

RIADENIE CHEMICKÉHO REAKTORA V PRÍTOMNOSTI PORÚCH POMOCOU NEURO-FUZZY SYSTÉMU RIADENIA

Lenka Blahová a Ján Dvoran

*Slovenská technická univerzita, Fakulta chemickej a potravinárskej technológie
Radlinského 9, 812 37 Bratislava
Tel.: +421 252 495 269 Fax: +421 252 496 469
e-mail: lenka.blahova@stuba.sk*

Abstract: V príspevku je popísaný inteligentný systém riadenia tvorený kombináciou neurónového prediktívneho regulátora a neuro-fuzzy regulátora typu ANFIS. ANFIS je zapojený paralelne a upravuje výstup získaný z prediktívneho regulátora, čím zlepšuje riadiace vlastnosti. Kvalita riadenia je overená na riadení prietokového chemického reaktora v nominálnom stave a v prítomnosti porúch. Experimentálne výsledky potvrdili zlepšenie kvality riadenia v porovnaní so samostatným neurónovým prediktívnym regulátorom a zároveň navrhnutý systém riadenia preukázal dobré zvládnutie poruchy.

Keywords: Neuro-fuzzy regulátor, Neurónová sieť, Prediktívne riadenie, Chemický reaktor.

1 ÚVOD

Cieľom každého riadeného procesu je dosiahnuť hodnotu žiadanej veličiny. V značnej miere sa práve o hodnotu tejto veličiny stará vhodne navrhnutý regulátor. Regulátor by mal spĺňať požiadavky flexibility a to hlavne z dôvodov ako sú výskyt nečakanej poruchy prípadne možná zmena podmienok a pod. V dnešnej dobe je na návrh inteligentných regulátorov vypracovaných množstvo metód medzi ktoré patria aj fuzzy regulátory, neurónové siete alebo expertné systémy. Vhodnou kombináciou týchto metód je možné dosiahnuť množstvo ďalších možností návrhov.

V príspevku je popísaný postup na vytvorenie inteligentného systému riadenia, ktorý by zlepšoval neurónové prediktívne riadenie chemického reaktora (Vasičkaninová, 2008). Toto bolo dosiahnuté paralelným zapojením neuro-fuzzy regulátora typu ANFIS k neurónovému prediktívnemu regulátoru. V príspevku je navrhnutý systém riadenia testovaný aj pri riadení chemického reaktora v prítomnosti porúch na overenie stability riadenia..

2 PREDIKTÍVNE RIADENIE

V mnohých prípadoch a to nie len v technickom ponímaní je predpoveď krokov vysoko žiadanou veličinou. A práve toto je prvotnou myšlienkou prediktívneho riadenia (Obr. 1), predvídať budúcnosť resp. predvídať kroky výstupnej veličiny. Tie sa získajú na základe modelu, ktorý je zväčša súčasťou bloku regulátora (Vasičkaninová, 2008). V našom prípade je modelom neurónová sieť, ktorá je natrénovaná offline. Regulátor pomocou tohto modelu vypočíta pred akčným zásahom budúce správanie sa systému. Túto predpoveď vykoná prediktívny regulátor optimalizačným algoritmom ten vyhodnotí a vyberie optimálny krok, ktorým následne ovplyvní akčnú veličinu minimalizáciou účelovej funkcie.


$$J(t, u(k)) = \sum_{i=N_1}^{N_2} (y_m(t+i) - y_r(t+i))^2 + \lambda \sum_{i=1}^{N_u} (\Delta u(t+i-1))^2 \quad (1)$$

Veličiny vystupujúce v rovnici:

$y_m(t+i)$ výstup z procesu predpovedaný i krokov dopredu s ohľadom na informácie získané do času t , $y_r(t+i)$ je následnosť žiadanej veličiny, $\Delta u(t+i-1)$ je následnosť budúcich zmien akčnej veličiny, ktoré majú byť vypočítané. Hodnoty N_1 a N_2 určujú interval, potreby pozorovania priebehu žiadanej veličiny v budúcnosti. N_u je horizont predikcie akčného zásahu. Parameter λ je váhový koeficient zmeny akčnej veličiny. Táto rovnica sa využíva zároveň s obmedzeniami na vstupné a výstupné veličiny:

$$\begin{aligned} u_{\min} &\leq u \leq u_{\max} \\ \Delta u_{\min} &\leq \Delta u \leq \Delta u_{\max} \\ y_{\min} &\leq y \leq y_{\max} \\ \Delta y_{\min} &\leq \Delta y \leq \Delta y_{\max} \end{aligned} \tag{2}$$


Z Modelu systému a z optimalizačného bloku je zostavený prediktívny regulátor. V optimalizačnom bloku sa vypočítava hodnota akčného zásahu, ktorá minimalizuje účelovú funkciu J . Následne takto získaná optimálna hodnota akčného zásahu vstupuje do riadeného systému.



Obrázok 1. Schéma prediktívneho riadenia

3 NEURO-FUZZY RIADENIE

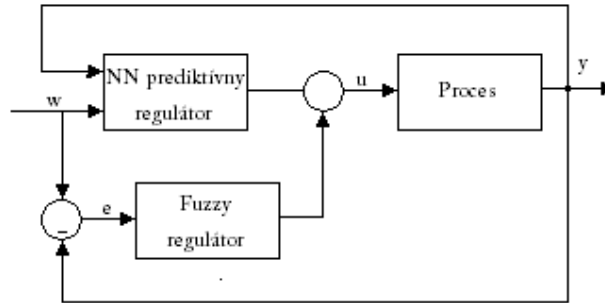
K zlepšeniu riadenia pomocou neurónového prediktívneho regulátora pomáha paralelné zapojenie iného typu regulátora. Vhodnou voľbou je neuro-fuzzy regulátor typu ANFIS (Adaptive Network-based Fuzzy Inference System) (Vasičkaninová, 2006). Takýto regulátor je päťvrstvová dopredná neurónová sieť, ktorej výsledkom je fuzzy inferenčný systém typu Takagi-Sugeno (Obr. 2).



Obrázok 2. Architektúra systému ANFIS

Na tréovanie neurónovej siete ANFIS používa hybridnú tréovaciu metódu. Parametre v predpoklade pravidla, ktoré určujú funkcie príslušnosti jednotlivých vstupných premenných, sú optimalizované gradientovou metódou. Parametre dôsledku, ktoré môžu byť konštanty alebo koeficienty lineárnej funkcie, sú vypočítané metódou najmenších štvorcov.

Potom predchádzajúce neurónové prediktívne riadenie je rozšírené o neuro-fuzzy regulátor typu ANFIS. Tento regulátor je zapojený paralelne s neurónovým prediktívnym regulátorom, tak ako je vidieť na obr. 3. Výstup z neuro-fuzzy regulátora priamo ovplyvňuje výstup z neurónového prediktívneho regulátora a tým akčný zásah do procesu lepšie upravuje priebeh riadenej veličiny.



Obrázok 3. Schéma neuro-fuzzy riadenia

4 EXPERIMENTÁLNE VÝSLEDKY

Riadený systém

Riadeným systémom je plášťový prietokový chemický reaktor s dokolnalým miešaním reakčnej zmesi (CSTR, Obr. 4) a s dvoma paralelnými exotermickými reakciami 1. poriadku typu (Mikleš, 2007):



Zjednodušený nelineárny model reaktora tvorí 5 diferenciálnych rovníc (Mikleš, 2007).

$$\frac{dc_A}{dt} = \frac{q}{V} c_{vA} - \frac{q}{V} c_A - k_1 c_A - k_2 c_A \quad (4)$$

$$\frac{dc_B}{dt} = \frac{q}{V} c_{vB} - \frac{q}{V} c_B + k_1 c_A \quad (5)$$

$$\frac{dc_C}{dt} = \frac{q}{V} c_{vC} - \frac{q}{V} c_C + k_2 c_A \quad (6)$$

$$\frac{d\mathcal{G}}{dt} = \frac{q}{V} \mathcal{G}_v - \frac{q}{V} \mathcal{G} - \frac{Ak}{V\rho\rho_p} [\mathcal{G} - \mathcal{G}_c] + \frac{Q_r}{V\rho\rho_p} \quad (7)$$


$$\frac{d\mathcal{G}_c}{dt} = \frac{q}{V_c} \mathcal{G}_{vc} - \frac{q}{V_c} \mathcal{G}_c + \frac{Ak}{V_c \rho_c c_{pc}} [\mathcal{G} - \mathcal{G}_c] \quad (8)$$

Kde rýchlostné konštanty sú definované na základe Arrheniusovej rovnice:

$$k_i = k_{i\infty} e^{\frac{-E_i}{R\mathcal{G}}} \quad (9)$$

Teplo vzniknuté reakciou je určené podľa rovnice (10).

$$Q_r = k_1 c_A V (-\Delta_r H_1) + k_2 c_A V (-\Delta_r H_2) \quad (10)$$



Obrázok 4: Zjednodušená schéma chemického reaktora

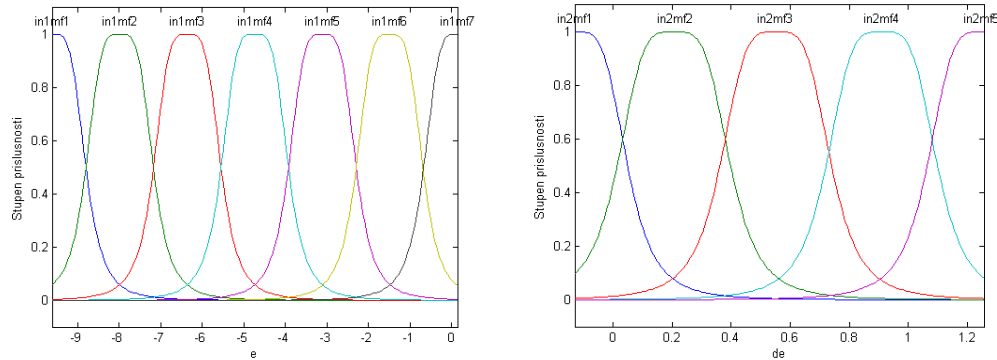
Do reaktora vstupuje reakčná zmes s prietokom q , ktorý obsahuje látku A. Latky B a C sa vo vstupnom prúde nenachádzajú. Výstupnými veličinami reaktora sú koncentrácie látok (c_A , c_B a c_C) a teplota reakčnej zmesi Θ . Reaktor je chladený chladiacim médiom s prietokom q_c , ktorý je riadiacou veličinou, a teplotou Θ_c . Parametre reaktora sú uvedené v Tabuľke 1.

Tabuľka 1: Parametre chemického reaktora

Parameter	Jednotka	Hodnota
c_{vA}	kmol m^{-3}	4,22
c_{vB}	kmol m^{-3}	0
c_{vC}	kmol m^{-3}	0
q	$\text{m}^3 \text{min}^{-1}$	0,015
Θ_v	K	328
P	kg m^{-3}	1020
c_p	$\text{kJ kg}^{-1} \text{K}^{-1}$	4,02
V	m^3	0,23
q_{vc}	$\text{m}^3 \text{min}^{-1}$	0,004
Θ_{vc}	K	298
ρ_c	kg m^{-3}	998
c_{pc}	$\text{kJ kg}^{-1} \text{K}^{-1}$	4,182
V_c	m^3	0,21
A	m^2	1,51
K	$\text{kJ min}^{-1} \text{m}^{-2} \text{K}^{-1}$	42,8
E_1/R	K	9850
$\Delta_r H_1$	kJ kmol^{-1}	$-8,6 \cdot 10^4$
$k_{1\infty}$	min^{-1}	$1,55 \cdot 10^{11}$
E_2/R	K	22019
$\Delta_r H_2$	kJ kmol^{-1}	$-1,82 \cdot 10^4$
$k_{2\infty}$	min^{-1}	$4,55 \cdot 10^{25}$


Riadenie systému v nominálnom stave

Riadenie bolo simulované v pracovnom prostredí Matlab/Simulink®. Pri riadení sa využíval Neural Network Toolbox a Fuzzy Logic Toolbox.



Obrázok 5. Funkcie príslušnosti pre vstupné hodnoty ANFIS regulátora

Na začiatok bol CSTR riadený pomocou samostatného neurónového prediktívneho regulátora (NNPR). Pre vytvorenie tohto regulátora bolo potrebné mať model procesu vo forme neurónovej siete. Tento model bol tréňovaný offline pomocou vstupných a výstupných údajov, ktoré boli vygenerované na základe nelineárneho modelu.



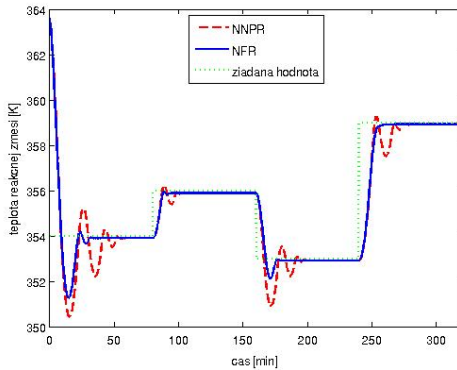
Obrázok 6 Riadenie chemického reaktora neurónovým prediktívnym regulátorom a neuro-fuzzy regulátorom

Vstup neurónovej siete predstavuje prietok chladiaceho média q_c a výstup teplotu reakčnej zmesi ϑ . Neurónová sieť bola tréňovaná metódou Levenberg-Marquardt backpropagation. Po nastavení optimalizačných parametrov bol systém riadený navrhnutým neurónovým prediktívnym regulátorom. Pribeh riadenia je zobrazený na obr. 6.

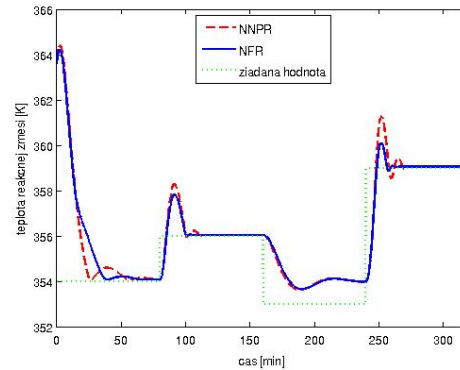
Ďalej bol CSTR riadený neuro-fuzzy systémom riadenia (NFR), ktorý bol vytvorený tak, že k predchádzajúcemu neurónovému prediktívnemu regulátoru bol paralelne zapojený ANFIS regulátor. Tento bol trénovaný na základe klasického PID regulátora navrhnutého Smith-Murrillovou metódou.

Vstupmi pre ANFIS sú regulačná odchýlka e a jej zmena Δe . Výstupom je akčný zásah, ktorý upravuje výstup z neurónového prediktívneho regulátora, tak ako je to zobrazené v schéme na obr. 3. Takto upravený akčný zásah vstupuje do riadeného systému a priebeh riadenia pomocou navrhnutého spôsobu riadenia je zobrazený na obr. 6. Pre vstup e do neuro-fuzzy regulátora bolo zvolených 7 funkcií príslušnosti zvonového tvaru a pre vstup Δe bolo zvolených 5 funkcií príslušnosti takisto zvonového tvaru ako to môžeme vidieť na obr. 5.

Riadenie systému pri pôsobení poruch




a)




b)

Obrázok 7. Porovnanie priebehu riadenia CSTR použitím NNPR a NFR – skoková zmena poruchy bola nastavená: a) + 8 K z nominálnej hodnoty vstupnej teploty reakčnej zmesi, b) – 8 K z nominálnej hodnoty vstupnej teploty reakčnej zmesi.

Okrem sledovania regulačných vlastností navrhnutého regulátora pri riadení CSTR v nominálnom stave, sa neuro-fuzzy regulátor testoval pri riadení CSTR v prítomnosti porúch. Bola nastavená skoková náhodná porucha vstupnej teploty reakčnej zmesi ϑ_v v rozsahu ± 8 K z nominálnej hodnoty a skoková náhodná porucha vstupnej koncentrácie látky A c_{vA} v rozsahu ± 10 % z nominálnej hodnoty. Systémy boli riadené neurónovým prediktívnym regulátorom a neuro-fuzzy regulátorom, priebehy riadenia sú zobrazené na Obr. 7 a Obr. 8.




a)



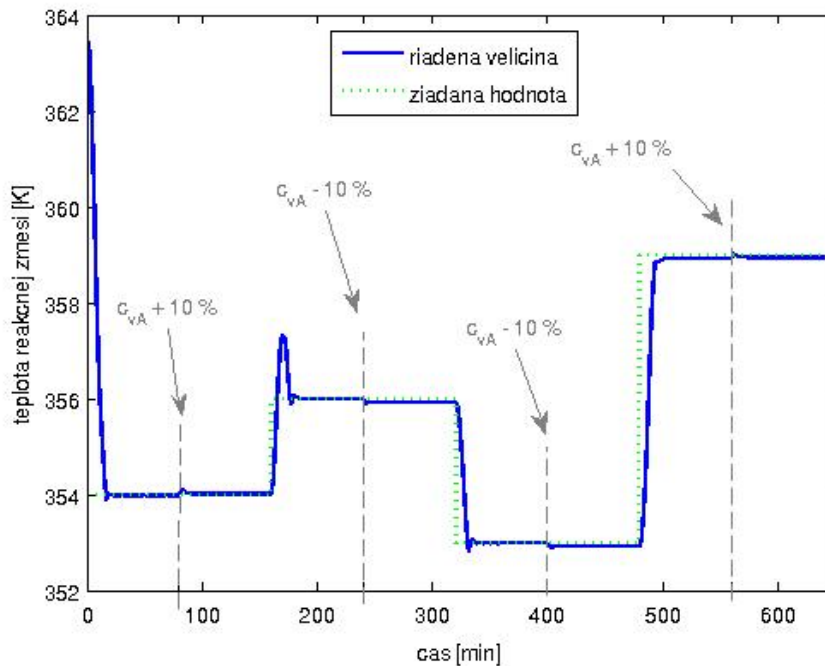
b)

Obrázok 8. Porovnanie priebehu riadenia CSTR použitím NNPR a NFR – skoková zmena poruchy bola nastavená: a) + 10 % z nominálnej hodnoty vstupnej koncentrácie látky A, b) – 10 % z nominálnej hodnoty vstupnej koncentrácie látky A.

V nasledujúcom experimente, boli aplikované skokové zmeny poruchy teploty reakčnej zmesi ϑ_v v rozsahu ± 8 K z nominálnej hodnoty a skokové zmeny poruchy vstupnej koncentrácie látky A c_{vA} v rozsahu ± 10 % z nominálnej hodnoty, v priebehu riadenia CSTR. NFR preukázal dobré zvládnutie poruchy, ako je vidieť na Obr. 9 a Obr. 10 (kde šípky ukazujú kde boli aplikované poruchy teploty reakčnej zmesi alebo vstupnej koncentrácie látky A).



Obrázok 9. Priebeh riadenia CSTR pri zmene vstupnej teploty reakčnej zmesi počas riadenia použitím neuro-fuzzy regulátora.



Obrázok 10. Priebeh riadenia CSTR pri zmene vstupnej koncentrácie látky A počas riadenia použitím neuro-fuzzy regulátora.

5 ZÁVER

V príspevku popísaný inteligentný systém riadenia CSTR, tvorený paralelným zapojením neurónového prediktívneho regulátora a neuro-fuzzy regulátora typu ANFIS, kombinuje výhody prediktívneho riadenia s neuro-fuzzy systémami, čím sa zlepšuje kvalita riadenia.

Zlepšenie riadenia potvrdzujú aj získané simulačné výsledky, z ktorých je tiež vidieť, že navrhnutý systém riadenia dobre zvláda náhodný výskyt poruchy vstupnej teploty reakčnej zmesi a vstupnej koncentrácie látky A. Získané výsledky ukazujú robustnosť a užitočnosť navrhnutého inteligentného systému riadenia a poukazujú na vhodnosť využitia tejto techniky pri riadení procesov.

Tento príspevok vznikol s podporou VEGA MŠ SR a SAV pre projekty č. 1/0071/09 a 1/0537/10 a s podporou APVV pre projekt č. APVV-0029-07.

LITERATÚRA

- MIKLEŠ, J., FIKAR, M. (2007).: *Process Modelling, Identification and Control*. Springer Verlag, Berlin Heidelberg
- VASIČKANINOVÁ, A., BAKOŠOVÁ, M., MÉSZÁROS, A., ZÁVACKÁ J. (2008).: Model-based predictive control of a chemical reactor. *In 18th International Congress of Chemical and Process Engineering*, 0623-1-0623-6
- VASIČKANINOVÁ, A., BAKOŠOVÁ, M., DVORAN, J.,(2006).: Tvorba neuro-fuzzy modelov metódou ANFIS. *V AT&P journal 11*, p. 73-76