

# Adaptivní řízení nelineární soustavy s využitím neuronové sítě

TEXT: prof. Ing. Ivan Taufer, DrSc., prof. Ing. Oldřich Drábek, CSc., Fakulta elektrotechniky a informatiky, Univerzita Pardubice

Předložená práce byla motivována snahou o rozšíření informací o výsledcích simulace řízení nelineární dynamické soustavy adaptivním neuronovým PS regulátorem (ANPSR), analýze řízené soustavy, cíle řízení, volby koeficientu učení neuronové sítě jakožto modelu řízené soustavy, volby koeficientu učení neuronové sítě regulátoru a porovnání kvality regulačního pochodu tímto typem regulátoru s klasickým PS regulátorem, realizovaným rovněž neuronovou sítí (dále jen klasickým PS regulátorem).

Předpokládá se, že čtenář je obeznámen s klasickými metodami identifikace a řízení systémů a rovněž i s metodami založenými na využití umělých neuronových sítí (UNS), použitelných k těmto účelům.

Pokud tomu tak není, je možno se s těmito principy identifikace a řízení seznámit v [1], [1], [3], [4], [5], [6], [7], [8], [9], [10].

Je známo, že adaptivní řízení [2], [9], [11], [12], [13] se realizuje vždy na základě znalosti matematického modelu řízeného procesu. Mění-li se v průběhu řízení vlastnosti tohoto procesu, pak je nutno on-line přestavovat i parametry

řídícího systému. Algoritmy tohoto řízení jsou dobře rozpracované pro případy, že je model prezentován ve tvaru diferenciální nebo diferenční rovnice. Sestavení takového modelu však předpokládá možnost jeho linearizace v okolí pracovního bodu [2].

Současný rozvoj umělých neuronových sítí mj. jako prostředků pro přímé modelování nelineárních systémů nabízí možnost použít tyto sítě i ve schématech adaptivního řízení.


Jako neuronová síť může pak být realizován i sám regulátor. Jeden ze způsobů realizace tohoto typu řízení bude dále popsán.

## Analýza regulované soustavy

Předpokládejme, že řízená soustava je popsána diferenční rovnicí [14]

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

kde  $u(k)$  je vstupní signál a  $y_s(k)$  výstupní signál regulované soustavy. Jmenovité hodnoty parametrů  $A$  a  $B$  (kdy nedochází v průběhu regulace k jejich změnám):  $A = 1,2$  a  $B = 0,92$ . Vlastnosti soustavy (1), která je prezentována v [3] bez jakéhokoliv bližšího popisu, určíme nejjednodušeji experimentálně, a to na základě analýzy výsledků simulačních výpočtů odezev



Obr. 1 Odezvy na impulsy



soustavy na posloupnost vstupních impulsů

$$u_i(k) = \begin{cases} u_i & \text{pro } k \in (0;15) \\ 0 & \text{pro } k \in (15;30) \end{cases}; \quad (2)$$

Pro impulsy o velikosti  $u_i = 0,05; 0,273; 0,65; 0,87; 1,087; 1,15$  jsou odezvy uvedené na obr. 1.

Odtud je patrné, že:

1) charakter odezvy soustavy závisí na velikosti vstupního signálu  $u_i$  (obr. 1); výsledky analýzy tohoto experimentu lze shrnout do následujících bodů:

- do hodnoty  $u \leq 0,2731$  je průběh výstupního signálu aperiodický;
- v rozsahu  $u \in (0,2731; 0,87)$  jsou průběhy odezvy kmitavé, tlumené, s růstem a následným poklesem kmitavosti;
- maximum kmitavosti je při  $u = 0,65$ ;
- při hodnotě  $u = 0,87$  se výstupní signál ustálí po prvním kroku jak při náběhu impulsu, tak i při jeho sestupu;
- v rozsahu  $u \in (0,87; 1,087)$  je průběh odezvy kmitavý, tlumený, s růstem kmitavosti;
- při hodnotě  $u = 1,087$  je soustava na mezí stability;

2) při  $u > 1,087$  je soustava nestabilní;  
3) při poklesu impulsu na nulovou hodnotu se výstupní signál soustavy v případě předcházející velikosti impulsu do hodnoty  $u < 1,087$  ustálí na hodnotě  $y_{\infty} = 0,2$ . Tzn. že diferenční rovnice (1) je v tomto rozsahu definována pro počáteční podmínky  $u(0) = 0; y_s(0) = 0,2$  (viz obr. 1);

2) při poklesu impulsu z hodnoty  $u = 1,087$  na nulovou hodnotu klesne hodnota  $y$  rovněž na nulovou hodnotu;

3) v případě poklesu impulsu z hodnoty  $u > 1,087$  na nulovou hodnotu, kdy je soustava nestabilní je řešení rovněž nestabilní;

4) statická charakteristika získaná z ustálených hodnot  $y$  je uvedena na obr. 2.


Z výše uvedených výpočtů vyplývá, že soustava je nelineární v ustálených stavech i v dynamických vlastnostech a její pracovní rozsah je v intervalu vstupní veličiny  $u \in (0;1)$  a výstupní veličiny  $y_s \in (0,2;1)$ . Anomálie uvedené v bo-

v bodech 4) a 5) vedou k závěru, že hodnota akčního signálu  $u(k)$  v případě řízení nesmí klesnout pod nulovou hodnotu.

#### Cíle řízení

Dále prezentovanými simulačními výpočty regulačních pochodů při řízení soustavy s použitím ANPSR jsou sledovány následující cíle:

1) po startu řídicího algoritmu požadujeme „co nejrychlejší“ nastavení regulované veličiny  $y_s(k)$  na její žádanou hodnotu do výchozího pracovního bodu P bez výrazného překmitu regulované veličiny. Pracovní bod má souřadnice středu pracovního rozsahu soustavy (viz obr. 2).



Obr. 2 Statická charakteristika

2) při přechodu z pracovního bodu P do jiného pracovního bodu požadujeme v podstatě totéž, jako v bodě předcházejícím, přičemž jsme si však vědomi toho, že pojem „nejrychlejší“ je pojmem relativním. Požadujeme, aby kvalita regulačního pochodu byla provedena v celém pracovním rozsahu soustavy pro změnu žádané hodnoty regulované veličiny ve tvaru stupňové funkce  $r(k) = 0,6; 1; 0,6; 0,2; 0,6$  s délkou jednoho stupně 25 kroků.

3) v souvislosti s možností změn  $\Delta A$  a  $\Delta B$  parametrů  $A(k)$  a  $B(k)$  soustavy ve tvaru impulsů, a poruch v akční veličině  $v_u(k)$  a v regulované veličině  $v_{y_s}(k)$  ve tvaru skoků (viz rovnice (3a,b) a (3c,d)) nás zajímá, jak rychle a účinně je eliminován vliv těchto poruch na průběh regulované veličiny

$$A(k) = \begin{cases} 1,2 & \text{pro } k \in (0;125) \\ 1,32 & \text{pro } k \in (126;150) \\ 1,2 & \text{pro } k \in (151;300) \end{cases}$$

$$B(k) = \begin{cases} 0,92 & \text{pro } k \in (0;175) \\ 1,012 & \text{pro } k \in (176;200) \\ 0,92 & \text{pro } k \in (201;300) \end{cases} \quad (3a,b)$$

a

$$v_u(k) = 0,1, \text{ pro } k \in (225;300)$$

$$v_{y_s}(k) = -0,1, \text{ pro } k \in (250;300) \quad (3c,d)$$

akční veličina musí splňovat podmínku  $u(k) \geq 0$ .

V podstatě se tedy jedná o zadání „úlohy sledování“, která je typická pro řízení realizované servomechanismem a „úlohy stabilizace“, kterou je zajišťováno udržování regulované veličiny na žádané hodnotě při poruchách nejružnějšího druhu, působících na soustavu. Úspěšnost řešení lze v jednodušším případě hodnotit pouze na základě vizuálního posouzení průběhů veličin regulačního pochodu, a to slovním vyjádřením „lepší – horší“, „vyhovující – nevyhovující“ a pod., analyticky prostřednictvím středně - kvadratického kritéria (viz dále kap. 3) nebo zjištěním hodnoty regulačního kroku, při kterém je docíleno žádané hodnoty regulované veličiny (viz dále kap. 4).

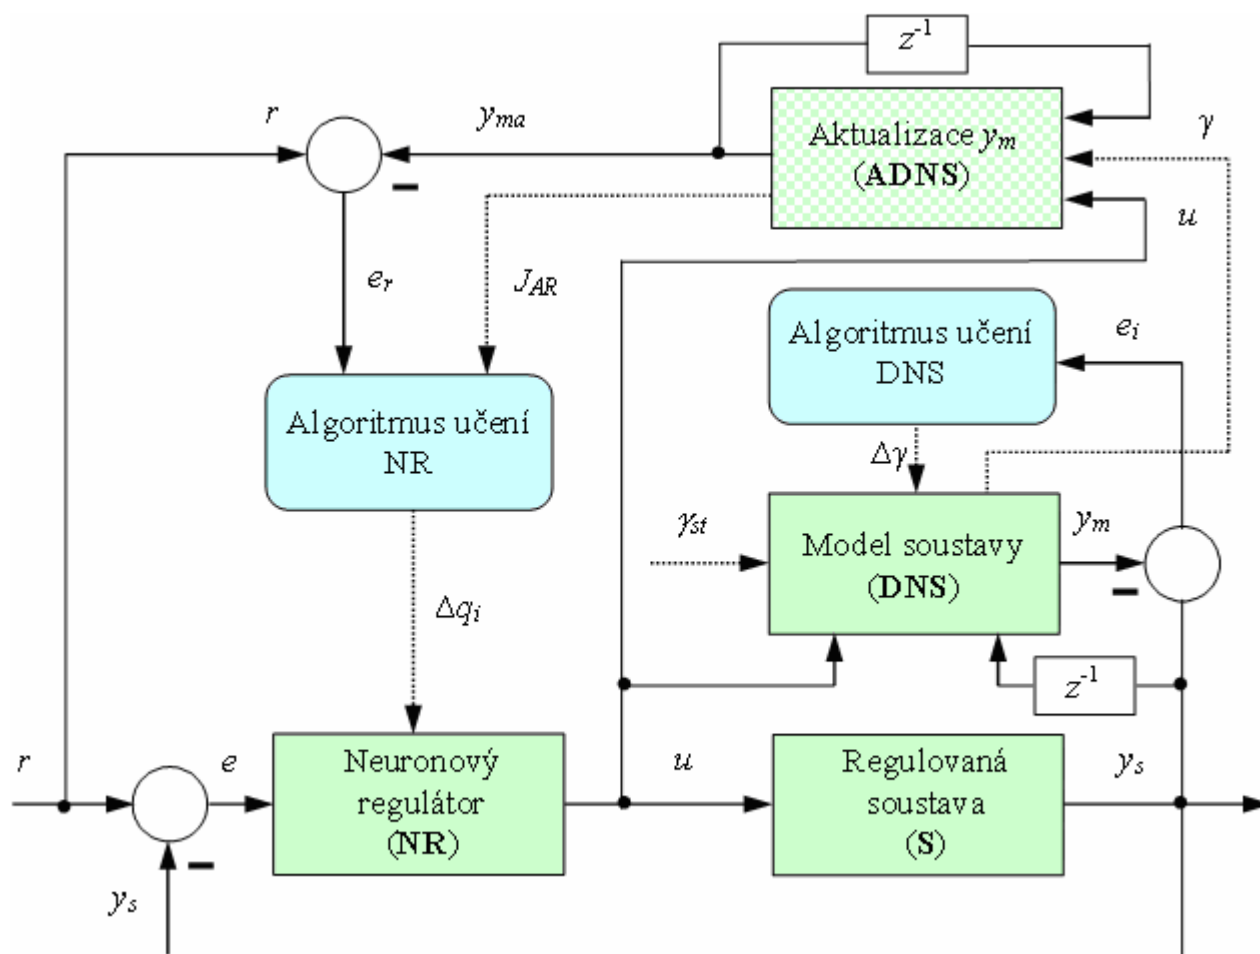
Z výše definovaných cílů řízení vyplývá, že půjde o návrh takového řídicího systému, jehož vlastnosti spadají do oblasti robustního řízení, realizovaného např. zmíněným adaptivním řídicím algoritmem. Ten umožňuje adaptaci regulátoru na různé přenosové vlastnosti regulované soustavy a přispívá k účinnější eliminaci vlivu poruch nejružnějšího druhu působících na soustavu atd.

#### Popis blokového schéma ANPSR

Regulační obvod s ANPSR je tvořen dvěma dílčími zpětnovazebními obvody podle obr. 3 s jedním, společným neuronovým regulátorem NR.

První zpětnovazební obvod je tvořen:

- přírůstkovým regulátorem NR, který je realizován perceptronem (viz např. [3] nebo [9]) s váhami  $q_i$ ,  $i = 0, 1, \dots$ , které mají obecně charakter koeficientů klasického PS regulátoru;
- nelineární regulovanou soustavou (S), v našem případě ve tvaru rovnice (1).



Obr. 3 Blokové schéma ASNRR

Druhý zpětnovazební obvod je tvořen: výše uvedeným neuronovým regulátorem NR;

1) modelem regulované soustavy ve tvaru dopředné neuronové sítě (DNS) se vstupem  $u$ , s výstupem  $y_m$  a s váhami spojení  $\gamma_i$ ;

2) algoritmem učení DNS. Před spuštěním řídicího algoritmu ANPSR je DNS off-line trénována BP – algoritmem. Výsledkem trénování jsou hodnoty vah  $\gamma_i$  DNS, počítané z rovnice

$$\gamma_i(k) = \gamma_i(k-1) + \Delta\gamma_i(k) \quad (4)$$

Změny vah  $\Delta\gamma_i(k)$  DNS počítáme metodou Backpropagation (BP – algoritmus), která vychází ze vztahu

$$\Delta\gamma_i(k) = -\alpha \frac{\partial E_s(k)}{\partial \gamma_i(k)} \quad (5)$$

V této rovnici je  $\alpha$  koeficient učení DNS a  $E_s(k)$  je kvadratická funkce odchylky

$$E_s = \sum_{k=1}^N e(k)^2 = \sum_{k=1}^N (y_s(k) - y_m(k))^2 \quad (6)$$

1) „aktualizovanou“ DNS (ADNS), jejíž výstupní veličina  $y_{ma}$  je funkcí okamžitých hodnot vah spojení  $\gamma_i$  DNS, vypočtených při jejím on-line trénovacím kroku, realizovaném v rámci řízení regulované soustavy;

2) algoritmem učení NR, kterým je v průběhu řízení zajišťováno průběžné zpřesňování startovacích hodnot  $q_{ist}$  ANPSR. Výsledkem učení NR jsou hodnoty  $q_i$  vah NR, počítané z rovnice

$$q_i(k) = q_i(k-1) + \Delta q_i(k) \quad (7)$$

Změny vah  $\Delta q_i(k)$  NR počítáme z analogických rovnic k rovnicím (5) a (6), tzn.

$$\Delta q_i(k) = -\beta \frac{\partial E_r(k)}{\partial q_i(k)} \quad (8)$$

V této rovnici je  $\beta$  koeficient učení NR a  $E_r(k)$  je kvadratická funkce odchylky

$$E_r = \sum_{k=1}^N e_r(k)^2 = \sum_{k=1}^N (r(k) - y_{ma}(k))^2 \quad (9)$$

Stručněji a v návaznosti na klasické adaptivní řízení s popisem adaptivního

regulátoru i soustavy diferenční rovnici je regulační obvod popsán v [2]. BP – algoritmus, použitý pro řízení s ANPSR je odvozen v [5] a odvození algoritmu učení NR čtenář nalezne např. v [13]. Postup při návrhu a ožívování ANPSR spočívá ve stručnosti v následujících krocích:

1) nastavení výchozích hodnot parametrů  $q_{ist}$  regulátoru NR, které jsou dále použity jako startovací hodnoty ANPSR;

2) výstavba modelu regulované soustavy ve tvaru DNS a její trénování off-line; průběžné zpřesňování hodnot  $q_{ist}$  učním NR za současného on-line trénování DNS.

#### Nastavení startovacích hodnot $Q_{IST}$ a řízení samotným neuronovým regulátorem NR

Výchozí hodnoty parametrů  $q_{ist}$  jsou nastavovány v prvním zpětnovazebním



obvodu (viz kap.3). Předpokládáme, že NR je ve tvaru přírůstkového PS regulátoru

$$u(k) = q_0 e(k) + q_1 e(k-1) + u(k-1) \quad (10)$$


s parametry  $q_i, i = 0, 1$ , kde  $e(k)$  je regulační odchylka a  $u(k)$  je výstupní signál regulátoru. I když v našem případě se jedná o řízení soustavy nelineární, její dynamické vlastnosti v okolí počátku (viz obr. 2), které jsou obdobou vlastností lineární soustavy 1. řádu, nás k aplikaci rovnice (3) opravňuje. Parametry regulátoru nastavíme zkusmo metodou „pokus – omyl“.

Za účelem nastavení parametrů NR položíme v druhém dílčím regulačním obvodu  $\beta = 0$  (tzn. že vyřadíme tento regulační obvod z činnosti) a pracujeme s prvním regulačním obvodem, tvořeným regulátorem (10) a soustavou (1).

Dále pak pro žádanou hodnotu regulované veličiny  $r(k)$  (nastavení režimu soustavy do pracovního bodu) nalezneme hodnoty parametrů  $q_0$  a  $q_1$ , odpovídající přibližně požadavku danému bodem 1) cílů, formulovaných v kap. 2, např.

$$q_0 = 0,45 \quad q_1 = -0,05 \quad (11a,b)$$

Proporcionální složka regulátoru je rovna parametru  $q_0$ , přírůstek akční veličiny – jedná se o přírůstkový regulátor –  $\Delta u = q_0 - q_1$ . Průběh regulačního pochodu při řízení soustavy (1) NR regulátorem s koeficienty podle rovnice (11a,b) v prvních deseti regulačních krocích je uveden na obr. 4. Regulovaná veličina dosahuje žádané hodnoty  $y_s(k) = r(k) = 0,6$  v 7. regulačním kroku s překmitem  $\Delta y_{smax} < 2\%$  ve třetím kroku.



Obr. 4 K nastavení parametrů NR

Tab. 1 Úspěšnost regulace klasickým PS regulátorem při změnách žádané hodnoty

Skok $w$	Dosažení žádané hodnoty	Regulační krok
0,6-1,0	95%	8
	100%	22
1,0-0,6	95%	9
	100%	24
0,6-0,2	95%	11
	100%	25
0,2-0,6	95%	3
	100%	16

Parametry  $q_0$  a  $q_1$  (11a,b) jsou dále označovány u adaptivního regulátoru ANP-SR jako startovací hodnoty  $q_{ist}, i = 0, 1$ .

Na obr. 5 je uveden průběh regulačního pochodu pro žádané hodnoty regulované veličiny ve tvaru stupňové funkce  $r(k)$ , definované v kap. 2, pro změny v parametrech  $A, B$  a poruchy  $v_u$  a  $v_{ys}$  – viz rovnice (3a,b) a (3c,d). Je patrné, že při odchylkách směrem k vyšším (nižším) žádaným hodnotám se regulační proces zpomaluje (zrychluje), což je v souladu s průběhem statické charakteristiky na obr. 3. Kmitající průběh veličin regulačního obvodu při  $r(k) = 0,2$

Tab. 2 Úspěšnost regulace klasickým PS regulátorem při poruchách

Porucha	Dosažení žádané hodnoty	Regulační krok
$A \uparrow$	95%	6
	100%	15
$A \downarrow$	95%	6
	100%	17
$B \uparrow$	95%	3
	100%	14
$B \downarrow$	95%	4
	100%	15
$v_u$	95%	7
	100%	19
$v_{ys}$	95%	6
	100%	18

odstraníme programovým omezením akční veličiny na  $u(k)_{min} = 0$ , jak bylo požadováno v „cílech řízení“ v kap. 2.

Průběhy odezvy na impulsní změny v parametrech  $A$  a  $B$  svědčí o poměrně rychlé eliminaci vlivu těchto poruch na průběh regulačního procesu. Stejně tak je tomu i s eliminací vlivu skokových poruch v akční veličině  $v_u$  a v regulované veličině  $v_{ys}$ .

Již z vizuálního pohledu je zřejmé, že požadované cíle řízení nejsou zcela splněny. Na základě analýzy výsledků simulačních výpočtů lze konstatovat, (viz tab. 1), že

a) při přechodu z pracovního bodu  $r(k) = 0,6$  na žádanou hodnotu  $r(k) = 1$  dosáhne regulovaná veličina 95% žádané hodnoty v 8. kroku řízení, ustálená hodnota dosažena není, od 22. kroku řízení  $y(k)$  kmitá;

b) při změně z  $r(k) = 1$  na  $r(k) = 0,6$  je 95% žádané hodnoty dosaženo v 9. kroku řízení, ustálení v 24. kroku;

c) při přechodu z pracovního bodu  $r(k) = 0,6$  na žádanou hodnotu  $r(k) = 0,2$  je 95% žádané hodnoty dosaženo v 11. kroku řízení, žádané hodnoty v 25. kroku zcela dosažena není. Je to způsobeno nutným omezením akčního zásahu na nulovou hodnotu;

d) při změně z  $r(k) = 0,2$  do pracovního bodu  $r(k) = 0,6$  kroku do pracovního bodu  $r(k) = 0,6$  se soustava chová jako při nastavování parametrů regulátoru v první fázi řízení. Překmit je v 3. kroku řízení, 95% žádané hodnoty je dosaženo v 5. kroku řízení, ustálení v 16. kroku. Výsledky eliminace poruch jsou uvedeny v tab. 2.

Z uvedeného plyne, že klasický PS regulátor bez problémů eliminuje vliv poruch zhruba ve stejných krocích řízení, 95% žádané hodnoty dosáhne výstupní veličina v rozmezí 7 až 8 kroků řízení, úplného ustálení pak v rozmezí 14 až 19 kroků.

Další možností, jak hodnotit úspěšnost řízení je výpočet středně - kvadratického kritéria odchylek mezi žádanou hodnotou a průběžnou hodnotou na výstupu ze soustavy (chybová funkce řízení) podle vztahu

$$E_\sigma = \sqrt{\frac{\sum_{k=1}^N (r(k) - y_s(k))^2}{N-1}} \quad (12)$$

V řešené úloze je hodnota tohoto kritéria vypočítaná pro celou oblast řízení rovna  $E_{\sigma 0} = 0,067902$ , pro oblast

změn žádané hodnoty  $E_{o1} = 0,10396$  a pro oblast poruch  $E_{o2} = 0,016830$ .

Nabízí se tak „vylepšit“ průběh regulačního pochodu nasazením ANPSR. Za tímto účelem je však třeba se zabývat výstavbou a trénováním dopřední neuronové sítě jakožto modelu soustavy.

**Model ve tvaru DNS a její trénování off-line**

Podrobněji se čtenář s návrhem topologie DNS, jejím trénováním a testováním může seznámit např. v [7]. V našem případě je navržena DNS, s následující topologií (bez nároků na její optimální strukturu):

- počet zdrojových uzlů: 2,
- počet skrytých vrstev: 1,
- počet neuronů ve skryté vrstvě: 3,
- počet neuronů na výstupu: 1,
- aktivační funkce skrytých neuronů: unipolární sigmoida se strmostí  $s=1$ ,
- aktivační funkce výstupního neuronu: lineární se strmostí  $K = 1$ .

Východiskem pro sestavení trénovací množiny DNS je stupňová funkce  $u(k) = 0,2; 0,4; 0,6; 0,8; 1; 0,8; 0,6; 0,4; 0,2; 0$  s počtem kroků v každém stupni rovném 30. Trénování se uskutečňuje BP – algoritmem.

Výsledky trénování jsou patrné z průběhů veličin  $u(k)$ ,  $y_s(k)$  a  $y_{ma}(k)$  na obr. 6 pro následující hodnoty parametrů BP – algoritmu:

- koeficient učení, zjištěný experimentálně a zajišťující minimální hodnotu kritériální funkce a její nejrych-

lejší konvergenci:  $\alpha = 0,3$ ,

- maximální počet epoch trénování, umožňující vizuálně sledovat splnění výše uvedené podmínky:  $p_{e_{max}} = 10.000$ ,
- výchozí váhy spojení  $w(j)$  (mezi skrytou vrstvou a výstupním neuronem) a  $v(i,j)$  (mezi vstupními uzly a skrytou vrstvou): náhodně zvolené – viz tab. 3.

Tab. 3 Startovací hodnoty vah spojení

j	0	1	2	3
w(j)	0,1	0,1	-0,5	0,2
	i / j	1	2	3
v(i,j)	0	-0,5	0,4	-0,3
	1	0,1	-0,2	0,3
	2	0,25	-0,35	0,45

Tab. 4 – Výsledné hodnoty vah spojení pro  $\alpha = 0,3$

j	0	1	2	3
w(j)	0,04	2,56	-2,57	0,03
	i / j	1	2	3
v(i,j)	0	-0,69	1,49	0,03
	1	-0,27	-2,16	-3,13
	2	-0,24	0,66	0,60

Z obr. 6 je patrné, že takto sestavená a trénovaná DNS jakožto model soustavy (1) velmi dobře aproximuje její dynamické chování. Charakter odezvy  $y_s(k)$  soustavy a  $y_m(k)$  DNS na stupňovou funkci  $u(k)$  je v souladu s charakterem odezvy soustavy na

skokové funkce na obr. 1. Tzn. že se zvyšující se hodnotou vstupního signálu se zvyšuje amplituda tlumených kmitů odpovídajících odezvy, přičemž je prakticky  $y_s(k) \approx y_m(k)$ . Dílčí odezvy na jednotlivé stupně funkce  $u(k)$  mají překmity periodického, tlumeného charakteru, přičemž tento jejich znak je výraznější u odezvy přibližujících se k maximum stupňové funkce.


Získané hodnoty vah spojení jsou uvedeny v tab. 4.

**Řízení s použitím ANPSR**

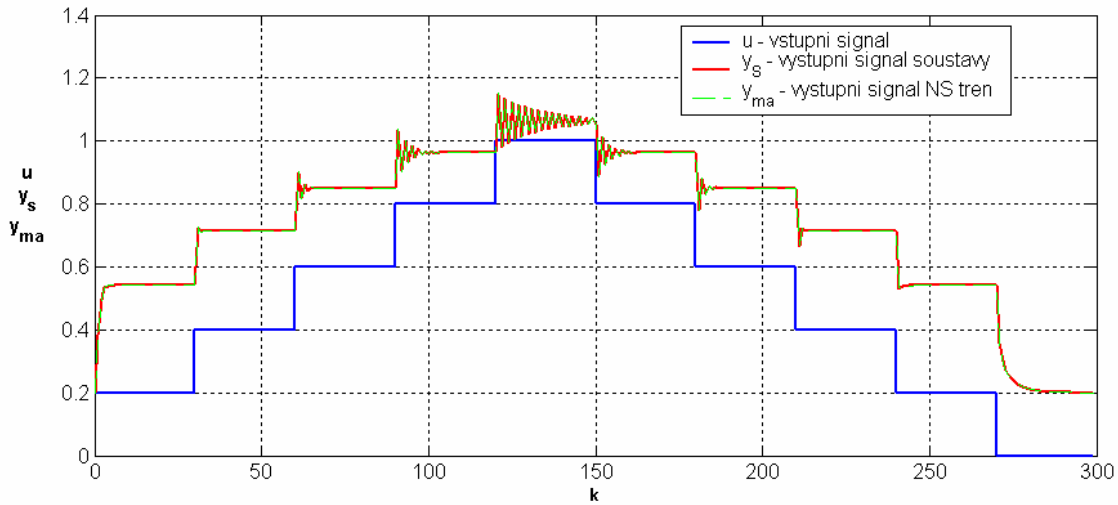
Výše získané hodnoty vah spojení DNS a startovací hodnoty parametrů  $q_{ist}$  neuronového regulátoru jsou startovacími parametry algoritmu ANPSR.

Po startu ANPSR dochází on-line postupně v jednotlivých krocích – stručně řečeno - k zpřesňování startovacích hodnot vah  $\gamma_{st}$  DNS, k aktualizaci výstupní veličiny  $y_{ma}$  prostřednictvím bloku ADNS a k následnému trénování NR při kterém jsou přestavovány parametry regulátoru  $q_0$  a  $q_1$  tak, aby byla zajištěna minimální hodnota regulační odchylky  $e$  (6) a kvadratické odchylky  $e_r$  (9).

Cílem simulačních výpočtů je pak podobně, jako při off-line trénování DNS, kdy se hledala optimální hodnota koeficientu učení DNS  $\alpha$  zajišťující minimální hodnotu kritériální funkce  $E_\alpha$  (6), nalézt takovou hodnotu koeficientu učení  $\beta$  NR, při které bude zajištěn požadovaný průběh regulačního pochodu.



Obr. 5 Řízení soustavy s použitím NR



Obr. 6 Průběh trénování

Za tímto účelem byla provedena série simulačních výpočtů pro  $\beta = 0,1$  až  $2,8$  a stejné změny žádané hodnoty  $r(k) = 0,6; 1; 0,6; 0,2; 0,6$ , poruchy v parametrech řízené soustavy  $A$  a  $B$  a poruchy v akční veličině a v regulované veličině  $v_u(k)$ ,  $v_{ys}(k)$  jako v případě řízení soustavy klasickým PS regulátorem (3a,b,c,d). Získané výsledky prezentované jako minimální počty regulačních kroků potřebných pro ustálení regulované veličiny na 95%, resp. 100% žádané hodnoty regulované veličiny pro jednotlivé skokové změny a odpovídající optimální hodnoty koeficientů učení NR  $\beta_{opt}$  jsou uvedeny v tab. 5.

Z tabulky je zřejmé, že optimální hodnota koeficientu učení  $\beta_{opt}$  se mění v závislosti na změně žádané hodnoty. Tento jev lze vysvětlit nelinearitou řízené soustavy (1). V případě změn žádané hodnoty v rozsahu  $0,6-1,0-0,6$ ,


kdy je zesílení soustavy menší než v pracovním bodě  $P = 0,6$ , je hodnota učení  $\beta_{opt}$  NR vysoká, v případě změn v rozsahu  $0,6-0,2-0,6$ , kdy je zesílení soustavy vyšší než v pracovním bodě  $P$ , je hodnota  $\beta_{opt}$  NR naopak menší.

Při porovnání s výsledky regulace klasickým PS regulátorem (viz tab. 1) lze konstatovat, že až na skok  $0,6-0,2$  (kdy je uměle zavedeno omezení akční veličiny na  $u \geq 0$ ), došlo k urychlení regulačního pochodu, tzn. k jeho zkvalitnění. To lze dokumentovat i na průbězích středně - kvadratického kritéria (12), viz obr. 7. Tyto průběhy byly vypočteny jak pro celou oblast simulovaného řízení (průběh  $E_{s0}$ ), tak pro oblast změn žádané hodnoty (průběh  $E_{s1}$ ) i pro oblast poruch (průběh  $E_{s2}$ ). Kroužkem jsou označeny minimální hodnoty, kterých je dosaženo pro celou oblast řízení i pro oblast změn žádané hodnoty při hodnotě koeficientu učení  $\beta \approx 2$ . Průběh v oblasti poruch je téměř neměnný a roven hodnotě, která byla dosažena při regulaci klasickým PS regulátorem. To lze vysvětlit tím, že změny parametrů soustavy i poruchy jsou zavedeny do soustavy, v režimu pracovního bodu, ve kterém byly stanoveny koeficienty klasického PS regulátoru.

Z uvedeného plyne, že jednoznačně stanovení koeficientu učení NR regulátoru pro měnící

se podmínky řízení není možné. Jeho volba je proto závislá nejen na podrobnější analýze chování regulačního obvodu pro předpokládané změny a poruchy v regulačním obvodu, ale i na zkušenostech projektanta řídicího systému.

Průběh řízení pro zvolenou hodnotu koeficientu učení NR  $\beta = 1,0$  je uveden na obr. 8. I vizuálně je patrné zlepšení kvality řízení v porovnání s řízením klasickým PS regulátorem. Výsledné adaptované hodnoty vah (parametrů) neuronového regulátoru jsou  $q_0 = 0,6070$  a  $q_1 = -0,1917$ .




Obr. 7 Průběhy středně-kvadratické odchylky  $E_s$  (12) při změně koeficientu učení NR

Tab. 5 – Mezní hodnoty regulačních kroků při ANPSR

skok	$\beta_{opt}$	0,1	0,3	0,4	0,7	1,1	1,4
0,6-1,0	95%				4		
	100%			22			
1,0-0,6	95%					4	
	100%						11
0,6-0,2	95%	11					
	100%	25					
0,2-0,6	95%		4				
	100%		5				

Zkvalitnění regulačního procesu při použití ANPSR je ve srovnání s výsledky řízení NR regulátorem zřejmé, ale nelze je považovat za ohromující. Dosažený výsledek jen potvrzuje známý fakt, že jednoduchým, klasickým PS regulátorem, ať už ve tvaru diferenční rovnice nebo neuronové sítě, lze řídit s úspěchem nejen sousta-


 Obr. 8 Průběh regulačního pochodu v režimu ANPSR pro  $\beta = 1,0$ 

vy lineární, ale s jistým omezením i jednodušší soustavy nelineární. A takovou je i prezentovaná soustava (1). Na druhé straně však není pouhou frází, že k řízení složitějších, nelineárních typů soustav je vhodné někdy použít i složitějších typů regulátorů, jako je např. ANPSR, prediktivní regulátor či regulátory hybridní. Proto je dobře se s principy a vlastnostmi těchto regulátorů seznámit a v případě potřeby umět tyto regulátory použít. Pochopitelně že použití toho či onoho regulátoru závisí také na specifikaci úlohy řízení, tzn. na cílech, které jsou řízením sledovány.

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

#### Literatúra

1. DRÁBEK, O.; MACHÁČEK, J. Experimentální identifikace. Pardubice : VŠCHT, 1987.
2. MIKLEŠ, J.; FIKAR, M. Modelovanie, identifikácia a riadenie procesov 2. Identifikácia a optimálne riadenie. Bratislava : Vydavateľstvo STU Bratislava, 2004. ISBN 80 227 2134-4.
3. DRÁBEK, O.; MACHÁČEK, J. Adaptivní řízení. Pardubice : VŠCHT, 1992.

4. SINČÁK, P.; ANDREJKOVÁ, G. Neuronové 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.
5. FAUSETT, L.V. Fundamentals of Neural Network: Architectures, Algorithm and Applications. New Persey : Prentice Hall, 1994.
6. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (6). CHEMagazin, 6 (XVI), 2006, s. 31-33. ISSN 1210 – 7409.
7. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (7). CHEMagazin, 3 (XVII), 2007, s. 38-41. ISSN 1210 – 7409.
8. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (8). CHEMagazin, 4 (XVII), 2007, s. 28-30. ISSN 1210 – 7409.
9. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (9). CHEMagazin, 6 (XVII), 2007, s. 32-34. ISSN 1210 – 7409.
10. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (12). CHEMagazin, 5 (XVIII), 2008, s. 28-30. ISSN 1210 – 7409.
11. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (13). CHEMagazin, 6 (XVIII), 2008, s. 28-30. ISSN 1210 – 7409.

12. DRÁBEK, O.; MACHÁČEK, J. Adaptivní řízení. Pardubice : VŠCHT Pardubice, 1992.
13. TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – teorie a aplikace (14). CHEMagazin, 1 (XIX), 2009, s. 26-28. ISSN 1210 – 7409.
14. TAN, Y. Architecture for adaptive neural control. Neural Control Journal A. vol. 34, No 4, 1993
15. 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

The paper deals with one of the possible methods for control of the nonlinear dynamical system, namely with the adaptive neural PS controller (ANPSC). Its principle is in on-line precision of the model system and then in the adaptive adjustment of the controller parameters. The model of the plant is realized with the two – layer feedforward neural network. The control part of the ANPSC has the structure of the classical PS – controller, and it is created likewise in the form of the neural network - simple perceptron.

RESUME