

MODELOVÁNÍ VÝVOJE HRUBÉHO DOMÁCÍHO PRODUKTU POMOCÍ DOPŘEDNÝCH NEURONOVÝCH SÍTÍ

Ivan Šeda, Vladimír Olej

Ústav systémového inženýrství a informatiky, FES, Univerzita Pardubice

Abstract: *The paper presents the possibility of the design of feed-forward neural networks with pre-processing inputs with learning algorithm Back-propagation in predicting of gross domestic product development. For design models are exploited index of leading economic indicators and diffusive index of leading economic indicators as a representative of leading indexes which enabled predicting break-even points.*

Key words: Gross domestic product, feed-forward neural networks, back-propagation, index of leading economic indicators, diffusive index of leading economic indicators

1 Úvod

Neuronové sítě (NS) [4] nabízejí v oblasti predikce ekonomických proměnných možnou alternativu k ekonometrickým metodám. Jejich nespornou výhodou je schopnost učení s učitelem a analýza rozsáhlých množin dat. Hrubý domácí produkt (HDP) [2, 3, 13] je základním národohospodářským agregátem jenž představuje makroekonomický výstup dané země. Je definován jako hodnota veškerých finálních statků a služeb vyprodukovaných uvnitř země během daného období. Velikost HDP a jeho změna v čase poskytují základní informace o ekonomické úrovni a výkonnosti země. Celkový HDP představuje ekonomickou sílu dané země.

Ve druhé části článku jsou popsány ekonometrické modely vývoje HDP, index vedoucích ekonomických indikátorů (IVEI) [9] a jeho difúzní index vedoucích ekonomických indikátorů (DIVEI) včetně vyrovnání trendové složky v časových řadách těchto indexů pomocí adaptivních přístupů. Ve třetí části je návrh modelu vývoje HDP pomocí dopředných neuronových sítí, jenž jsou učeny algoritmem Back-propagation. Čtvrtá část obsahuje analýzu navrhnutého modelu pro predikci HDP a výsledky odchylek. V poslední části je souhrn tohoto článku.

2 Modely vývoje hrubého domácího produktu

Moderní ekonometrie umožňuje konstrukci a testování široké škály modelů reálných vztahů. V oblasti predikce ekonomických proměnných jsou nejčastěji používané modely založené na těchto metodách [Spěv99]:

- metoda extrapolace časových řad,
- ekonometrické modely,
- metoda scénářů,
- reflexivní a intuitivní metody,
- expertní metody.

V ekonomické praxi existují modely pro predikci makroekonomických veličin, které sestávají důležité národní a nadnárodní instituce a organizace [9]. Těmito modely (pro HDP USA) jsou například model predikce OECD nebo model Federální rezervní banky San Francisco (FRBSF). Predikce OECD tvoří konzistentní časovou řadu, umožňující objektivní komparaci přesnosti modelu v čase. Studie o tomto modelu uvádějí [9], že predikované hodnoty OECD jsou co do velikosti i směru porovnatelné s predikcemi podobných institucí, např. Mezinárodního měnového fondu. Výsledný predikovaný vývoj HDP je v modelu FRBSF určován jako řetězec vážených ukazatelů, které mají vliv na budoucí vývoj HDP. Jsou to výše zaměstnanosti, průmyslová výroba, maloobchodní prodeje a HDP za tři předchozí období. Výsledky tohoto modelu jsou v porovnání s modelem OECD horší z důvodů nižší komplexnosti struktury modelu. Existující modely predikce vývoje HDP používají různé formulace vztahů a různé metody odhadů parametrů, což způsobuje různou míru jejich přesnosti.

Přesnost predikce pro všechny typy modelů lze měřit pomocí střední chyby ε , střední absolutní chyby σ a střední kvadratické odchylky δ .

Ekonomické ukazatele [6] lze obecně rozdělit do tří skupin podle načasování bodů zvratu v jejich časových řadách ve vztahu k referenční řadě, která charakterizuje skutečný výskyt bodu zvratu. Nejsledovanější jsou předstihové ukazatele (např. IVEI), které umožňují předvídatí a prognózování bodů zvratu. V časových řadách těchto ukazatelů se projevuje bod zvratu s určitým časovým předstihem před jeho výskytem v referenční řadě. Vedle předstihových ukazatelů jsou z hlediska načasování (ve vztahu ke skutečnému bodu zvratu) rozlišovány ještě souběžné ukazatele a zaostávající ukazatele.


Index vedoucích ekonomických indikátorů [9, 6] patří do skupiny agregátních ukazatelů. Je definován jako vážený aritmetický průměr 10 ekonomických proměnných, o kterých je známo, že vedou ekonomický cyklus a že jsou procyklické, předstihové. To znamená, že změny v jejich trendu nastávají před změnami v trendu agregátní ekonomické aktivity a to ve stejném směru. Těmito ekonomickými proměnnými jsou:

- průměrný týdenní počet odpracovaných hodin ve zpracovatelském průmyslu,
- průměrný týdenní počet nových nároků na čerpání pojištění v nezaměstnanosti,
- hodnota nových objednávek zpracovatelů na spotřební produkty a materiály,
- rychlost dodavatelů (podíl zpracovatelů hlásících zpomalení dodávek),
- nové objednávky zpracovatelů na civilní kapitálové statky,
- počet stavebních povolení na nové soukromé bytové jednotky,
- ceny akcií podle indexu Standard's & Poors 500 Common Stocks,
- peněžní zásoba (agregát M2),
- rozpětí úrokových sazeb (rozdíl mezi krátkodobými a dlouhodobými úrokovými sazbami),
- index spotřebitelských očekávání.


K IVEI existuje difúzní IVEI, který měří jaké procento z ekonomických proměnných zahrnutých v IVEI klesá a jaké roste, tedy jaká proporce ekonomických proměnných již naznačuje změnu trendu ekonomického růstu.

Na modelování predikce vývoje HDP je možné použít indexy IVEI i DIVEI [11]. Oba indexy jsou v praxi používané na predikci recese. Spojením těchto dvou indexů vzniká spolehlivý signál recese. Předpokládá se, že recese nastane, když průměrná míra růstu IVEI klesne pod 2% a zároveň hodnota DIVEI klesne pod kritickou hodnotu 0.5. Vývoj IVEI a DIVEI je znázorněn na obr. 1 a obr. 2.

Provádění dekompozice časové řady je motivováno nadějí, že se v jednotlivých složkách rozkladu snáze podaří identifikovat pravidelné chování řady než v původní nerozložené řadě. Časovou řadu [5] lze pomocí klasického modelu dekomponovat na trendovou, sezónní, cyklickou a náhodnou složku.




Obr. 1: Vývoj IVEI v letech 1965 - 1995




Obr. 2: Vývoj DIVEI v letech 1965 - 1995

Trendová složka [1] odráží dlouhodobé změny v průměrném chování časové řady a lze ji modelovat pomocí adaptivních přístupů. Výhodou těchto přístupů je schopnost pracovat s trendovými složkami, které mění v čase globálně svůj charakter, takže pro popis nelze použít žádnou matematickou křivku s neměnnými parametry. Mezi adaptivní přístupy k vyrovnání trendové složky se řadí různé varianty klouzavých průměrů [1] (jednoduché, vážené, trojúhelníkové atd.), exponenciální vyrovnávání [5] a robustní klouzavé průměry [7]. Trendové složky IVEI i DIVEI byly vyrovnány pomocí sedmiměsíčního klouzavého průměru (7KP), sedmiměsíčního váženého klouzavého průměru (7VKP), sedmiměsíčního trojúhelníkového klouzavého průměru (7TKP) a sedmiměsíčního klouzavého mediánu (7KM). Dále byly vyrovnány pomocí šestiměsíčního centrovaného klouzavého průměru a jednoduchého exponenciálního vyrovnávání s parametrem $\alpha=0.2$ [1]. Příklad vyrovnání trendové složky IVEI i DIVEI pomocí 7KM je uveden na obr. 3 a obr. 4.



Obr. 3: Vývoj IVEI v letech 1965 - 1995 vyrovnaný pomocí 7KM



Obr. 4: Vývoj DIVEI v letech 1965 - 1995 vyrovnaný pomocí 7KM

3 Návrh modelu na predikci hrubého domácího produktu

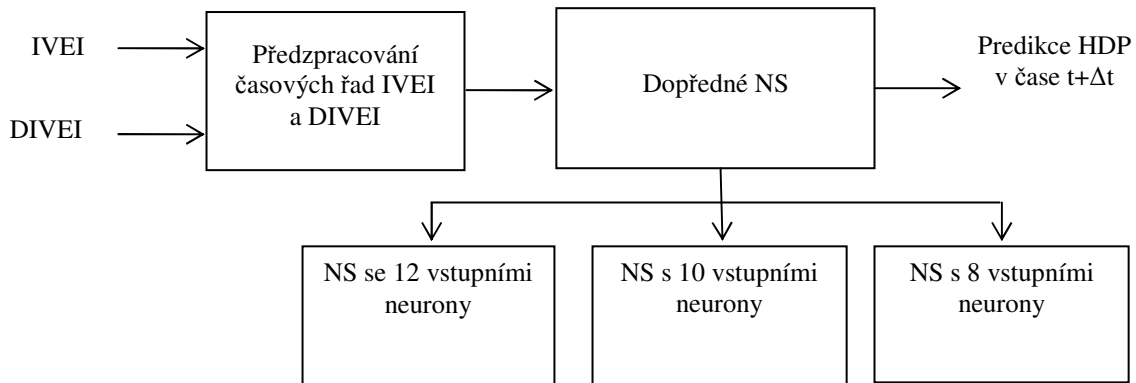
Do navrženého modelu vstupují dva indexy, IVEI a DIVEI. Trendové složky v jejich časových řadách jsou následně vyrovnány pomocí adaptivních metod uvedených v předchozí části. Vybraná část takto předzpracovaných časových řad tvoří vstupy do dopředné NS, jejichž výstupem je predikce HDP v čase $t + \Delta t$. Změnu výsledku modelu přináší změna struktury dopředné NS. Model na predikci HDP je znázorněn na obr. 5.

Neuronové sítě s dopředným šířením signálu jsou acyklickým typem sítí [8], nikdy v nich nevzniká zpětnovazební smyčka. V modelu na predikci HDP jsou využity tyto typy sítí s tím, že vstupní vektor je tvořen hodnotami vyrovnaných časových řad pro IVEI a DIVEI. Výstup dopředné neuronové sítě je možné vyjádřit takto [9]

$$Y = \sum_{k=1}^K \alpha_k \cdot d \left(\sum_{j=1}^J \beta_{jk} \cdot X_{jk} \right),$$


- kde: - Y je výstup neuronové sítě,
 - α je vektor vah mezi neurony ve skryté vrstvě a výstupním neuronem,

- β je vektor vah synapsí mezi vstupními neurony a neurony ve skryté vrstvě,
- k je index neuronu ve skryté vrstvě,
- d je aktivační funkce,
- j je index vstupního neuronu,
- X je vstupní vektor neuronové sítě.



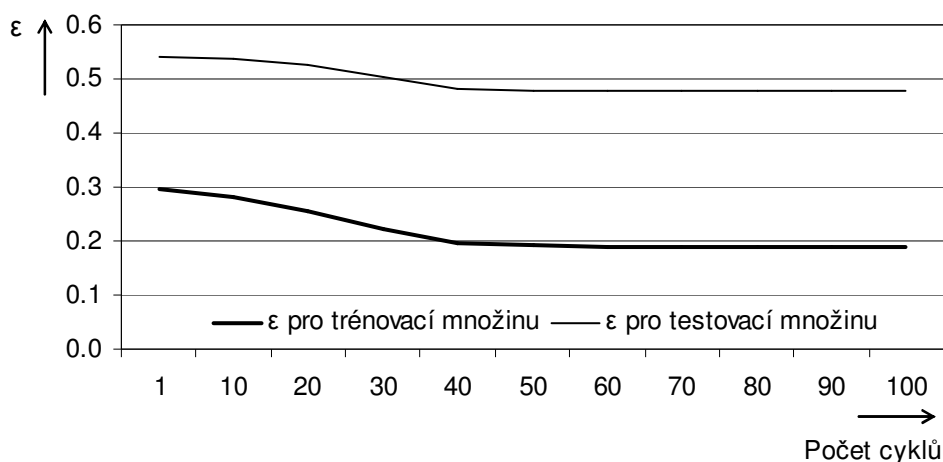
Obr. 5: Model na predikci HDP

Na obr. 6 je uvedena struktura dopředné NS s jednou skrytou vrstvou, kde X jsou vstupní vektory a Y je výstupní neuron.



Obr. 6: Dopředná neuronová síť

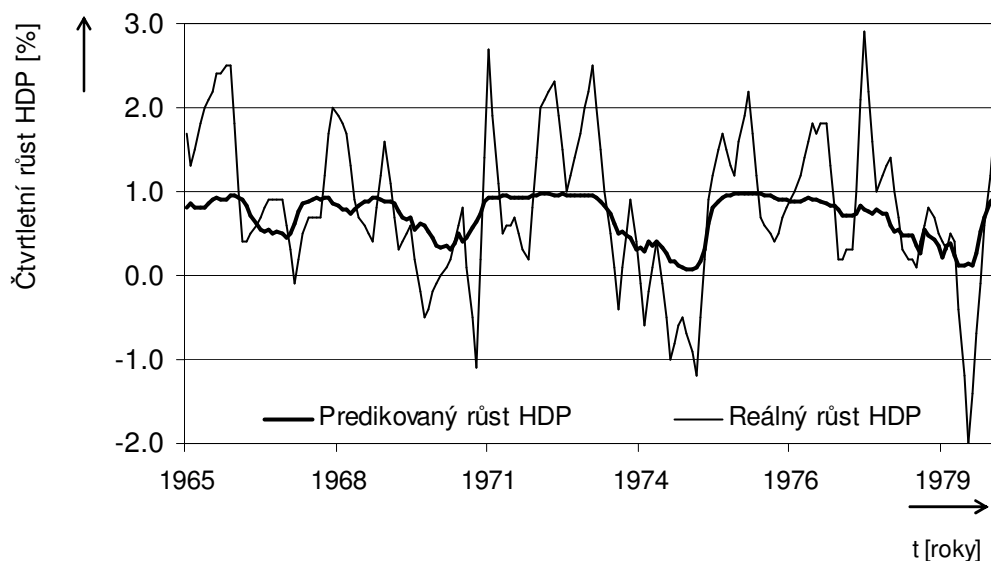
V procesu učení dopředné NS se využívá učící algoritmus zpětného šíření chyby Back-propagation [8], jenž se skládá ze tří hlavních etap. První etapou je dopředné šíření vstupního signálu učícího vzoru skrz všechny vrstvy NS. Predikovaná hodnota, výstup z NS, se porovnává se skutečnou hodnotou. Rozdíl mezi těmito hodnotami, chyba, se ve druhé etapě zpětně šíří. Ve třetí etapě se upravují hodnoty vah synapsí tak, aby došlo k minimalizaci chyby NS. Zobrazení chyby ε během trénování a testování NS je uvedeno na obr. 7.



Obr. 7: Zobrazení ε pro trénovací a testovací množinu.

4 Analýza výsledků

Navržené modely dopředných neuronových sítí byly trénovány na historických datech z let 1965 – 1980 a testovány na datech z let 1980 – 1995. Na obr. 8 je znázorněn vývoj růstu HDP a predikovaný vývoj růstu HDP (tučně).



Obr. 8: Predikce čtvrtletního růstu HDP

Střední chyby ε a střední kvadratické odchylky δ pro jednotlivé navržené modely včetně počtu cyklů, které jsou potřebné k natrénování daných modelů uvádí tab. 1. Hodnota indikátoru δ poukazuje na existenci několika velkých individuálních chyb v predikci. Název modelu vypovídá o jeho struktuře, počtu neuronů v jednotlivých vrstvách. Z tab. 1 vyplývá, že snižováním počtu neuronů ve vstupní a skryté vrstvě vede ke snižování ε a δ . Neuronová síť s malým počtem neuronů však není schopna zachytit veškeré závislosti ve vstupních datech. Počet neuronů je třeba pečlivě volit.

Problematická je predikční schopnost [10] IVEI a DIVEI v letech 1981, 1982 a 1991, kdy došlo k jasnému signálu recese až na začátku samotné recese, a v roce 1966, kdy došlo k falešnému signálu recese.

Tab. 1: Výsledky modelů

Model	ε	δ	Počet cyklů
12-11-1	0.9896	0.9948	200
12-9-1	0.5372	0.7329	150
12-7-1	0.3646	0.6038	100
12-5-1	0.2962	0.5442	50
12-13-1	5.6480	2.3766	350
10-9-1	0.4087	0.6393	125
10-7-1	0.3095	0.5564	75
10-5-1	0.2464	0.4964	50
10-3-1	0.2023	0.4498	25
8-7-1	0.2845	0.5334	75
8-5-1	0.2394	0.4892	45
8-3-1	0.2055	0.4533	25

Recese [10] v letech 1981-82 byla spojena s restriktivní monetární politikou nejen v USA, ale také v zemích s nimiž obchoduje. Index IVEI však nebere do úvahy ekonomické proměnné charakterizující vývoj v zahraničí. Recese v roce 1991 souvisela s náhlým poklesem poptávky domácností. Ekonomické proměnné zachycující změny v agregátní poptávce jsou v IVEI velmi málo zastoupené.

5 Závěr

Článek je zaměřen na ukázkou možnosti použití dopředných NS na modelování vývoje HDP. Obsahuje návrh modelu na predikci vývoje HDP sestávající se z předzpracování časových řad indexů IVEI a DIVEI, které následně vstupují do NS jejichž výstupem je predikovaná hodnota HDP v čase $t+\Delta t$. Výsledky navrženého modelu jsou reprezentovány z hlediska minimalizace střední kvadratické odchylky s ohledem na počty neuronů ve vstupních a skrytých vrstvách v NS.

Literatura:

- [1] CIPRA, T. Analýza časových řad s aplikacemi v ekonomii. 1. vydání. Praha: SNTL/Alfa, 1986, (248 s). ISBN 04-012-86.
- [2] DORNSBUCH, R., FISHER, S. Macroeconomics. 6. vydání. Boston: McGraw-Hill, Inc., 1994, (s. 42-48). ISBN 80-04-25556-6.
- [3] FRANK R., BERNANKE, B. Ekonomie. 1 vydání. Praha: Grada Publishing, a. s., 2003, (804 s). ISBN 80-247-0471-4.
- [4] HAYKIN, S. Neural Networks – A Comprehensive Foundation. 2nd edition. New Jersey: Prentice Hall. 1999, (842 s). ISBN 0-13-273350-1.
- [5] HINDLS, R., KAŇOKOVÁ, J., NOVÁK, I. Metody statistické analýzy pro ekonomy. 1. vydání. Praha: Management Press, 1997, (248 s). ISBN 80-85943-44-1.
- [6] KADERÁBKOVÁ, A. Základy makroekonomické analýzy. 1. vydání. Praha: Linde, 2003, (175 s). ISBN 80-86131-36-X.
- [7] KOZÁK, J., HINDLS, R., ARTL, J. Úvod do analýzy ekonomických časových řad. 1. vydání. Praha: VŠE v Praze, 1994, (208 s). ISBN 80-7079-760-6.
- [8] MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. a kol. Umělá inteligence (4). 1. vydání. Praha: Academia, Akademie věd České republiky, 2003, (475 s). ISBN 80-200-1044-0.
- [9] OLEJ, V. Modelovanie ekonomických procesov na báze výpočtovej inteligencie. Hradec Králové: Miloš Vognar – M&V, 2003, (160s). ISBN 80-903024-9-1.
- [10] OLEJ, V. Design of the Models of Neural Networks and the Takagi-Sugeno Fuzzy Inference System for Prediction of the Gross Domestic Product Development. *WSEAS Transactions on Systems*. WSEAS Press, Issue 4, Vol.4, April 2005, pp.314-319, ISSN 1109-2777. Special Issue: Selected Papers the 6th WSEAS International Conference of Fuzzy Systems and the 6th International Conference on Neural Networks, Lisbon, Portugal, June 16-18, 2005.
- [11] OLEJ, V., KŘUPKA, J. Prediction of Gross Domestic Product Development by Takagi-Sugeno Fuzzy Inference Systems. *Proc. of the IEEE 5-th International Conference on Intelligent Systems Design and Applications, ISDA 05*. Wroclaw, Poland, Kwasnicka, Paprzycki, Eds., IEEE Computer Society, Los Alamitos, California, 2005, September 8-10, pp.186-191, ISBN 0-7695-2286-6.

[12] SPĚVÁČEK, V. Makroekonomická analýza a prognózování. Praha: Vysoká škola ekonomická, Fakulta národohospodářská, 1999, (119 s). ISBN 80-7079-922-6.

[13] ŽÁK M., a kol. Velká ekonomická encyklopedie. 2. rozšířené vydání. Praha: Linde Praha, a. s. 2002, (887 s). ISBN 80-7201-381-5.

Kontaktní adresy:

Ing. Ivan Šeda, prof. Ing. Vladimír Olej, CSc.
Ústav systémového inženýrství a informatiky
Fakulta ekonomicko-správní
Univerzita Pardubice
Studentská 84, 532 10 Pardubice
i.seda@seznam.cz, vladimir.olej@upce.cz
tel. č.: 466036075, 466036004