

# UMĚLÉ NEURONOVÉ SÍTĚ – ZÁKLADY TEORIE A APLIKACE (14)

I. TAUFER, O. DRÁBEK, P. SEIDL

UNIVERZITA Pardubice, Fakulta elektrotechniky a informatiky, Katedra řízení procesů,  
e-mail: ivan.taufer@upce.cz

Ve čtrnáctém dílu seriálu je popsáno adaptivní řízení nelineární soustavy samočinně se nastavujícím regulátorem s využitím neuronových sítí. Je poukázáno na analogii mezi klasickým řízením lineární soustavy a řízením nelineární soustavy s použitím NS. Na příkladu je demonstrován průběh tohoto řízení a poukázáno na jeho vlastnosti a výhody.

## 14. ADAPTIVNÍ ŘÍZENÍ NELINEÁRNÍCH SYSTÉMŮ S VYUŽITÍM NEURONOVÝCH SÍTÍ

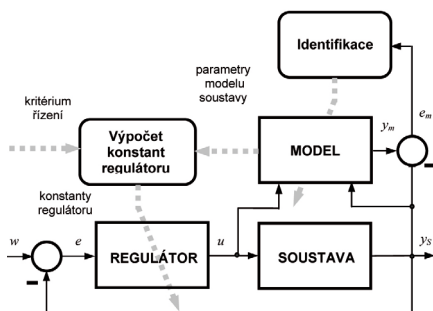
### 14.1 Adaptivní řízení

Adaptivní řídicí systémy podle [1] přizpůsobují parametry nebo strukturu jedné části systému (regulátoru) změnám parametrů nebo struktury jiné části systému (regulované soustavy) tak, aby na základě zvoleného kritéria zajistily optimální chování celého systému, nezávisle na nastalých změnách. Od předcházejících způsobů přímého a nepřímého řízení se liší tím, že regulační systém je doplněn zpětnou vazbou a vstupem regulátoru je regulační odchylka. Tímto zapojením jsou pak odstraněny nedostatky řízení, popsané v [2], [3] a [4],

Základní filosofie adaptivního řízení s použitím neuronových sítí vychází z algoritmu adaptivního řízení lineárních soustav, kde model soustavy a adaptivní regulátor jsou ve tvaru diferenciálních rovnic. V dalším výkladu budeme tento přístup adaptivního řízení nazývat přístupem klasickým. Než přistoupíme k podrobnému popisu adaptivního řízení s využitím umělých neuronových sítí, krátce si klasické adaptivní řízení připomeneme.

Blokové schéma je uvedeno na obr. 14.1. Algoritmus tohoto řízení je podrobně uveden např. v [5] a [6].

Obr. 14.1 – Schéma adaptivního řízení se samočinně se nastavujícím regulátorem



Řízení se uskutečňuje ve dvou fázích. Je to:

- průběžná identifikace regulované soustavy, např. rekurentní metodou nejmenších čtverců (RMNČ) nebo některou její modifikací;
- průběžný výpočet konstant adaptivního regulátoru.

Model soustavy je ve tvaru lineární diferenciální rovnice  $n$ -tého řádu

$$y_m(k) + \sum_{i=1}^n \hat{a}_i y_m(k-i) = \sum_{i=1}^n \hat{b}_i u(k-i) \quad (14.1)$$

kde  $\hat{a}_i, \hat{b}_i$  jsou odhady parametrů modelu soustavy, které získáme v procesu identifikace metodou nejmenších čtverců, vycházející z minimalizace kritériální funkce

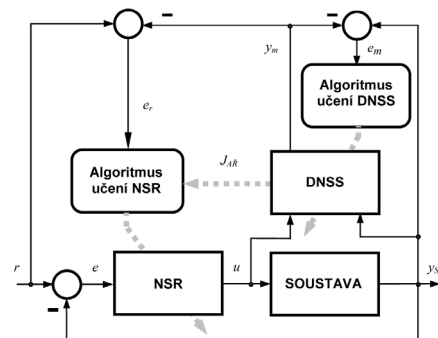
$$E = \sum_{k=1}^m e^2(k) = \sum_{k=1}^m (y_m(k) - y_s(k))^2 \Rightarrow \min \quad (14.2)$$

Odhady koeficientů  $\hat{a}_i, \hat{b}_i$  diferenciální rovnice (14.1) potom slouží k výpočtu konstant adaptivního regulátoru.

### 14.2 Adaptivní řízení se samočinně se nastavujícím neuronovým regulátorem

V literatuře, např. [7], [8], [9] a [10] je uvedeno několik možných způsobů realizace tohoto řízení. Jeho blokové schéma prezentované v [10] je uvedeno na obr. 14.2.

Obr. 14.2 – Schéma adaptivního řízení s použitím neuronové sítě



Model soustavy a číslicový regulátor jsou ve tvaru dopředných neuronových sítí a jejich učení se uskutečňuje BP – algoritmem [11].

Neuronový model soustavy ve tvaru dopředné neuronové sítě soustavy (DNSS) má obdobnou funkci jako model ve tvaru diferenciální rovnice při klasickém adaptivním řízení. Místo koeficientů modelu ve tvaru diferenciální rovnice jsou v případě řízení s použitím NS počítány parametry neuronové sítě, tj. váhy spojení mezi neurony jednotlivých vrstev a případně strmosti aktivizačních funkcí neuronů. Výstup z neuronového modelu soustavy slouží jako referenční signál pro učení neuronové sítě regulátoru NSR (výpočet vah spojení - parametrů regulátoru). Další pomocnou výstupní veličinou modelu soustavy je jacobíán  $J_{AR}$  (jacobíán adaptivního řízení).

Algoritmus adaptivního řízení lze rozdělit na dvě části:

- V první etapě je v režimu off-line trénována neuronová síť modelu soustavy DNSS pro různé hodnoty koeficientu učení  $\alpha$ , případně i koeficientu setrvačnosti  $\gamma$ . Hodnoty  $\alpha$ , resp.  $\gamma$ , jsou určovány s využitím libovolného optimalizačního algoritmu, nejjednodušeji metodou totálního průzkumu. Optimální hodnota koeficientu učení  $\alpha_{opt}$  (případně i koeficient setrvačnosti  $\gamma_{opt}$ ), je pak hodnota, při které je dosaženo minimální hodnoty kritériální funkce  $E(\alpha)$  pro daný počet epoch trénování [11].

$$E_{\min} = \min_{\alpha} \{E(\alpha)\} \quad (14.3)$$

kde

$$E(\alpha) = \sum_{k=1}^{ptm} e^2(\alpha, k) = \sum_{k=1}^{ptm} [y_m(\alpha, k) - y_s(k)]^2 \quad (14.4)$$

$$\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_h\},$$

$ptm$  – počet vzorů trénování množiny DNSS,  
 $h$  – počet pokusů.

Vypočtené hodnoty vah spojení a strmostí aktivačních funkcí ( $w_j, v_{ij}, \sigma_j$  a  $K$  v případě dvouvrstvé NS [11]) pro optimální hodnoty  $\alpha_{opt}$  a  $\gamma_{opt}$  slouží jako startovací hodnoty DNSS v další etapě řízení;

b) druhá etapa probíhá pro jednotlivé vzory trénovací množiny NSR  $k = 1, \dots, ptr$  ( $ptr$  je počet vzorů této trénovací množiny) v režimu on-line ve dvou krocích:

– V prvním kroku jsou podle aktuálních přenosových vlastností řízené soustavy upřesněny parametry DNSS – váhy spojení, případně i strmosti aktivačních funkcí, které zajistí minimální kvadratickou odchylku mezi výstupem ze soustavy a výstupem z DNSS.

$$E_m = \sum_{k=1}^{ptr} e_m^2(k) = \sum_{k=1}^{ptr} [y_m(k) - y_s(k)]^2 \Rightarrow \min \quad (14.5)$$

kde  $k$  je pořadové číslo vzoru řídicí množiny.

Na základě aktuální hodnoty akční veličiny  $u$  (vstup do DNSS) je vypočítána aktualizovaná hodnota výstupu DNSS  $y_{ma}$  a hodnota jacobiana  $J_{A\check{R}}$ :

– V druhém kroku je NSR trénována pro zvolenou hodnotu koeficientu učení  $\beta$  neuronové sítě regulátoru, případně koeficientu setrvačnosti  $\delta$  a vypočítány parametry neuronového regulátoru, kterými je zajištěna minimální hodnota kvadratické odchylky mezi aktualizovaným výstupem  $y_{ma}(k)$  z DNSS a žádanou hodnotou regulované veličiny  $r(k)$ .

$$E_r = \sum_{k=1}^{ptr} e_r^2(k) = \sum_{k=1}^{ptr} [y_{ma}(k) - r(k)]^2 \Rightarrow \min \quad (14.6)$$

kde  $k$  je pořadové číslo vzoru trénovací množiny NSR.

Druhou etapu trénování NSR je nutno podobně jako trénování DNSS opakovat pro různé hodnoty  $\beta$ , případně  $\delta$  a stanovit jejich optimální hodnoty  $\beta_{opt}$ ,  $\delta_{opt}$ , které zajistí nejvhodnější průběh regulačního pochodu (nejrychlejší přechod na žádanou hodnotu s minimálním překmitem).

Vzhledem k tomu, že kvalitu regulačního pochodu nelze vyjádřit kvantitativním kritériem (průběh regulačního pochodu se hodnotí vizuálně) nelze pro výpočet hodnot  $\beta$ , případně  $\delta$  použít regulární optimalizační algoritmus. Je tedy nutno použít některou z metod náhodného pokusu, kde se úspěšnost řešení hodnotí jenom slovním vyjádřením „lepší“ / „horší“.

### 14.3 Příklad

Uvažujeme již známou soustavu, jejíž chování je popsáno diferenční rovnicí

$$y_s(k+1) - A y_s(k) = B u^2(k) \quad (14.7)$$

kde  $A = 0,6$  a  $B = 0,2$ .

Jako model řízené soustavy byla použita DNSS s topologií 2-3-1 [4]. Aktivační funkce neuronů ve skryté vrstvě jsou unipolární sigmoidální funkce se strmostí  $s_j = 1$ , aktivační funkce výstupního neuronu je lineární se strmostí  $K = 1$ .

Učení této neuronové sítě bylo provedeno již výše uvedeným BP algoritmem. Startovací hodnoty vah  $w_j$  a  $v_{ij}$  byly zvoleny náhodně v intervalu  $\langle -0,5; 0,5 \rangle$  a koeficient setrvačnosti  $\gamma = 0$ . Trénovací množina byla generována signálem

$$u(k) = \begin{cases} 1 & 0 \leq k \leq 120 \\ 1,41 & 121 \leq k \leq 170 \\ 1 & 171 \leq k \leq 300 \end{cases} \quad (14.8)$$

čemuž odpovídají žádané hodnoty  $r(k) = 0,5; 1; 0,5$  regulované veličiny.

Minimální hodnoty kritéria funkce  $E(p_e)$  bylo dosaženo při počtu epoch trénování  $p_e = 5000$  a koeficientu učení  $\alpha_{opt} = 0,3$ .


Neuronová síť regulátoru je ve tvaru jednoduchého perceptronu jako u nepřímého řízení, které bylo popsáno v předcházejícím díle seriálu [3]. Učení této sítě bylo odstartováno s nulovými hodnotami vah  $q_1 = q_2 = 0$ .

Trénovací množina NSR měla tvar stupňové funkce

$$r(k) = \begin{cases} 0,5 & 0 \leq k \leq 120 \\ 1,0 & 121 \leq k \leq 170 \\ 0,5 & 171 \leq k \leq 300 \end{cases} \quad (14.9)$$


Opakovanými simulačními výpočty byl stanoven optimální koeficient učení  $\beta = 0,8$  NS regulátoru (při nulové hodnotě koeficientu setrvačnosti  $\delta = 0$ ), zajišťující nejrychlejší odezvu na žádanou hodnotu regulované veličiny bez výrazného překmitu. V krocích  $k = 220$  a  $k = 260$  byla provedena změna parametru soustavy  $A$  o hodnoty  $\Delta A = \pm 0,03$ , tj. změna koeficientu  $A$  o  $\pm 5\%$ . Výsledky průběhu regulačního pochodu jsou uvedeny na obr. 14.3.

Obr. 14.3 – Průběhy regulačního pochodu AŘ




Pro možnost porovnání s předcházejícími způsoby přímého a nepřímého řízení jsou na obr. 14.4 a obr. 14.5 uvedeny průběhy změn jacobiana a parametrů regulátoru.

Obr. 14.4 – Časový průběh jacobiana  $J_{A\check{R}}$



Obr. 14.5 – Časový průběh vah  $q_1$  a  $q_2$



### 14.4 Závěr

Vzhledem k on-line identifikaci regulované soustavy je v tomto případě zajištěna i velmi účinná eliminace vlivu změny parametru  $A$  regulované soustavy na průběh regulované veličiny řízené soustavy. S velmi dobrými výsledky bychom se setkali i v případě eliminace

*Dokončení na další straně*

vlivu poruch v akční a regulované veličině na průběh žádané hodnoty regulované veličiny.

Detailní popis a řadu výsledků simulace řízení soustavy nelineární ve statických i dynamických vlastnostech výše popsaným typem adaptivního regulátoru čtenář nalezne např. v [12].

*Problematika je řešena v rámci výzkumného záměru MŠM 0021627505 „Řízení, optimalizace a diagnostika složitých systémů“.*

## Literatura

- [1] BOBÁL, V. aj. Praktické aspekty samočinně se nastavujících regulátorů: algoritmy a implementace. Brno : VUT Brno, 1999.
- [2] TAUFER, I.; DRÁBEK, O. a SEIDL. P. Umělé neuronové sítě-základy teorie a aplikace (11), CHEMagazín, 4 (XVII), s.28-30, ISSN 1210-7409
- [3] TAUFER, I.; DRÁBEK, O. a SEIDL. P. Umělé neuronové sítě-základy teorie a aplikace (12), CHEMagazín, 4 (XVII), s.28-30, ISSN 1210-7409
- [4] TAUFER, I.; DRÁBEK, O. a SEIDL. P. Umělé neuronové sítě-základy teorie a aplikace (13), CHEMagazín, 4 (XVII), s.28-30, ISSN 1210-7409
- [5] DRÁBEK, O. a MACHÁČEK, J. Experimentální identifikace. Pardubice : VŠCHT, 1987.
- [6] DRÁBEK, O. a MACHÁČEK, J. Adaptivní řízení. Pardubice : VŠCHT, 1992.
- [7] LEONDES, C.T. (editor). Industrial and Manufacturing Systems. Vol 4. Neural Network Systems Techniques and Applications. San Diego (California, USA) : Springer, 1998. 391 p. ISBN 0-12443864-4.
- [8] PSALTIS. D.; SIDERIS. A. and YAMAMURA. A. 1988. A Multilayered Neural Network Controller. IEEE Control Systems Magazine. Vol. 8. 1988. pp. 17 - 21.
- [9] OMATU, S.; KHALID, M. and ZUSOF, R. Neuro - Control and its Applications. London : Springer - Verlag, 1996. ISBN 3-540-19965-9. (Ruský překlad: Nejrovnoprávnění i jeho priměnenie. Moskva : IPRŽR, 2000. 272 s. ISBN 5-93108-006-6).
- [10] TAN, Y. An architecture for adaptive neural control. Neural Control. Journal A. vol. 34, No 4, 1993, pp. 12 - 16.
- [11] TAUFER, I.; DRÁBEK, O. a SEIDL. P. Umělé neuronové sítě-základy teorie a aplikace (8), CHEMagazín, 4 (XVII), s.28-30, ISSN 1210-7409
- [12] TAUFER, I. a DRÁBEK, O. Control of the Nonlinear Plant by an Adaptive Self Tuning Neural Controller (I and II), In Proceedings 7th International Scientific Conference – PROCESS CONTROL 2006, June 13–16, 2006, Kouty nad Desnou, Czech Republic, Pardubice : University of Pardubice, 2006, pp 172 and 173, ISBN

## Abstract:

THE ARTIFICIAL NEURAL NETWORKS – BASIC THEORY AND APPLICATION (14)

*Summary: In the fourteenth part of the serial the self – tuning adaptive neural network controller is described. It is refer to an analogy between the classical and neural network control. Within the framework of the simulation example the control course is presented and the features of the method are mentioned.*

**Keywords:** non-linear system, neural network, adaptive control