

# UMĚLÉ NEURONOVÉ SÍTĚ – ZÁKLADY TEORIE A APLIKACE (16)

TAUFER I., DRÁBEK O., DOLEŽEL P.

Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Katedra řízení procesů, ivan.taufer@upce.cz

V příspěvku je uveden popis principu řízení nelineární soustavy prediktivním regulátorem, založeným na využití umělé neuronové sítě. Je pokračováním seriálu „Umělé neuronové sítě – základy teorie a aplikace“, publikovaném v tomto časopise v letech 2005 až 2009. V příspěvku je popsána umělá neuronová síť ve funkci prediktoru, stručně je popsán algoritmus hledání optimálních predikovaných hodnot akční veličiny a postup prediktivního řízení. Na příkladu jsou demonstrovány vlastnosti prediktivního řízení a jeho výsledky jsou porovnány s výsledky adaptivního řízení.

## 16 Prediktivní řízení s využitím neuronové sítě

Prediktivní řízení [1], [2] představuje jeden z účinných algoritmů řízení, který při předpokládaných změnách žádané hodnoty regulované veličiny umožňuje v určitém „předstihu“ reagovat na tyto změny. Při tomto řízení pracuje matematický model řízené soustavy též mj. v režimu tzv. prediktoru. Na přesnosti tohoto modelu pak jednoznačně závisí i přesnost vlastního řízení. A to může v řadě případů, zejména jde-li o soustavy složité a nelineární, vést k problémům při návrhu řídicího systému. Jde proto o významný funkční blok v obvodu prediktivního řízení.

Řešením této situace je např. použití modelu regulované soustavy ve tvaru umělé neuronové sítě [3] – [6].

### 16.1 Neuronová síť ve funkci modelu soustavy

Jak je známo, lze chování nelineární dynamické soustavy s dopravním zpožděním popsat diferenční rovnicí ve tvaru

$$y_m(k) = f[y_m(k-1), y_m(k-2), \dots, y_m(k-n), u(k-1-d), u(k-2-d), \dots, u(k-m-d)], \quad (16.1)$$

kde  $u, y_m$  – vstupní, resp. výstupní signál modelu soustavy,  $d$  – diskrétní dopravní zpoždění,  $f[\cdot]$  – nelineární funkce závislosti výstupu modelu soustavy na vstupu.

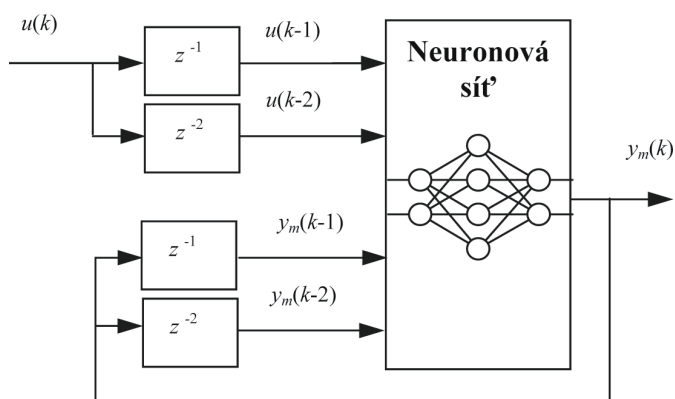
Tomuto vstupně/výstupnímu vztahu pak musí odpovídat svými vlastnostmi i model soustavy ve tvaru dopředné neuronové sítě.

Pro zjednodušení demonstrujeme tvorbu prediktoru ve tvaru dopředné neuronové sítě (DNS) na modelu soustavy 2. řádu bez dopravního zpoždění, která je popsána nelineární diferenční rovnicí ve tvaru

$$y_m(k) = f[y_m(k-1), y_m(k-2), u(k-1), u(k-2)] \quad (16.2)$$

Blokové schéma odpovídající dopředné neuronové síti je uvedeno na obr. 16.1. Metodiku učení a testování této sítě najde čtenář v příslušné literatuře [8] – [16].

**Obr. 16.1 – Schéma dopředné neuronové sítě, modelující soustavu 2. řádu**



Jestliže na vstup DNS přivedeme postupně, v diskrétních časových okamžicích  $k = 0, 1, 2, \dots, N-1$  prvky vektoru vstupního signálu  $u = [u(0), u(1), \dots, u(N-1)]$ ,

$$(16.3)$$

potom, za předpokladu znalosti počátečních podmínek  $y_m(0), y_m(-1)$  a  $u(-1)$ , obdržíme na výstupu DNS pořadnice odezvy

$$\begin{aligned} y_m(1) &= f[y_m(0), y_m(-1), u(0), u(-1)] \\ y_m(2) &= f[y_m(1), y_m(0), u(1), u(0)] \end{aligned} \quad (16.4)$$

...

$$y_m(N) = f[y_m(N-1), y_m(N-2), u(N-1), u(N-2)]$$

Ve vektorovém tvaru

$$y_m = f[y_m(1), y_m(2), \dots, y_m(N)] \quad (16.5)$$

Schématicky je výše popsaný postup znázorněn na obr. 16.2 [3].

Uvedenou neuronovou síť lze dále využít jako prediktoru. V tomto smyslu hovoříme také o neuronové síti, pracující v režimu prediktoru.

### 16.2 Neuronová síť pracující v režimu prediktoru

Jestliže na vstup popsané neuronové sítě přivedeme v časovém okamžiku  $k$  postupně, v diskrétních časových okamžicích  $i = 0, 1, \dots, N-1$  prvky vektoru akční veličiny

$$u_{mp}(k) = f[u_{mp}(k+0), u_{mp}(k+1), \dots, u_{mp}(k+N-1)] \quad (16.6)$$

potom za předpokladu znalosti počátečních podmínek  $y_{mp}(k+0)$ ,  $y_{mp}(k-1)$  a  $u_{mp}(k-1)$  obdržíme na výstupu DNS pořadnice

$$\begin{aligned} y_{mp}(k+1) &= f[y_{mp}(k+0), y_{mp}(k-1), u_{mp}(k+0), u_{mp}(k-1)] \\ y_{mp}(k+2) &= f[y_{mp}(k+1), y_{mp}(k+0), u_{mp}(k+1), u_{mp}(k+0)] \end{aligned} \quad (16.7)$$

$$y_{mp}(k+N) = f[y_{mp}(k+N-1), y_{mp}(k+N-2), u_{mp}(k+N-1), u_{mp}(k+N-2)]$$

Ve vektorovém tvaru

$$y_{mp}(k) = f[y_{mp}(k+1), y_{mp}(k+2), \dots, y_{mp}(k+N)] \quad (16.8)$$

V rovnici (8) jsou pořadnice  $y_{mp}(k+1), \dots, y_{mp}(k+N)$  tzv. predikce proměnné  $y_{mp}$  o 1, 2, ...,  $N$  - intervalů vpřed, a to od časového okamžiku  $k$ . Výše popsaný postup výpočtů predikcí lze podle [3] schématicky zobrazit podle obr. 16.3. Hodnoty prvků vektoru  $u_{mp}(k)$  jsou při prediktivním řízení předmětem optimalizačního procesu a první z nich je přiveden v každém regulačním kroku jako optimální akční zásah na vstup řízené soustavy.

#### Příklad

Pojem prediktoru si přiblížíme na modelu soustavy popsané diferenční rovnicí

$$y_{mp}(k) = 0,6 y_{mp}(k-1) + 0,4 u(k-1) \quad (16.9)$$

Vypočteme predikce pro  $i = 1, 2, 3$  a 4, jestliže vstupní signál je od časového okamžiku  $k = 7$  konstantní, tzn. že  $u_{mp}(7) = u_{mp}(8) = u_{mp}(9) = u_{mp}(10) = 0,75$  a počáteční podmínky  $u_{mp}(5) = u_{mp}(6) = 0$ ;  $y_{mp}(6) = y_{mp}(7) = 0,2$ .

Pro predikce v časových okamžicích  $i$  platí (rov.(16.8)):

$$y_{mp}(k+i) = 0,6 y_{mp}(k+i-1) + 0,4 u_{mp}(k+i-1) \quad (16.10)$$


odtud je predikce pro jeden krok vpřed od časového okamžiku  $k = 7$

$$y_{mp}(7+1) = 0,6 y_{mp}(7+0) + 0,4 u_{mp}(7+0) = 0,42$$


pro dva kroky vpřed od časového okamžiku  $k = 7$

Dokončení na další straně

Obr. 16.2 – K postupu výpočtu odezvy DNS na vstupní signál



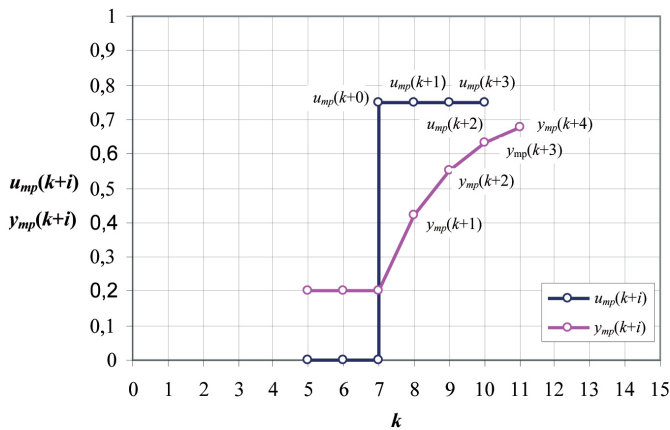
Obr. 16.3 – K postupu výpočtu predikcí



$y_{mp}(7+2) = 0,6 y_{mp}(7+1) + 0,4 u_{mp}(7+1) = 0,552$   
 atd., takže pro  $i = 3$  je  $y_{mp}(7+3) = 0,6312$  a pro  $i = 4$  je  $y_{mp}(7+4) = 0,67872$ .

Grafické zobrazení řešení úlohy je na obr. 16.4.

Obr. 16.4 – K příkladu



16.3 Algoritmus prediktivního řízení (PŘ)

Stručně lze popisované PŘ definovat jako takový postup výpočtu akčního signálu, při kterém je jeho hodnota určována minimalizačním kritériem (účelové funkce), definovaného jako součet kvadrátů odchylek mezi žádanými a predikovanými hodnotami regulované veličiny na výstupu modelu regulované soustavy ve tvaru neuronové sítě, a to v horizontu zvoleného počtu kroků predikce. Robustnost řídicího algoritmu je zajišťována on-line průběžnou identifikací regulované soustavy (průběžným trénováním DNS). V algoritmu PŘ pracujeme mj. s následujícími pojmy:

a) vektor *žádaných hodnot regulované veličiny*  $r(k)$ , definovaný v diskretních časových okamžicích  $k + i$ ,  $i = N_1, N_1 + 1, \dots, N_2$

$$r(k) = [r(k+N_1), r(k+N_1+1), \dots, r(k+N_2)], \quad (16.11)$$

kde  $N_1$  – je *minimální (dolní) horizont predikce*, pro který platí  $N_1 = d + 1$ ;

$N_2$  – je *maximální (horní) horizont predikce* (obvykle jej volíme tak, aby predikovanými hodnotami byla pokryta významná část odezvy soustavy).

b) vektor *predikce akčního signálu*, daný rovnicí (16.6), v rozsahu dolního a horního horizontu predikce  $N_1$  a  $N_2$

$$u_{mp}(k) = [u_{mp}(k+N_1-1), u_{mp}(k+N_1), \dots, u_{mp}(k+N_2-1)] \quad (16.12)$$

kterým je na výstupu modelu regulované soustavy generován vektor *predikovaných hodnot regulované veličiny* (viz rovnice (16.8))

$$y_{mp}(k) = [y_{mp}(k+N_1), y_{mp}(k+N_1+1), \dots, y_{mp}(k+N_2)] \quad (16.13)$$

c) *účelová funkce (kritériální funkce)*; vektor (16.13) spolu s žádanými hodnotami regulované veličiny (rovnice (16.10)) slouží k formulaci účelové funkce ve tvaru středně – kvadratického kritéria

$$J_{kr} = \sum_{i=N_1}^{N_2} [r(k+i) - y_{mp}(k+i)]^2, \quad (16.14a)$$

které bývá doplněno ještě dalším, penalizačním členem

$$\lambda \sum_{i=1}^{N_u} [\Delta u_{mp}(k+i-1)]^2, \quad (16.14b)$$

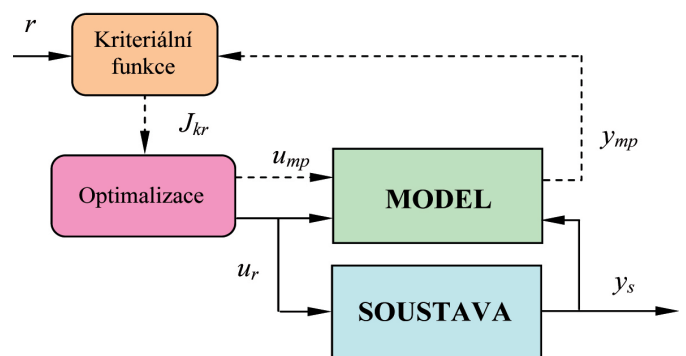
$$\text{kde } \Delta u_{mp}(k+i-1) = u_{mp}(k+i-1) - u_{mp}(k+i-2) \quad (16.15a)$$

V tomto členu je  $N_u$  tzv. *horizont řízení*. Pro soustavu bez dopravního zpoždění je podle [18]  $N_u \leq N_2/2$ . Implicitně lze předpokládat omezení na přírůstky akční veličiny ve tvaru [1]

$$\Delta u(k+i-1) = 0, \quad N_u < i \leq N_2 \quad (16.15b)$$

Tzn., že od horizontu řízení  $N_u$  je časový průběh akční veličiny konstantní. Velikostí *penalizační konstanty*  $\lambda$  lze ovlivňovat rychlost změn regulované veličiny. Výpočet hodnot predikované regulované veličiny je realizován dopřednou neuronovou sítí, trénovanou on-line.

Obr. 16.5 – Blokové schéma prediktivního řízení



d) *minimalizace účelové funkce*; optimální průběh akčního signálu v daném horizontu řízení obdržíme minimalizací účelové funkce  $J_{kr}$  (16.14a,b) podle prvků vektoru predikce akčního signálu, daného rovnicí (16.12), tj. řešením rovnic

$$\frac{\partial J_{kr}}{\partial u_{mp}(k)} = 0 \quad (16.16)$$

Jelikož analytické řešení vztahu (16.16), zajišťující výpočet minimální hodnoty  $J_{kr}$ , je vzhledem k složitosti jeho analytického vyjádření velmi složité, je vhodné použít řešení numerické. Lze použít např. systémový program MATLABu, realizovaný funkcí *fminsearch*. Tato funkce řeší minimum daného vztahu modifikovanou metodou simplexů Nelder a Meada (metoda pružných polyedrů) [17]. Podrobněji je možné se s optimalizační metodou simplexů a jejími aplikacemi seznámit např. v [18] – [20], ve zjednodušené formě pak v [21]. Na základě uvedeného lze pak sestavit schéma obvodu prediktivního řízení.

#### 16.4 Blokové schéma prediktivního řízení

V literatuře je popsána a v praxi realizována celá řada obvodů prediktivního řízení [6], [22]. Principiální schéma jednoho ze způsobů prediktivního řízení – strategie pohyblivého horizontu (RHC – Receding Horizon Control), nebo také řízení s použitím modelu procesu (MPC – Model Predictive Control), je uvedeno na obr. 16.5 [4], [5]. Skládá se ze čtyř bloků: modelu soustavy pracující v režimu prediktora, bloku výpočtu hodnoty kritériální funkce, bloku optimalizace a vlastní řízené soustavy.

Model řízené soustavy ve tvaru dopředné neuronové sítě a blok optimalizace jsou určeny k výpočtu optimálních predikovaných hodnot vektoru akčních veličin  $u_{mp}$ , zajišťujících na daném horizontu predikce maximální shodu mezi vektorem referenčních (žádaných) hodnot  $r$  a vektorem výstupních hodnot  $z$  modelu  $y_{mp}$ , jakožto minimum kritériální funkce  $J_{kr}$ . První prvek  $u_{mp}(1)$  akčních veličin vektoru  $u_{mp}$  je přiváděn na vstup řízené soustavy jako optimální hodnota akční veličiny  $u_r(k)$  v aktuálním kroku řízení  $k$ .

Hodnot vstupně/výstupních veličin řízené soustavy je využito k aktualizaci parametrů dopředné neuronové sítě.

Podrobnější popis funkce daného zapojení a popis jednotlivých bloků je uveden v dalším díle příspěvku.

*Problematika je řešena v rámci výzkumného záměru MŠM 0021627505 „Řízení, optimalizace a diagnostika složitých systémů“ a programu vědeckovýzkumné spolupráce ČR a SR KONTAKT MŠMT č. MEB 0810003 „Identifikace a řízení složitých nelineárních soustav s využitím metod umělé inteligence“.*

#### Literatura

- [1] MIKLEŠ, J.; FIKAR, M. *Modelovanie, identifikácia a riadenie procesov 2. Identifikácia a optimálne riadenie*. Bratislava : Vydavateľstvo STU Bratislava, 2004. ISBN 80 227 2134-4.
- [2] CAMACHO, E. F.; BORDONS, C. *Model Predictive Control*. London : Springer, 405 p. ISBN 1-85233-694-3
- [3] LAZAR, M.; PASTRAVANU, O. A neural predictive controller for non-linear systems. *Mathematics and Computers in Simulation*, 60 (2002), pp. 315–324.
- [4] SKLIARENKO, E. G. Prediktívne regulovanie slorosti elektroprivoda robotov na baze neimodeli [on line]. *Elektromashinoborudovannia ta elektroobladnannia*. 52. [cit. 11.8.2009]. Dostupné na „http://www.nbu.gov.ua/Articles/OSPU/ee\_52/2.htm“.
- [5] NN Predictive Control. [on line]. *Neural Network Toolbox*. [cit. 11.8.2009]. Dostupné na „http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/control3.html“.
- [6] JADLOVSKÁ, A. *Modelovanie a riadenie dynamických procesov s využitím umelej inteligencie*. [Habilitationná práca]. Košice : Technická univerzita Košice, Fakulta elektrotechniky a informatiky, Katedra kybernetiky a umelej inteligencie, 2004. 185 s.
- [7] KOZÁK, Š.; KAJAN, S. Adaptive Control of Nonlinear Dynamical Systems Using Neural Networks. In *Proceeding of the*

*2nd Slovak Conference on Artificial Neural Networks SCANN 98*, November 10–12, 1998, pp. 72–76.

- [8] DRÁBEK, O.; MACHÁČEK, J. *Adaptivní řízení*. Pardubice : VŠCHT, 1992.
- [9] TAUFER, I.; DRÁBEK, O. Non-linear system adaptive Control by Neural Network exploitation. [on line]. In *Proceedings 10th International Scientific Conference New Ways in Manufacturing Technologies*. Prešov (Slovak public), 17 – 19, June 2010. Košice (Slovak Republic) : TU Košice, 2010. pp. 483 – 496. ISBN 978-80-553-0441-0. (In Czech). Dostupné na <http://www.monka.eu/2010/2010nwmtabst.zip>
- [10] FAUSETT, L. V. *Fundamentals of Neural Network: Architectures, Algorithm and Applications*. New Persey : Prentice Hall, 1994.
- [11] HAYKIN, S. *Neural Network*. New Persey (USA) : Prentice-Hall, Inc., 1999. 842 p. ISBN 978-0-13-273350-1.
- [12] SINČÁK, P.; ANDREJKOVÁ, G. *Neurónové siete. Inžiniersky prístup*. 1. a 2. diel. Košice : elfa s.r.o., 1996. 107 s. a 63 s. ISBN 80-88786-38-X a ISBN 80-88786-42-8.
- [13] KVASNIČKA, V. a kol. *Úvod do teorie neuronových sítí*. Bratislava: IRIS, 1997. 285 s. ISBN 80-88778-30-1.
- [14] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (3). *CHEMagazín*, 1 (XVI), 2006, s. 12–14. ISSN 1210-7409.
- [15] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (5). *CHEMagazín*, 5 (XVI), 2006, s. 29–30. ISSN 1210-7409.
- [16] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (6). *CHEMagazín*, 6 (XVI), 2006, s. 31–33. ISSN 1210-7409.
- [17] NELDER, J. A.; MEAD, R. A simplex method for function minimization. *Computer Journal*, vol. 7, 1965, p. 308.
- [18] SPENDLEY, W.; HEXT, G. R.; HIMSWORTH, F. R. Sequential application of simplex designs in optimization and Evolutionary Operation. *Technometrics*, vol. 4, No 4, p. 441
- [19] KRUG, G. K.; TAUFER, I. Simplexní metoda plánování experimentů. *Technika v chemii*, 1974, č.57, s. 1–8.
- [20] BRUNOVSKÁ, A. *Malá optimalizácia*. Bratislava : ALFA, 1990, 244 s. ISBN 80-05-00770-1.
- [21] TAUFER, I.; DRÁBEK, O.; JAVŮREK, M. Metoda simplexů – efektivní nástroj pro řešení optimalizačních úloh. *CHEMagazín*, 6 (XX), 2010, s. 31–34. ISSN 1210-7409.
- [22] ŠKUTOVÁ, J. *Využití umělé inteligence pro řízení složitých systémů* [Disertační práce]. Ostrava : Vysoká škola báňská – TU Ostrava, Fakulta strojní, Katedra automatizační techniky a řízení, 2009. 145 s.

#### Abstract

THE ARTIFICIAL NEURAL NETWORKS – BASIC THEORY AND APPLICATION

*Summary:* Predictive nonlinear control based on artificial neural network is described in the paper. It is continuation of the serial “Artificial neural networks – basics and applications” published during years 2005-2009. Artificial neural network as a predictor, algorithm of optimal control actions finding and predictive control are described. Properties of the predictive controller are demonstrated on example and results are compared with adaptive control.

**Key words:** predictor, predictive control, artificial neural network.