UŽITÍ UMĚLÝCH NEURONOVÝCH SÍTÍ V NELINEÁRNÍCH MODELECH SPOTŘEBY PLYNU

Doc. Ing. Aleš Procházka, CSc, Ing. Jaroslav Stříbrský, Ing. Jiří Ptáček

Ústav počítačové a řídicí techniky, VŠCHT Praha

Ing. Zdeněk Kánský

Ústřední plynárenský dispečink, Praha

Souhrn: *Umělé neuronové sítě poskytují možnost modelování a predikce signálu s nelineárními vnitřními vazbami a návazností na další veličiny ovlivňující jejich časový vývoj. Obecným problémem aplikace neuronových sítí je přitom volba jejich struktury, tvaru přenosových funkcí a optimalizace jejich parametrů před aplikací evolučních algoritmů nebo gradientní metody pro vyhledání globálního minima na chybové ploše. Předností matematických modelů těchto sítí je jejich obecnost a využití v řadě inženýrských oborů. Příspěvek je zaměřen na popis základní architektury dílčích neuronů takovýchto neuronových sítí včetně jejich optimalizace a dále na jejich použití pro modelování a predikci časových řad spotřeby plynu. Zvláštní pozornost je přitom věnována analýze těchto dat a souvislosti spotřeby plynu s průběhem teploty, a to zejména z hlediska volby struktury příslušného nelineárního modelu. Výsledky stanovené pomocí navržené neuronové sítě jsou v závěru porovnány s lineárními autoregresními modely pro predikci spotřeby plynu vycházejícími ze vstupních dat měřených s danou periodou vzorkování.*

Klíčová slova: Modelování signálů, nelineární modely časových řad, umělé neuronové sítě, učicí algoritmy, optimalizace, predikce signálů

1 Úvod

Predikce časových řad [2, 14, 3, 12, 7] tvoří podstatnou součást metod číslicového zpracování signálů [5, 4, 15, 9] s řadou aplikací v různých inženýrských oblastech [11, 1]. Příslušné metody zahrnují přitom aplikaci lineárních autoregresních modelů [8] a dále nelineárních struktur založených v řadě případů na užití umělých neuronových sítí [6] a Wavelet funkcí [10, 13].

Příspěvek je zaměřen na problematiku nelineárních modelů a jejich porovnání s klasickými metodami lineárními. Vlastním cílem je přitom stručné seznámení s užitím umělých neuronových sítí, jejich strukturou, optimalizací a aplikací pro predikci spotřeby plynu.

2 Umělé neuronové sítě

Umělé neuronové sítě představují matematickou strukturu schopnou optimalizace jejích parametrů tak, aby se chování sítě blížilo chování požadovanému. Ve fázi učení existuje ke každé množině hodnot vstupního vektoru vzorů vektor hodnot požadovaných a optimalizace parametrů sítě se provádí tak, aby se vypočítaný výstupní vektor hodnot sítě ve smyslu nejmenších čtverců blížil těmto hodnotám žádaným. Zobecňující vlastnost takovéto sítě spočívá v její následné aplikaci i pro neznámý vektor vstupních hodnot. Při užití umělé neuronové sítě pro predikci časové řady je ve fázi učení požadovanou hodnotou vždy hodnota řady, která má být výsledkem predikce z hodnot předcházejících.

Obr. 1 ukazuje základní strukturu jednoho neuronu. Výsledná hodnota A(1,k) se v tomto případě počítá pro každé k na základě vektoru vstupních hodnot $\{P(1,k), P(2,k), \cdots, P(R,k)\}$ ze vztahu

$$A(1,k) = F((\mathbf{W} * \mathbf{P}(:,k) + B(1)) \tag{1}$$

pro parametry sítě $\{W(1,1), W(1,2), \cdots, W(1,R)$ a $B(1)$. Nelineární přenosová funkce F umožňuje v tomto případě značnou flexibilitu celé struktury pro aproximaci daných hodnot vstupních vzorů. Pro případ lineární přenosové funkce se ovšem struktura redukuje na případ lineární a model časové řady pomocí autoregresního modelu ve tvaru

$$A(1,k) = W(1,1)P(1,k) + W(1,2)P(2,k) + \cdots + W(1,R)P(R,k) + B(1) \tag{2}$$

Je-li $T(1,k)$ vektor hodnot požadovaných, představuje proces optimalizace konstant minimalizaci součtu čtverců odchylek ve tvaru

$$S(\mathbf{W}, B) = \sum_{k=1}^{Q} (A(1,k) - T(1,k))^2 \tag{3}$$

kde Q představuje celkový počet vzorů. Zatímco v případě lineárním představuje v nejjednodušším případě dvou parametrů minimalizace vztahu (3) řešení soustavy dvou lineárních algebraických rovnic, je v případě nelineárním chybová plocha representovaná tímto vztahem značně nelineární. Minimalizace parametrů uvedená na obr. 1 vede k aplikaci gradientní metody a relativně složitý výpočet, u kterého nemusí být zajištěna jeho konvergence.

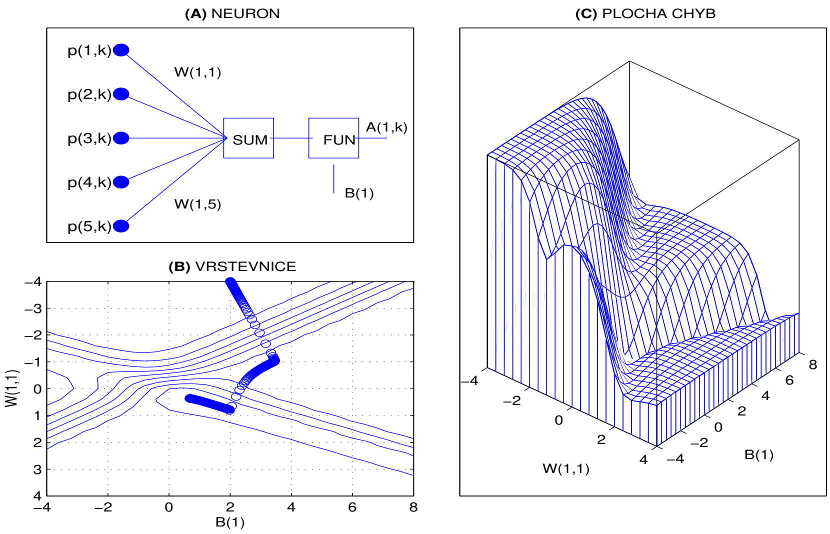

Obrázek 1: Struktura elementárního neuronu a optimalizace jeho parametrů pro sigmoidální přenosovou funkci a zvolené výchozí konstanty $W(1,1) = -4$ a $B(1) = 2$

Obr. 2 uvádí příklad jednoduché neuronové sítě se strukturou $R - S1 - 1$ složené z jednotlivých neuronů. Výstup takovéhoto modelu pro libovolný vstupní vektor $\mathbf{P}_{R,1}$ je v tomto případě definovaný vztahem

$$\mathbf{A2} = F2(\mathbf{W2} * F1\ (\mathbf{W1} * \mathbf{P} + \mathbf{B1}) + \mathbf{B2}) \tag{4}$$

kde matice $\mathbf{W1}_{S1,R}, \mathbf{W2}_{1,S1}$ definující koeficienty neuronové sítě a vektory $\mathbf{B1}_{S1,1}$ a $\mathbf{B2}_{1,1}$ representující jednotlivé prahové úrovně. Optimalizace sítě je již v tomto případě značně náročná s ohledem na řadu lokálních minim a řešení tohoto úkolu je samostatným problémem aplikace neuronových sítí. Při nalezení globálního minima je však výsledná síť již schopna popsat sledovaný proces s podstatně větší spolehlivostí než lineární model.

3 Modelování spotřeby plynu

Časová závislost spotřeby plynu měřené s periodou vzorkování jednoho dne uvedená na obr. 3 je posloupností s významnou periodicitou jednoho roku, jednoho týdne a jednoho dne, která vyplývá z podstaty sledovaného signálu. Z rozboru korelace mezi průběhem spotřeby a teploty dále vyplývá, že částečný podíl této spotřeby je významně svázán s vývojem teploty. Tato souvislost je významná v zimních měsících, ve kterých je korelační koeficient blízký jedné, zatímco v letních měsících je významně nižší a signalizuje spotřebu nezávislou na teplotních změnách.

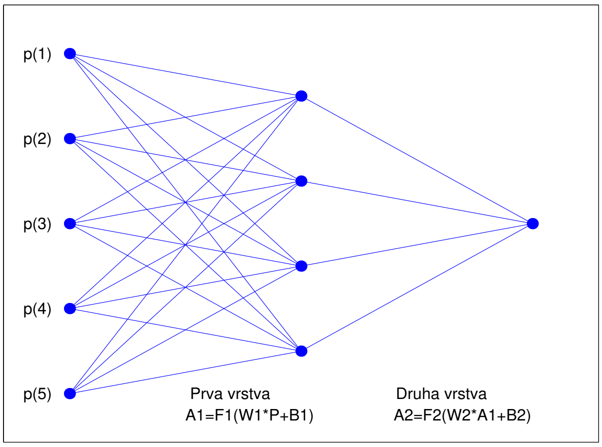

Obrázek 2: Neuronová síť se strukturou $5-4-1$

Z posouzení souvislosti mezi spotřebou plynu a teplotou vyplývají možnosti konstrukce nelineárních modelů pro její predikci. Při učení neuronové sítě lze vektory vzorů vytvářet z předchozích hodnot spotřeby a v zimním období navíc z hodnot teploty. Zřejmě tedy nelze vytvořit globální model platný pro celý rok a učení je nutné provádět separátně pro úvodní část zimního období a během tohoto období model dále zpřesňovat. Obr. 4 uvádí metodiku predikce spotřeby s učicí a aplikační částí separátní v každé zimní sezóně.

Tabulka 1 porovnává výsledky jednokrokové predikce spotřeby plynu pro vstupní data měřená a periodou vzorkování jednoho dne. Pro každou ze zimních sezón je uvedena střední chyba predikce určená pomocí autoregresního lineárního modelu řádu 4 a dále pomocí nelineárního modelu ve tvaru neuronové sítě se strukturou 4-3-1 (bez užití teploty mezi vstupními vzory) a dále se strukturou 4-3-1 (s využitím teploty jako pomocné veličiny mezi vektory vzorů).

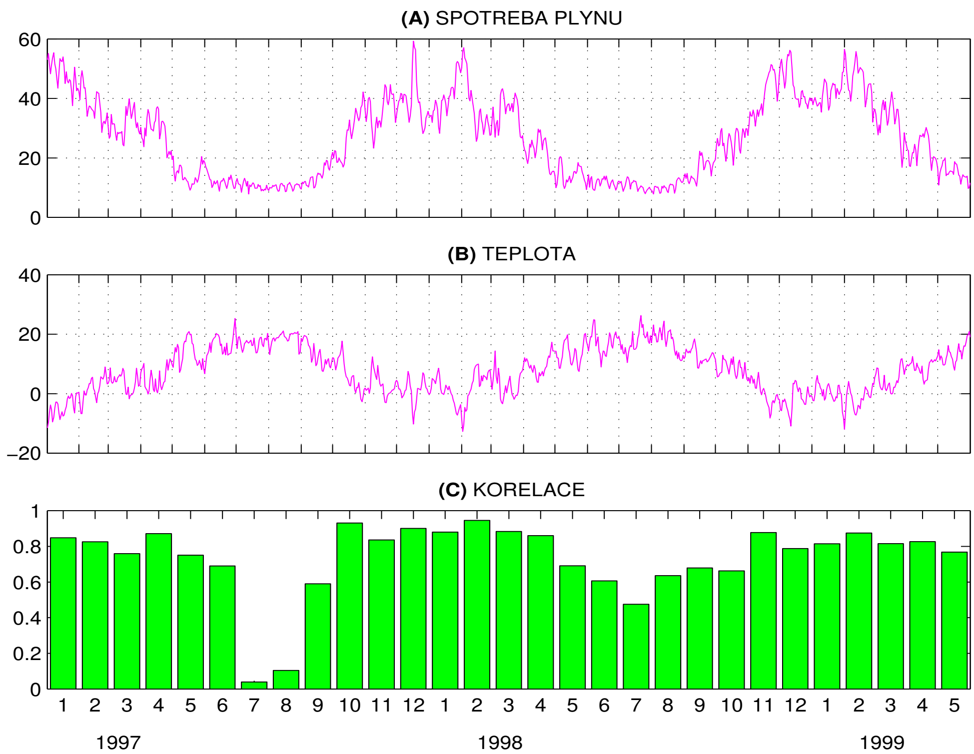

Obrázek 3: Průběh **(a)** spotřeby plynu a **(b)** teploty v období od 1.1.1997 do 5.5.1999 s periodou vzorkování jednoho dne, a dále **(c)** vzájemné korelace po jednotlivých měsících

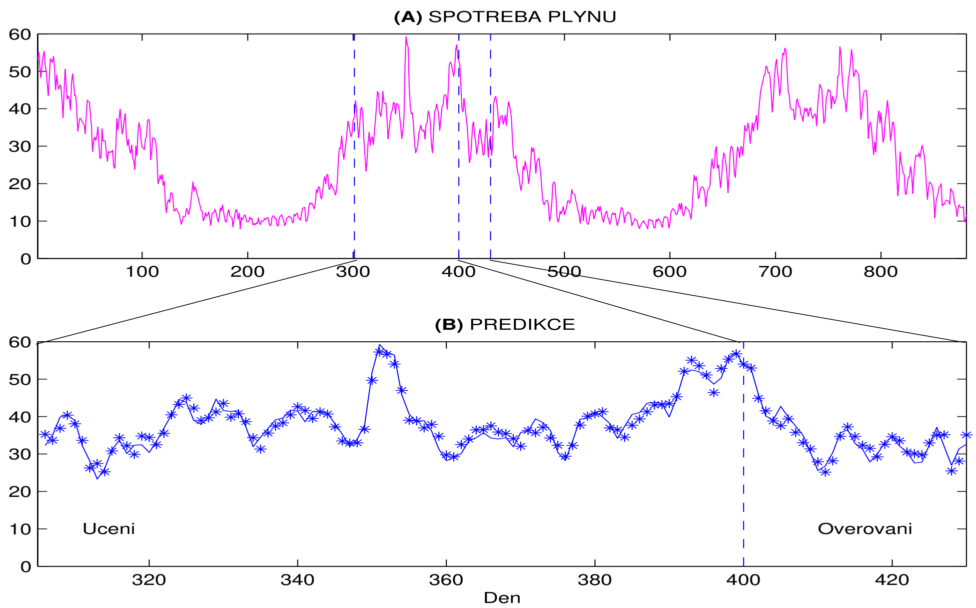

Obrázek 4: Predikce spotřeby plynu pro zimní období roku 1997/98 a 1998/99 s vyznačením období pro učení a aplikaci neuronové sítě zvolené struktury

Lineární model je vzhledem k jeho jednoduchosti velice často používán a v daném případě je pro zimní sezónu 1998/99 popsán diferenční rovnicí ve tvaru

$$x(n) = 1.14x(n-1) - 0.41x(n-2) - 0.07x(n-3) + 0.08x(n-4) \tag{5}$$

Model ve formě umělé neuronové sítě 4-3-1 je pro stejné období charakterizován maticí

$$\mathbf{W1} = \begin{bmatrix} -3.88 & 1.85 & -11.59 & 15.93 \\ 3.9 & -2.69 & -0.45 & -0.78 \\ -0.05 & 0.01 & -0.03 & 0.06 \end{bmatrix} \tag{6}$$

s koeficienty prvé vrstvy a vektorem konstant $\mathbf{W2} = [0.30, 0.36, -0.98]$ druhé vrstvy. Přes složitější strukturu tohoto modelu se sigmoidální přenosovou funkcí prvé vrstvy a lineární funkcí ve vrstvě druhé, jsou výsledky predikce tímto modelem významně lepší zejména v případě, že se jako pomocná veličina uvažuje teplota.

Model	*Střední chyba predikce [%]*	
	Zima 1997/98	*Zima 1998/99*
(a) AR řádu 4	6.1 / 7.5	4.8 / 6.7
(b) NN 4-3-1	4.9 / 6.9	3.8 / 6.3
(c) NN 4-3-1 (včetně teploty)	3.8 / 4.1	3.1 / 4.9

Tabulka 1: Střední chyba jednokrokové predikce spotřeby plynu určené **(a)** pomocí lineárního autoregresního modelu řádu 4, **(b)** umělé neuronové sítě 4-3-1 vycházející pouze z předchozích 4 hodnot spotřeby a **(c)** umělé neuronové sítě 4-3-1 vycházející z předchozích 3 hodnot spotřeby a předpovědi teploty, a to pro učicí část zahrnující období 100 dní od 28.10. (s chybou uvedenou před lomítkem) a část aplikační pro období 30 dní od 5.2. (s chybou uvedenou za lomítkem) v zimním období roku 1997/98 a 1998/99

4 Závěr

Z výsledků analýzy průběhu spotřeby plynu a teploty vyplývá, že lineární model je v řadě případů postačující pro stanovení jednokrokové predikce. Nelineární model ve formě neuronové sítě, a to zejména při využití průběhu teploty, může příslušný výsledek dále upřesnit. Předpokladem je ovšem vhodná volba délky učicí části, korektně navržená optimalizace sítě a vhodně volená struktura sítě. Problémem je dále volba přenosových funkcí sítě a její inicializace před aplikací vhodného optimalizačního algoritmu. Přes tyto problémy lze využití neuronových sítí pro predikci dat spotřeby plynu doporučit.

Reference

[1] A. Atyia, S. El-Shoura, S. Shaheen, and M. El-Sherif. River Flow Forecasting Using Neural Networks. In *World Congress on Neural Networks*, pages 461–464, San Diego, California, 1996. Lawrence Erlbaum Associates.

[2] G. E. P. Box, G. M. Jenkins, and G. C. Reinsel. *Time Series Analysis: Forecasting and Control.* Prentice Hall, Engelwood Cliffs, U.S.A., third edition, 1994.

[3] E. S. Chng, S. Chen, and B. Mulgrew. Gradient Radial Basis Function Networks for Nonlinear and Nonstationary Time Series Prediction. *IEEE Trans. on Neural Networks*, 7(1):190–194, 1996.

[4] P. Denbigh. *System Analysis and Signal Processing.* Addison Wesley, 1998.

[5] M. H. Hayes. *Statistical Digital Signal Processing and Modeling.* John Wiley & Sons, Inc., New York, 1996.

[6] S. Haykin. *Neural Networks.* IEEE Press, New York, 1994.

[7] P. P. Kanjilal. *Adaptive Prediction and Predictive Control.* Peter Peregrinus Ltd., IEE, U.K., 1995.

[8] L. Ljung. *System Identification.* Prentice Hall, Englewood Cliffs, N.J., 1987.

[9] B. Mulgrew, P. Grant, and J. Thompson. *Digital Signal Processing, Concepts and Applications.* Macmillan Press, Ltd, Houndmills, Hampshire, U.K., 1999.

[10] D. E. Newland. *An Introduction to Random Vibrations, Spectral and Wavelet Analysis.* Longman Scientific & Technical, Essex, U.K., third edition, 1994.

[11] E. Pelikán, Matějka P., Sláma M., and Vinkler K. Interactive Forecasting of the Electric Load Using Kohonen Self-Organizing Feature Maps. In *World Congress on Neural Networks*, pages 435–442, San Diego, California, 1996. Lawrence Erlbaum Associates.

[12] H. Phillips. Adaptive Forecasting. In *World Congress on Neural Networks*, pages 504–507, San Diego, California, 1996. Lawrence Erlbaum Associates.

[13] A. Procházka, M. Mudrová, and J. Fiala. Non-Linear Time Series Modelling and Prediction. *Neural Network World*, 6(2):215–221, 1996.

[14] A. Procházka and V. Sýs. Time Series Prediction Using Genetically Trained Wavelet Networks. In *Neural Networks for Signal Processing 3 - Proceedings of the 1994 Workshop*, pages 195–203. IEEE, 1994.

[15] A. Procházka, J. Uhlíř, P. J. W. Rayner, and N. G. Kingsbury, editors. *Signal Analysis and Prediction.* Birkhauser, Boston, U.S.A., 1998.

Doc. Ing. Aleš Procházka, CSc, narozený 1948, je absolventem oboru Technická kybernetika fakulty elektrotechnické ČVUT. V současné době působí jako proděkan FCHI a vedoucí Ústavu počítačové a řídicí techniky VŠCHT Praha. Jeho odborná činnost je zaměřena na analýzu a číslicové zpracování signálů, umělé neuronové sítě, aplikaci Wavelet transformace a dále na modelování, klasifikaci a predikci časových řad.

Ing. Jaroslav Stříbrský, narozený 1974, je absolventem oboru Automatizované systémy řízení VŠCHT Praha. Jeho odborná práce v rámci doktorského studijního programu v oboru Technická kybernetika je zaměřena na lineární a nelineární modely časových řad a užití umělých neuronových sítí pro predikci signálů. Další zájmy zahrnují počítačové sítě a jejich implementaci.

Ing. Jiří Ptáček, narozený 1975, je absolventem oboru Automatické řízení a inženýrská informatika ČVUT fakulty strojní. Jeho odborná práce v rámci doktorského studijního programu v oboru Technická kybernetika je zaměřena na modelování jednorozměrných a dvourozměrných signálů a užití umělých neuronových sítí.

Abstract

Problems of nonlinear signal modelling and prediction are very common in many information and control systems. A specific research area is devoted to construction of artificial neural networks and their optimization allowing a broad range of applications. The contribution presents their basic features and possibilities of their use in signal prediction of gas consumption using supporting information about temperature. Results of one day ahead signal prediction are compared with that obtained by autoregressive models.