

VYBRANÉ ASPEKTY MODELOVÁNÍ DEVIZOVÉHO KURZU POMOCÍ NEURONOVÝCH SÍTÍ

V. Mastný

Došlo: 19. prosince 2004

Abstract

MASTNÝ, V.: *Selected aspects of modelling of foreign exchange rates with neural networks*. Acta univ. agric. et silvic. Mendel. Brun., 2005, LIII, No. 3, pp. 109-116

This paper deals with forecasting of the high-frequency foreign exchange market with neural networks. The objective is to investigate some aspects of modelling with neural networks (impact of topology, size of training set and time horizon of the forecast on the performance of the network). The data used for the purpose of this paper contain 15-minute time series of US dollar against other major currencies, Japanese Yen, British Pound and Euro. The results show, that performance of the network in terms of correct directorial change is negatively influenced by increasing number of hidden neurons and decreasing size of training set. The performance of the network is influenced by sampling frequency.

forecasting, foreign exchange market, neural networks, backpropagation

Vývoj na devizovém trhu je ovlivněn velkým množstvím ekonomických, technických a psychologických faktorů, mezi nimiž jsou nelineární vztahy. Vývoj devizových kurzů se až do současnosti nepodařilo zcela objasnit, avšak zdá se, že je determinován emocemi a očekáváními účastníků na trhu. Přes zdánlivě náhodné chování devizových kurzů lze v jejich vývoji nalézt určité závislosti. Jednou ze slibných metod, která byla opakovaně s úspěchem použita na modelování finančních časových řad, je technologie umělých neuronových sítí. K použití neuronových sítí v oblasti finančních trhů je předurčují jejich typické vlastnosti: schopnost učit se nelineární závislosti, použitelnost při zpracovávání zdeformovaných dat, schopnost generalizace, a z toho plynoucí schopnost predikce. Neuronové sítě jsou stále relativně novým, ne zcela doceněným nástrojem se širokým spektrem použití. Jsou použitelné zejména tam, kde chybí nebo selhávají teorie založené na příčinných souvislostech. Právě proto jsou vhodným nástrojem pro modelování vývoje devizových kurzů. Modelování finančních časových řad pomocí neuronových sítí se věnuje řada prací, přičemž při srovnávání různých přístupů po-

dávají neuronové sítě lepší výsledky než jiné metody (např. Yao a Tan, 2000; Dunis a Williams, 2002; Kamruzzaman a Sarker, 2003). Práce, které se zabývají modelováním a předpovídáním devizového kurzu většinou stručně popisují dosažené výsledky bez podrobnějšího zkoumání vlivu délky použitého učícího období, vlivu použité topologie či použití různých učících algoritmů na kvalitu získaných předpovědí. Z tohoto důvodu se práce věnuje empirickému zkoumání vybraných aspektů modelování devizových kurzů pomocí neuronových sítí.

Cílem práce je prezentace poznatků získaných při modelování a předpovídání intradenního vývoje devizových kurzů pomocí neuronových sítí. Snahou práce není dosažení vysoké úspěšnosti předpovědi (ve smyslu odhadu růstu/poklesu), avšak na základě experimentů demonstrovat vybrané aspekty modelování devizových kurzů pomocí neuronových sítí. Práce se věnuje empirickému zkoumání vlivu použité topologie sítě a velikosti učícího souboru dat na kvalitu předpovědi a zjištění, zda je vhodnější předpovídat devizový kurz s použitím 15min údajů v čase $t + 4$ nebo předpovídat s použitím 60min dat kurz v čase

$t + 1$. Zejména poslední dvě otázky nebyly dosud řešeny a v tomto smyslu je práce novým přínosem.

Problémem neuronových sítí je kromě nutnosti volby mnoha faktorů experimentálně také skutečnost, že i při opakování stejného experimentu může síť poskytnout odlišné výsledky. Z tohoto důvodu jsou jednotlivé experimenty prováděny třikrát a v tabulkách jsou uvedeny průměrné hodnoty experimentů. Z důvodu snahy o zobecnitelnost závěrů je analýza prováděna na třech různých časových řadách – měnových párech EUR/USD, GBP/USD a USD/JPY.


MATERIÁL A METODY

Použité časové řady tvoří 15min údaje nejvíce obchodovaných měnových párů EUR/USD, GBP/USD a USD/JPY za období 1. 1. 2002–30. 4. 2002 (délka řad cca 8000 údajů). Vzhledem ke skutečnosti, že originální časové řady devizových kurzů obsahují výraznou náhodnou složku a je obtížné je modelovat, jsou na vstup sítí často přiváděny klouzavé průměry o různé délce (5, 10, 15, ..., 40), které vyhlazují průběh vývoje devizových kurzů. Cílem je předpovědět budoucí hodnotu kurzu, proto požadovanou výstupní hodnotu tvoří kurz v čase $t + 1$.

Použitá data byla před použitím v sítích transformována na interval $[-1, 1]$ podle vztahu:

$$x_{fix} = 2 \cdot \frac{x_t - x_{min}}{x_{max} - x_{min}} - 1.$$

Dále byla data rozdělena na učící datový soubor (prvních cca 7000 vzorů) a testovací datový soubor (posledních 1000 vzorů). Z učících dat byla dále zvlášť vyčleněna v pravidelných intervalech každá čtvrtá hodnota jako tzv. validační data (viz obr. č. 1).



1: rozdělení dostupných dat na tréninková, validační a testovací

Validační data, stejně jako data testovací, nebyla použita při učení a pro síť představují nová neznámá data. Při učení se postupně s rostoucím počtem učících cyklů (epoch) snižuje chyba sítě na tréninkových i validačních datech, od určitého okamžiku se však chyba na validačních datech začíná opět zvyšovat (Zimmerer, 1997). V tomto okamžiku je vhodné ukončit učení a tím zabránit přeučení sítě. Vlastní porovnání kvality předpovědi různých naučených sítí

bylo prováděno na testovacích datech (posledních 1000 vzorů).

Při tvorbě sítě byl postupně měněn počet vstupních proměnných a neuronů ve skryté vrstvě. Protože při modelování pomocí neuronových sítí je snaha vytvořit síť, která při stejné kvalitě poskytovaných předpovědí obsahuje síť co nejméně neuronů a spojů mezi nimi, byla skrytá vrstva tvořena malým počtem skrytých neuronů (2–14).

Jednotlivé sítě byly učeny tak dlouho, dokud síť nejevila známky přeučení na validačních datech nebo dokud nebylo dosaženo požadované přesnosti sítě nebo dokud nebylo dosaženo maximálního stanoveného počtu učících cyklů (300). Při učení byl použit Levenberg-Marquardtův algoritmus, který je charakteristický svojí vysokou rychlostí. Učení bylo prováděno v prostředí Matlab.

Po natrénování sítí a vytvoření předpovědi byla porovnávána kvalita těchto předpovědí pomocí vybraného kritéria. Tvorba předpovědi byla prováděna na pro síť neznámých datech – testovacím souboru. Pro porovnávání kvality předpovědi lze použít mnoha kritérií (např. MSE, NMSE, korelační koeficient, Theilův koeficient nesouladu aj.). V této práci je použito jediné hodnotící kritérium – odhad správného budoucího směru vývoje (růstu/poklesu) devizového kurzu (correct directorial change).

$$CDC = \frac{100}{N} \sum a_t,$$

kde $a_t = 1$ když $(x_t - x_{t-1})(\hat{x}_t - x_{t-1})$, jinak $a_t = 0$ (zdroj Yao a Tan, 2000).

Výsledky v tabulkách jsou uváděny v procentech.

VÝSLEDKY

A) Závislost úspěšnosti předpovědi na zvolené topologii sítě

Cílem tohoto experimentu je analýza závislosti kvality předpovědi (růst/pokles) na zvolené topologii sítě a počtu vstupních proměnných. Vstupní údaje tvoří klouzavé průměry o různých délkách (MA5, MA10, MA15, ..., MA40) v čase t .

Na počátku experimentu byly na vstup sítě přivedeny dva klouzavé průměry MA5 a MA10. Postupně byla zvyšována dimenze vstupního vektoru a na vstup sítě byly přidávány další klouzavé průměry o větší délce (na druhém řádku v tabulkách I až III byly na vstup sítě přivedeny další průměry MA15 a MA20).

Pro každou velikost vstupního vektoru byl postupně měněn počet neuronů ve skryté vrstvě od 2 do 14. Pro omezení vlivu náhody při učení sítě je každé učení sítě opakováno třikrát a v tabulkách č. I až III a grafu č. 2 jsou uvedeny průměrné dosažené hodnoty (v procentech) správného odhadu směru budoucího vývoje (růst/pokles). Požadovaný výstup představuje budou-

cí hodnota kurzu v čase $t + 1$. Každý experiment byl opakovan třikrát, výsledky v tabulkách představují průměrné dosažené hodnoty správného odhadu budoucího směru vývoje.

I: Odhad budoucího směru vývoje kurzu EUR/USD v čase $t + 1$

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	57,3	56,5	57,3	56,6	56,8	56,4	56,8	56,8
4	57,4	56,9	57,3	57,8	57,1	57,5	56,4	57,2
6	57,4	57,0	56,6	57,1	57,7	57,5	57,3	57,2
8	57,7	57,1	57,0	58,0	56,9	57,8	57,0	57,3
průměr	57,4	56,8	57,0	57,4	57,1	57,3	56,9	57,1

II: Odhad budoucího směru vývoje kurzu GBP/USD v čase $t + 1$


vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	53,7	54,6	53,9	53,7	53,2	53,2	53,2	53,6
4	54,2	54,4	54,2	53,3	53,1	53,4	53,2	53,7
6	53,7	53,8	53,9	52,6	53,8	54,0	52,8	53,5
8	53,9	53,8	54,0	54,7	53,0	54,6	52,9	53,8
průměr	53,9	54,1	54,0	53,6	53,3	53,8	53,0	53,7

III: Odhad budoucího směru vývoje kurzu USD/JPY v čase $t + 1$

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	54,9	54,6	55,2	54,8	55,4	54,2	53,9	54,7
4	56,4	56,2	55,7	55,7	55,9	54,0	54,4	55,5
6	56,7	56,2	55,5	54,1	55,7	54,6	53,2	55,0
8	56,4	55,8	53,5	55,1	54,3	53,1	54,5	54,6
průměr	56,1	55,7	55,0	54,9	55,1	54,0	54,0	54,9

Z tabulek č. I až III je zřejmé, že s rostoucím počtem neuronů ve skryté mírně klesá úspěšnost předpovědi. Tento trend je zřetelný zejména u párů GBP/USD a USD/JPY. Na základě opakování stejného experimentu lze konstatovat, že pomocí neuronových sítí lze dosáhnout správné předpovědi budoucího směru

vývoje s průměrnou pravděpodobností cca 54–57 %, přičemž kvalitnějších předpovědí lze dosáhnout s použitím jednodušších sítí. Závislost kvality předpovědi na počtu skrytých neuronů je zřetelná z grafu č. 2. Podobnou závislost lze vypořádat také u výsledků dalších experimentů (tabulky č. IV až IX).



2: Závislost úspěšnosti předpovědi na počtu neuronů ve skryté vrstvě

B) Analýza úspěšnosti předpovědi v čase $t + 60$ min při použití časových řad o periodě 15 min a 60 min

Cílem tohoto experimentu je dokázat, zda pro předpovídání budoucího kurzu za 60 min je vhodnější předpovídat hodnotu v čase $t + 1$ při použití 60min dat nebo zda lze dosáhnout kvalitnější předpovědi v čase $t + 4$ při použití 15min dat. Testovací období u 60min dat zůstává stejné, avšak z důvodu použití 60min dat je místo původních 1000 testovacích vzorů použito pouze 250 vzorů (hodinové údaje). V první fázi byl s pomocí 15min údajů předpovídan budoucí kurz v čase $t + 4$. Výsledky jsou uvedeny v tabulkách č. IV, VI a VIII. Oproti předpovědím v čase $t + 1$ dochází k mírnému poklesu kvality u páru EUR/USD.

U párů GBP/USD a USD/JPY jsou dosažené průměrné výsledky téměř podobné. Pomocí neuronových sítí je tedy možné předpovídat budoucí kurz v delším časovém horizontu, než je v čase $t + 1$.

Ve druhé fázi byl předpovídan budoucí kurz s využitím 60min údajů v čase $t + 1$. Dosažené výsledky byly u všech tří analyzovaných měnových párů méně kvalitní než při předpovídání kurzu za 60 min při použití 15min dat. Z výsledků lze usoudit, že je vhodné používat data o vyšší frekvenci a předpovídat budoucí hodnotu i v delším časovém horizontu.

Učení každé sítě bylo prováděno třikrát a v tabulkách č. IV až IX jsou uvedeny průměrné hodnoty v procentech.

IV: Odhad budoucího směru vývoje kurzu EUR/USD v čase $t + 4$ (15min data)

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	57,7	57,5	57,4	55,7	54,1	53,6	54,3	55,8
4	55,8	56,6	56,2	53,9	55,0	54,4	54,2	55,2
6	56,9	55,8	55,2	54,8	54,6	55,2	54,0	55,2
8	54,2	52,8	54,3	54,2	53,9	55,0	54,2	54,1
průměr	56,2	55,7	55,8	54,7	54,4	54,6	54,2	55,1

V: Odhad budoucího směru vývoje kurzu EUR/USD v čase $t + 1$ (60min data)

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	49,4	48,9	51,1	50,2	51,5	48,9	48,5	49,8
4	51,1	48,5	48,1	53,2	49,4	49,8	50,2	50,0
6	51,0	49,8	48,5	48,1	47,7	48,1	46,4	48,5
8	51,1	50,2	49,4	48,5	46,4	50,2	47,2	49,0
průměr	50,7	49,4	49,3	50,0	48,8	49,3	48,1	49,3

VI: Odhad budoucího směru vývoje kurzu GBP/USD v čase $t + 4$ (15min data)

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	57,6	52,8	54,5	51,7	54,3	53,1	54,3	54,0
4	54,7	54,0	53,4	53,3	53,7	52,7	56,0	54,0
6	53,5	53,7	54,0	54,9	53,9	56,3	55,1	54,5
8	53,1	52,6	52,7	54,7	52,8	51,7	52,7	52,9
průměr	54,7	53,3	53,7	53,7	53,7	53,5	54,5	53,9

VII: Odhad budoucího směru vývoje kurzu GBP/USD v čase $t + 1$ (60min data)

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	55,2	53,5	56,5	56,1	53,0	55,2	54,8	54,9
4	53,1	53,9	53,6	53,0	50,7	52,2	52,6	52,7
6	53,0	55,7	52,2	52,2	50,2	53,5	52,2	52,7
8	54,3	51,7	52,6	49,1	49,4	52,2	51,3	51,5
průměr	53,9	53,7	53,7	52,6	50,8	53,3	52,7	53,0

VIII: Odhad budoucího směru vývoje kurzu USD/JPY v čase $t + 4$ (15min data)

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	56,9	56,8	55,7	56,0	55,0	54,1	55,7	55,7
4	56,8	56,6	55,9	55,2	54,0	53,8	52,9	55,0
6	54,5	54,8	53,4	54,3	53,9	53,4	54,1	54,1
8	55,2	54,3	51,7	55,6	54,0	53,7	54,0	54,1
průměr	55,9	55,6	54,2	55,3	54,2	53,8	54,2	54,7

IX: Odhad budoucího směru vývoje kurzu USD/JPY v čase $t + 1$ (60min data)

vstupní neurony	počet neuronů ve skryté vrstvě							průměr
	2	4	6	8	10	12	14	
2	52,0	53,6	53,6	53,2	51,5	50,5	53,2	52,5
4	52,4	52,8	52,0	52,2	53,6	53,6	51,1	52,5
6	50,7	49,9	53,2	52,0	52,8	54,9	52,0	52,2
8	55,3	50,7	55,3	49,9	52,4	52,0	50,7	52,3
průměr	52,6	51,8	53,5	51,8	52,6	52,8	51,8	52,4

C) Závislost úspěšnosti předpovědi na počtu učicích vzorů

Cílem tohoto experimentu je analýza závislosti kvality předpovědi (růst/pokles) na délce učicího období. Vstupní údaje tvoří stejně jako v předchozích experimentech klouzavé průměry o různých délkách (MA5, MA10, MA 15, ..., MA40) v čase t . Požadovaným výstupem je budoucí hodnota kurzu v čase $t + 1$.

Na počátku experimentu bylo použito cca 8000 vzorů. Z tohoto dostupného množství cca 7000 vzorů


sloužilo jako učicí a validační data, posledních 1000 vzorů tvořil testovací soubor. Učicí a validační data byla postupně zkracována o 1000 nejstarších vzorů. Pro porovnatelnost výsledků nebylo testovací období měněno. Skrytá vrstva obsahovala takový počet skrytých neuronů, při kterém bylo v předchozím experimentu dosaženo vyšší úspěšnosti předpovědi (2-6 neuronů). Učení každé sítě bylo prováděno třikrát a v tabulce č. X jsou uvedeny průměrné hodnoty v procentech.

X: Odhad budoucího směru vývoje kurzu v čase $t + 1$ při proměnlivé délce učicího souboru

vstupní neurony	počet učicích a validačních vzorů						průměr
	7000	6000	5000	4000	3000	2000	
(EUR/USD) 4-2-1	57,2	57,3	55,2	57,5	55,7	54,6	56,3
(EUR/USD) 4-4-1	57,1	57,7	54,8	53,6	55,4	56,8	55,9
(EUR/USD) 4-6-1	57,2	57,2	53,2	54,2	54,9	52,6	54,9
průměr	57,2	57,4	54,4	55,1	55,3	54,7	55,7
(GBP/USD) 4-2-1	55,1	55,1	54,3	54,3	54,8	54,2	54,6
(GBP/USD) 4-4-1	55,6	53,2	55,1	6,1	54,1	55,2	54,9
(GBP/USD) 4-6-1	54,5	54,1	53,4	53,2	55,0	54,1	54,1
průměr	55,1	54,2	54,3	54,5	54,6	54,5	54,5
(USD/JPY) 4-2-1	56,0	55,2	55,8	55,4	56,0	54,3	55,5
(USD/JPY) 4-4-1	55,4	55,4	55,3	54,9	53,0	54,5	54,8
(USD/JPY) 4-6-1	55,8	54,8	55,7	55,1	56,6	53,9	55,3
průměr	55,7	55,1	55,6	55,1	55,2	54,2	55,2
průměr všech měn	56,0	55,6	54,7	54,9	55,0	54,5	55,1

Z tabulky č. X je zřejmé, že s rostoucím počtem učicích vzorů roste velmi mírně kvalita dosažených předpovědí. U páru EUR/USD došlo v případě zkrá-

cení učicího souboru k výraznějšímu poklesu úspěšnosti předpovědí, u ostatních dvou párů je úbytek v kvalitě modelu nepatrný.



3: Závislost úspěšnosti předpovědi na počtu učicích a validačních vzorů

SOUHRN

Práce se věnuje třem vybraným aspektům modelování devizových kurzů pomocí umělých neuronových sítí. Vstupními údaji jsou klouzavé průměry o různé délce, požadovanou výstupní hodnotou je budoucí hodnota kurzu. Při učení byl použit Levenberg-Marquardtův algoritmus, který je charakteristický svojí vysokou rychlostí. U všech tří sledovaných devizových kurzů je kvalitnějších předpovědí dosahováno při nižším počtu neuronů ve skryté vrstvě. Tato skutečnost je zřetelná také u ostatních experimentů. Pomocí neuronových sítí je možné s úspěchem předpovídat také hodnotu kurzu v delším časovém horizontu.

Dosažené předpovědi růstu/poklesu kurzu (15min údaje) jsou při predikci budoucí hodnoty kurzu v čase $t + 4$ nepatrně horší než předpovědi v čase $t + 1$, avšak jsou výrazně kvalitnější než předpověď kurzu v čase $t + 1$ při použití 60min dat. Zjištění, že je vhodné předpovídat budoucí vývoj v delším časovém horizontu pomocí časových řad s kratšími intervaly představuje vhodnou oblast pro další zkoumání.

Poslední experiment se věnuje analýze vhodné délky učícího období. Při použití delších učících řad bylo u jednoho měnového páru dosaženo výrazně kvalitnějších předpovědí, u dvou měnových párů jsou dosažené výsledky při použití delšího učícího období mírně lepší. Lze konstatovat, že pro získání kvalitní předpovědi je třeba mít dostatečné množství učících vzorů.

předpovídání, devizový trh, neuronové sítě, backpropagation

LITERATURA

- BISHOP, Ch. M.: *Neural networks for pattern recognition*, Oxford University Press, New York, 2002.
- DUNIS CH. L., WILLIAMS M.: „Modelling and Trading the EUR/USD Exchange Rate: Do Neural Networks Models Perform Better?“ *Derivatives Use, Trading and Regulation*, 2002, No 8/3, 211-239
- KAMRUZZAMAN, J., SARKER, R.: „Forecasting of currency exchange rates using ANN: a case study“, *Proceeding of IEEE International Conference on Neural Networks & Signal Processing*, 2003, 793-797.
- YAO, J., TAN, Ch. L.: ‘A case study on using neural networks to perform technical forecasting of forex’, *Neurocomputing*, 2000, 34, 79-98.
- ZIMMERER, T.: *Künstliche Neuronale Netze versus ökonomische und zeitreihenanalytische Verfahren zur Prognose ökonomischer Zeitreihen*, Peter Lang, Frankfurt, 1997.

Adresa

Ing. Václav Mastný, Ústav financí, Mendelova zemědělská a lesnická univerzita v Brně, Zemědělská 1, 613 00 Brno, Česká republika

