

POROVNANIE PREDIKČEJ PRESNOSTI EKONOMETRICKÝCH MODELOV A MODELOV RBF UNS NA VÝVOJI INFLÁCIE

Milan Marček

¹Medis, spol. s r.o., Pri Dobrotke, 659/81, 948 01 Nitra, Žilinská univerzita FRI Žilina,
Slezská univerzita - Ústav informatiky Opava, marcek@fria.utc.sk, marcek@medis.sk

Anton Vorčák

Žilinská univerzita FRI Žilina, Anton.Vorcak@fri.uniza.sk

Abstrakt

Cieľom príspevku je prezentovať vyvinuté prediktory pre modelovanie a prognózovanie finančných procesov s využitím RBF umelých neurónových sietí a ekonometrických metód. Práca sa zaoberá ekonometrickými metódami, prognostikou a umelými neurónovými sieťami. Presnosť modelovania pomocou RBF neurónových sietí je porovnávaná s presnosťou modelovania pomocou ekonometrických metód.

Kľúčové slova

Ekonometria, ekonometrický model, prognózovanie, umelá neurónová sieť, RBF umelá neurónová sieť, ekonomická hypotéza.

1 ÚVOD

V poslednej dobe nastal výrazný rozvoj v modelovaní časových radov ekonomických a finančných veličín. Dôvodom k tomu sú nové informačné technológie, predovšetkým smery soft computing [3], ale aj nové teoretické poznatky v teórii financií.

Cieľom príspevku je informovanie o niektorých nových vyvinutých prediktorov ekonomických veličín s použitím ekonomickej teórie a metód soft computingu, konkrétne špecifickej triedy umelých neurónových sietí – RBF (Radial Basis Function) sietí.

Kapitola druhá sa zaoberá architektúrou RBF neurónovej siete a jej modifikáciami. Kapitola tretia prezentuje niektoré výsledky aproximačnej a predikčnej modelovania vývoja inflácie. Kapitola štvrtá je venovaná vyhodnoteniu modelov inflácie založených na RBF sieťach a ich modifikáciách. Záverečné poznámky k výsledkom sú uvedené v kapitole piatej.

2 MOŽNÉ TOPOLOGIE (MODIFIKÁCIE) A UČENIE RBF SIETÍ

V lit. [1] sú uvedené 2 základné architektúry RBF sietí – klasická a soft (fuzzy logic). Na obr. 2.1 sú tieto architektúry nakreslené pre zobrazenie vstupného vektora dát $\mathbf{x} = (x_1, x_2, \dots, x_k) \in \mathfrak{R}^k$ do premennej $y \in \mathfrak{R}^1$ na výstupe. RBF siete na obr. 2.1 sú siete s dopredným šírením signálov a v tomto zmysle je ekvivalentná s viacvrstvovou sieťou perceptrónového typu. Obidve siete (RBF sieť a sieť perceptrónového typu) majú jednu skrytú vrstvu s procesnými neurónmi a s nelineárnymi aktivačnými funkciami spravidla gaussovského typu. Potenciál neurónu v skrytej vrstve RBF siete je rovný štvorcov rozdielu vzdialenosti medzi koncovými bodmi vstupného vektora \mathbf{x} a vektora váh \mathbf{w}_j , t. j.


$$u_j = \|\mathbf{x} - \mathbf{w}_j\|^2, \quad j = 1, 2, \dots, s, \quad (2.1)$$

a výstup z neurónov v strednej vrstve je daný

$$\psi_2(u_j) = \exp(u_j / 2\sigma_j^2) \quad (2.2)$$

Táto metóda je spojená s rozhodovaním o voľbe počtu RBF neurónov. Predpokladá sa, že počet neurónov s v skrytej vrstve RBF siete je daný.

Z metód na vyhľadávanie zhlukov sa v podstate používajú dve. Prvá je štatistická metóda s označením K -stredov (K -means clustering algorithm), kde symbolom K je určený počet zhlukov, a teda aj počet neurónov skrytej vrstvy. Metóda bola vyvinutá v rámci matematickej štatistiky. V súčasnej dobe je obsiahnutá takmer v každom štatistickom software.



Obr. 2.1 Architektúra RBF siete na zobrazenie $\mathfrak{R}^k \rightarrow \mathfrak{R}^1$ - klasická vľavo, soft vpravo.

Ak hodnoty týchto výstupov sa budú normalizovať tak, že každý výstup o_j neurónu v skrytej vrstve sa vydělí súčtom hodnôt všetkých výstupov neurónov v strednej vrstve, t. j. výrazom $\sum_{j=1}^S o_j$, získa sa soft RBF sieť. Iné možné vylepšenie aproximačnej a predikčnej schopnosti soft RBF siete s architektúrou na obr. 2.1 vpravo je, ak sa do inferenčného mechanizmu zakomponuje tzv. cloud koncept [3], t. j. štandardná gaussovská aktivačná funkcia RBF neurónov sa zamení funkciou založenou na cloud koncepte. Bližšie podrobnosti je možné nájsť v lit. [3] a [5].

3 MODELOVANIE A VYHODNOTENIE MODELOV INFLÁCIE ZALOŽENÝCH NA RBF SIETĎACH

V tejto kapitole sa skúma schopnosť RBF umelej neurónovej siete modelovať mieru inflácie na základe prijatých ekonomických teórií [5]. Konkrétne ide o jednoduché hypotézy závislosti inflácie r_t od miery nezamestnanosti U_t , potom od miezd W_t , model zotrvačnosti, viacfaktorový model závislosti inflácie od miery nezamestnanosti a miezd a nakoniec viacfaktorový model so zohľadnením aj zotrvačnosti inflácie, ktoré boli kvantifikované na základe štvrtročných dát odhadovou metódou OLS v tvaroch:

$$r_t = 1,6788 + 0,1303 \cdot U_{t-1} \quad (3.1)$$

$$r_t = 6,7046 - 0,5089 \cdot W_{t-1} \quad (3.2)$$

$$r_t = 0,415 - 0,79 \cdot r_{t-1} \quad (3.3)$$

$$r_t = 8,8104 + 1,0365 \cdot U_{t-1} - 1,0424 \cdot W_{t-1} \quad (3.4)$$

$$r_t = -0,8774 - 0,135 \cdot U_{t-1} + 0,1683 \cdot W_{t-1} + 0,8444 \cdot r_{t-1} \quad (3.5)$$

Pri modelovaní inflácie podľa tvaru funkcií (3.1) až (3.5) sa parametre sietí volili tak, aby dávali optimálne výsledky. Ide hlavne o veľkosť tréningovej množiny, počet procesných neurónov, parameter rýchlosti učenia váh, počet epoch zhlukovania a rýchlosť adaptácie centier RBF neurónov. Vplyv najdôležitejších parametrov sietí na presnosť modelovania inflácie je uvedený v lit. [6]. Výsledky o dosiahnutých chybách presnosti aproximácie vývoja inflácie jednotlivých typov RBF sietí a modelov (3.1) až (3.5) sú uvedené v tabuľkách 3.1 a 3.2.

Tab. č. 3.1: Charakteristika presnosti jednotlivých typov modelov inflácie r_t meraných pomocou MSE

	RBF	soft-RBF	Cloud-RBF	soft-cloud-RBF	dopredná UNS	Regr. analýza $r_t = f(U_{t-1})$
MSE _{TRAIN}	0,131065	0,190475	0,191246	0,190396	0,150865	0,150739
MSE _{VAL}	0,191502	0,190475	0,191246	0,190396	0,173661	0,607902
r _{1Q2008} (%)	3,468	3,871	3,331	3,922	3,736	7,262

	RBF	soft-RBF	Cloud-RBF	soft-cloud-RBF	dopredná UNS	Regr. analýza $r_t = f(W_{t-1})$
MSE _{TRAIN}	0,239871	0,151723	0,234712	0,151723	0,154176	0,137741
MSE _{VAL}	0,130141	0,193902	0,123717	0,193906	0,196002	0,295846
r _{1Q2008}	2,179	4,031	2,139	3,969	3,957	4,928

	RBF	soft-RBF	Cloud-RBF	soft-cloud-RBF	dopredná UNS	Regr. analýza $r_t = f(r_{t-1})$
MSE _{TRAIN}	0,2771	0,085275	0,271885	0,179803	0,061214	0,0492562
MSE _{VAL}	0,085521	0,179002	0,083788	0,179803	0,083312	0,096008
r _{1Q2008}	3,292	2,189	3,568	2,198	3,691	3,89

	RBF	soft-RBF	cloud-RBF	soft-cloud-RBF	dopredná UNS	Regr. analýza $r_t = f(r_{t-1})$
MSE _{TRAIN}	0,202953	0,151615	0,198822	0,151615	0,156871	0,115928
MSE _{VAL}	0,13632	0,193911	0,127905	0,193902	0,195616	0,1331853
r _{1Q2008}	1,951	4,017	1,89	3,995	4,076	2,142

	RBF	soft-RBF	Cloud-RBF	soft-cloud-RBF	dopredná UNS	Regr. analýza $r_t = f(U_{t-1}, W_{t-1}, r_{t-1})$
MSE _{TRAIN}	0,217477	0,15163	0,213419	0,15163	0,141536	0,048608
MSE _{VAL}	0,07501	0,193902	0,072883	0,193901	0,191577	0,1291521
r _{1Q2008}	2,731	4,092	2,597	3,985	4,109	4,511

4 Porovnanie inflačných hypotéz

Vývoj inflácie sme modelovali pomocou piatich ekonomických hypotéz (3.1) až (3.5). K najpresnejším prognózam sme sa dopracovali, keď sme vychádzali z hypotézy, ktorá definuje závislosť inflácie od miery nezamestnanosti, priemerných miezd a hodnoty inflácie v predchádzajúcom období – model (3.5).

Nasledujúca tabuľka 3.2 vznikla porovnaním tejto hypotézy s ostatnými použitými ekonomickými hypotézami. Pri každej hypotéze je uvedená chyba MSE_{VAL} , metódy, vďaka ktorej sme sa dopracovali k danej hodnote a prognózovaná hodnota inflácie na prvý štvrťrok 2008.

Tabuľka 3.2. Porovnanie inflačných hypotéz

	$r_t = f(U_{t-1})$	$r_t = f(W_{t-1})$	$r_t = f(r_{t-1})$	$r_t = f(U_{t-1}, W_{t-1})$	$r_t = f(U_{t-1}, W_{t-1}, r_{t-1})$
MSE _{VAL}	0,173661	0,123717	0,083312	0,127905	0,072883
použitá metóda	UNS	Cloud-RBF	UNS	cloud-RBF	cloud-RBF
r _{1Q2008}	3,736	2,139	3,691	1,89	2,597

Ekonomika Slovenskej republiky prešla od roku 1993 výrazným rozvojom, ktorý vplýval na vývoj cien. V prvých mesiacoch vzniku SR miera inflácie dosahovala dvojčíferné hodnoty, v roku 1996 sa ustálila okolo hodnoty 5,5 %. V rokoch 1999 a 2000 nastal vysoký rast inflácie spôsobený ozdravnými opatreniami. Po roku 2000 inflácia začala postupne klesať. Vývoj cien v SR bol za minulé obdobia veľmi neštandardný.

Údaje, ktoré sa použijú na kvantifikáciu modelu veľkou mierou ovplyvňujú jeho modelovacie schopnosti. Doteraz sme na modelovanie inflácie používali údaje z rokov 1994 – 2007. Ak budeme kvantifikovať model (3.5) na iných, vekovo mladších množinách dát, získame iné výsledky presnosti aproximácie a predikcie vývoja inflácie. Tieto hodnoty sú uvedené v tabuľke 3.3. Model bol kvantifikovaný pomocou vekovo mladších údajov.

Tabuľka 3.3: Modelovanie vzťahu $r_t = f(U_{t-1}, W_{t-1}, r_{t-1})$ založenom na cloud-RBF sieti kvantifikovaného na rôznych množinách dát

Množiny dát	1994 - 2007	1996 - 2007	1998 - 2007	2000 - 2007	2002 - 2007
MSE _{TRAIN}	0,217477	0,19299	0,247539	0,254352	0,254952
MSE _{VAL}	0,07501	0,07634	0,063469	0,036225	0,030382
r _{1Q2008}	2,739	2,557	2,525	2,878	2,937

Prognostická schopnosť modelov sa pri vynechaní starších údajov zlepšuje. Treba však poznamenať, že pri menšej množine vstupných dát sa zmenší i validačná množina a presnosť modelu je vtedy hodnotená na menšom počte údajov. Voľba správnej množiny pozorovaní je veľmi podstatná.

5 Závery z realizovaných experimentov

Výskum a aplikácie neurónových sietí súi zamerané jednak na zdokonaľovanie učiacich metód a architektúr RBF sietí a na ich overenie v praxi na ekonomických procesoch pre konštrukciu krátkodobých prognóz a aproximáciu vstupno-výstupných funkcií ekonomických procesov a systémov.

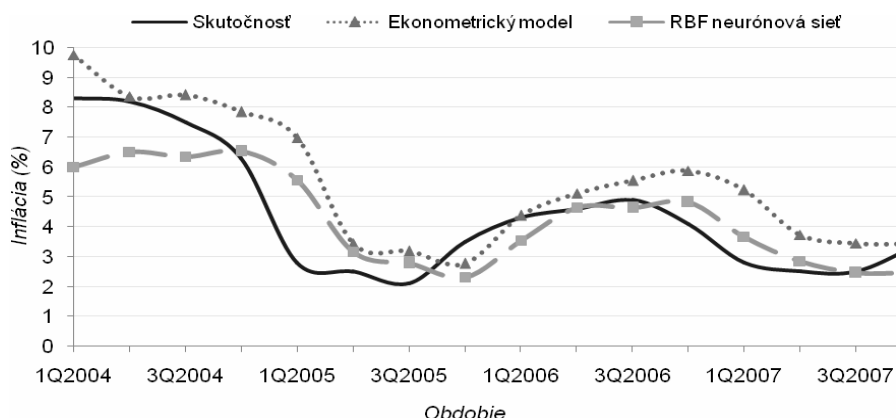
V súčasnosti sa mnoho výskumníkov zaoberá prognózovaním časových radov pomocou UNS a vedú sa diskusie, či UNS je spoľahlivou kvantitatívnou prognostickou metódou v porovnaní s tradičnými kvantitatívnymi predikčnými metódami založenými na štatistických a ekonometrických metódach. Existuje mnoho článkov o výskume UNS pre prognózovanie krátkych a cvičných (vzorových, testovacích) časových radov [8]. Posledné publikácie v uznávaných časopisoch [2], [8], dokumentujú schopnosť prognózovania časových radov s poukázaním na ich stále zvyšujúcu sa výpočtovú výkonnosť a s naznačením možnosti vytvárania automatických prognostických systémov pre automatické prognózovanie.

Výsledky v tejto kapitole dokumentujú vhodnosť konštruovania prognóz na báze strojového učenia SVM a UNS. Tieto výsledky možno zhrnúť do nasledujúcich bodov.

- SVM metóda [] sa v aplikácii prejavila ako metóda s najlepšimi aproximačnými vlastnosťami vstupno-výstupných funkcií systémov. Je to pochopiteľné, lebo špecifikované funkcie sú s veľkým počtom parametrov. Na odhad parametrov sa používa štandardná optimalizačná metóda konvexného kvadratického programovania pri minimalizácii účelovej funkcie empirického rizika. Na druhej strane vysoko parametrizované funkcie majú tú nevýhodu, že slabo zovšeobecňujú, čo je známym poznatkom a čo bolo i vidieť vo všetkých aplikáciách SVM metódy.

- RBF neurónové siete (klasická, soft a granulárne) preukázali na dlhom časovom rade schopnosť lepšie aproximovať a súčasne lepšie (s lepšou chybovou prijateľnosťou) predikovať časové

rady. Na ďalšom obrázku 5.1 [6] je grafické porovnanie skutočných hodnôt inflácie s prognózami ex-post získanými pomocou ekonometrického modelu a RBF umelej neurónovej siete.



Obr. 5.1 Porovnanie skutočných hodnôt inflácie s prognózami ex-post

PodĎakovanie: Príspevok bol napísaný za podpory Grantovej agentúry Slovenskej republiky VEGA pod číslom projektu 1/0024/08 a grantovou agentúrou Českej republiky GAČR č. projektu 402/08/0022.

Literatúra

- [1] Kecman, V. 2001: *Learning and Soft Computing, Support Vector Machines, Neural Networks, and Fuzzy Logic Models*. Massachusetts Institute of Technology, The MIT Press, 2001
- [2] Liao, K. P. & Fildes, R.: The accuracy of a procedural approach to specifying feedforward neural networks for forecasting. *Computers & Operations Research*, 32, 2151-2169 (2005)
- [3] Marček, D. – Marček, M. 2006. *Neurónové siete a ich aplikácie*. Žilina: EDIS – vydavateľstvo ŽU, 2006
- [4] Marček, D. 1999. *Ekonometria, základy, postupy, aplikačné príklady*. Žilina: ES ŽU, 1999
- [5] Marček, M. – Pančíková, L. – Marček, D. 2008. *Ekonometria a soft computing*. Žilina: EDIS – vydavateľstvo ŽU, 2008
- [6] Marček, M., Vorčák, A.: *Modelovanie inflácie RBF sieťami*. 4. mezinárodná konferencia Řízení a modelování finančních rizik . VŠB-TU Ostrava, Ekonomická fakulta, katedra Financí 11.-12. září 2008, (v tlači)
- [7] Vorčák, A.: *Algoritmy a prediktory ekonomických veličín s využitím ekonometrických metód a RBF funkcií*. Diplomová práca FRI ŽU, máj 2008
- [8] Zhang, G. P. & Qi, M.: Neural network forecasting for seasonal and trend time series. *European J. of Operational Research*, 160, 501-514 (2005)

Autori:

Milan Marček, Medis, spol. s r.o., Pri Dobrotke, 659/81, 948 01 Nitra, marcek@medis.sk, marcek@fria.utc.sk, Fakulta riadenia a informatiky, Žilinská univerzita, Vysokoškolákov 1, 010 26 Žilina, Slezská univerzita, Ústav informatiky, Bezručovo nám. 13, 746 01 Opava
Anton Vorčák, Fakulta riadenia a informatiky, Žilinská univerzita, Vysokoškolákov 1, 010 26 Žilina, Anton.Vorcak@fri.uniza.sk