

# RIADENIE NELINEÁRNYCH SYSTÉMOV POMOCOU NEURÓNOVÝCH SIETÍ OPTIMALIZOVANÝCH GENETICKÝMI ALGORITMAMI

Zuzana Dideková a Slavomír Kajan

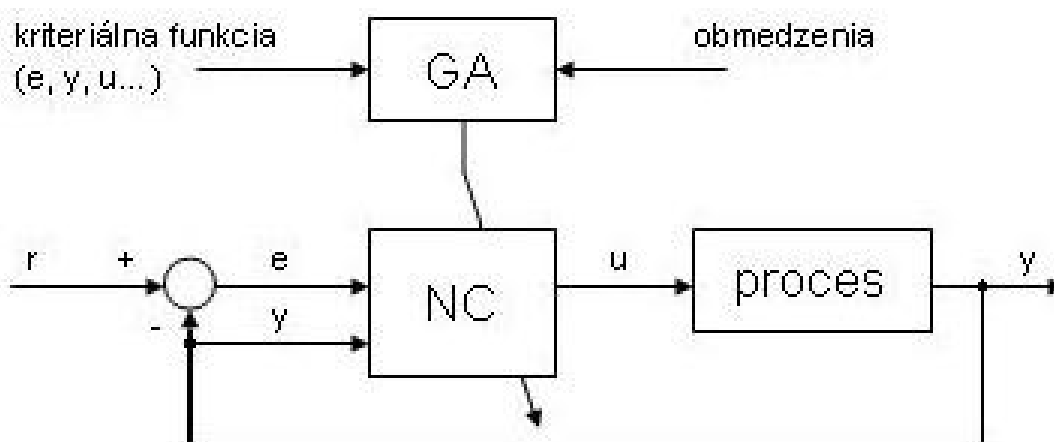
*Slovenská technická univerzita, Fakulta elektrotechniky a informatiky  
Ilkovičova 3, 812 19 Bratislava, Slovenská republika  
Tel.: +421 2 60291621  
e-mail: [zuzana.didekova@stuba.sk](mailto:zuzana.didekova@stuba.sk)*

**Abstrakt:** Riadenie nelineárnych procesov nie je jednoduchou úlohou. Jedným zo spôsobov riadenia takýchto procesov je riadenie pomocou neurónovej siete, ktorá predstavuje inteligentný regulátor. V tomto článku je predstavená metóda návrhu neurónového regulátora použitím genetických algoritmov. Táto metóda umožňuje nájsť optimálne nastavenie váh neurónovej siete tak, aby bola zabezpečená požadovaná kvalita riadenia v celom pracovnom rozsahu procesu. Navrhnutá metóda riadenia je overená v prostredí Matlab-Simulink na príklade izotermického reaktora, ktorý reprezentuje reálny nelineárny proces.

**Kľúčové slová:** genetické algoritmy, neurónová sieť, neurónový regulátor

## 1 ÚVOD

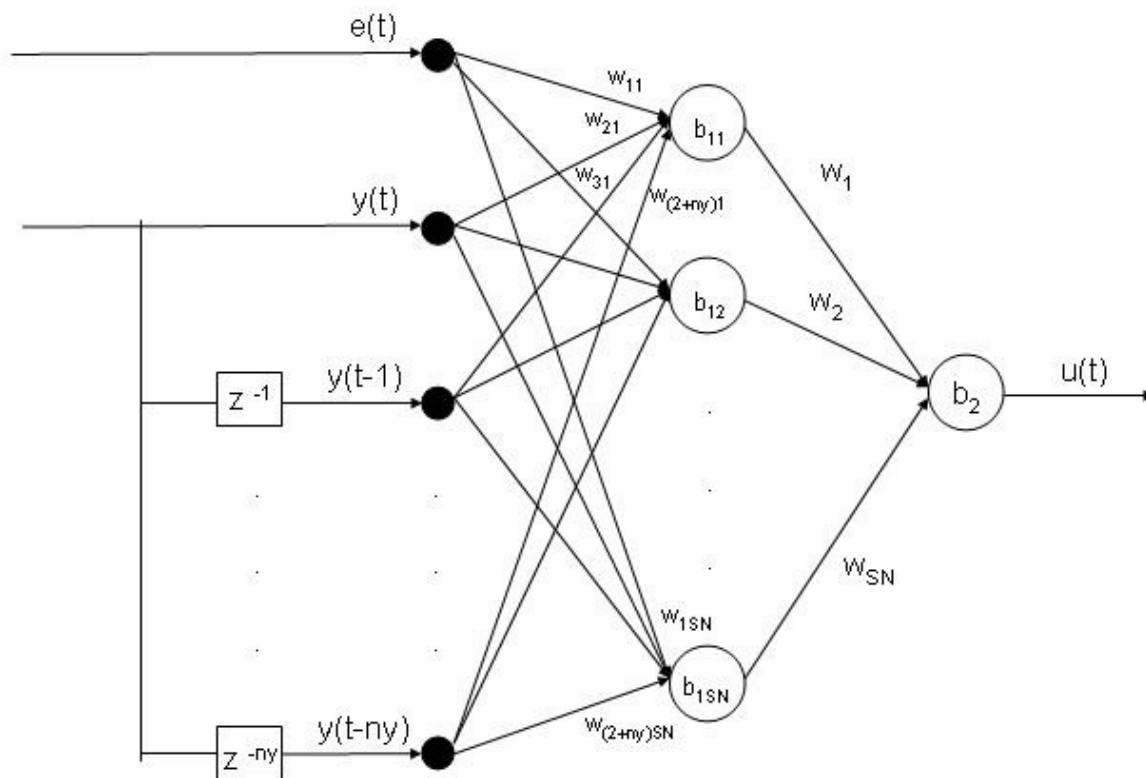
Pri riadení niektorých tried nelineárnych dynamických systémov sa s výhodou využívajú neurónové regulátory (neural controllers, NC). Neurónová sieť sa môže použiť pre riadenie nelineárnych procesov v rôznych typoch riadenia, ako sú priame inverzné riadenie, neuro-prediktívne riadenie, riadenie s referenčným modelom alebo ako neurónový regulátor optimalizovaný pomocou genetických algoritmov (GA). Tento článok sa zaoberá posledným spomenutým prípadom, t.j. neurónovými regulátormi optimalizovanými pomocou genetických algoritmov. Na obrázku 1 je zobrazený riadiaci systém s NC optimalizovaný pomocou GA (Sekaj, 2003).



Obrázok 1: Blokovo schéma riadiaceho systému s NC optimalizovaným pomocou GA

## 2 FORMULÁCIA PROBLEMATIKY

Neurónový regulátor je reprezentovaný viacvrstvou perceptrónovou (multi-layer perceptron, MLP) sieťou s jednou skrytou vrstvou. Tento typ neurónovej siete je schopný aproximovať ľubovoľnú spojitú nelineárnu funkciu, čo jej umožňuje pri dobrom nastavení parametrov sledovať zmenu dynamiky procesu v závislosti od pracovného bodu. Schéma neurónového regulátora je na obrázku 2.



Obrázok 2: Schéma neurónového regulátora

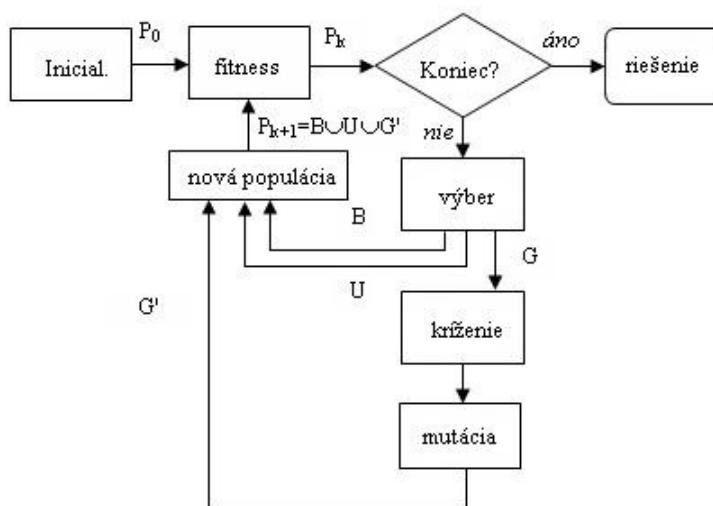
Vstupmi do neurónovej siete sú regulačná odchýlka  $e(t)$ , regulovaná výstupná veličina  $y(t)$  a predchádzajúce hodnoty regulovanej výstupnej veličiny  $y(t-i)$ , kde  $i = 1, \dots, ny$  a  $ny$  je počet predchádzajúcich hodnôt regulovanej výstupnej veličiny. Výstupom z neurónovej siete je akčný zásah  $u(t)$ .

Váhy medzi vstupnou a skrytou vrstvou sú označené ako premenné  $w_{ij}$ , čo znamená váhu prepojenia medzi neurónom  $i$  zo vstupnej vrstvy ( $i = 1, \dots, 2+ny$ ) a neurónom  $j$  zo skrytej vrstvy ( $j = 1, \dots, SN$ ,  $SN$  – počet neurónov v skrytej vrstve). Váhy medzi skrytou a výstupnou vrstvou sú premenné  $w_k$ , kde  $k$  označuje neurón v skrytej vrstve ( $k = 1, \dots, SN$ ), ktorý je spojený s jediným neurónom na výstupe. Premenné  $b_{1k}$  ( $k = 1, \dots, SN$ ) sú prahy v skrytej vrstve a  $b_2$  prah vo výstupnej vrstve. (Demuth, 2003; Jadlovská, 2003)

Genetický algoritmus je silným stochastickým prehľadávacím/optimalizačným prístupom, ktorý napodobňuje evolúciu v prírode. Je opísaný napr. v (Goldberg, 1989; Man, et al., 2001; Michalewicz, 1996; Sekaj, 2005) a v mnohých ďalších prácach. Všeobecná schéma GA môže byť opísaná nasledujúcimi krokmi (obrázok 3):

1. Inicializácia počiatočnej populácie chromozómov (náhodne generované chromozómy).
2. Ohodnotenie kriteriálnej funkcie (fitness) pre každý chromozóm.

3. Výber rodičovských chromozómov.
4. Kríženie a mutácia rodičov → deti.
5. Vytvorenie novej populácie z detí a z vybratých členov starej populácie.
6. Ak bol vykonaný predpísaný počet generácií → koniec algoritmu, inak skok na krok 2.



Obrázok 3: Bloková schéma genetického algoritmu

Návrh neurónového regulátora je v podstate optimalizačnou úlohou – hľadanie takých parametrov riadenia (váh a prahov neurónovej siete) z definovaného priestoru, ktoré minimalizujú hodnotu kriteriálnej funkcie, predstavujúcej kvalitu riadenia. Kriteriálna funkcia (fitness) je zobrazenie  $R^n \rightarrow R$ , kde  $n$  je počet navrhovaných parametrov riadenia (váh a prahov siete). Kriteriálnu funkciu môže predstavovať suma regulačných odchýlok v absolútnej hodnote (sum of absolute control errors, SAE) alebo suma časovo váhovaných regulačných odchýlok v absolútnej hodnote (sum of time weighting absolute control errors, STAE) v nasledujúcej forme:

$$J = \sum_{i=1}^N |e_i| = \sum_{i=1}^N |r_i - y_i|, \quad (1)$$

$$J = \sum_{i=1}^N t_i |e_i| = \sum_{i=1}^N t_i |r_i - y_i|, \quad (2)$$

kde  $t$  je čas,  $r$  je referenčná premenná,  $y$  je riadený výstup,  $e$  je regulačná odchýlka a  $N$  je počet vzoriek. Fitness predstavuje kriteriálnu funkciu alebo modifikovanú kriteriálnu funkciu, ktorá je penalizovaná napríklad deriváciou výstupu procesu  $y$ , preregulovaním výstupu procesu alebo obmedzením akčného zásahu  $u$ .

Na optimalizáciu parametrov NC sa môžu použiť GA. Chromozómy v GA predstavujú v tomto prípade váhy a prahy neurónovej siete.

Po inicializácii počiatkovej populácie chromozómov sa vypočíta hodnota fitness každého chromozómu z populácie. Pre výpočet fitness sa vykoná niekoľko simulácií riadiaceho systému pre rozličné skokové zmeny hodnoty referenčnej premennej  $r$ . Nasledujú genetické operácie výber, kríženie a mutácia, ktorými sa vytvorí nová populácia chromozómov. Algoritmus pokračuje ďalším výpočtom hodnôt fitness, genetickými operáciami a tvorbou nových populácií, až kým nie sú splnené podmienky ukončenia, v tomto prípade dosiahnutie predpísaného počtu generácií. Výstupom z tohto algoritmu je neurónová sieť, ktorá dosiahla v poslednej generácii minimálnu hodnotu fitness.

### 3 PRÍKLAD

Overenie metódy návrhu neurónového regulátora pomocou genetických algoritmov bolo realizované na príklade izotermického reaktora v prostredí Matlab. Matematický model izotermického reaktora je opísaný diferenciálnymi rovnicami:

$$\frac{dC_a}{dt} = -k_1 C_a - k_3 C_a^2 + \frac{F}{V} (C_{af} - C_a) \quad (2)$$

$$\frac{dC_b}{dt} = k_1 C_a - k_2 C_b - \frac{F}{V} C_b \quad (3)$$

Hodnoty parametrov reaktora:

$$k_1 = 50 \text{ h}^{-1}$$

$$k_2 = 100 \text{ h}^{-1}$$

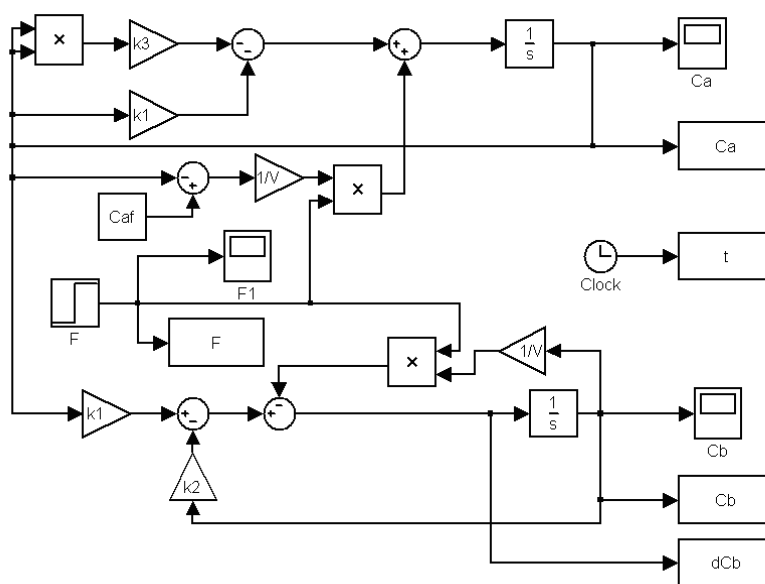
$$k_3 = 10 \text{ mol}^{-1} \cdot \text{l} \cdot \text{h}^{-1}$$

$$C_{af} = 10 \text{ mol} \cdot \text{l}^{-1}$$

$$V = 1 \text{ l}$$

Vstupom do systému je prietok  $F$  [ $\text{l} \cdot \text{h}^{-1}$ ] a výstupom zo systému je koncentrácia látky B  $C_b$  [ $\text{mol} \cdot \text{l}^{-1}$ ].


Na obrázku 4 sa nachádza schéma modelu procesu v prostredí Matlab-Simulink.




Obrázok 4: Schéma modelu procesu izotermického reaktora v prostredí Matlab-Simulink

Obrázok 5 zobrazuje prevodovú charakteristiku izotermického reaktora. Proces je silno nelineárny, so statickou nelinearitou. Z obrázku možno odčítať prípustný rozsah vstupnej a výstupnej veličiny pre modelovanie a riadenie: vstupná veličina  $u$  ( $F$ )  $\in \langle 0; 70,3626 \rangle$  [ $\text{l} \cdot \text{h}^{-1}$ ] a výstupná veličina  $y$  ( $C_b$ )  $\in \langle 0; 1,264 \rangle$  [ $\text{mol} \cdot \text{l}^{-1}$ ].

Na obrázku 6 sú znázornené časové odozvy výstupu procesu  $y$  na rôzne skokové zmeny vstupnej veličiny  $u$ . Skokové zmeny boli vykonané z počiatočnej hodnoty vstupu  $u_p = 0$  [ $\text{l} \cdot \text{h}^{-1}$ ] na koncovú hodnotu vstupu  $u_k$ : 2,9942, 7,2995, 13,8062, 25,0000 a 70,3626 [ $\text{l} \cdot \text{h}^{-1}$ ] tak, aby výstupná veličina  $y$  dosiahla v ustálenom stave hodnoty: 0,250, 0,500, 0,750, 1,000 a 1,264 [ $\text{mol} \cdot \text{l}^{-1}$ ].



Obrázok 5: Prevodová charakteristika izotermického reaktora



Obrázok 6: Časové odozvy výstupu procesu y na rôzne skokové zmeny vstupnej veličiny  $u$

Pre riadenie izotermického reaktora boli navrhnuté rôzne neurónové regulátory. Vstupmi do neurónovej siete sú regulačná odchýlka  $e$ , regulovaná výstupná veličina  $y$  a  $numdy$  predchádzajúcich hodnôt regulovanej výstupnej veličiny. Neurónová sieť má  $SN$  neurónov v skrytej vrstve. Rozsah hodnôt váh a prahov je od hodnoty  $rangeL$  po hodnotu  $rangeH$  a počet generácií je označený ako  $numgen$ .

Použité parametre neurónového regulátora a genetického algoritmu:

$$numdy = 1$$

$$SN = 7$$

$$rangeL = -20$$

$$rangeH = 20$$

$$numgen = 1000$$

Ak bola ako kritériálna funkcia a zároveň fitness použitá rovnica (1), suma absolutných hodnôt odchýlok bez penalizácie, kvalita riadenia nebola vysoká. Časové priebehy výstupnej veličiny vykazovali veľké prerégulovania (až nad 20%). Pri skokových zmenách  $r$  na veľmi vysoké hodnoty (blízko hornej hranice výstupnej veličiny) sa tiež vyskytovali veľké trvalé regulačné odchýlky  $e_\infty$  (pri skokovej zmene  $r$  z  $r_p = 0 \text{ mol.l}^{-1}$  na  $r_k = 1,264 \text{ mol.l}^{-1}$   $e_\infty = 6,2342 \%$ ).

Pre odstránenie prerégulovania sa kritériálna funkcia daná rovnicou (1) ešte penalizovala hodnotou prerégulovania, výsledná tvar funkcie fitness je potom:

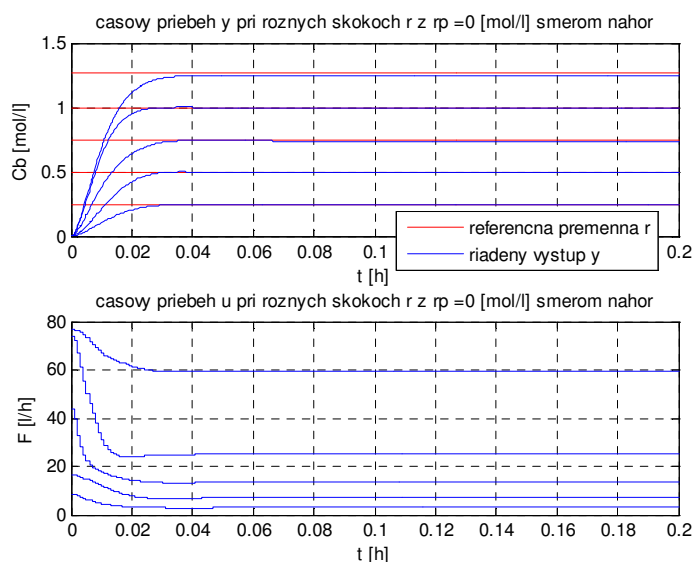
$$fitness = J + \alpha \eta_{reg} + \sum_{i=1}^N |e_i| + \alpha \eta_{reg} = \sum_{i=1}^N |r_i - y_i| + \alpha \eta_{reg}, \quad (3)$$

kde  $J$  je hodnota kritériálnej funkcie,  $r$  je referenčná premenná,  $y$  je riadený výstup,  $e$  - regulačná odchýlka,  $N$  - počet vzoriek,  $\alpha$  - konštanta penalizácie prerégulovania a  $\eta_{reg}$  je hodnota prerégulovania.


Na obrázku 7 je zobrazený časový priebeh regulovanej výstupnej veličiny  $y$  a akčnej veličiny  $u$  ako odozvy na rôzne skokové zmeny referenčnej premennej  $r$  z počiatočnej hodnoty  $r_p = 0 \text{ mol.l}^{-1}$ , kde pri návrhu NC pomocou GA bola použitá prerégulovaním penalizovaná fitness, podľa vzťahu (3), pričom  $\alpha = 500$ .

Obrázok 8 zachytáva závislosť najmenej hodnoty fitness v populácii od počtu generácií a závislosť hodnoty kritériálnej funkcie  $J$ , ktorá prináleží k tejto hodnote fitness v závislosti od generácie, pre prípad prerégulovaním penalizovanej fitness.

Kvalita riadenia je vyššia, ako pri riadení, kde sa pri návrhu NC neuvažovalo s penalizáciou prerégulovania. Riadený systém je síce pomalší, ale bez prerégulovania riadeného výstupu. Stále sa však objavuje trvalá regulačná odchýlka  $e_\infty$  (pre skokovú zmenu  $r$  z  $r_p = 0 \text{ mol.l}^{-1}$  na  $r_k = 0,250 \text{ mol.l}^{-1}$   $e_\infty = 1,5600 \%$ , na  $r_k = 0,500 \text{ mol.l}^{-1}$   $e_\infty = 1,9200 \%$ , na  $r_k = 0,750 \text{ mol.l}^{-1}$   $e_\infty = 1,4667 \%$  a na  $r_k = 1,264 \text{ mol.l}^{-1}$   $e_\infty = 1,2104 \%$ ). Jej hodnoty však nie sú veľké (pod 2%) a dali by sa zanedbať, ak by sa nepočítalo s 2 % pásmom necitlivosti, ale so 4 % pásmom necitlivosti.



Obrázok 7: Časové odozvy  $y$  a  $u$  na rôzne skokové zmeny  $r$ , pre prípad prerégulovaním penalizovanej fitness



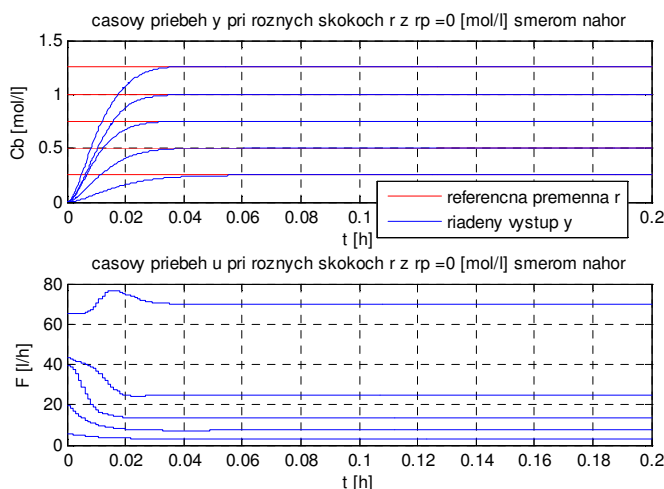
Obrázok 8: Najmenšia hodnota fitness v populácii a k nej prislúchajúca hodnota kriteriálnej funkcie v závislosti na generácii, pre prípad preregulovaním penalizovanej fitness

Trvalá regulačná odchýlka sa dá odstrániť pridaním penalizácie trvalej regulačnej odchýlky do fitness:

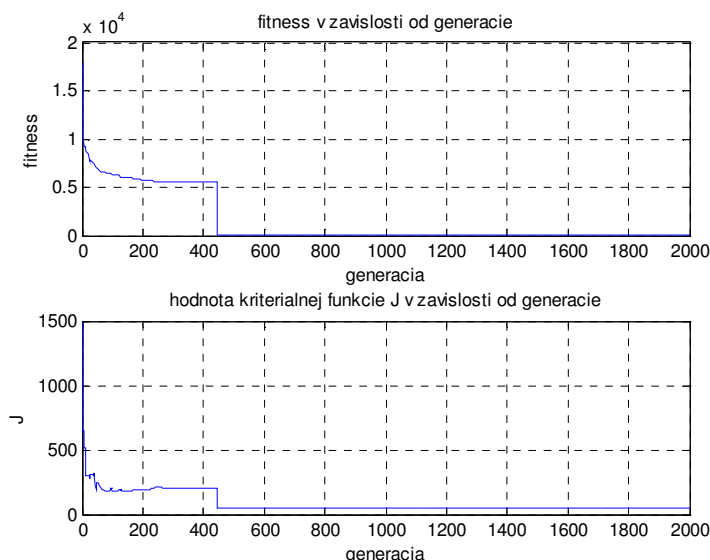
$$fitness = J + \alpha\eta_{reg} + \beta e_{\infty} + \sum_{i=1}^N |e_i| + \alpha\eta_{reg} + \beta e_{\infty} = \sum_{i=1}^N |r_i - y_i| + \alpha\eta_{reg} + \beta |r_N - y_N|, \quad (4)$$

kde  $J$  je hodnota kriteriálnej funkcie,  $r$  je referenčná premenná,  $y$  je riadený výstup,  $e$  - regulačná odchýlka,  $e_{\infty}$  - trvalá regulačná odchýlka,  $N$  - počet vzoriek,  $r_N$  a  $y_N$  sú hodnoty referenčnej premennej a riadeného výstupu v poslednej vzorke,  $\alpha$  - konštanta tlmenia preregulovania,  $\beta$  - konštanta tlmenia trvalej regulačnej odchýlky a  $\eta_{reg}$  je hodnota preregulovania.

Na obrázku 9 je zobrazený časový priebeh regulovanej výstupnej veličiny  $y$  a akčnej veličiny  $u$  ako odozvy na rôzne skokové zmeny referenčnej premennej  $r$ , kde pri návrhu NC pomocou GA bola použitá fitness penalizovaná preregulovaním a trvalou regulačnou odchýlkou, podľa vzťahu (4), pričom  $\alpha = 2000$  a  $\beta = 1500$ . Obrázok 10 zachytáva pre tento prípad závislosť najmenšej hodnoty fitness v populácii od počtu generácií a závislosť hodnoty kriteriálnej funkcie  $J$ , ktorá prináleží k tejto hodnote fitness v závislosti od generácie.



Obrázok 9: Časové odozvy  $y$  a  $u$  na rôzne skokové zmeny  $r$ , pre prípad preregulovaním a trvalou regulačnou odchýlkou penalizovanej fitness



Obrázok 10: Najmenšia hodnota fitness v populácii a k nej prislúchajúca hodnota kriteriálnej funkcie v závislosti na generácii, pre prípad preregulovaním a trvalou regulačnou odchýlkou penalizovanej fitness

Riadený systém je síce o niečo pomalší, ako v predchádzajúcom prípade, avšak vďaka penalizácii, bez trvalej regulačnej odchýlky.


Tabuľka 1 porovnáva doby regulácie  $t_{reg}$  pre 2 % a 4 % pásmo necitlivosti, veľkosť preregulovania pri použití 2 % pásma necitlivosti a sumu štvorcov odchýlok ISE (sumu absolútnych hodnôt odchýlok IAE) pre každú skokovú zmenu referenčnej premennej  $r$  z obrázkov 7 a 9 pre uvedené prípady riadenia bez penalizácie trvalej regulačnej odchýlky (pr. 1) a s penalizáciou trvalej regulačnej odchýlky (pr. 2).

Tabuľka 1: Porovnanie dôb regulácie, trvalých regulačných odchýlok, ISE a IAE pre prípad bez a s penalizáciou trvalej regulačnej odchýlky

zmena $r$ na [mol.l <sup>-1</sup> ]	$t_{reg}$ pre 2 % p. n. [h]		$t_{reg}$ pre 4 % p. n. [h]		$e_{\infty}$ [%]		ISE		IAE	
	pr.1	pr. 2	pr.1	pr. 2	pr. 1	pr. 2	pr.1	pr. 2	pr.1	pr. 2
0,250	-	0,0540	0,0327	0,0486	1,5600	-	0,5732	0,7393	3,9492	4,7178
0,500	-	0,0361	0,0289	0,0335	1,9200	-	2,2572	2,2348	7,9425	7,0686
0,750	-	0,0309	0,0328	0,0281	1,4667	-	4,4291	4,2001	10,8415	14,0678
1,000	0,0259	0,0331	0,0236	0,0295	-	-	6,4973	8,2120	9,7620	12,1282
1,264	-	0,0343	0,0339	0,0312	1,2104	-	11,8843	12,7471	17,0366	15,9491

Na obrázku 11 sú porovnané časové odozvy riadenej výstupnej veličiny  $y$  a akčnej veličiny  $u$  na rôzne skokové zmeny referenčnej premennej  $r$ , pre dve rôzne riadenia: riadenie s neurónovým regulátorom optimalizovaným pomocou GA, kde sa ako fitness použila kriteriálna funkcia (1) penalizovaná veľkosťou preregulovania a veľkosťou trvalej regulačnej odchýlky a riadenie s PID regulátorom. Ako vidno z obrázka, riadenie s PID regulátorom je rýchlejšie pre menšie skokové zmeny referenčnej premennej na menšie hodnoty, ale výrazne pomalšie pri väčších zmenách  $r$  na väčšie hodnoty. Navrhnutý neurónový regulátor riadi systém s vyššou kvalitou riadenia, pretože aj pri veľkých zmenách referenčnej premennej sú doby regulácie pomerne krátke (do 0,05 h).





Obrázok 11: Porovnanie časových odoziev  $y$  a  $u$  na rôzne skokové zmeny  $r$  s riadením s NC a s PID regulátorom

## 4 ZÁVER

Genetické algoritmy sú účinným prostriedkom optimalizácie neurónových regulátorov. Nie je to však jednoduchá úloha. Je nutné správne vybrať parametre genetického algoritmu a tiež parametre neurónovej siete. Problémom môže byť tiež výber vhodnej fitness.

Cieľom práce bolo navrhnúť parametre neurónového regulátora použitím genetických algoritmov pre nelineárny proces. Navrhnutý neurónový regulátor pre izotermický reaktor je vhodný pre riadenie. Dokáže riadiť systém s vysokou kvalitou riadenia bez prerégulovania a trvalej regulačnej odchýlky. Táto forma riadenia bola tiež porovnaná s riadením s PID regulátorom. Výhodou navrhnutého NC je pomerne krátka doba regulácie (do 0,05 h) v celom rozsahu želaných hodnôt výstupnej veličiny.

Neurónový regulátor je pre nelineárne systémy schopný zabezpečiť vysokú kvalitu riadenia.

## LITERATÚRA

- DEMUTH, H., BEALE M. (2003). *Neural Network Toolbox, For use with Matlab, User's guide*.
- GOLDBERG, D.E. (1989). *Genetic Algorithms in Search, Optimisation and Machine Learning*. Addison-Wesley.
- JADLOVSKÁ, A. (2003). *Modelovanie a riadenie dynamických procesov s využitím neurónových sietí*. Informattech, Košice.
- MAN, K.F., TANG, K.S., KWONG, S. (2001). *Genetic Algorithms, Concepts and Design*. Springer.
- MICHALEWICZ, Z. (1996). *Genetic Algorithms + Data Structures = Evolutionary Programs*. Springer.
- SEKAJ, I. (2003). Genetic Algorithm Based Controller Design. In: *2nd IFAC conference Control System Design'03*. Bratislava.
- SEKAJ, I. (2005). *Evolučné výpočty a ich využitie v praxi*. Iris, Bratislava.