lot představuje 100 000 jednotek základní měny.

2.3 Pákový efekt

Pomocí pákového efektu (*leverage*) můžou obchodníci nakupovat objemy daleko větší než je jejich reálný stav účtu. Využívá se k tomu maržový účet, na kterém část hodnoty broker zablokuje, jako záruku pokud se pozice dostane do ztráty. Jakmile taková situace nastane, dochází k výzvě na vložení další hotovosti nebo uzavření pozice, takzvaný *margin call*. Pokud obchodník nic neudělá uzavře broker pozici sám. Velikost páky se podle brokera pohybuje od 1:1 po 1:500.

² někteří brokeři uvádějí cenu v desetinných pip.

³ někdy se také používá mini-lot (10 000 jednotek) a micro-lot (1 000 jednotek)

3 POPIS METOD

3.1 Algoritmické obchodování

Algoritmické obchodování⁴ (automatizované obchodování, *black-box* obchodování nebo také *algo-trading*) [8] dále jen AT je proces využívající počítač k následování souboru instrukcí vedoucích k provedení obchodního pokynu s cílem profitovat.

Podskupinou AT je *algorithmic decision-making*. Zde je vyhodnocována situace na trhu a podle sledované investiční strategie jsou generovány příslušné pokyny, které může provádět člověk, nebo dále počítač. Kromě investiční strategie se také přihlíží k řízení rizik (MM, Money management) a je určována optimální velikost obchodu.

Další podskupině AT - *algorithmic execution*, kde je algoritmu svěřeno pouze vlastní provedení obchodu. Účelem je dosáhnout výhodnější ceny, pomocí optimalizace provedení pokynu.

Program generující pokyny je často označován jako automatický obchodní systém (ATS, Automated Trading Systems) [8]. Jeho součástí je zdroj aktuálních tržních dat, a rozhraní pro realizaci investičního rozhodnutí. Obchodníci s danými finančními instrumenty (brokeři) obvykle poskytují rozhraní pro programování aplikací (API, Application Programming Interface)⁵, pomocí kterého můžeme získávat aktuální burzovní data, ale také provádět pokyny. Někteří obchodníci také poskytují platformu umožňující běh samotného ATS.

Hlavními benefity a zároveň i důvody k přechodu z rozhodování obchodníků na rozhodování počítače jsou:

- okamžité a přesné provádění pokynů přináší vyšší šanci exekuce na požadované hodnotě
- nižší transakční poplatky

⁴ Speciální podskupinou AT je také Vysokofrekvenční algoritmické obchodování (HFT, high-frequency trading) [8]

⁵ Např. API od Interactive Brokers Group, Inc.'s

- současné sledování mnoha instrukcí a trhů
- nižší riziko lidské chyby při manuálním provádění pokynů
- nižší riziko lidské chyby způsobené emočními a psychologickými faktory
- zpětné ověřování strategií (Backtest)

Stěžejním pilířem ATS je investiční strategie, která generuje vstupní a výstupní signály. Vstupem se rozumí otevření pozice, které může být dvojího typu – dlouhá (long) a krátká (short). Vstup do long pozice znamená spekulovat na cenový růst. Vstup do short pozice je spekulace na cenový pokles.

Prodejní a nákupní signály obvykle získáváme pomocí fundamentální, technické analýzy, nebo psychologické analýzy. Výstupní signály mohou být, ale také generovány money managementem (aktivace stop lossu). Pro AT se využívá především technické analýzy. Rád bych podotkl, že využívat technickou analýzu jako jediný nástroj spekulace, není vhodné. Je nezbytné sledovat všechny aspekty, které ovlivňují kurz.

3.1.1 Money management

Jelikož ne vždy se vyvíjí cena v souladu s naší spekulací, je důležité si určit optimální objem a maximální ztrátu na jeden obchod. Úkolem MM je minimalizovat ztráty a zajistit stabilní zisky. Mezi základní přístupy patří:

- riskovat jen určité procento kapitálu, tak aby nás neohrozila ani série za sebou jdoucích ztrát (*Drawdown*),
- stanovit si poměr zisku ku ztrátě (RRR, Risk reward ratio) pomocí cílového profitu (PT, *Profit target*⁶) a zastavením ztrát (Stop loss),
- navyšování jednotlivých pozic (PS, Position sizing).

3.1.2 Testování

Vytvořený ATS je před nasazením do ostrého provozu potřeba důkladně otestovat. To se provádí dvěma způsoby:

- testováním na historických datech (*backtesting*)
- testováním s virtuálními prostředky (*paper trading*)

Jako první se provádí backtesting, který pokud je prováděn na dostatečném množství dat, nám může dát obrázek, jak je náš ATS úspěšný. Hypotetická nebo simulovaná výkonnost ATS má své limity. Simulované výsledky nereprezentují

⁶ Někdy také *Take profit*

skutečné obchodování. Jelikož obchody nebyly provedeny, výsledky mohou být zkresleny nadhodnocením nebo podhodnocením například z důvodu nedostatečné likvidity. Výhoda zpětného pohledu backtestingové metody je také jeho největší limitací, jelikož budoucí vývoj nemusí vycházet z vývoje minulého.

Po provedení backtestingu se přistupuje k paper tradingu, který kromě výkonnosti ATS ověří i funkčnost komunikace s brokerem.

3.1.3 Hodnocení výsledků

Pro hodnocení úspěšnosti ATS se obvykle sleduje několik ukazatelů, podle [7] to mohou být tyto:

- Sharpeho poměr (Sharpe Ratio)
- Ulcereho index (UPI, Ulcer Performance Index)
- složená roční úroková míra (CAGR, Compound Annual Growth)
- maximální propad (MDD, Maximum Drawdown)
- procento ziskových obchodů (PPT, Percent Profitable Trades)
- poměr průměru ziskových a ztrátových obchodů (AvgWLR, Avg. Win / Avg. Loss Ratio)
- křivka zůstatku (Equity Curve)

3.2 Technická analýza

Technická analýza je nejstarší [1], [2] analytický přístup pro vyhodnocování budoucích trendů. Technická analýza finančních produktů je užívána k odhadování budoucích trendů pouze na základě současných a předcházejících dat finančních produktů. Provádí se vždy výhradně na jednotlivých titulech. Jejím vstupem je pouze historický vývoj kurzu a objemu obchodů. Oproti tomu fundamentální analýza využívá vnějších skutečností, jako jsou politická situace, daňová politika aj.

Podstatu technické analýza lze shrnout do tří tezí (podle [1], [2] a [4]):

Tržní vývoj diskontuje vše

Technická analýza předpokládá, že tržní cena již obsahuje všechny potřebné informace pro analýzu, které jsou známé a relevantní k danému finančnímu produktu, ale reakce kurzu na danou informaci je pomalá a postupná. Toto postupné přizpůsobování je základem vzniku trendu. Technickou analýzu nezajímá příčina pohybu kurzu, ale pohyb kurzu samotný.

Existují vzory v pohybech kurzů

Pravidelně se opakující formace, empiricky ověřené v minulosti, se technická analýza snaží v pohybu kurzu včas objevit a prognózovat další vývoj.

Historie se opakuje

Na pohyb kurzu akcie působí kromě fundamentálních faktorů i faktory neracionálního a psychologické, nepředvídatelného charakteru. Fundamentální vnitřní hodnota tedy nemůže stanovit kurz, jelikož není schopna obsáhnout tyto nefundamentální vlivy.

V průběhu let byly vyvinuty stovky nástrojů technické analýzy. Velké množství těchto indikátorů je principiálně totožné a liší se pouze v detailech. Lze je rozdělit do dvou nejběžnějších skupin, a to na grafické metody (charting) a technické indikátory. V technické analýze existuje několik desítek, možná i stovek indikátorů.

3.2.1 Grafické metody

Grafické metody využívají tržních dat zobrazených v různých grafických podobách. Nejdůležitějšími údaji zobrazovanými v podobě grafů jsou otevírací cena, zavírací cena, maximální cena a minimální cena pro rozličné časové úseky a také objem obchodů. Pro přehledné zobrazení těchto informací bylo vytvořeno množství grafů. Nejpoužívanějšími grafy jsou v současnosti svícový graf a schodový graf. Zde je výčet nejznámějších:

- svícový graf
- schodový graf
- čárový graf (tvořený ze zavírací ceny)
- graf Equivolume [4]
- Point & Figure graf [4]

Dnes a denně vznikají další formy grafů. Mezi grafy [4], téměř exotické, které poslední dobou získávají na oblibě, patří například⁷ Kagi chart, Three Line Break Chart, nebo Renko Chart.

Dalším nástrojem jsou takzvané grafické formace, tedy jakési hodnocení tržního vývoje na základě obrazců, které vytváří samotný trh. Tento přístup je často

⁷ všechny tři jmenované grafy vznikly v Japonsku

kritizován kvůli subjektivitě interpretace. Neboli různí analytici docházejí k různým interpretacím.

3.2.2 Technické indikátory

Technické indikátory jsou matematické vzorce, založené na empirických pozorování, které se snaží odhadnout pravděpodobný vývoj budoucího kurzu. Můžeme je rozdělit následujícím způsobem:

- trendové indikátory
- indikátory volatility
- oscilátory
- objemové indikátory
- indikátory šíře trhu

Toto rozdělení není nikde definované a často se jednotlivé indikátory mohou nacházet ve více skupinách.

3.3 Neuronové sítě

Počátky Neuronových sítí [9](ANN, Artificial Neural Networks) sahají do roku 1943, kdy Warrena McCulloch a Waltera Pitts vytvořili první umělý neuronový model a tím nastartovali vývoj nové vědní disciplíny.

V roce 1949 [9] byla publikována kniha Donalda Hebba - *The Organization of Behavior*, která obsahovala učící pravidlo pro synapse neuronu (Hebbovské učení). Značné zpomalení vývoje nastalo roku 1969 po publikaci článku Marvinina Minska a Seymoura Paperta - *Perceptron*⁸, který narážel na problém samostatného neuronu naučit se XOR⁹ funkci. Další zásadní milník pro ANN byl rok 1982, kdy byl publikován¹⁰ algoritmus učení zpětným šířením chyby (BP, Back-Propagation). Tento algoritmus je dnes součástí většiny ANN aplikací.

ANN se v poslední době těší velké pozornosti. Je to zapříčiněno především jejich vlastnostmi, které jsou s úspěchem využívány v mnoha oborech. Zde jsou některé z nich:

- rozpoznávání textů, písma a podpisů
- komprese obrázků

⁸ perceptron je dnes už pomalu zanikající název pro neuron

⁹ Stephen Grossber roku 1972 představil síť schopnou naučit se XOR funkci

¹⁰ tento algoritmus byl předtím publikován v letech 1969, 1974, 1985, ale svého „objevení“ se dočkal až s nástupem výkonných počítačů

- predikce finančních dat
- detekce úvěrového rizika
- medicínské, bezpečnostní aplikace

Oběcně jsou neuronové sítě vhodné pro problémy:

- regrese
- klasifikace
- shluková analýza

ANN se inspiřují nervovým systémem živých organizmů a představují jejich zjednodušený model. Neuronová síť je složena z jednotlivých neuronů, které jsou navzájem propojeny tak, že výstup neuronu je zároveň vstupem dalších neuronů, jako tomu je u neurofyziologické předlohy. Tam jsou axony přes synaptické vazby spojeny s dendrity jiných neuronů.

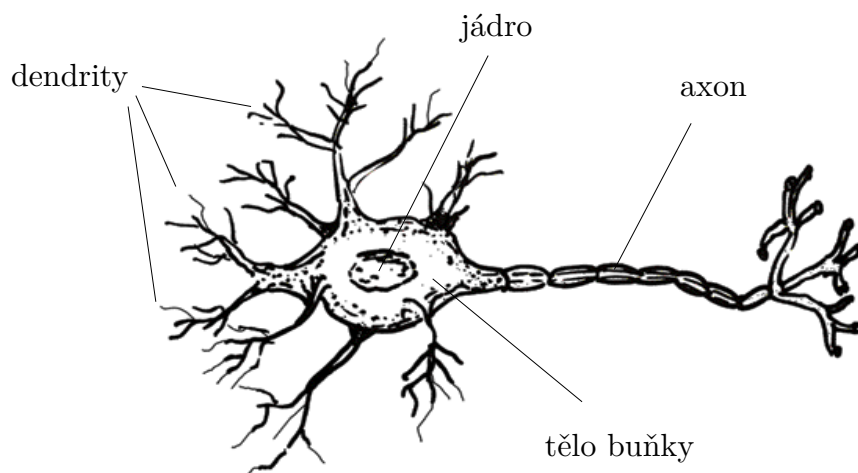


Fig. 1: Náčrt biologického neuronu podle [36] vytv. autor

Počet neuronů a jejich propojení napříč vrstvami určuje topologii neuronové sítě. U umělé neuronové sítě rozlišujeme neurony vstupní, skryté a výstupní. Analogii by byly receptory pro vstup a efekторы pro výstup u biologické předlohy. Propojení neuronů, váhy a jejich stavy se v čase mění a s tím celková dynamika sítě, stejně jako je tomu u neurofyziologické předlohy, tam však tyto děje probíhají naráz. Dynamika neuronové sítě lze rozdělit do tří kategorií. Organizační (změna topologie), aktivní (změna stavu) a adaptivní (změna

konfigurace). Tyto dynamiky jsou zadány počátečním stavem a matematickou rovnicí, která určuje jejich vývoj.

Základní rozdělení konvenčních ANN

- ANN s učitelem (viz. Tab. 2)¹¹ / ANN bez učitele
- feedforward (Statická, někdy také acyklická) / rekurentní (Dynamická, někdy také cyklická)
- podle stupně polynomu

1.1.1 Topologie neuronové sítě

Každá neuronová síť je [14] složena z jednotlivých neuronů propojených tak, že výstup jednoho neuronu je vstupem do dalších neuronů. Běžně se používají především dvě uspořádání, které určují topologii (architekturu) neuronové sítě:

- dopředná (feedforward)
- rekurentní (recurrent)

Právě první zmíněná je pravděpodobně nejpoužívanější způsob uspořádání neuronů. Dopředná síť je charakteristická tím, že nemá žádné zpětné vazby. U této neuronové sítě lze neurony rozdělit do vrstev, které jsou uspořádány tak, že neuronové spoje vedou jen ve směru z vstupní vrstvy do výstupní vrstvy. Účelem vstupní vrstvi je normalizace dat. Účelem výstupní zase formulovat výstup. Výstupem nemusí být jenom jeden neuron, ale například, jako tomu je u rozpoznávání znaků, pro každý znak jeden výstupní neuron.

V rekurentní topologii je síť propojena i zpětnými vazbami. To vytváří jakousi krátkodobou paměť. Jinými slovy výstup sítě nebude dán pouze vstupy, ale také tím, co tento stav předcházelo. To přináší komplikaci adaptace této sítě. Cílem totiž je, aby ANN reagovala ne jen na jednotlivé vstupní vzory, ale také na kontext.

3.3.1 Neuron

Základním stavebním kamenem neuronové sítě je matematický model biologického neuronu, někdy označovaný jako perceptron. [14] Má n vstupů (synapse) x_1, x_2, \dots, x_n a každý vstup je vážen váhami w_1, w_2, \dots, w_n (synaptická operace). Ve shodě s neurofyzilogickou předlohou mohou být váhy i záporné, čímž se vyjadřuje jejich inhibiční charakter. Tím je určena propustnost jednotlivých vstupů (podněty z okolí, nebo výstupy jiných neuronů). Ve vstupní

¹¹ NS typu Radial Basis Function a Support vector Machines patří do NS s učitelem, ale s odlišnou koncepcí

matici se také vyskytuje číslo 1. Jde o takzvaný bias, neboli vychýlení [14]. To zajišťuje vymanění se z lokálních minim a divergenci ke globálnímu minimu. Vlastní neuron má pak potenciál ξ , tedy hodnotu, která je zpracována formou aktivační (přenosové) funkce ϕ (somatická operace) typicky to může být sigmoidální funkce, skoková, hyperbolický tanget aj.




Fig. 2: matematický model biologického neuronu vytv. autor

neuronové modely jsou pak funkcí typu:

$$y = f_{(X, W)}, \quad (1)$$

kde X je vektor vstupů a W vektor neurálních vah. Více o jednotlivých jednotlivých neuronových jednotkách níže.

3.3.2 Základní neuronové architektury

Existuje velké množství neuronových architektur, a protože je to živé vědní odvětví, stále vznikají nové koncepce. Základní neuronové architektury podle [10],[11], [16] a [12], které budou využity v dalších částech práce jsou uvedeny v **Tab. 1** Jednotlivé neuronové modely jsou funkcemi podle (1), kde:

- X je vektorem vstupů
- W je vektorem neurálních vah (u **MLP** ve skryté vrstvě)
- V je vektorem vah výstupního neuronů **MLP** sítě
- $colX$ je vektorem vstupu neuronu vypočíný z vektoru vstupů X podle příslušné neuronové architektury
- y je výstupní veličinou neuronu, která podle aplikace a vrstvy sítě, může a nemusí být dále zpracována přenosovou funkcí

- ξ je vektorem potenciálu jednotlivých neuronů sítě **MLP**
 v je vektorem výstupů synaptických operací skrytých neuronů
 ϕ je přenosová funkce (somatická operace)
 \tilde{Y} je naučeným vektorem výstupu odpovídajícím jednotlivým naučeným vstupům **RBF** sítě
 \tilde{X} je naučeným vektorem vstupů odpovídajícím jednotlivým naučeným výstupům **RBF** sítě
 φ je euklidovskou vzdáleností naučených vstupů od vstupů vektoru X do **RBF** sítě
 β je šířka pásma aktivační funkce **RBF** sítě

Neuronová architektura	Funkce neuronového modelu $f_{(.)}$
Lineární neuronová jednotka LNU , Linear Neural Unit (1. řád HONU)	$y = W \cdot colX$ $colX = X$ (2)
Kvadratická neuronová jednotka QNU , Quadratic Neural Unit (2. řád HONU)	$y = W \cdot colX$ $colx_{ij} = x_i \cdot x_j$ (3) $i = 0..n, j = i..n$
Kubická neuronová jednotka CNU , Cubic Neural Unit (1. řád HONU)	$y = W \cdot colX$ $colx_{ijk} = x_i \cdot x_j \cdot x_k$ (4) $i = 0..n, j = i..n, k = j..n$
Neuronová architektura (Neuronová síť)	Funkce neuronové sítě $f_{(.)}$
Více vrstvá neuronová síť MLP/MLP-ELM , Multi Layer Perceptron- Extreme Learning Machine (1 skrytá vrstva)	$y = V \cdot \xi$ $\xi = \left[\begin{array}{c} 1 \\ \phi(W \cdot X) \end{array} \right]$ (5) $\phi(v) = 1 - \frac{2}{1 + e^v}$
Síť s radiálně bázovou funkcí RBF (Radial Basis Function)	$y = \frac{\sum w_i \cdot \tilde{y}_i}{\sum w_i}$ (6) $w_i = e^{-\varphi/\beta}$ $\varphi = \sqrt{\sum (\tilde{x}_i - x)^2}$

Tab. 1: Matematické detaily základních neuronových architektur [12]

3.3.3 Učení (trénování)

Pro účely této práce jsou použity neuronové sítě s učitelem, kde pro učení ANN potřebujeme vstupy (patterns) a jim odpovídající výstupy (targets). Naučené znalosti jsou ukládány především prostřednictvím síly vazby mezi jednotlivými neurony. Spojení dávající správné výstupy jsou posilovány, naopak spojení dávající špatné výstupy jsou oslabovány. Právě učení ANN je základní rozdíl, který ANN odlišuje od klasických algoritmů. Běžně se snažíme algoritmovat problém, který transformuje vstupy na výstupy. Neuronové sítě pak toto dokáží svépomocí podle předložených příkladů popisujících řešený problém.

Dnes nejrozšířenější metodou učení je Backpropagation. Tedy zpětné šíření chyby. Tato metoda sleduje chybu e na výstupu sítě. Rozdíl mezi výstupem y sítě a skutečnou hodnotou přiřazenou vstupům \tilde{y} podle

$$e = y - \tilde{y} \quad (7)$$

a podle ní přispůsobuje váhy v nižších vrstvách. Tato metoda vyžaduje, aby aktivační funkce neuronů byla diferencovatelná. Jako optimalizační algoritmus se pak nejčastěji používá Gradient Descent (gradient klesání) (8) (9), nebo také metoda nejmenších čtverců – např. Levenberg-Marquardt (tlumená metoda nejmenších čtverců) (11) (12) (13) více viz. Tab. 2, zde je rozepsán postup výpočtu změny vah pro jednotlivé neuronové architektury kde:

- μ je rychlostí učení (zapomínání)
- V je vektorem vah výstupního neuronu MLP sítě
- J je Jakobiho maticí pro vektor vah W nebo V
- I je jednotkovou maticí

			Neuronová architektura			
			LNU	QNU	CNU	MLP (1 skrýtá vrstva)
Učení	Postupné	Gradient Descent	$\Delta W = \mu \cdot e \cdot \text{col}X^T \quad (8)$		$\Delta V = \mu_v \cdot e \cdot \frac{\partial y}{\partial V} \quad (9)$ $\Delta W = \mu_w \cdot e \cdot \frac{\partial y}{\partial W}$	$\Delta V = \mu_v \cdot e \cdot \frac{\partial y}{\partial V} \quad (10)$
	Dávkové	Levenberg-Marquardt	$\Delta W = (J^T \cdot J + \frac{1}{\mu} \cdot I)^{-1} \cdot J^T \cdot e \quad (11)$			
			$J_w = \text{col}X^T \quad (12)$	$J_w = \frac{\partial y}{\partial W} \quad (13)$ $J_v = \frac{\partial y}{\partial V}$	$J_v = \frac{\partial y}{\partial V} \quad (14)$	

Tab. 2: Základní učící algoritmy neuronových architektur [12]

U nejjednodušší **RBF** sítě je naučení dáno výchozí konfigurací sítě. Tedy váhy neuronů skryté (tj. **RBF**) vrstvy \tilde{X} jsou řádky matice trénovacích dat X . Pak každá dvojice (řádek) \tilde{X} , \tilde{Y} představuje jeden **RBF** neuron.

3.3.1 Testování

Každou naučenou neuronovou síť je potřeba otestovat na ne-trénovacích datech, aby byla otestována schopnost generalizace. V praxi se toto provádí rozdělením dat až na 3 množiny. Tedy na trénovací data na kterých síť v epochách naučíme požadované vzory, na validační na kterých sledujeme schopnost neuronové sítě naučené vztahy aplikovat, na testovací ke kterým přistupujeme až v poslední fázi, kdy jsme s výsledky na validačních datech spokojeni a chceme jen potvrdit výkonnost neuronového modelu z validačních dat.

3.4 Neuronové sítě pro finanční časové řady

Zahng Yudong a Wu Lenan ve své práci [17] prezentují neuronovou síť využívající IBCO optimalizaci a BP pro predikci burzovního indexu S&P 500. Srovnávají výkonnost klasické sítě učené pomocí BP a sítě učené pomocí IBCO-BP. Ač IBCO-BP dosahuje zřetelně lepší výkonnosti oproti klasické BP ani tak

nedosahuje uspokojivých výsledků. Své poznatky zde nekonfrontují s žádnou investiční strategií, takže chybí srovnání.

Joarder Kamrwzaman a Ruhul A Sarkeg ve své práci [18] srovnávají běžně používaný ekonomický ARIMA model s **MLP** sítí učenou podle 3 různých algoritmů. Modely testují na 6 měnových párech pro týdenní data. Výsledky ukazují, že **MLP** síť s jakýmkoliv učícím algoritmem předčí ARIMA model. Na Fig. 3 je vidět výsledek jedné z publikovaných predikcí pro SGD/AUD. Výsledky nejsou dále rozvedeny v investiční strategii, není tedy možné srovnání.




Fig. 3: Průběh predikce a skutečné ceny z práce [18] - predikována je závěrečná cena SGD/AUD v období 65 týdnů (str. 6)

Woon-Seng Gan a Kah-Hwa Ng v [19] používají **MLP** síť ve dvou konfiguracích pro predikci 3 měnových párů za období 1 roku. Své výsledky hodnotí pouze pomocí RMSE proti jednotlivým konfiguracím. Žádná investiční strategie zde není opět uvedena.

Kyoung-jae Kim a Ingo Han ve své publikaci [20] predikují Korejský index KOSPI v období 10 let. Využívají k tomu **MLP** síť a pro ladění vah a diskretizaci vstupních komponent (jejich prahu) využívají genetického algoritmu. Vstupem jsou zde indikátory technické analýzy. Jejich síť poté srovnávají s **MLP** sítí trénovanou pomocí BP a **MLP** sítí trénovanou pomocí genetického algoritmu (váhy). Jejich řešení dosahuje v průměru o 10% lepší úspěšnost v predikci oproti výše uvedeným strukturám. Není zde navrženo a poté provedeno žádné srovnání s konvenčními investičními strategiemi.

V [21] je využíváno k predikci Tokijského burzovního indexu TOPIX (Tokyo Stock Exchange Prices Index) modulární ANN složenou z modulů pro historická data, technické indikátory a ekonomické indikátory. ANN predikovala pouze kdy koupit a kdy prodat na základě týdenní návratnosti. Pro učení byl použit upravený algoritmus BP. Pro období 33 měsíců dosáhla oproti strategii buy & hold o 31% lepšího teoretického výsledku. V daném období byl poměrně silný up-trend. Je otázkou, jak by vypadaly výsledky pro delší období napříč různými finančními instrumenty.

Yoon a Swales v [22] využívají **MLP** síť ke klasifikaci burzovních titulů na základě fundamentálních dat. Svě výsledky srovnávají s MDA a dosahují o 12,5% lepších výsledků.

V práci [24] Yao a Lim Tana je k predikci 6 měnových párů za období 1984 – 1995 (trénování, validace, testování) užitá **MLP** síť ve dvou variantách. V první jsou na vstupu pouze pár posledních vzorků dat. Ve druhé variantě jsou na vstupu klouzavé průměry. Varianta s klouzavými průměry přitom vykazuje lepší výsledky. Jsou zde uvedeny dvě investiční strategie, které jsou poté srovnány pro jednotlivé měnové páry s ARIMA modely. V závěru práce je provedeno podrobnější testování pro CHF/USD. V průměru je teoreticky dosaženo až 28% ročního výnosu v nejvýkonnější variantě investiční strategie v porovnání s buy & hold (9.98% roční výnos) a trend-following (1.81% roční výnos) strategiemi.




Fig. 4: **MLP** síť s vstupními daty v podobě klouzavých průměrů [24]
(str. 91)

V článku [25] Kablan představuje komplexní Neuro-Fuzzy inferenční systém využívající sezónnost pro obchodování EUR/USD měnového páru v období

04/2006 až 09/2007. Systém je učen algoritmem Steepest Descent a metodou nejmenších čtverců. Vstupem jsou pouze historická data. Pro samotný Neuro-Fuzzy systém dosahuje teoretického výnosu 31% s využitím sezónnosti 39%. Otázkou zde zůstává rozdělení jejich dat na trénovací a testovací. Trénování i testování (výsledky) je zde prezentováno na totožných datech.

V článku [26] je využívána **MLP** síť pro predikci dvou burzovních titulů na BM&F BOVESPA, což je Brazilská burza. Na vstupu ANN jsou technické indikátory. Síť predikuje denní low a high cenu v klouzavém okně. Podle toho je také uzpůsobena strategie, která každých 15 minut porovnává aktuální cenu s predikovanou low-high cenou a podle toho exekvuje příkazy. V hodnocení výsledků je přihlédnuto ke skluzu ceny, transakčním poplatkům a nutnosti obchodovat celé loty, což u všech výše uvedených chybí. Teoretický roční výnos dosahuje podle konfigurace sítě a titulu od 23% do 432%.




Fig. 5: Predikce a skutečná data pro filtrovaná data v práci [27] (str. 29)

Cain Evans, Konstantinos Pappas a Fatos Xhfab ve svém článku [27] představují ANN pro intra-denní obchodování 3 měnových párů GBP/USD, EUR/BGP a EUR/USD na FOREXu. Experimentální data za období 10/2010 až 2/2012 jsou převedena na logaritmickou návratnost a dále z nich vypočítán klouzavý průměr. ANN je tvořena **MLP** sítí, jejíž topologie je optimalizována pomocí GA. Jako učící algoritmus je použit BP v kombinaci s LM. Ve své práci dosahují teoretického ročního výnosu 27.8%.

Podle jedné z nejaktuálnějších prací [28], kde je pro predikci použita **MLP** síť učená pomocí BP v kombinaci s GD. Predikuje se zde pohyb HSBC Holdings¹² plc. za období 1/2004 až 12/2005. Ačkoli dosahuje jejich síť úspěšnosti predikce přes 74%, po testování jejich investiční strategie zohledňující transakční poplatky, končí jejich investování v červených číslech. V závěru se autoři zmiňují, že i kdyby jejich ANN predikovala se 100% úspěšností, skončili by kvůli transakčním poplatkům, které jsou u obchodování akcii vysoké, v červených číslech.

Článků na toto téma existuje velké množství. Výše je jen výběr několika z nich. Je patrné, že s využitím ANN pro obchodování finančních instrumentů je dosahováno rozporupných výsledků. Na jedné straně [26] závratných zisků, na straně druhé [28] i přes velice vysoké procento úspěšnosti ztrát. Zde je několik poznatků vyvozených z výše uvedených prací:

- většina prací se zabývá buď obchodováním akcii, nebo měnových párů
- většina prací navrhuje swingovou¹³ investiční strategii
- všechny práce byly testovány pouze pomocí backtestingu
- metriky založené na chybě jsou přijatelné pro měření výkonu, ale hlavním cílem jakéhokoliv predikčního systému je spolu s vhodnou investiční strategií generovat zisk, a podle toho musí být uzpůsobena i metrika

3.5 Analýza závislostí ve finančních časových řadách

Jak bylo vysvětleno v úvodu, tato práce se zaměřuje na analýzu a krátkodobou autonomní predikci jednotlivých časových řad, proto jsou zde korelační koeficient, autokorelace a výpočet vzájemné informace zmíněny jen pro úplnost.

3.5.1 Pearsonovův korelační koeficient

Z literatury [32], [33], [34] a z provedených experimentů s korelačním koeficientem vyplývá jeho značná časová proměnlivost. V současnosti se využívá především pro diverzifikaci portfolia. Jeho využití v technické analýze jako takové se nevyskytuje. Vzhledem ke své časové proměnlivosti jeho korektní problém přesahuje rozsah této práce.

¹² akcie kótovaná na Hong Kongské burze HKEx (Hong Kong Stock Exchange)

¹³ obchodní styl snažící se využít zisků z pohybů v rozsahu několika dní

Pearsonův korelační koeficient, který nám říká zda a jak moc jsou průběhy dvou veličin lineárně závislé je definovaný jako [29]:

$$r(X, Y) = \frac{1}{N} \sum_k \frac{(Y_k - \bar{Y})(X_k - \bar{X})}{\sigma_X \sigma_Y}, \quad (15)$$

kde:

- X, Y jsou průběhy veličin
- lag je posunutí
- \bar{Y}, \bar{X} je střední hodnota veličin Y, X
- σ je směrodatná odchylka

Pro ilustraci je na Fig. 6 ukázán průběh Pearsonova korelačního koeficientu pro páry GBP/USD a EUR/USD, jak se mění v čase. Kdy:

- ΔdT je délka okna
- Δt je vzorkování
- lag časové posunutí mezi průběhy dvou veličin




Fig. 6: Korelační koeficient plovoucího okna mezi veličinami GBP/USD a EUR/USD - z obrázku je patrné, že hodnota korelačního koeficientu se v čase mění, $dT=6hod$, $dt=15min$, $lag=0$

3.5.2 Autokorelační funkce

Autokorelační funkce ukazuje lineární závislost dvou intervalů v průběhu jedné veličiny. Tyto dva intervaly jsou vzájemně posunuté v čase (lag).

$$r(lag) = \frac{1}{N} \sum_k^N \frac{(Y_{k+lag} - \bar{Y})(Y_k - \bar{Y})}{\sigma_Y^2}, \quad (16)$$

kde:

Y	je průběh veličiny
lag	je posunutí
\bar{Y}	je střední hodnota veličiny Y
σ	je směrodatná odchylka

V dostupné literatuře se využití autokorelační funkce pro krátkodobé obchodování, a tedy i pro algo-trading, nenachází.

3.5.3 Vzájemná informace (Mutual Information)

Vzájemná informace [35] ukazuje nelineární závislost dvou veličin (nebo dvou průběhů časově posunutých v rámci jedné veličiny), nebo i celých stavů (vektorů).

$$I(X, Y) = \sum_{i,j} P_{X,Y} \log_a \frac{P_{X,Y}(i,j)}{P_X(i)P_Y(j)}, \quad (17)$$

kde:

$p_{X,Y}(i,j)$	je sdružená distribuční funkce X a Y
$p_X(i)$	je marginální distribuční funkce X
$p_Y(j)$	je marginální distribuční funkce Y
X, Y	jsou průběhy veličin

V dostupné literatuře využití vzájemné informace pro krátkodobé obchodování, a tedy i pro algo-trading, nebylo nalezeno.

4 EXPERIMENTÁLNÍ STUDIE

NEURONOVÝCH MODELŮ PRO

PREDIKCI FINANČNÍCH ČASOVÝCH

ŘAD

V této kapitole je provedena originální studie funkčnosti různých typů neuronových modelů (popsaných v kapitole 3.3) pro krátkodobou autonomní predikci finančních časových řad. Nejlépe fungující model je pak využit v návrhu metody a strategie monitorování trendu v kapitole 5.

Na poli využití ANN pro obchodování finančních instrumentů bylo provedené množství výzkumů s více či méně uspokojivými výsledky. Často chybí jakékoliv vyhodnocení z hlediska finančního využití nebo délka vyhodnocovaných dat nebývá dostatečně reprezentativní. I přesto však poskytují cenné informace. Pro zhodnocení závislostí dat a také vyhodnocení výkonnosti neuronových architektur bude v této kapitole otestováno 5 neuronových modelů, které budou porovnány jak z hlediska přesnosti predikce, tak využitelnosti pro algo-trading.

V přehledu literatury v kapitole 3.4 je téměř výhradně zastoupeno pouze využití **MLP** sítě v různých konfiguracích a nikde není uvedeno srovnání s ostatními neuronovými modely. Pro zvolení vhodné neuronové architektury je proto nezbytné mít srovnání jejich výkonnosti.

Neuronové modely byly naprogramovány jak v prostředí MATLAB, tak i v open-source programovacím jazyce Python. Nakonec bylo pro realizaci vybráno prostředí MATLAB, který díky své knihovně Trading Toolbox umožňuje do budoucna implementovat snáze řešení pro paper trading. Trading Toolbox obsahuje API pro komunikaci s některými brokery. Zdrojové kódy pro MATLAB i Python jsou přílohou.

4.1 Popis Experimentu

Funkčnost naprogramovaných neuronových modelů bude nejdříve ověřena na umělých datech rozdělených na učící/validační/testovací v poměru 70/15/15. Tato série čítá celkem 100 000 vzorků.

První umělá data budou generována podle lineární funkce:

$$y_k = 4 \cdot x_k + 0,25 \quad , \quad (18)$$

kde:

x jsou náhodná čísla z intervalu $(0,1)$

Zde bude ověřena základní funkčnost všech neuronových modelů při vstupu neuronového modelu x_k a výstupu (target) y_k . Předpokládá se, že všechny neuronové modely obstojí.

Poté bude ověřeno, že neuronový model nedokáže predikovat náhodná data. Tedy na vstupu neuronového modelu bude x_k a na výstupu (target) y_{k+1} . Toto má odhalit možnou chybu v naprogramování neuronového modelu.

Dále budou neurony otestovány na datech generovaných Logistickou funkcí podle:

$$y_{k+1} = 4 \cdot y_k \cdot (1 - y_k) \quad , \quad (19)$$

kde:

y_k je vypočtená hodnota z předchozího kroku

$y_{k=0}$ je zvoleno 0.1

Neuronové modely budou mít na vstupu y_t a na výstupu (target) y_{t+1} . Zde už není funkce lineární a je otázkou, jak se budou jednotlivé neuronové modely chovat.

Pro samotný experiment byla použita FOREXová data. Konkrétně 8 měnových páru za období leden 2012 až leden 2016 v 15 minutových sloupcích. Dostupné 1 minutové sloupce nebyly použity z důvodu náročnosti na výpočetní výkon. Data jsou rozdělena na učící/validační/testovací v poměru 70/15/15. Páry USD/JPY a XAU/USD, jejichž kurz je kótovaný v řádech 10^2 a 10^3 , byly poděleny 10^2 a 10^3 , aby byla zajištěna stabilita neuronových modelů. Pro

jednotlivé neuronové architektury je použit jako učící algoritmus LM v upravené formě pro možnost kontinuálního učení. V každém novém bodě je síť přetrénována oknem předcházejících dat o délce I_{window} . Síť je tedy v každém novém bodě trénována v plovoucím okně, aby byly nejaktuálnější data, a tedy i nejnovější dynamika co nejlépe aktuálnímu okamžiku predikce.

Jako metrika výkonnosti neuronové sítě jak pro umělá data, tak pro historická je použita fit funkce využívající normalizovanou průměrnou kvadratickou chybu [30] vypočítaná podle :

$$NMSE = 1 - \left\| \frac{close_{actual} - close_{predicted}}{close_{actual} - \text{mean}(close_{actual})} \right\|^2, \quad (20)$$

kde:

$\|$ je norma vektoru

Dále bude každá neuronová síť pro reálná historická data otestována velice jednoduchou investiční strategií pro vyhodnocení schopnosti předpovídat krátkodobý trend, a to

$$\text{pokud } close_{t+1} > close_t \text{ pak nakup jinak prodej.} \quad (21)$$

Často (např.: v [27], [25], [24]) je tato metoda naprosto vytržena z kontextu reálného světa. Aby mohly být dělány závěry o predikci trendu a o využití této predikce je potřeba do simulace zahrnout alespoň poplatky za exekuci.

Proto v této studii, v případě že přijde signál k nákupu nebo prodeji, je zobchodován za cenu $open_{t+1}$ pro simulaci skluzu. Pro účely backtestingu je někdy poplatek počítán až na konci podle četnosti obchodů. To však vnáší do testování soustavnou chybu, jelikož je během backtestingu obchodováno s vyšším kapitálem než ve skutečnosti v danou chvíli je. V této studii je za každou exekuci tedy počítán poplatek vycházející z ceníku Interactive Brokers [31]. Výše poplatku je 0.002 % z hodnoty obchodu, minimálně však \$2 pro velikost obchodu < \$100 000, tedy \$4 za dvojicí příkazů nákup-prodej.

Jako metrika bude použita dopočítaná roční míra návratnosti (AR, Annualized Return) vypočítaná podle:

$$R_c = \frac{V_f - V_i}{V_i}, \quad (22)$$

kde:

V_f je hodnota investice na konci pozorovaného období
 V_i je počáteční hodnota investice

$$R_a = (1 + R_c)^{(365/n)} - 1 \quad , \quad (23)$$

kde:

R_c je míra návratnosti za sledované období (22)
 n je délka sledovaného období

Možnou chybou, která je do testování vnášena je opožděná exekuce příkazů. Jelikož sloupce jsou délky 15 minut, k exekuci příkazů může docházet se zpožděním až 15 minut od skutečného signálu ke vstupu/výstupu. Na jednu stranu nás může toto zpoždění ochránit od ztrátových obchodů, na druhou stranu dochází k opožděnému vstupování a vystupování z pozic. Především v prudkých změnách trendu to může hrát významnou roli.

Strategie má ověřit pouze schopnost predikce a pro jednodušší srovnávání je zanedbán money-management (SL, PT, RRR a PS). Jako srovnání poslouží strategie *buy & hold*, která spočívá v nakoupení na začátku a prodeji na konci srovnávaného úseku.

4.2 LNU

První testovaný neuron je nejjednodušší neuronová jednotka, tedy lineární neuron vypočítaný podle (1), (11) a (12).

4.2.1 Ověření funkčnosti neuronového modelu

Naprogramovaný neuronový model byl otestován na naučení se lineární funkce podle (18), dále na predikci náhodných čísel (zde je očekáváno selhání) a nakonec pro predikci Logistické funkce (19). Testování bylo provedeno podle metody uvedené v kapitole 4.1 a bylo dosaženo výsledků shrnutých v Tab. 3

Umělá data	Lineární (18)	Náhodná	Logistická funkce (19)
NMSE	1	-1,8863e+07	-0.0077

Tab. 3: Tabulka výsledků pro testování **LNU** neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných Logistickou funkcí (19)

Jak je vidět z tabulky, **LNU** model neměl problém naučit se během 100 000 vzorků lineární funkci (18) a nedokázal predikovat náhodná data, čímž byla ověřena jeho funkčnost. Logistickou funkci není lineární model kvůli nelineární dynamice schopen predikovat.

Pro ilustraci průběhu predikce Logistické funkce je připojen obrázek Fig. 7.

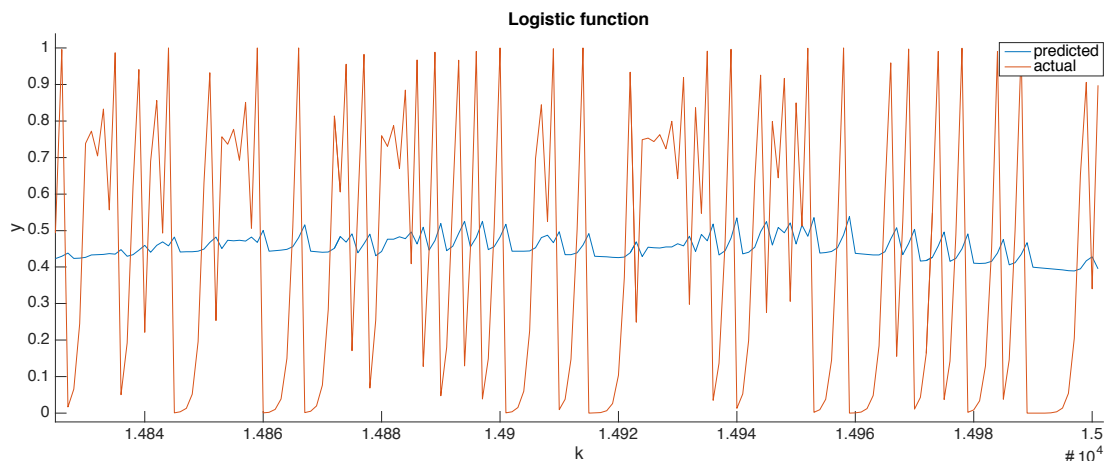


Fig. 7: Průběh predikce Logistické funkce (19) jednotkou **LNU** (1),(11) a (12) – lineární model není schopen predikovat nelineární dynamiku

4.2.2 Experiment

Vstupem neuronu jsou zavírací ceny 5 vzorků zpět, tedy $close_t \dots close_{t-4}$. Výstupem neuronu, na který je učen, je zavírací cena 1 vzorek dopředu, tedy $close_{t+1}$.

Přeučení probíhá vždy po výpočtu nové hodnoty $close_{t+1}$ pomocí okna o délce 5 posledních vzorků, tedy $close_t \dots close_{t-4}$. Váhy W jsou iniciovány náhodně v intervalu $(0,1)$ podle rovnoměrného rozdělení a dále poděleny počtem vah. Pro úplnost zde jsou zvolené parametry **LNU** jednotky:

$\mu=0.01$

rychlost učení

$l_{window}=5$	délka plovoucího okna
$X = close_t \dots close_{t-4}$	vstupní vektor
$W = w_1 \dots w_n$	matice vah
$w_i = (0,1)/n$	i-tá váha matice vah

V Tab. 4 je srovnání výkonnosti **LNU** pro jednotlivé měnové páry. Celkově dopadá investování podle predikční strategie o něco hůře jako u strategie buy & hold.

Měnový pár	NMSE (20)	AR (23) za 159 dní	
		Strategie (21)	Buy & hold
AUD/USD	0,997	-23,27%	-18,86%
EUR/USD	0,996	-6,97%	-0,92%
GBP/USD	0,977	-20,88%	-17,21%
NZD/USD	0,996	26,81%	-9,16%
USD/CAD	0,995	-1,83%	32,12%
USD/CHF	0,989	12,10%	13,82%
USD/JPY	0,946	-13,45%	-12,18%
XAU/USD	0,933	-22,48%	-2,51%
Průměr	0,979	-6,25%	-1,86%

Tab. 4: Tabulka výkonnosti **LNU** neuronového modelu pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce **LNU** hůře jak u srovnávací strategie buy & hold

Pro ilustraci průběhu predikce a backtestingu jsou připojeny obrázky Fig. 8, Fig. 9 a Fig. 10 pro měnový pár GBP/USD. Měnový pár GBP/USD byl vybrán, jelikož jeho NMSE se nejvíce blíží průměrnému NMSE.




Fig. 8: Výřez z průběhu skutečné a predikované ceny podle **LNU** neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)




Fig. 9: Výřez z průběhu nákupů a prodejů podle predikce pomocí **LNU** neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej)




Fig. 10: Průběh stavu účtu během backtestingu pro predikci podle LNU neuronového modelu

4.3 QNU

Druhý testovaný neuron je neuronová jednotka využívající kvadratický vstupní vektor, tedy kvadratická neuronová jednotka **QNU** vypočítaná podle (2), (11) a (12).

4.3.1 Ověření funkčnosti neuronového modelu

Nejprve byl naprogramovaný neuronový model otestován na naučení se lineární funkce podle (18), dále na predikci náhodných čísel (zde je očekáváno selhání) a nakonec pro predikci Logistické funkce (19). Testování bylo provedeno podle metody uvedené v kapitole 4.1 a bylo dosaženo výsledků shrnutých v Tab. 5

Umělá data	Lineární (18)	Náhodná	Logistická funkce (19)
NMSE	1,000	-4,0278e+82	1,000

Tab. 5: Tabulka výsledků pro testování **QNU** neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných logistickou funkcí (19)

Jak je vidět z tabulky, **QNU** model neměl problém naučit se během 100 000 vzorků lineární funkci (18) a nedokázal predikovat náhodná data, čímž byla ověřena jeho funkčnost. Logistickou funkci byl kvadratický model schopen predikovat bez problému.

Pro ilustraci průběhu predikce logistické funkce je připojen obrázek Fig. 11.




Fig. 11: Průběh predikce logistické funkce (19) jednotkou **QNU** – kvadratický model je schopen predikovat nelineární dynamiku (červená predikovaná a modrá skutečná se překrývají)

4.3.2 Experiment

Vstupem neuronu jsou historické zavírací ceny 3 vzorky zpět, tedy $close_t \dots close_{t-2}$. Výstupem neuronu je zavírací cena 1 vzorek dopředu, tedy $close_{t+1}$.

Přeučení probíhá vždy po výpočtu nové hodnoty $close_{t+1}$, na kterou je neuron učen pomocí okna o délce 3 posledních vzorků, tedy $close_t \dots close_{t-2}$.

Váhy W jsou iniciovány náhodně v intervalu $(0,1)$ podle rovnoměrného rozdělení a dále poděleny počtem vah. Zde je soupis zvolených paramterů **QNU** jednotky:

$\mu=0.001$	rychlost učení
$l_{window}=3$	délka plovoucího okna
$X=close_t \dots close_{t-2}$	vstupní vektor
$W=w_1 \dots w_n$	matice vah
$w_i=(0,1)/n$	i-tá váha matice vah

V Tab. 6 je srovnání výkonnosti **QNU** pro jednotlivé měnové páry. Celkově dopadá investování podle predikční strategie hůře než u strategie buy & hold. NMSE i investování podle zvolené strategie je oproti **LNU** horší. **QNU** neuron je mnohem citlivější a během testování byl i problematický z hlediska stability.

Měnový pár	$NMSE$ (20)	AR (23) za 159 dní	
		Strategie (21)	Buy & hold
AUD/USD	0,998	-16,0%	-18,9%
EUR/USD	0,997	-4,8%	-0,9%
GBP/USD	0,941	-32,8%	-17,2%
NZD/USD	0,970	2,1%	-9,2%
USD/CAD	0,972	-9,6%	32,1%
USD/CHF	0,692	-14,1%	13,8%
USD/JPY	0,965	-0,5%	-12,2%
XAU/USD	0,953	-11,1%	-2,5%
Průměr	0,936	-10,8%	-1,9%

Tab. 6: Tabulka výkonnosti QNU neuronového modelu pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce QNU hůře jak u srovnávací strategie buy & hold

Pro ilustraci průběhu predikce a backtestingu jsou připojeny obrázky Fig. 12, Fig. 13 a Fig. 14 pro měnový pár GBP/USD. Měnový pár GBP/USD byl vybrán, jelikož jeho $NMSE$ se nejvíce blíží průměru.




Fig. 12: Výřez z průběhu skutečné a predikované ceny podle QNU neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)




Fig. 13: Výřez z průběhu nákupů a prodejů podle predikce pomocí QNU neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej)




Fig. 14: Průběh stavu účtu během backtestingu pro predikci podle *QNU* neuronového modelu

4.4 MLP

Dalším testovaným modelem je **MLP** síť s 10 neurony ve skryté vrstvě. Vypočítaná je podle (5), (11) a (13) .

4.4.1 Ověření funkčnosti neuronového modelu

Nejprve byl naprogramovaný neuronový model otestován na naučení se lineární funkce podle (18), dále na predikci náhodných čísel (zde je očekáváno selhání) a nakonec pro predikci Logistické funkce (19). Testování bylo provedeno podle metody uvedené v kapitole 4.1 a bylo dosaženo výsledků shrnutých v Tab. 7

Umělá data	Lineární (18)	Náhodná	Logistická funkce (19)
NMSE	0,994	NaN	0,947

Tab. 7: Tabulka výsledků pro testování **MLP** neuronového modelu na umělý data generovaná lineární funkcí (18), náhodných datech a logistickou funkcí (19)

Jak je vidět z tabulky, **MLP** model neměl problém naučit se během 100 000 vzorků lineární funkci (18) a nedokázal predikovat náhodná data, čímž byla ověřena jeho funkčnost. Při predikci neuronový model dokonce selhal. Logistickou funkcí byl **MLP** model schopen predikovat s NMSE 0,95.

Pro ilustraci průběhu predikce logistické funkce je připojen obrázek Fig. 15.




Fig. 15: Průběh predikce logistické funkce (19) **MLP** neuronovým modelem – **MLP** model je schopen predikovat nelineární dynamiku s NMSE 0,94 (červená - predikovaná, modrá - skutečná)

4.4.2 Experiment

Vstupem **MLP** neuronového modelu jsou historické zavírací ceny 5 vzorků zpět, tedy $close_t \dots close_{t-4}$. Výstupem sítě je zavírací cena 1 vzorek dopředu, tedy $close_{t+1}$.

Přeučení probíhá vždy po výpočtu nové hodnoty $close_{t+1}$, na kterou je neuron učen pomocí okna o délce 5 posledních vzorků, tedy $close_t \dots close_{t-4}$.

Váhy W u každého neuronu skryté vrstvy jsou iniciovány náhodně v intervalu (0,1) podle rovnoměrného rozdělení a dále poděleny počtem vah. Váhy V výstupního neuronu jsou iniciovány náhodně v intervalu (0,1) podle rovnoměrného rozdělení a dále poděleny počtem vah.

Zde jsou všechny zvolené parametry **MLP** sítě:

$\mu_w = 0.05$	rychlost učení neuronů ve skryté vrstvě
$\mu_v = 0.01$	rychlost učení výstupního neuronu
$l_{window} = 5$	délka plovoucího okna
$X = close_t \dots close_{t-4}$	vstupní vektor
$j = 10$	počet neuronů ve skryté vrstvě
$W = W_1 \dots W_j$	matice matic vah neuronů ve skryté vrstvě
$W_i = w_{i1} \dots w_{in}$	matice vah i-tého neuronu ve skryté vrstvě
$w_{ik} = (0,1)/n$	i-tá váha k-tého neuronu ve skryté vrstvě
$V = v_1 \dots v_j$	matice vah výstupního neuronu
$v_j = (0,1)/n$	j-tá váha matice vah výstupního neuronu

V Tab. 8 je srovnání výkonnosti **MLP** sítě pro jednotlivé měnové páry. Celkově dopadá investování podle predikční strategie lépe než u strategie buy & hold. Investování podle strategie (21) je také oproti **LNU** a **QNU** lepší. NMSE je oproti **QNU** lepší, avšak oproti **LNU** horší.

Měnový pár	NMSE (20)	AR (23) za 159 dní	
		Strategie (21)	Buy & hold
AUD/USD	0,993	3,48%	-18,86%
EUR/USD	0,984	-8,51%	-0,92%
GBP/USD	0,932	2,54%	-17,21%
NZD/USD	0,983	-0,23%	-9,16%
USD/CAD	0,991	16,30%	32,12%
USD/CHF	0,914	27,60%	13,82%
USD/JPY	0,998	-15,14%	-12,18%
XAU/USD	0,994	4,18%	-2,51%
Průměr	0,974	3,78%	-1,86%

*Tab. 8: Tabulka výkonnosti **MLP** sítě pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce **MLP** sítě lépe jak u srovnávací strategie buy & hold*

Pro ilustraci průběhu predikce a backtestingu jsou připojeny obrázky Fig. 16, Fig. 17 a Fig. 18 pro měnový pár NZD/USD. Měnový pár NZD/USD byl vybrán, jelikož jeho NMSE se nejvíce blíží průměru.

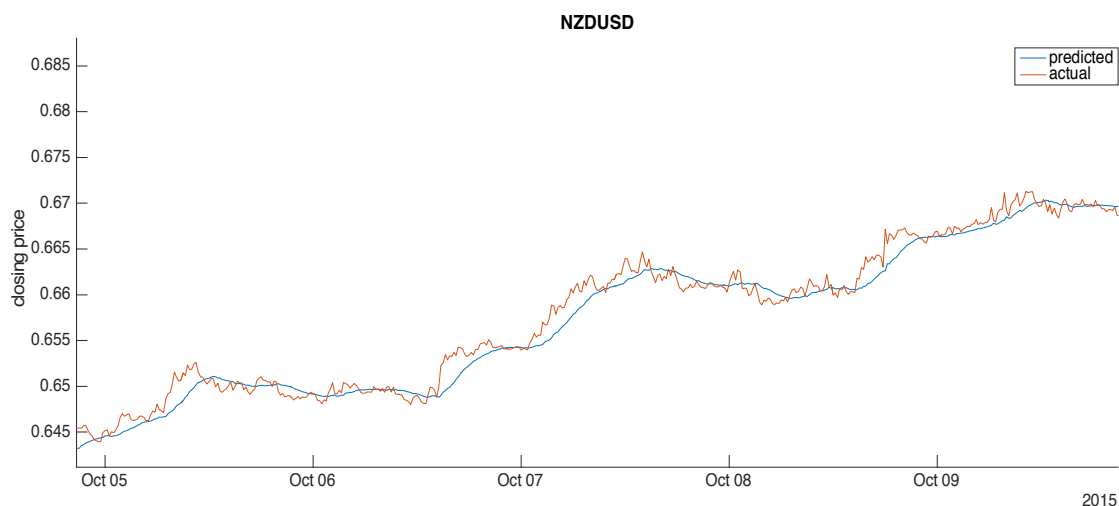


Fig. 16: Výřez z průběhu skutečné a predikované ceny podle **MLP** neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)




Fig. 17: Výřez z průběhu nákupů a prodejů podle predikce pomocí **MLP** neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej)




Fig. 18: Průběh stavu účtu během backtestingu pro predikci podle *MLP* neuronového modelu

4.5 RBF

Další testovanou sítí je **RBF** sít podle (6).

4.5.1 Ověření funkčnosti neuronového modelu

Jako první byl naprogramovaný neuronový model otestován na naučení se lineární funkce podle (18), dále na predikci náhodných čísel (zde je očekáváno selhání) a nakonec pro predikci Logistické funkce (19). Testování bylo provedeno podle metody uvedené v kapitole 4.1 a bylo dosaženo výsledků shrnutých v Tab. 9

Umělá data	Lineární (18)	Náhodná	Logistická funkce (19)
NMSE	1	-0,941	0,999

Tab. 9: Tabulka výsledků pro testování **RBF** neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných Logistickou funkcí (19)

Jak je vidět z tabulky, **RBF** model neměl problém naučit se během 100 000 vzorků lineární funkci (18) a nedokázal predikovat náhodná data, čímž byla ověřena jeho funkčnost. Logistickou funkci byl **RBF** model schopen predikovat s NMSE 0,999.

Pro ilustraci průběhu predikce logistické funkce je připojen obrázek Fig. 19.




Fig. 19: Průběh predikce logistické funkce (19) **RBF** neuronovým modelem – **RBF** model je schopen predikovat nelineární dynamiku s NMSE 0,999 (červená – predikovaná a modrá - skutečná se téměř překrývají)

4.5.2 Experiment

Vstupem sítě jsou zavírací ceny 3 vzorky zpět, tedy $close_t \dots close_{t-2}$. Výstupem sítě je zavírací cena 1 vzorek dopředu, tedy $close_{t+1}$, na kterou je síť učena.

Skrytá vrstva obsahuje 10 neuronů, které se obnovují vždy po výpočtu nové hodnoty $close_{t+1}$. V každém kroku je tedy přidán jeden nový neuron ve skryté vrstvě a odebrán nejstarší neuron skryté vrstvy. Nejdůležitější parametry jsou shrnuty následovně:

$\beta = 0.001$	šířka pásma
$l_{window} = 10$	počet neuronů v zásobníku
$X = close_t \dots close_{t-2}$	vstupní vektor

V Tab. 10 je srovnání výkonnosti **RBF** sítě pro jednotlivé měnové páry. Investování dopadá podle predikční strategie lépe než u strategie buy & hold. Investování podle strategie (21) i NMSE dopadá oproti všem předcházejícím neuronovým modelům lépe.

Měnový pár	$NMSE$ (20)	AR (23) za 159 dní	
		Strategie (21)	Buy & hold
AUD/USD	0,998	1,6%	-18,9%
EUR/USD	0,998	-0,7%	-0,9%
GBP/USD	0,999	8,9%	-17,2%
NZD/USD	0,998	36,2%	-9,2%
USD/CAD	0,999	14,8%	32,1%
USD/CHF	0,999	32,7%	13,8%
USD/JPY	0,998	-16,8%	-12,2%
XAU/USD	0,999	10,1%	-2,5%
Průměr	0,999	10,9%	-1,9%

Tab. 10: Tabulka výkonnosti **RBF** sítě pro jednotlivé měnové páry během 159 dní – celkově dopadá investování podle predikce **RBF** sítě lépe jak u srovnávací strategie buy & hold

Pro ilustraci průběhu predikce a backtestingu jsou připojeny obrázky Fig. 20, Fig. 21 a Fig. 22 pro měnový pár USD/CHF. Měnový pár USD/CHF byl vybrán, jelikož jeho $NMSE$ se nejvíce blíží průměru (v tabulce jsou již zaokrouhlené hodnoty). Pro tuto neuronovou síť by byla potřeba clustering, nicméně měla být ověřena prostá predikce a clustering by byl nad rozsah práce. Na průběhu backtestingu (Fig. 21 a Fig. 22) je zajímavé, že neúspěšné obchody dosahují často velkých propadů, čemuž by bylo možné zamezit použitím stop-lossu. Velkou výhodou této sítě je také fakt, že díky své jednoduchosti a robustnosti je možné ji využívat bez zdlouhavého učení. K faktickému naučení dochází již po prvním naplnění skryté vrstvy. Tedy v našem případě po 10 vzorcích. Trénovací data byla v tomto případě tedy nadbytečná.




Fig. 20: Výřez z průběhu skutečné a predikované ceny podle **RBF** neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)




Fig. 21: Výřez z průběhu nákupů a prodejů podle predikce pomocí **RBF** neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej)

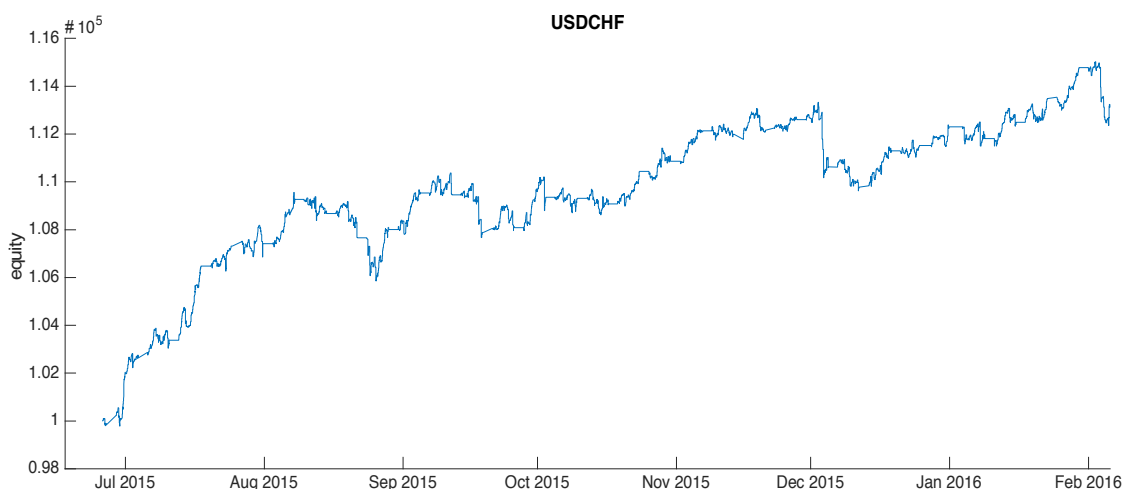


Fig. 22: Průběh stavu účtu během backtestingu pro predikci podle **RBF** neuronového modelu

4.6 MLP-ELM

Sít **MLP-ELM** vypočítaná je podle (5), (11) a (14). Je to variace **MLP** sítě. Její název **ELM** (Extreme Learning Machine) [16] vychází ze způsobu jejího učení, kdy váhy neuronů skryté vrstvy jsou iniciovány náhodně a již nejsou učeny.

4.6.1 Ověření funkčnosti neuronového modelu

Naprogramovaný neuronový model byl otestován na naučení se lineární funkce podle (18), dále na predikci náhodných čísel (zde je očekáváno selhání) a nakonec pro predikci logistické funkce (19). Testování bylo provedeno podle metody uvedené v kapitole 4.1 a bylo dosaženo výsledků shrnutých v Tab. 11


Umělá data	Lineární (18)	Náhodná	Logistická funkce (19)
NMSE	0,994	NaN	0,941

Tab. 11: Tabulka výsledků pro testování **MLP-ELM** neuronového modelu na umělých datech generovaných lineární funkcí (18), na náhodných datech a datech generovaných logistickou funkcí (19)

Jak je vidět z tabulky, **MLP-ELM** model neměl problém naučit se během 100 000 vzorků lineární funkci (18) a nedokázal predikovat náhodná data, čímž byla ověřena jeho funkčnost. Stejně jako **MLP** síť při predikci náhodných čísel

tento neuronový model selhal. Pro logistickou funkci dosahuje **MLP-ELM** podobný výsledek jako **MLP** neuronový model.

Pro ilustraci průběhu predikce logistické funkce je připojen obrázek Fig. 23.



*Fig. 23: Průběh predikce Logistické funkce (19) neuronovým modelem **MLP-ELM** – tento neuronový model je schopen predikovat nelineární dynamiku s NMSE 0,94 (červená predikovaná a modrá skutečná se překrývají)*

4.6.2 Experiment

Pro porovnání výkonosti s ostatními neuronovými modely bude tato síť vyzkoušena hned v několika konfiguracích lišících se podle počtu neuronů ve skryté vrstvě. Nejvýkonnější konfigurace bude poté rozepsána podrobněji pro jednotlivé měnové páry.

Vstupem sítě jsou zavírací ceny 5 vzorků zpět, tedy $close_t \dots close_{t-4}$. Výstupem sítě je zavírací cena 1 vzorek dopředu, tedy $close_{t+1}$.

Přeučení probíhá vždy po výpočtu nové hodnoty $close_{t+1}$, na kterou je neuron učen, pomocí okna o délce 5 posledních vzorků, tedy $close_t \dots close_{t-4}$. Váhy W u každého neuronu skryté vrstvy jsou iniciovány náhodně v intervalu $(0,1)$ podle rovnoměrného rozdělení a dále poděleny počtem vah. Váhy V výstupního neuronu jsou iniciovány náhodně v intervalu $(0,1)$ podle rovnoměrného rozdělení a dále poděleny počtem vah.

Zde jsou všechny zvolené parametry **MLP-ELM** sítě:

$\mu_v=0.01$	rychlost učení výstupního neuronu
$l_{window}=5$	délka plovoucího okna
$X=close_t \dots close_{t-4}$	vstupní vektor

$j=10$	počet neuronů ve skryté vrstvě
$W = W_1 \dots W_j$	matice matic vah neuronů ve skryté vrstvě
$W_i = w_{i1} \dots w_{in}$	matice vah i -tého neuronu ve skryté vrstvě
$w_{ik} = (0,1)/n$	i -tá váha k -tého neuronu ve skryté vrstvě
$V = v_1 \dots v_j$	matice vah výstupního neuronu
$v_j = (0,1)/n$	j -tá váha matice vah výstupního neuronu

V Tab. 12 je srovnání výkonnosti **MLP-ELM** sítě podle počtu neuronů ve skryté vrstvě. Od vrstvy obsahující 100 neuronů ve skryté vrstvě už nedochází k výraznějšímu zlepšení NMSE navíc s každým neuronem ve skryté vrstvě výrazně narůstají požadavky na výpočetní výkon.

Počet neuronů ve skryté vrstvě	<i>NMSE</i>	<i>AR</i> (23) za 159 dní pro 8 měnových párů
5	0,945	1,20%
10	0,967	2,54%
20	0,982	2,08%
50	0,997	3,48%
100	0,998	3,95%
200	0,998	2,31%
500	0,998	1,15%

Tab. 12: Srovnání výkonnosti MLP-ELM sítě pro predikci všech 8 měnových párů podle počtu neuronů ve skryté vrstvě – nejlépe dopadá vrstva se 100 skrytými neurony

Pro srovnání s ostatními neuronovými architekturami byla vybrána síť se 100 neurony ve skryté vrstvě, jelikož při testování dosahovala největšího průměrného *AR* .

V Tab. 13 je srovnání výkonnosti pro tuto síť napříč jednotlivými měnovými páry. Celkově dopadá investování podle predikční strategie lépe než u strategie buy & hold. Investování podle strategie (21) je také oproti **LNU**, **QNU** a **MLP** lepší. Oproti **RBF** je horší. NMSE je oproti **LNU**, **QNU** a **MLP** lepší, avšak oproti **RBF** opět horší.

Měnový pár	$NMSE$ (20)	AR (23) za 159 dní	
		Strategie (21)	Buy & hold
AUD/USD	0,994	1,85%	-18,86%
EUR/USD	0,995	-10,46%	-0,92%
GBP/USD	0,999	4,42%	-17,21%
NZD/USD	0,984	16,05%	-9,16%
USD/CAD	0,999	14,81%	32,12%
USD/CHF	0,997	28,92%	13,82%
USD/JPY	0,994	-12,82%	-12,18%
XAU/USD	0,998	-13,03%	-2,51%
Průměr	0,995	3,72%	-1,86%

*Tab. 13: Tabulka výkonnosti **MLP-ELM** sítě pro jednotlivé měnové páry za 159 dní – celkově dopadá investování podle predikce **MLP-ELM** sítě lépe jak u srovnávací strategie buy & hold*

Pro ilustraci průběhu predikce a backtestingu jsou připojeny obrázky Fig. 24, Fig. 25 a Fig. 26 pro měnový pár EUR/USD. Měnový pár EUR/USD byl vybrán, jelikož jeho $NMSE$ se nejvíce blíží průměru. Průběhy jsou velice podobné samotné **MLP** síti.




Fig. 24: Výřez z průběhu skutečné a predikované ceny podle **MLP-ELM** neuronového modelu (modrá – predikovaná zavírací cena, červená skutečná zavírací cena)




Fig. 25: Výřez z průběhu nákupů a prodejů podle predikce pomocí **MLP-ELM** neuronového modelu během backtestingu (modrá – zavírací cena, zelené kolečko nákup, červené kolečko prodej)



Fig. 26: Průběh stavu účtu během backtestingu pro predikci podle **MLP-ELM** neuronového modelu

4.7 Výsledky

Bylo naprogramováno 5 neuronových modelů tedy **LNU**, **QNU**, **MLP**, **RBF** a **MLP-ELM** v prostředí MATLAB a otestováno na umělých datech.

Na základě metodiky uvedené v publikacích v kapitole 3.4 byla naržena metoda testování neuronových modelů. Podle navržené metody bylo otestováno výše uvedených 5 neuronových modelů na historických datech, zde FOREX a výsledky jsou shrnuty v Tab. 14. Nejlepších výsledků je dosaženo u **RBF** sítě.

	LNU	QNU	MLP	RBF	MLP-ELM
Strategie (16)	-6,24%	-10,84%	3,78%	10,80%	3,70%
NMSE	0,979	0,936	0,973	0,99	0,99

Tab. 14: Srovnání výsledků 5 neuronových architektur pro provedené testování na historických datech - **RBF** neuronová síť dopadá nejlépe

Provedené testování neuronových modelů a výsledky slouží především k porovnání mezi sebou. Všechny sítě by pro skutečné nasazení potřebovaly být lépe odladěny. Například počáteční volba synaptických vah hraje velký význam a lepších výsledků je dosahováno v případě využití optimalizačních algoritmů, jako jsou například genetické algoritmy [20]. Často [20],[21] a [26] jsou vstupem do neuronových sítí také ukazatele technické analýzy s pozitivními výsledky.

Strategie (21) využitá pro srovnávání je od skutečně využitelné strategie velice vzdálená a také slouží především k porovnání mezi jednotlivými modely. Během testování je dosahováno velkých drawdownů, což je nepřijatelné. Při větších propadech, které jsme zažili ať už v roce 2008 při americké hypoteční krizi, v roce 2010 při takzvaném Flash Crash, nebo z důvodů intervence v roce 2011 ze strany Švýcarské národní banky, by byly následky pro naše obchodování fatální.

5 NÁVRH METODY PRO OKAMŽITÉ VYHODNOCOVÁNÍ TRENDU

V této kapitole je navržena metoda vyhodnocování trendů s využitím nejlépe fungujícího neuronového modelu nalezené na základě experimentálních analýz z minulé kapitoly. Pro možnost využití ekonomických metrik a tedy posouzení kvality vyhodnocení trendu je opět využito jednoduché investiční strategie.

Nejznámějším ukazatelem trendu jsou bezesporu klouzavé průměry. Klouzavé průměry díky svému vyhlazujícímu charakteru dokáží definovat současný trend, tedy především odhadovat zda se trh nachází v rostoucí nebo klesající fázi.

Spojením autonomní predikce a tohoto léty prověřeného indikátoru vzniká nový nástroj pro vyhodnocování trendu.

5.1 Popis metody

Pro ověření navrhované metody byla opět použita FOREXová data z kapitoly 4. Těchto 8 měnových páru za období leden 2012 až leden 2016 v 15 minutových sloupcích je rozděleno na data učící/validační/testovací v poměru 70/15/15.

Z provedené studie se pro predikci nejlépe osvědčila neuronová síť typu **RBF** a bude proto použita i nyní.

Simulace burzovního prostředí bude provedena podle metody uvedené v 4.1 s následující investiční strategií pro jednoduché klouzavé průměry:

$$\text{pokud } close_t > ma_t \text{ pak } nakup \text{ jinak } prodej. \quad (24)$$

kde:

$close$ je závírací cena
 ma je jednoduchý klouzavý průměr závírací ceny podle (30)

a se strategií pro klouzavé průměry ve spojení s predikcí podle:

$$\text{pokud } close_{t+1} > ma_{t+1} \text{ pak nakup jinak prodej.} \quad (25)$$

kde:

$close$ je predikovaná zavírací cena
 ma je jednoduchý klouzavý průměr predikované zavírací ceny podle (30)

Strategie pro klouzavé průměry není běžně obchodována, ale slouží spíše jako indikátor trendu. Bude zde porovnáván léty prověřený indikátor technické analýzy, proto budou použity následující ekonomické metriky:

Maximální propad vypočítaný podle:

$$MDD = \frac{MAX - MIN}{MAX} , \quad (26)$$

kde:

MAX je nejvyšší hodnota před největším propadem
 MIN je nejnižší hodnota po nové nejvyšší hodnotě

sloužící k posouzení rizika spojeného s maximálním propadem, který můžeme očekávat.

Další metrikou bude procento profitabilních obchodů vypočítané podle:

$$PPT = \frac{N_w}{N} \cdot 100 , \quad (27)$$

kde:

N_w je počet ziskových obchodů
 N je celkový počet obchodů

Tato metrika nám říká, jak úspěšní jsme byli v odhadu směru trhu. U trend-followingových strategií bývá tato metrika typicky nižší.

Mezi další metriky jsou zařazeny průměrný zisk na obchod a průměrná ztráta na obchod vypočítané podle:

$$AW = \frac{\sum_k^{N_L} TW_k}{N_L}, \quad (28)$$

kde:

TW jsou ziskové obchody
 N_L je celkový počet ziskových obchodů

a

$$AL = \frac{\sum_k^{N_L} TL_k}{N_L}, \quad (29)$$

kde:

TL jsou ztrátové obchody
 N_L je celkový počet ztrátových obchodů

Pro testovací data byly vypočítány jednoduché klouzavé průměry podle:

$$MA_t(n) = \frac{close_t + close_{t-1} \dots + close_{t-n}}{n}, \quad (30)$$

kde:

$close$ je zavírací cena
 n je délka periody.

5.2 Jednoduchý klouzavý průměr pro predikovaná data

Pro možnost porovnání je v Tab. 15 simulována strategie (31) pro jednoduchý klouzavý průměr na základě délky periody. Klouzavé průměry byly počítány do délky periody $n=1000$, kde již vzhledem k délce testovaného období 159 dní přestávají být výsledky reprezentativní.

Metrika	<i>AR</i> (12)	<i>MDD</i> (26)	<i>PPT</i> (27)	<i>AW</i> (28)	<i>AL</i> (29)	$\frac{AW}{AL}$
MA(5)	-39,6%	31,2%	14,3%	\$133	\$28	4,75
MA(10)	-28,3%	21,1%	12,1%	\$183	\$32	5,72
MA(20)	-25,0%	18,3%	10,6%	\$251	\$37	6,78
MA(50)	-23,7%	48,1%	9,0%	\$415	\$46	9,02
MA(100)	-12,8%	12,5%	8,6%	\$513	\$49	10,47
MA(200)	-7,4%	9,5%	7,7%	\$661	\$55	12,02
MA(500)	-5,6%	7,8%	3,4%	\$1 137	\$57	19,95
MA(1000)	-6,5%	9,8%	3,9%	\$1 084	\$59	18,37
Průměr	-18,6%	19,8%	8,7%	\$547	\$45	10,89

Tab. 15: Srovnání výkonnosti klouzavých průměrů seřazených podle délky periody n za 159 dnů na 8 měnových párech

V Tab. 16 jsou klouzavé průměry vypočítané na základě predikce neuronového modelu **RBF**. Stejně jako u jednoduchých klouzavých průměrů byly klouzavé průměry vypočítané na základě predikce neuronového modelu počítány do délky periody $n=1000$, kde již vzhledem k délce testovaného období 159 dní přestávají být výsledky reprezentativní.

Metrika	<i>AR</i> (12)	<i>MDD</i> (26)	<i>PPT</i> (27)	<i>AW</i> (28)	<i>AL</i> (29)	$\frac{AW}{AL}$
MA(5)	-33,0%	28,9%	19,3%	\$111	\$29	3,88
MA(10)	-18,0%	16,3%	16,8%	\$137	\$32	4,28
MA(20)	-14,1%	17,1%	14,8%	\$187	\$39	4,79
MA(50)	-7,4%	11,6%	12,4%	\$302	\$50	6,04
MA(100)	-7,9%	9,5%	12,9%	\$365	\$55	6,64
MA(200)	-1,1%	8,4%	11,1%	\$532	\$66	8,06
MA(500)	-4,3%	7,0%	11,3%	\$372	\$70	5,31
MA(1000)	-4,5%	11,3%	12,4%	\$493	\$86	5,73
Průměr	-11,3%	13,8%	13,9%	\$312	\$53	5,59

Tab. 16: Srovnání výkonnosti klouzavých průměrů využívajících predikci **RBF** neuronového modelu seřazených podle délky periody n za 159 dnů na 8 měnových párech

V Tab. 15 a Tab. 16 jsou uvedeny výsledky dosažené pro klouzavé průměry a klouzavé průměry vypočítané na základě predikce. Klouzavé průměry se používají především ke sledování trendu, nikoliv jako samostatná investiční strategie, a proto končí simulace obchodování ve ztrátě. V obou hlavních metrikách, tedy v roční návratnosti a maximálním propadu, dopadají klouzavé průměry s predikcí lépe jak klouzavé průměry bez predikce.

V metrice pro hodnocení počtu ziskových obchodů PPT klouzavé průměry s predikcí dosahují dokonce o 5,2 vyšší procento PPT. Tato metrika posuzuje ze všech metrik nejlépe schopnost monitorovat trend. Ve vztahu ke generování falešných signálů si vedou klouzavé průměry s predikcí lépe a generují jich méně, což je zřejmě důvodem lepších výsledků. U klouzavých průměrů o nízké periodě jsou falešné signály velkým problémem. Proto pro obchodování krátkých časových sloupců, tedy obchodování krátkých časových sloupců, se jeví tato metoda jako velice vhodná. Na Fig. 27 je výřez z průběhu backtestingu pro klouzavé průměry s predikcí a bez predikce. Na tomto obrázku jsou zvýrazněna místa, kde si klouzavé průměry s predikcí vedly lépe a kde hůře. Ačkoliv

nedávají klouzavé průměry s predikcí signály ke vstupu/výstupu dříve, což by se dalo očekávat díky svému filtrujícím charakteru, generují přesnější signály pro vstup/výstup.

V metrikách průměrného zisku na obchod AW a průměrné ztráty na obchod AL klouzavé průměry s predikcí zaostávají.

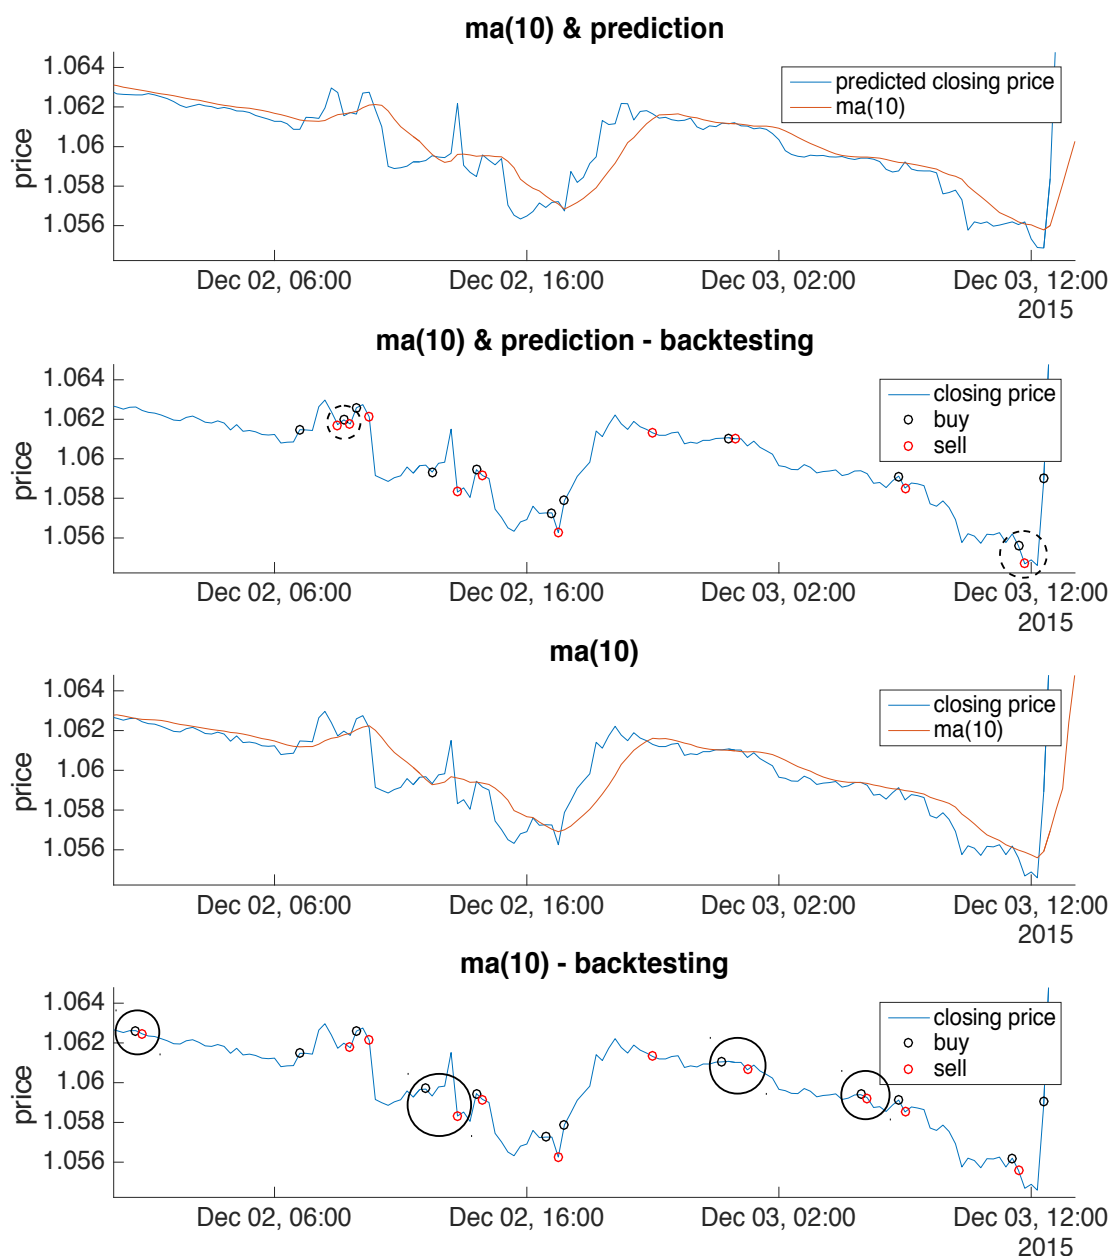



Fig. 27: Výřez z průběhu backtestingu - Srovnání klouzavých průměru s predikcí (a, b) a bez predikce (c, d), překřížení průběhu zavírací ceny s MA(10) je signálem pro vstup/výstup, plným kroužkem jsou vyznačena místa, kde si klouzavé průměry s predikcí vedly lépe, čárkovaným kroužkem, kde si vedly hůře

5.3 Výsledky

V této kapitole byla představena nová metoda monitorování trendu založená na predikci neuronového modelu **RBF** a klouzavých průměrech. Tato nová metoda dosahovala v testovaném období lepších výsledků jako samotné klouzavé průměry. Oproti samotným klouzavým průměrům generovali klouzavé průměry založené na predikovaných datech méně falešných signálů k nákupu/prodeji. Na Fig. 28 je grafické znázornění dvou metrik v závislosti na periodě použitého klouzavého průměru. Metrikami jsou AR, která je celkovým zhodnocením a PPT, která vyjadřuje procento profitabilních obchodů, tedy je metrikou úspěšnosti monitorování trendu.



*Fig. 28: Porovnání klouzavých průměrů využívajících predikci **RBF** neuronového modelu (červená) s konvenčními klouzavými průměry (modrá) pro metriku PPT (procento profitabilních obchodů) a metriku profitu – klouzavé průměry využívající predikci dopadají ve všech variantách lépe*

ZÁVĚR

V kapitole 2 bylo představeno algoritmické obchodování a související témata a v kapitole 3 byla provedena rešerše současných prostředků pro algoritmické obchodování včetně neuronových sítí.

Podle provedené rešerše pro využití neuronových sítí pro finanční časové řady byl navržen experiment pro krátkodobou predikci založenou pouze na historických cenách dané finanční časové řady, tedy jakousi autonomní predikci vycházející principiálně ze studií uvedených v rešerši, avšak s různými neuronovými modely. V uvedených studiích je totiž výhradně využíváno více vrstvé neuronové sítě (**MLP**, Multi Layer Perceptron) a neexistuje tedy srovnání pro jiné neuronové architektury. Pro tento experiment bylo vytvořeno 5 neuronových modelů. Lineární neuronová jednotka (**LNU**, Linear Neural Unit), kvadratická neuronová jednotka (**QNU**, Quadratic Neural Unit), více vrstvá neuronová síť (**MLP**, Multi Layer Perceptron), síť s radiální bázovou funkcí (**RBF**, Radial Basis Function) a více vrstvá neuronová síť v konfiguraci extrémního učení **MLP-ELM** (ELM, Extreme Learning Machine). Tyto neuronové modely byly naprogramovány v prostředí MATLAB. Pro ověření funkčnosti jsou všechny neuronové modely otestovány na umělých datech.

Pro simulaci byl navržen model burzovního prostředí využívající historická data 8 měnových párů zahraničního směnného trhu FOREX za období leden 2012 - leden 2015 v 15 minutových sloupcích. Pro hodnocení výsledků je kromě metriky hodnotící chybu predikce také využito metriky roční návratnosti investice pro hodnocení využitelnosti daného neuronového modelu. Výsledky jsou srovnávány s investiční strategií buy & hold.

Pro neuronový model dosahující nejlepších výsledků je navržen systém pro vyhodnocování trendu založený na indikátoru technické analýzy – klouzavých průměrech. V testech provedených na modelu burzovního prostředí překonává tato nová metoda klasické klouzavé průměry téměř ve všech metrikách.

V navazujících pracích by bylo vhodné ověřit získané poznatky pomocí Paper-Tradingu a navrhnout ATS využívající neuronových sítí ať už jako nástroj predikce, nebo nástroj monitorování trendu.

REFERENCE

- [1] DURČÁKOVÁ, Jaroslava a MANDEL, Martin. Mezinárodní finance 4. aktualiz. a dopl. vyd. Praha: Management Press, 2010. ISBN 978-80-7261-221-5.
- [2] REJNUŠ, Oldřich. Teorie a praxe obchodování s cennými papíry. 1. vydání: Computer Press, Praha, 2001, ISBN 80-7226-571-7.
- [3] ALDRIDGE, Irene. High-Frequency Trading: A Practical Guide to Algorithmic Strategies and Trading Systems 2 edition: Wiley, 2013, ISBN 978-1118343500
- [4] VESELÁ Jitka. Některé méně známé grafické metody technické analýzy a možnosti jejich využití k identifikaci změny trendu: Český finanční a účetní časopis 3/2007. ISSN: 1802-2200.
- [5] Forex – FX. investpedia.com [on-line] [vid. 27. Dubna 2016] dostupné z : <http://www.investopedia.com/terms/f/forex.asp?o=40186&l=dir&qsrc=999&qo=investopediaSiteSearch&ad=dirN&ap=investopedia.com>.
- [6] Forex trading hours. forexmarkethours.com [on-line] [vid. 27. Dubna 2016] dostupné z : <http://www.forexmarkethours.com/>
- [7] REVIEWS OF TRADING STRATEGIES, oxfordstrat.com. [on-line] [vid. 28. Dubna 2016] dostupné z : <http://www.oxfordstrat.com/resources/>
- [8] Algoritmické obchodování. rsj.com. [on-line] [vid. 27. Dubna] dostupné z : <http://www.rsj.com/cs/principy-a-technologie/algoritmicke-obchodovani/>
- [9] ŠÍMA, J. A NERUDA, R. Teoretické otázky neuronových sítí: Matfyzpress, Praha, 1996, ISBN 80-85863-18-9
- [10] BUKOVSKÝ, Ivo. Nonconventional Neural Architectures and their Advantages for Technical Applications: ČVUT, Praha.
- [11] BUKOVSKÝ, Ivo a HOMMA, Noriyas. An Approach to Stable Gradient Descent Adaptation of Higher-Order Neural Units: IEEE Transactions on Neural Networks and Learning Systems, 2016, DOI:10.1109/TNNLS.2016.2572310.
- [12] BUKOVSKÝ, Ivo. Základní neuronové architektury a učící algoritmy - Poznámky k předmětu Umělá inteligence a neuronové sítě (2015/16): ČVUT, Praha, 2016.
- [13] BÍLA, Jiří. Umělá inteligence a neuronové sítě v aplikacích: ČVUT, Praha, 1998.
- [14] VOLNÁ, Eva. Neuronové sítě 1.: Skripta Ostravská universita v Ostravě, Ostrava, 2008.

- [15] MELOUN, Milan a MILITKÝ Jiří. Statistická analýza experimentálních dat, vydání 2., upravené a rozšířené: Academia Praha, 2004, ISBN 978-80-200-1254-8.
- [16] HUANG, Guang-Bin a ZHU, Qin-Yu a SIEW Chee-Kheong, Extreme learning machine: Theory and applications: Neurocomputing, 2006, doi:10.1016/j.neucom.2005.12.126 (str. 489–501)
- [17] YUDONG, Zhang a LENAN, Wu. Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network: Expert Systems with Applications 36, 2009, ISSN:8849–8854
- [18] KAMRWZAMAN, Joarder a A SARKEG, Ruhul. Forecasting of currency exchange rates using ann: a case study: IEEE Int. Conf. Neural Networks & Signal Processing 12/2003, Conference Paper 1/2004 (str. 793 - 797 Vol.1), ISBN: 0-7803-7702-8
- [19] GAN, Woon-Seng a NG, Kah-Hwa. Multivariate FOREX Forecasting using Artificial Neural Networks: IEEE International Conference on Neural Networks, 1995 , ISBN: 0-7803-2768-3 (str. 1018 - 1022 vol.2)
- [20] KIM, Kyoung-jae a HAN, Ingoo. Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index: Expert Systems with Applications 19 (2000) (str. 125–132)
- [21] KIMOTO, Takashi a ASAKAWA, Kazuo a YODA, Morio a TAKEOKA Masakazu. Stock Market Prediction System with Modular Neural Networks: IJCNN International Joint Conference on Neural Networks, 1990 (str. 1 – 6 vol. 1)
- [22] YOON, Youngohc a SWALES, George. Predicting Stock Price Performance: A Neural Network Approach: Proceedings of the Twenty-Fourth Annual Hawaii International Conference on System Sciences, 1991 (str. 156 – 162 vol.4)
- [23] VANSTONE, B. a FINNIE, G. An Empirical Methodology for Developing Stockmarket Trading Systems using Artificial Neural Networks: Expert Systems with Applications, vol. In Press, 2008, doi>10.1016/j.eswa.2008.08.019 (str. 6668-6680)
- [24] YAO, Jingtao a TAN, Chew Lim. A case study on using neural networks to perform technical forecasting of forex: Neurocomputing 34, 2000 (str. 79 – 98)
- [25] KABLAN, Abdallan. Adaptive Neuro-Fuzzy Inference System for Financial Trading using Intraday Seasonality Observation Model: World Academy of Science, Engineering and Technology 58, 2009 (str. 479 – 488)

- [26] MARTINEZ, Leonardo C. a HORA, Diego N. a PALOTTI, Joao R. de M. A MEIRA, Wagner a PAPPA, Gisele L. From an Artificial Neural Network to a Stock Market Day-Trading System: A Case Study on the BM&F BOVESPA: International Joint Conference on Neural Networks, 2009, ISSN : 2161-4393 (str. 2006 – 2013)
- [27] EVANS, Cain a PAPPAS, Konstantinos a XHAFI, Fatos. Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation: Mathematical and computer modelling, 9/2013 (str. 1249-1266 vol. 58)
- [28] TSANG, Philip M. a KWOK, Paul a CHOY, S.O. a KWAN, Reggie a NG, S.C. a MAK, Jacky a TSANG, Jonathan a KOONG, Kai a WONG, Tak-Lam. Design and implementation of NN5 for Hong Kong stock price forecasting, Engineering Applications of Artificial Intelligence 20, 2007 (str. 453–461)
- [29] TSAY, Ruey S. Analysis of Financial Time Series Second Edition: 2005, ISBN: 0-471-69074-0
- [30] Goodness of fit between test and reference data, www.mathworks.com [on-line] [vid. 26. Května 2016] dostupné z: <<http://www.mathworks.com/help/ident/ref/goodnessoffit.html>>
- [31] Spot Forex and Forex CFDs - Pricing Structure, www.interactivebrokers.com [on-line] [vid. 26. květena 2016] dostupné z: <<https://www.interactivebrokers.com/en/index.php?f=1590&p=fx>>
- [32] SONG, Lei. Informative Correlation Extraction from and for Forex Market Analysis: Auckland University of Technology (AUT), School of Computing and Mathematical Sciences, Disertační práce, 2010, Vedoucí práce: Dr. Shaoning Pang
- [33] Forex Correlation, Mataf.net. [on-line] [vid. 6. června] dostupné z: <<https://www.mataf.net/en/forex/tools/correlation>>
- [34] PAL Mayukha, RAO Madhusundana, MANIMARA P. Multifractal detrended cross-correlation analysis on gold, crude oil and foreign exchange rate time series: Physica A: Statistical Mechanics and its Applications, 2014, doi:10.1016/j.physa.2014.09.004, (str. 452-460)
- [35] COVER, Thomas M. a THOMAS Joy A. Elements of Information Theory (Wiley Series in Telecommunications and Signal Processing) 99th Edition: Wiley-Interscience, 1991, ISBN-13: 978-0471062592 (str. 18 – 26)
- [36] Biologické algoritmy – Neuronové sítě, root.cz. [on-line] [vid. 6. června] dostupné z: < <http://www.root.cz/clanky/biologicke-algoritmy-4-neuronove-site/>>

PŘÍLOHY

Příloha 1 – Zdrojový kód lineární neuronové jednotky LNU.....	61
Příloha 2 – Zdrojový kód kvadratické neuronové jednotky QNU.....	62
Příloha 3 – Zdrojový kód vícevrstvé neuronové sítě MLP.....	63
Příloha 4 – Zdrojový kód neuronové sítě s radiální bázovou funkcí RBF.....	65
Příloha 5 – Zdrojový kód více vrstvé neuronové sítě v konfiguraci extrémního učení MLP-ELM.....	66
Příloha 6 – CD s testovanými daty a neuronovými modely naprogramovanými v jazyce Python.....	67

PŘÍLOHA 1 – ZDROJOVÝ KÓD LINEÁRNÍ NEURONOVÉ JEDNOTKY LNU

```
function [yn, w] = LNU_LM_MW(Y, X, window, w)

% Linear Neural Unit - Levenberg-Marquardt - Moving window
% You can set mu, and prediction lag inside function

% Neuron - preparation
% Parameters
prediction = 1;
mu = 0.001;

% Variables
N = size(Y,1);
nx = size(X,2) .* 1 + 1; %lenX * X width + 1
nw = nx;
e=zeros(1, N);
yn = Y;
yn = 0;
colX = ones(nx, 1);
if length(w) == 0
    w = randn(1, nw) ./ nw;
end
learningIndex = 0;

%LM
J=zeros(N,nw);
I=eye(nw);

% Neuron - count
for k = 1:N-prediction

    e(k)=Y(k)-yn(k);
    dydw=colX;
    J(k,:)=dydw;

    % LMMV - learning
    start = k - window;
    ende = k;
    if k > window & ~isnan( e(start:ende) ) % start after window and check NaN
        % Levenberg-Marquardt
        a = J(start:ende,:).' * J(start:ende,:);
        b = inv(a+1 ./ mu.*I);
        c = b * J(start:ende,:).';
        dw= c * e(start:ende)';
        % update weights
        w = w + dw';
    end

    % Input variables
    colX(2:ende) = X(k);

    % Neuron Count
    yn(k+prediction) = w * colX;

end

MSE = sum(e.^2)./N;
yn = yn';

end
```

PŘÍLOHA 2 – ZDROJOVÝ KÓD KVADRATICKÉ NEURONOVÉ JEDNOTKY QNU

```
function [yn, w] = QNU_LM_MW(Y, X, window, w)
% Quadratic Neural Unit - Levenberg-Marquardt - Moving window
% You can set mu, and prediction lag inside function

% Neuron - preparation

% Parameters
prediction = 1;
mu = 0.001;

% Variables
N = size(Y,1);
lindex = 0;
nx = size(X,2) .* 1 + 1; %lenX * X width + 1
nw = (nx*nx+nx)./2;
colx = zeros(nw, 1);
e=zeros(1, N);
yn = zeros(N,1);
x = ones(1,nx);
if length(w) == 0
    w = randn(1, nw) ./ nw;
end

%LM
J=zeros(N,nw);
I=eye(nw);

% Neuron - count
for k = 1:N-prediction

    % error from previos prediction
    e(k)=Y(k)-yn(k);
    dydw=colx;
    J(k,:)=dydw;

    % LMMV - learning
    start = k - window;
    ende = k;
    if k > window & ~isnan( e(start:ende) ) % start after window and check NaN
        % Levenberg-Marquardt
        a = J(start:ende,:).' * J(start:ende,:);
        b = inv(a+1 ./ mu.*I);
        c = b * J(start:ende,:).';
        dw= c * e(start:ende)';
        % update weights
        w = w + dw';
    end

    % Input variables
    x(2:end) = X(k);

    % Input vector colx
    index=1;
    for i=1:nx
        for j=i:nx
            colx(index) = x(i) .* x(j);
            index = index + 1;
        end
    end

    % Neuron Count
    yn(k+prediction) = w * colx;

end

end
```


PŘÍLOHA 3 – ZDROJOVÝ KÓD VÍCEVRSTVÉ NEURONOVÉ SÍTĚ MLP

```

function [yn, w, v] = MLP_LM_MW(Y, X, window, w, v)
% Quadratic Neural Unit - Levenberg-Marquardt - Moving window
% You can set mu, and prediction lag inside function

% Settings
prediction = 1;
muw = 0.01;
muv = 0.001;

% Prepare variables
N = size(Y,1);
n1 = 10; % hidden layer nodes
nx = size(X,2) .* 1 + 1;
nv = 1 + n1;
nxi = nv;

if length(w) == 0
    w = randn( n1, nx ) ./ nx;
end

if length(v) == 0
    v = randn( 1, nv ) ./ nv;
end

e = zeros(N, 1);
yn = zeros(N, 1);
x = ones(nx,1);
xi = ones(nxi,1);
dxidny = zeros(1, n1 + 1);
dydv = zeros(N, nv);
dydw = zeros(N, nx, n1);
Iv = eye(nv);
Iw = eye(nx);

% Main loop
for k = 1:N-prediction

    % error from previous prediction
    e(k) = Y(k) - yn(k);

    % Levenberg-Marquardt - Moving Window - Learning
    % from output node
    dydv(k, :) = xi;

    % from hidden nodes
    dphidny = 2. .* exp( -ny ) ./ ( 1. + exp( -ny ) ) .^2;
    dxidny(2:end) = dphidny;
    for i = 2:n1
        dydw(k, :, i) = v(i) .* dxidny( i ) .* x;
    end

    start = k - window;
    ende = k;
    if k > window & ~isnan( e(start:ende) ) % start after ...
        window is filled and check NaN

        % Output node
        Jv = dydv(start:ende,:);

        % LM
        a = Jv.' * Jv;
        b = inv(a+1 ./ muv.*Iv);
        c = b * Jv.';
        dv= c * e(start:ende);

        % update weights
        v = v + dv';

        % Hidden nodes
        for i = 2:n1
            Jw = dydw( start:ende, :, i );

            %LM
            a = Jw.' * Jw;
            b = inv(a+1 ./ muw.*Iw);
            c = b * Jw.';
            dw= c * e(start:ende);

            % update weights

```

```
        w( i, : ) = w( i, : ) + dw';
    end

end

% Count next yn
% Input variables
x(2:end) = X(k);

% Output of hidden nodes
ny = w * x;
phi = 2. ./ ( 1. + exp( -ny ) ) - 1.;
xi(2:end) = phi;

% Output of output node
yn(k + prediction) = v * xi;

end

end
```

PŘÍLOHA 4 – ZDROJOVÝ KÓD NEURONOVÉ SÍTĚ S RADIÁLNÍ BÁZOVOU FUNKCÍ **RBF**

```
function Yn = RBF_MW(Y, X, window)

    %Settings
    prediction = 1;
    beta = 0.01;

    import java.util.LinkedList
    W = LinkedList();
    Yw = LinkedList();

    % Initial training
    for k=2:window+1
        W.add( X(k-prediction) );
        Yw.add( Y(k) );
    end

    N = length(Y);
    Nw = window; %Row count = neurons count
    Nx = size(X,2);
    Yn=zeros(N,1);
    e=zeros(N,1);
    phi = zeros(Nw, 1);
    nu = zeros(Nw, 1);
    colx = ones(Nx+1);

    for k=1:N-prediction

        %update neuronu FIFO (moving window) start updating after prediction lag
        if k > 1 && k > prediction
            W.remove(); %remove first
            Yw.remove(); %remove first
            W.add( X(k - prediction) );
            Yw.add( Y(k) );
        end

        for i=0:Nw-1 % Indexing form 0 beacause using java LinkedList Object
            fnu = sqrt(sum( (W.get(i) - X(k)).^2));
            nu(i+1) = fnu;
        end

        % output of RBF neuronu
        phi = exp(-nu/beta); %nu^2 if nu < 0
        Yn(k+prediction) = sum(phi .* cell2mat( cell( Yw.toArray() ) ) ) / sum(phi);
    end
end
```

PŘÍLOHA 5 – ZDROJOVÝ KÓD VÍCE VRSTVÉ NEURONOVÉ SÍTĚ V KONFIGURACI EXTRÉMNIHO UČENÍ **MLP-ELM**

```

function [yn, w, v] = MLP_ELM_LM_MW(Y, X, window, w, v)
% Quadratic Neural Unit - Levenberg-Marquardt - Moving window
% You can set mu, and prediction lag inside function

% Settings
prediction = 1;
muv = 0.01;

% Prepare Variables
N = size(Y,1);
yn = zeros(N, 1);
n1 = 200; % hidden layer nodes
nx = size(X,2) .* 1 + 1;
nv = 1 + n1;
nxi = nv;

if length(w) == 0
    w = randn( n1, nx ) ./ nx;
end

if length(v) == 0
    v = randn( 1, nv ) ./ nv;
end

e = zeros(N, 1); % "empty " array for errors in data length
x = ones(nx,1);
xi = ones(nxi,1);
dxidny = zeros(1, n1 + 1);
dydv = zeros(N, nv);
dydw = zeros(N, nx, n1);
Iv = eye(nv);
Iw = eye(nx);

% Main Loop
for k = 1:N-prediction

    % error from previous prediction
    e(k) = Y(k) - yn(k);

    %vahy vystupniho neuronu
    dydv(k, :) = xi;

    % LMMV - learning
    start = k - window;
    ende = k;
    if k > window & ~isnan( e(start:ende) ) % start after window and check NaN

        % Levenberg-Marquardt
        Jv = dydv(start:ende,:);
        a = Jv.' * Jv;
        b = inv(a+1 ./ muv.*Iv);
        c = b * Jv.';
        dv= c * e(start:ende);

        % update weights
        v = v + dv';
    end

    % Input variables
    x(2:end) = X(k);

    % Output of hidden layer
    ny = w * x;
    phi = 2. ./ ( 1. + exp( -ny ) ) -1.;
    xi(2:end) = phi;

    % Output of output node
    yn(k + prediction) = v * xi;
end
end

```

PŘÍLOHA 6 – CD S TESTOVANÝMI DATY A NEURONOVÝMI MODELY NAPROGRAMOVANÝMI V JAZYCE PYTHON