

PREDIKČNÍ MODELY S NEURONOVÝMI SÍTĚMI

V. Konečný

Došlo: 16. října 2007

Abstract

KONEČNÝ, V.: *Predictions models with neural nets*. Acta univ. agric. et silvic. Mendel. Brun., 2008, LVI, No. 3, pp. 109–118

The contribution is oriented to basic problem trends solution of economic pointers, using neural networks. Problems include choice of the suitable model and consequently configuration of neural nets, choice computational function of neurons and the way prediction learning. The contribution contains two basic models that use structure of multilayer neural nets and way of determination their configuration. It is postulate a simple rule for teaching period of neural net, to get most credible prediction.

Experiments are executed with really data evolution of exchange rate Kč/Euro. The main reason of choice this time series is their availability for sufficient long period. In carry out of experiments the both given basic kind of prediction models with most frequent use functions of neurons are verified. Achieve prediction results are presented as in numerical and so in graphical forms.

trend, neural net, time series, model, learning of neural net, error function, prognosis

Pro jednoduchou aplikovatelnost a dostupnost výpočetní techniky nacházejí umělé neuronové sítě stále širší využití v automatizaci rozhodovacích procesů. Představují určitou konkurenční metodu oproti tradičním metodám a jsou jedním ze základních nástrojů pro dolování dat v aplikacích podnikové inteligence (Konečný, 2005). Využívají samoučení na vzorových datech, která mohou obsahovat neznámé nebo těžce vyjádřitelné vnitřní souvislosti a navíc mnohdy ještě zastřené šumem. Schopnost filtrace šumu a odhalení zákonitosti vývoje je staví do popředí zájmu při řešení prognostických úloh.

Vícevrstvé umělé neuronové sítě představují univerzální aproximační (lineární i nelineární) nástroj, kterým lze v průběhu procesu učení, na základě vzorových dat, vytvořit nelineární model funkce n proměnných. Pro účely tvorby prognóz lze sestavit různě složité modely, ovšem pro jejich úspěšné využití je nutno vždy řešit několik základních problémů, jako např. konfiguraci neuronové sítě, výpočetní funkci neuronů, přesnost učení neuronové sítě, atd. A právě na tyto problémy je zaměřena hlavní pozornost tohoto příspěvku.

Uvedená problematika byla řešena v rámci VZ MSM 6215648904.

MATERIÁL A METODY


Praktické využití vícevrstvé neuronové sítě je ve všech aplikacích založeno na vytvoření aproximačního modelu funkce(i) více proměnných. Jeho vlastnosti jsou ovlivňovány konfigurací sítě, tj. počtem vstupních a výstupních neuronů, počtem neuronů ve skryté vrstvě, počtem skrytých vrstev a výpočetní funkcí neuronů.

Schéma n vrstvé sítě modelující funkce $O_i(x_1, x_2, \dots, x_p)$ je uvedena na obr. 1. Za předpokladu, že neuronová síť má p – vstupních neuronů, q – ve skrytých vrstvách a r – výstupních neuronů, v procesu učení se musí nastavit:

- $q(p + 1)$ parametrů mezi vstupní a první skrytou vrstvou,
- $(n - 3)(q + 1)q$ parametrů ve skrytých vrstvách ($n \geq 3$),
- $(q + 1)r$ parametrů ve výstupní vrstvě, tj. celkem

$$S_n = q(p + 1) + (q + 1)[q(n - 3) + r] \quad (1)$$

reprezentovaných vahami W a prahovými hodnotami Θ .



1: Vícevrstvá neuronová síť

S růstem počtu vrstev a neuronů ve skrytých vrstvách se počet parametrů sítě zvětšuje a tím i možnosti modelování složitějších funkcí. Pro většinu úloh je však postačující jedna skrytá vrstva s počtem neuronů

$$q \geq \min(p, r), \quad (2)$$

resp.

$$q \geq \max(p, r). \quad (3)$$

Vztahem (2) je v případě rovnosti garantována minimalizace počtu neuronů ve skrytých vrstvách, ale síť se může hůře učit. To znamená, že pro zadanou hodnotu chybové funkce je zapotřebí více epoch učení, případně zadaná hodnota není dosažitelná. Pro první pokusy je vhodnější použít vztah (3) a v rámci optimalizace buď zmenšovat nebo zvětšovat počet neuronů a případně i vrstev.

Jak již bylo uvedeno, kromě konfiguračních parametrů jsou vlastnosti modelu ovlivněny i funkcí neuronů. Nejčastěji se používá sigmoidální funkce

$$Y_1(x) = \frac{1}{1 + e^{-x}}, \quad (4)$$

kde $Y_1(x) \in (0, 1)$ nebo

$$Y_2(x) = \frac{Y_{\max} - Y_{\min}}{1 + e^{-x}} + Y_{\min}, \quad (5)$$

kde $Y_2(x) \in (Y_{\min}, Y_{\max})$ a lineární funkce

$$Y_3(x) = c \cdot x, \quad (6)$$

kde koeficient $c < 1$ (např. $c \approx 0,1$).

Učení vícevrstvé neuronové sítě (korekce parametrů W a Θ) na základě vzorů (učení s učitelem) se provádí obvykle metodou zpětného šíření chyb – viz

(Konečný a kol., 2005) a to tak, aby se minimalizovala hodnota chybové funkce

$$E = \frac{1}{2} \sum_i \sum_j [Y_j(X_i) - Y_j^o(x_i)]^2, \quad (7)$$

kde $Y_j^o(x_i)$ je požadovaná hodnota a $Y_j(X_i)$ skutečná hodnota j -tého výstupu, při vstupech daných vektorem X_i . Proces učení se ukončí:

- při dosažení hodnoty chybové funkce $E \leq E_o$ (E_o – zadaná hodnota),
- je-li absolutní hodnota změny chybové funkce na zadaný počet epoch učení menší než zadaná hodnota, tj. $|\Delta E|/N_e \leq \delta$ (N_e – zadaný počet epoch, δ – přípustná velikost změny)
- nebo po provedení požadovaného počtu epoch učení.

Všemi uvedenými způsoby ukončení procesu učení sítě lze způsobit tzv. *nedoučení* (nepřesné učení velká hodnota E) nebo *přeučení sítě* (důsledné učení malá hodnota E) a v důsledku toho získat lépe nebo hůře fungující model. Pojem přeučení není zcela správný, protože při tvorbě aproximačních modelů by mělo platit, že čím přesněji je vytvořen model zadané funkce, tím lépe. Nicméně experimenty ukazují, že i nedoučení sítě může někdy způsobit zlepšení funkčnosti prognostického modelu.

Další problém, který může ovlivnit vlastnosti prognostických modelů, souvisí s počátečním nastavením parametrů W a Θ . Na počátku učení sítě neuronové sítě se tyto parametry nastavují zcela náhodně, často na hodnoty z intervalu $(0, 1)$. Nastavení jiných počátečních podmínek může způsobit nalezení jiného extrému chybové funkce, který je definován jinými parametry W a Θ , a které mohou způsobit i chování prognostického modelu.

Závěrem k uvedenému přehledu faktorů, které ovlivňují vlastnosti prognostického modelu, je nutno uvést, že dva základní konfigurační parametry neu-

ronové sítě, tj. počet vstupů a výstupů, jsou dány typem zvoleného trendového modelu.

Modely trendů


Odvození základního trendového modelu vychází z obecného pohledu na chování systému (Konečný, 2006) s pamětí. Jeho výstupy v následujícím časovém okamžiku jsou závislé na aktuálních vstupech a vnitřních stavech systému. Takovému předpokladu vyhovují ekonomické i sociální systémy, které jsou nejčastěji předmětem zkoumání jejich budoucího chování.

Nechť $X = \{x_1, x_2, \dots, x_p\}$ je vektor vstupů (viz obr. 2) a $S = \{s_1, s_2, \dots, s_k\}$ – vektor vnitřních stavů systému, pak výstupy systému $Y = \{y_1, y_2, \dots, y_r\}$ lze chápat jako závislosti

$$y_i(t) = f_i[X(t-1), S(t-1)], \quad (8)$$

resp.

$$Y(t) = F[X(t-1), S(t-1)]. \quad (9)$$



2: Obecný systém

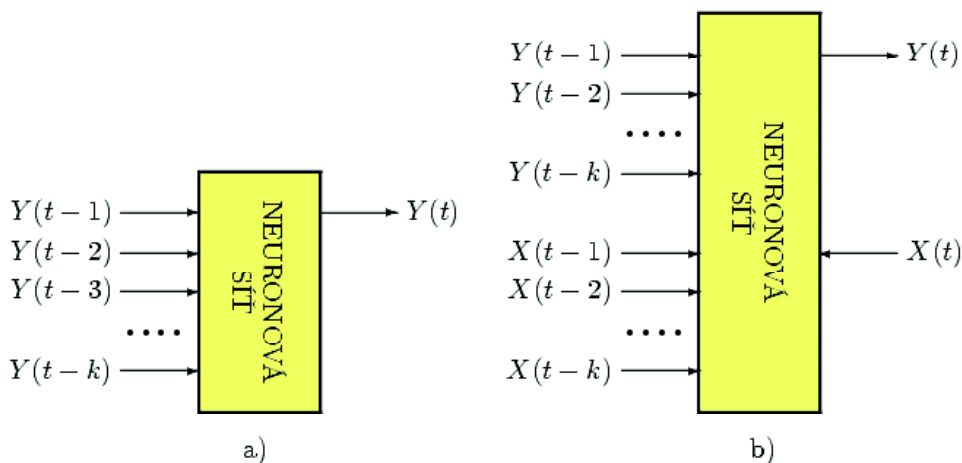
Pro zkoumání budoucího chování systémů mohou být obecně k dispozici hodnoty několika výstupních, případně i vstupních ukazatelů, a to v podobě časových řad. Hodnoty stavů a ve většině případů i vstupů systému nejsou známy, protože je prakticky nelze zjistit, a tedy nelze ani vytvořit prognostický model přímo, podle vztahu (8). Při neznámých hodnotách stavů i vstupů se musí předpokládat, že adekvátní informace je obsažena v hodnotách výstupů, protože každá hodnota časové řady výstupů je podle (8) závislá na stavu a vstupech systému. Funkci mo-

delu pro predikci následujících hodnot časových řad Y lze pak formálně vyjádřit vztahem

$$Y(t) = F[Y(t-1), Y(t-2), \dots, Y(t-k)], \quad (10)$$

kde k je počet předchozích hodnot časové řady použitých pro predikci požadované hodnoty.

Vztah (10) je formálním vyjádřením funkce predikčního modelu s neuronovou sítí, který je uveden na obr. 3a.



3: Základní modely trendů

Výchozí struktura neuronové sítě pro tento prognostický model bude obsahovat

$$N_{in} = r \cdot k \quad (11)$$

neuronů ve vstupní vrstvě, r neuronů ve výstupní a v souladu se vztahem (3) $r \cdot k$ neuronů ve skryté vrstvě.

V případě, že k dispozici jsou nejen časové řady výstupních veličin, ale také vstupních veličin, lze sestavit model, který umožní zkoumání vlivu vstupů X na výstupy systému Y . Formálně lze funkci takového modelu zapsat vztahem

$$Y(t) = F[Y(t-1), Y(t-2), \dots, Y(t-k), X(t), X(t-1), X(t-2), \dots, X(t-k)]. \quad (12)$$

Tento vztah představuje formální vyjádření prognostického modelu uvedeného na obr. 3b. Neuronová síť bude v tomto případě obsahovat

$$N_{in} = (p+r)k + p \quad (13)$$

vstupních neuronů, stejný počet neuronů ve střední vrstvě a r výstupních neuronů.

Uvedené modely lze jednoduše rozšířit o výstupy pro predikci hodnot dalších časových intervalů, tj. $Y(t+i\Delta_t)$, ale bez výrazného praktického přínosu, takže v uvedených modelech nejsou tyto výstupy uvažovány.

Vztahy (10) a (12) lze považovat za reprezentanty struktur učících souborů odpovídajících modelů. Po naučení se neuronová síť využívá ve výpočetním režimu, ve kterém se na základě posledních k hodnot časových řad X , Y a p vstupních hodnot $X(t)$ spočte jedna hodnota výstupů $Y(t)$. Doplněním spočtených hodnot do příslušných časových řad a následným výpočtem dalších hodnot lze provést libovolný počet kroků predikce a získat prognózu vývoje příslušné veličiny na delší časové období.

VÝSLEDKY A DISKUSE

V experimentech s predikčními modely budou využity časové řady vývoje kurzu Kč/USD a Kč/EUR s hodnotami, které jsou uvedené v tab. I a graficky znázorněné na obr. 4. Důvodem pro jejich výběr je dostupnost, dále i to, že představují proces charakterizovaný globální složkou a změnami, které mají spíše náhodný charakter.

I: Časové řady R1 a R2

1–10	11–20	21–30	31–40	41–50	51–60	61–70	71–80	81–85
Časová řada R ₁ (Kč/USD – 20,00)								
1,49	1,50	1,02	0,87	0,67	0,84	0,95	1,02	1,36
1,58	1,41	0,96	0,78	0,59	0,90	1,05	1,11	1,36
1,45	1,38	0,95	0,84	0,69	0,90	1,02	1,31	1,33
1,41	1,26	0,98	0,74	0,67	0,89	1,06	1,34	1,32
1,35	1,17	1,06	0,65	0,59	0,82	0,98	1,40	1,35
1,39	0,91	1,06	0,63	0,64	0,73	1,01	1,45	
1,47	0,85	0,92	0,58	0,67	0,85	1,04	1,47	
1,47	0,95	0,92	0,61	0,76	0,89	1,01	1,40	
1,39	1,00	0,91	0,61	0,72	0,95	1,03	1,35	
1,44	0,94	0,78	0,60	0,70	0,97	1,03	1,33	
Časová řada R ₂ (Kč/EUR – 27,00)								
1,32	1,17	0,96	0,90	1,02	1,24	1,25	1,39	1,68
1,42	1,23	0,96	0,93	1,06	1,24	1,25	1,41	1,62
1,38	1,20	0,98	0,98	1,13	1,26	1,31	1,46	1,69
1,24	1,11	1,04	0,97	1,12	1,28	1,33	1,47	1,70
1,11	1,04	1,07	0,96	1,14	1,27	1,30	1,50	1,73
1,16	0,85	1,00	0,95	1,15	1,14	1,33	1,53	
1,14	0,73	0,96	0,94	1,13	1,13	1,28	1,59	
1,13	0,85	0,96	0,99	1,14	1,20	1,27	1,57	
1,13	0,94	0,95	1,02	1,15	1,16	1,36	1,60	
1,14	0,96	0,91	1,01	1,19	1,23	1,41	1,59	

Délka časové řady by v obecném případě měla být taková, aby obsahovala podstatnou informaci pro predikci budoucího vývoje sledovaného ukazatele.


V případě uvedených časových řad kurzů se předpokládá, že rozhodující pro prognózu vývoj budou hodnoty za uplynulé čtvrtletí (tj. cca 80 údajů). Převzaté časové řady neobsahují hodnoty za dny pracovního klidu. Otázka, zda může tato neúplnost časových řad výrazně ovlivnit funkci prognostického modelu, není předmětem zkoumání v tomto příspěvku. Následujících 5 hodnot bude použito pro kontrolu přesnosti vlastní predikce.

Pro lepší konvergenci procesu učení a přesnost prognostického modelu jsou skutečné hodnoty

kurzu zmenšeny o 27 – pro kurz Kč/EUR a 20 pro kurz Kč/USD.

Obě časové řady lze považovat za časové řady výstupů systému KB (Komerční banka 23. 2. 2006–19. 6. 2006), ale vzhledem k tomu, že kurz koruny je vázán na USD a EUR a tyto se také vzájemně ovlivňují, je možné považovat jednu řadu za výstupní a druhou za vstupní.

Za hlavní faktory, které ovlivňují řešení prognostických úloh pomocí vícevrstvé neuronové sítě, budou považovány: *typ modelu, konfigurace neuronové sítě pro daný model, výpočetní funkce neuronů a podmínky učení.*



4: Grafy časových řad

Typ modelu

V případě, že reálný systém je reprezentován pouze časovými řadami výstupů, bude pro řešení použit model uvedený na obr. 3a. Jsou-li k dispozici časové řady vstupů i výstupů systému, pak lze zkoumat prognózu výstupů v závislosti na vstupech systému, a pro řešení je nutno použít model uvedený obr. 3b.

Oba typy modelů předpokládají práci s několika časovými řadami. Jejich počtem je ovlivněna složitost modelu, neuronové sítě a také nároky na výpočetní systém. V současné době je ovšem výkon běžných osobních počítačů naprosto dostatečný i pro řešení poměrně rozsáhlých neuronových sítí obsahujících stovky neuronů.

Konfigurace neuronové sítě

Řešením konfigurace vícevrstvé neuronové sítě se rozumí stanovení počtu vstupních a výstupních neuronů sítě, počtu skrytých vrstev a počtu neuronů ve skrytých vrstvách. Pro modely na obr. 3 je počet vstupních neuronů dán vztahy (11) a (13).

S růstem hodnoty parametru k bude narůstat složitost neuronové sítě a v důsledku toho i možnost přesnějšího modelování požadované funkce definované zbytkem časové řady. Současně se ale bude ztrácet informace o dřívějším chování systému. To znamená, že přílišné zvyšování hodnoty parametru k nemusí zvyšovat kvalitu modelu. Naopak, malá hodnota k může způsobovat přílišnou filtraci, a tedy musí existovat nějaká optimální hodnota, při které je funkce modelu nejlepší. Pro počáteční konfiguraci bude proto volena malá hodnota tohoto parametru a potom, podle kvality modelu a možností daných délkou časové řady, bude zvyšována.

Počet výstupů modelu je dán počtem současně zpracovávaných časových řad, které reprezentují hodnoty vstupů a výstupů reálného systému. Praktické výsledky s modely na bázi vícevrstvé neuronové sítě ukazují, že modely jednou skrytou vrstvou jsou obvykle naprosto postačující. Je-li použita lineární funkce neuronu, pak je postačující síť pouze se vstupní a výstupní vrstvou, protože funkci komplikovanější sítě lze přetransformovat na funkci této jednoduché neuronové sítě.

Počet neuronů ve skryté vrstvě lze pro první přiblížení stanovit podle vztahu (2) nebo (3) a v rámci učení predikce jej dle potřeby upravovat.

Učení modelu

Učení neuronové sítě generovat požadované výstupní hodnoty se obvykle provádí tak, aby byla dosažena minimální hodnota chybové funkce (14). Jinak řečeno, aby neuronová síť realizovala zadanou funkci co nejpřesněji. Taková úroveň naučení neuronové sítě ale nemusí být vhodná pro prognostický model, protože zde se jedná o učení co nejlépe stanovit budoucí hodnoty zkoumaného výstupu systému. Nevhodné je jak přeučení ($E_{opt} > E$), tak i tzv. ($E_{opt} < E$) predikčního modelu s neuronovou sítí. Za optimální se považuje taková hodnota chybové funkce E , při které je funkce predikčního modelu nejlepší. Příklad možného projevu přeučení nebo nedoučení neuronové sítě je znázorněn na obr. 5. Zvýrazněná čára reprezentuje průběh hodnot naučené neuronové sítě.


Základním problémem procesu učení predikci je v dané fázi stanovení optimální hodnoty chybové funkce E_{opt} . Stanovení této hodnoty bude založeno na předpokladu, že hodnota E_{opt} platná pro predikci poslední hodnoty časové řady bude platná i pro predikci následujících hodnot. Její hodnota je rovna takové hodnotě chybové funkce E , při které chyba predikce

$$E_p(E) = \frac{1}{2} (Y_n^p - Y_n)^2 \quad (14)$$

poslední známé hodnoty (Y_n) časové řady bude minimální. Y_n^p je hodnota predikovaná modelem.

Minimalizací funkce E_p se nalezne optimální hodnota úrovně naučení neuronové sítě, tj. hodnota chybové funkce E , při které je E_p minimální. Není-li dosaženo uspokojivého výsledku, lze změnit hodnotu parametru k , funkci neuronů, případně i počet vrstev sítě.

Souhrnně jsou výsledky experimentů uvedeny v tab. II a pro větší názornost i v grafické podobě na obr. 6 a 7. Zvýrazněnou čarou jsou zobrazeny hodnoty naučené neuronové sítě. Predikované hodnoty jsou zobrazeny za 80. pozicí. V rámci prováděných experimentů byly testovány modely:



5: Vliv nedoučení a přeučení na prognostický model

- s jednou časovou řadou výstupu systému – modely 1÷5,
- se dvěma časovými řadami výstupů systému – modely 8÷9,
- s jednou časovou řadou vstupu a jednou časovou řadou výstupu systému – modely 6÷7.


V prvním modelu – kurz KČs/EUR (viz tab. II) se predikce provádí na základě 20 hodnot (tj. $k = 20$), se dvěma vrstvami neuronů (vstupní a výstupní) a s lineární výpočetní funkcí neuronů. Učení neuronové sítě s časovou řadou $Y_1 \div Y_{79}$ je prováděno tak, aby byla dosažena hodnota chybové funkce učení $E = 0,075$. Taková přesnost umožňuje predikci hodnoty Y_{80} s přesností $E_p = 5,024 \cdot 10^{-6}$ a predikci všech pěti hodnot ($Y_{81} \div Y_{85}$) s $E_p^5 = 4,593 \cdot 10^{-3}$. Maximální absolutní chyba činí 0,07 Kč. Horší výsledek byl dosažen

při využití sigmoidální funkce neuronů a při $k = 25$ (viz model 2 tab. II).


Nevyhovující výsledky byly dosaženy v modelech, kde se prováděla predikce hodnot dvou časových řad současně (modely 8 a 9). Slabší výsledek byl dosažen také v případě predikce KČ/USD s využitím sigmoidální funkce neuronů. Výsledky ostatních modelů lze považovat za přijatelné.

Zajímavé jsou výsledky modelů, ve kterých jsou hodnoty jedné časové řady považovány za vstupní hodnoty systému, tj. jejich hodnoty jsou známy i do budoucna a hodnoty druhé časové řady za výstupní, pro než se provádí predikce (modely 6 a 7).

Jak je patrné z tabulky II, predikce modelů s lineární funkcí je ve většině případů lepší. Těmito modely je, v důsledku větší filtrace náhodných změn, lépe sledován globální trend sledované veličiny.



6: Výsledky predikce modelů 1÷5



7: Výsledky predikce modelů 6÷9

II: Výsledky experimentů

Model	Predikce kurzu	Parametry modelu						$ \Delta_{\max} $ [Kč]
		Funkce	k	Vrstvy	E	E_p	E_p^5	
1.	Kč/EUR	lineární	20	2	0,075	$5,042 \cdot 10^{-6}$	$4,593 \cdot 10^{-3}$	0,07
2.	Kč/EUR	sigmoida	25	2	0,037	$4,815 \cdot 10^{-6}$	$2,054 \cdot 10^{-2}$	0,12
3.	Kč/USD	lineární	20	2	0,462	$6,879 \cdot 10^{-7}$	$5,830 \cdot 10^{-3}$	0,07
4.	Kč/USD	sigmoida	15	2	0,400	$1,760 \cdot 10^{-5}$	$5,590 \cdot 10^{-2}$	0,19
5.	Kč/USD	sigmoida	15	3	0,33	$7,440 \cdot 10^{-7}$	$7,990 \cdot 10^{-3}$	0,07
6.	Kč/EUR = $f(\text{Kč/USD})$	lineární	20	2	0,133	$5,262 \cdot 10^{-5}$	$1,113 \cdot 10^{-2}$	0,09
7.	Kč/USD = $f(\text{Kč/EUR})$	lineární	15	2	0,345	$1,352 \cdot 10^{-5}$	$3,660 \cdot 10^{-3}$	0,06
8.	Kč/EUR a Kč/USD	lineární	20	2	0,072	$4,10 \cdot 10^{-4}$	0,169	0,31
9.	Kč/EUR a Kč/USD	sigmoida	20	3	0,056	$2,324 \cdot 10^{-3}$	$9,618 \cdot 10^{-2}$	0,19

III: Výsledky predikce

Y(t)	Skutečnost		Experiment a predikce Kč/měna											
	EUR	USD	1	2	3	4	5	6	7	8		9		
			EUR	EUR	USD	USD	USD	EUR	USD	EUR	USD	EUR	USD	
Y _{s1}	1,68	1,36	1,61	1,59	1,34	1,25	1,31	1,60	1,33	1,51	1,34	1,49	1,25	
Y _{s2}	1,62	1,36	1,63	1,59	1,36	1,22	1,29	1,62	1,33	1,48	1,45	1,49	1,34	
Y _{s3}	1,69	1,33	1,65	1,60	1,38	1,16	1,28	1,62	1,35	1,50	1,54	1,47	1,34	
Y _{s4}	1,70	1,32	1,67	1,60	1,39	1,17	1,28	1,64	1,38	1,56	1,62	1,52	1,42	
Y _{s5}	1,73	1,35	1,69	1,61	1,39	1,16	1,28	1,64	1,38	1,64	1,64	1,54	1,40	

SOUHRN

Cílem příspěvku je řešení technických problémů realizace prognostického modelu v obecné rovině. Aplikace na predikci kurzů měny má pouze praktický důvod, kterým je dostupnost. Modely postavené na bázi vícevrstvé neuronové sítě nelze přeceňovat, ale ani podceňovat. Experimenty aplikující uvedená pravidla pro tvorbu a učení predikčních modelů vykazují vcelku přijatelné výsledky.

Za zajímavý poznatek lze uvést to, že v mnoha případech jsou lepší výsledky dosahovány s prostou lineární funkcí neuronů. U těchto modelů je postačující vstupní a výstupní vrstva neuronů, protože složitější konfiguraci lze transformací převést na dvouvrstvou síť, a tudíž je zde zbytečné se zabývat složitější konfigurací. Důležité je pouze stanovení počtu hodnot časové řady, na jejichž základě bude prováděná predikce.

V experimentech 6 a 7 byl použit model s jednou vstupní a jednou výstupní časovou řadou. Vzhledem k tomu, že u vstupní časové řady jsou hodnoty známé i do budoucna, tento typ modelů umožňuje zkoumat vliv vstupu na hodnoty predikce.

Uvedené experimenty byly provedeny na modelu vícevrstvé neuronové sítě realizovaném na Ústavu informatiky PEF, který umožňuje jednoduchou realizaci a korekci všech typů uvedených modelů, včetně grafické prezentace časových řad a predikce.

trend, neuronová síť, časová řada, učení neuronové sítě, chybová funkce, prognóza

SUMMARY

Intention of this contribution consists in solution of technical problems prognostic's models and realization in a general level. Application to exchange prediction has only practical reason, which is availability of time series. Models created on the base of multilevel neural nets are neither overvalue nor undervalue. Experiments that apply presented rules for creation and learning of prediction models, document on whole receivable results.

As an interesting observation is possible introduce, that in many cases are better results obtained with a simple linear function of neurons. Models have only input and output layer, because more compound configuration neural nets can be transformed to two layer neural nets and so it is unnecessary deal with complicated configuration. There is important only establish number of time series value for the learning prediction.

In experiments 6 and 7 was used the model with only one input and one output time series. Because values of input time series are known values also for future, these types of models make influence exploration of input on prediction values.

Mentioned experiments had performed with model multilayer neural nets, that was realized on at the Business and Economy Faculty, Department of Informatics. The model enables simple realization and correctness all types of mentioned models, including graphical presentation of time series and predictions.

LITERATURA

- KONEČNÝ, V., 2005: Umělá inteligence v BI. In: Informatika XVII, 2005. Brno, Konvoj, s. 63–72. ISBN 80-7302-110-2.
- KONEČNÝ, V., MATIÁŠOVÁ, A., RÁBOVÁ, I., 2005: Učení n-vrstvé neuronové sítě. Acta univ. agric.

et silvic. Mendel. Brun., LIII, 6, str. 75–84. ISSN 1211-8516.

- KONEČNÝ, V., 2006: Modely trendů s vícevrstvou neuronovou sítí. In: Firma a konkurenční prostředí 2006. Sekce 7, IS/IT a konkurenceschopnost podniků, Brno, Konvoj, s. 29–35. ISBN 80-7302-097-1.

Adresa

Doc. Ing. Vladimír Konečný, CSc. Ústav informatiky, Mendelova zemědělská a lesnická univerzita v Brně, Zemědělská 1, 613 00 Brno, Česká republika, e-mail: konecnym@mendelu.cz

