

Adaptívny neurónový regulátor založený na hybridnom modelovaní

Anton Andrášik
Alojz Mészáros
Lubomír Šperka

Tento príspevok obsahuje návrh nelineárneho regulačného obvodu s využitím hybridného modelovania. Neurónový regulátor je trénovaný on-line na báze dobre známej metódy spätného šírenia, ale koeficient učenia je adaptovaný v každom iteračnom kroku, čo má za následok podstatné urýchlenie konvergenzie algoritmu. Hodnota koeficientu učenia je vybraná v zmysle Ljapunovovej teórie stability, a tak je zaručená konvergencia navrhnutého algoritmu. Výhody použitia uvádzanej techniky sú deklarované simulačnými výsledkami na modeli bioprocesu, ktorý opisuje rast kultúry *Saccharomyces cerevisiae* na glukóze v prietokovom biochemickom reaktore.

Úvod

Návrh väčšiny regulačných schém s využitím umelých neurónových sietí (UNS) je založených na nastavovaní váhových koeficientov s využitím optimalizačného algoritmu, napr. metódy spätného šírenia. Hoci určité problémy nelineárneho riadenia môžu byť riešené týmito technikami, v prípade systémov, ktoré vykazujú vysoký stupeň nelinearity a neurčitosti, môžu existujúce nelineárne regulačné mechanizmy zlyhať. Jednou z hlavných nevýhod použitia UNS ako regulátora pri riadení reálnych systémov býva pomalá schopnosť adaptácie pri zmenených reakčných podmienkach, takže často dochádza k vzniku regulačnej odchýlky.

V tomto článku predstavujeme novú stratégiu riadenia založenú na nepriamom adaptívnom riadení, kde model riadeného procesu je reprezentovaný hybridnou neurónovou sieťou. Len tri váhové koeficienty neurónového regulátora sú adaptované on-line, pričom sa využíva špeciálny trénovací algoritmus v zmysle Ljapunovovej teórie stability. Na demonštrovanie kvality navrhovanej metódy riadenia je vybraný model prietokového biochemického reaktora ako objekt riadenia. Simulačné výsledky poukazujú na robustnosť navrhnutého systému riadenia.

1. Hybridné neurónové siete

Hybridný model vznikne kombináciou neurónového modelu black-box a známeho fyzikálneho modelu procesu, opísaného napr. jeho materiálovou a energetickou bilanciou. Použitie hybridných modelov je vhodné najmä pri opise procesov so silne nelineárnym správaním v celom operačnom rozsahu. Kombinácia techník black-boxu a fyzikálneho modelu procesu sa dostáva stále viac do pozornosti od počiatku 90. rokov [1]. V článku [2] je navrhnutý hybridný model semi-prietokového bioreaktora, kde UNS slúži na odhad kinetických parametrov bioprocesu, ktoré sú následne použité v materiálovej bilancii na získanie modelovaných stavových veličín. V porovnaní s konvenčnými prístupmi je hybridné modelovanie výkonným nástrojom na modelovanie procesov najmä v prípadoch, keď je k dispozícii čiastočný matematický opis procesu [3].

Problémom trénovania hybridných UNS je, že pri učení priamo nepoznáme hodnotu modelovaného parametra. Chybový signál, ktorý potrebujeme na zmenu hodnôt váhových koeficientov, je v tomto prípade počítaný na základe čiastkového matematického opisu procesu. Odchýlka predikovanej hodnoty stavových veličín od nameraných hodnôt môže byť spätne šírená cez známu sadu rovníc opisujúcich proces, a tak môže byť transformovaná na chybový signál.

Uvažujme proces opísaný diferenciálnou rovnicou

$$\frac{dy}{dt} = f(y(t), u(t), w) \quad (1)$$

kde f je nelineárny funkčný vektor systémových vstupov $u(t)$, systémových výstupov $y(t)$ a parametrov w , ktoré v našom prípade reprezentujú hodnoty váhových koeficientov UNS. Najčastejšou požiadavkou pri získavaní modelu procesu je, aby suma štvorcov odchýlok predikovaných a meraných hodnôt bola minimálna

$$J = \frac{1}{2} \sum_{i=1}^N (y_i - y_i^*)^2 \quad (2)$$

Všeobecne známy spôsob minimalizácie J spočíva v použití gradientových metód, ako napr. metódy najstrmšieho spádu, kde sa zmena váh v n -tom iteračnom kroku deje v smere záporného gradientu

$$w_{ij,n+1} = w_{ij,n} - \alpha \frac{\partial J}{\partial w_{ij,n}} \quad (3)$$

prícom

$$\frac{\partial J}{\partial w_{ij,n}} = \sum_{i=1}^N \left[(y_i - y_i^*) \frac{\partial y_i}{\partial w_{ij,n}} \right] \quad (4)$$


Na určenie vplyvu stavových veličín na váhové koeficienty UNS sa využíva metóda nazvaná „sensitivity approach“ [4]. Hlavnou myšlienkou tejto metódy je zakomponovanie váhových koeficientov w ako prídavných premenných diferenciálnej rovnice. Počas trénovacej fázy musí byť táto rovnica riešená pre fixné $u(t)$. Diferenciáciou rovnice (1) so zreteľom na váhové koeficienty dostaneme

$$\frac{d}{dt} \left(\frac{\partial y}{\partial w} \right) = \frac{\partial f}{\partial y} \frac{\partial y}{\partial w} + \frac{\partial f}{\partial w} \quad (5)$$

s počiatočnou podmienkou

$$\left. \frac{\partial y}{\partial w} \right|_{t=0} = 0 \quad (6)$$

Uvažujme prietokový biochemický reaktor, v ktorom prebieha kultivácia kultúry *Saccharomyces cerevisiae* na glukóze. Pre získanie



Obr.1 Štruktúra hybridnej UNS fermentačného procesu

vstupno-výstupných dát na tréningovanie hybridnej siete bol použitý matematický model prezentovaný v článku [5]. Štruktúra hybridného modelu, pozostávajúca z UNS a dostupnej informácie o procese v podobe materiálovej bilancie, je znázornená na obr. 1.

Predpokladajme, že modelovanou veličinou je koncentrácia biomasy X . Potom môžeme zjednodušene zapísať materiálovú bilanciu fermentácie pomocou nasledujúcich diferenciálnych rovníc

$$\frac{dX}{dt} = \mu X - \frac{q}{V_l} X \quad (7)$$

$$\frac{dS}{dt} = -k_1 \mu X - \frac{q}{V_l} (S - S_{in}) \quad (8)$$

kde S je koncentrácia substrátu vo fermentore, μ reprezentuje neznámu hodnotu špecifického koeficientu rastu, q je prietok substrátu, V_l je objem kvapalnej fázy v bioreaktore a S_{in} je koncentrácia substrátu vo vstupnom prúde. Vzhľadom na rovnicu (1) môžeme formálne zapísať model ako

$$f = \mu X - \frac{q}{V_l} X \quad (9)$$

Pre adaptáciu váhových koeficientov podľa rovnice (3) potrebujeme poznať hodnotu gradientu koncentrácie biomasy podľa jednotlivých váhových koeficientov. Aplikáciou „sensitivity approach“ podľa rovnice (5) dostaneme sadu diferenciálnych rovníc

$$\frac{d}{dt} \left(\frac{\partial X}{\partial w} \right) = \left(\mu + X \frac{\partial \mu}{\partial X} - \frac{q}{V_l} \right) \frac{\partial X}{\partial w} + X \frac{\partial \mu}{\partial w} \quad (10)$$


Neznáme parciálne derivácie

$$\frac{\partial \mu}{\partial X} \text{ a } \frac{\partial \mu}{\partial w}$$


závisia od zvolenej štruktúry UNS a ich hodnoty môžeme získať použitím metódy spätného šírenia.

2. Návrh riadiaceho systému

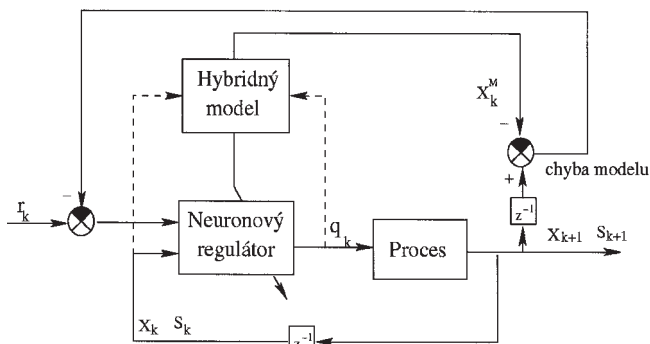
Navrhovaný regulačný obvod pozostáva z dvoch UNS: hybridnej UNS (obr. 1) v úlohe modelu procesu a doprednej UNS, natrénovanej ako inverzný dynamický model procesu. Tréningovanie inverz-



Obr.2 Architektúra navrhnutého inverzného modelu bioprocessu



Obr.3 Neurónový regulátor so zakomponovanými PID neurónmi pre učenie on-line



Obr.4 Bloková schéma navrhnutého regulačného systému

ného dynamického modelu procesu je dôležité z hľadiska riadenia [6]. V ideálnej situácii môžeme uvažovať dynamiku regulátora rovnou dynamike inverzného modelu procesu. V našom prípade uvažujeme štruktúru inverzného modelu, aká je na obr. 2. UNS je trénovaná off-line, na základe dostupných vstupno-výstupných dát. Problémom býva, že inverzné dynamické modely zvyknú dávať nesprávne výsledky, najmä ak proces obsahuje nelinearity. Aby sme zabránili vzniku trvalej regulačnej odchýlky, neurónový regulátor obsahuje namiesto prahového neurónu tzv. PID neuróny (obr. 3). Vstupnými signálmi do PID neurónov sú podľa poradia regulačná odchýlka e , suma regulačnej odchýlky a jej zmena vzhľadom na predchádzajúcu periódu vzorkovania. Váhové spojenia PID neurónov, označené w_p , w_i a w_D , sú adaptívne nastavované on-line s použitím špeciálneho optimalizačného algoritmu opísaného v nasledujúcej podkapitole. Bloková regulačná schéma je znázornená na obr. 4.

2.1 On-line ladenie váhových koeficientov PID

On-line tréningovanie neurónového regulátora (obr. 3) spočíva v nastavovaní váh PID neurónov takým spôsobom, aby regulačná odchýlka konvergovala k nule. Princíp dôkazu konvergencie uvádzaného algoritmu je prevzatý z článku [7] a rozšírený pre náš prípad. Výsledkom je nájdenie vhodného intervalu výberu stupňa učenia α z rovnice (3) tak, že algoritmus je stabilný v zmysle Ljapunovovej teórie stability.

Uvažujme diskretnú Ljapunovovu funkciu v tvare

$$J_k = \frac{1}{2} (e_k^2 + \lambda \Delta u_k^2) = \frac{1}{2} \left[(r - y_k^M)^2 + \lambda (u_k - u^{old})^2 \right] \quad (11)$$

kde r predstavuje žiadanú hodnotu, y_k^M je predikovaná hodnota regulovanej veličiny s využitím hybridného modelu, u_k je odhadovaná hodnota akčného zásahu ako výstup z neurónového PID regulátora (obr. 3), u^{old} je hodnota posledného akčného zásahu aplikovaného na systém a k predstavuje iteračný index. Ak bude adaptácia PID neurónov prebiehať podľa rovnice (3), tak proces tréningovania bude stabilný pre

$$\alpha_k < \frac{2}{\left(\left\| \frac{\partial e_k}{\partial w} \right\|^2 + \lambda \|\bar{B}\|^2 \right)} \quad (12)$$

kde \bar{B}^T je vektor vstupov do neurónového PID regulátora a $\|\cdot\|$ predstavuje euklidovskú normu. Odvodenie uvedenej závery presahuje rámec príspevku, podrobne je rozpísané v [8].

Počas regulačnej fázy je nevyhnutné synchronizovať nasledujúce kroky:

- snímanie dát z procesu,
- ladenie váhových koeficientov neurónového regulátora PID,
- výpočet nového akčného signálu a jeho aplikácia na proces.

Jedinou neznámou procedúrou zostáva to, ako ladíť on-line váhové koeficienty neurónov PID. Kľúčovou úlohou je vhodne zvoliť koeficient učenia α tak, aby sme urýchlili optimalizačný proces. Na tento účel potrebujeme poznať hodnotu gradientu $(\partial e_k)/(\partial w)$. Ak prijmeme predpoklad, že hybridný model je presným modelom

riadeného procesu, potom môžeme nájsť hodnotu tohto gradientu pomocou metódy stochastickej aproximácie [9].


Keďže algoritmus je uskutočniteľný iteračne, môžeme ho rozpisovať pomocou nasledujúcich bodov:

1. perturbácia váhového koeficientu v pozitívnom smere,
2. výpočet odozvy neurónového regulátora: q_t ,
3. hodnota q_t je použitá ako vstup do materiálovej bilancie hybridnej siete,
4. výpočet odozvy hybridnej siete X_{t+1} ako predikcie riadenej veličiny v nasledujúcej perióde vzorkovania,
5. opakovanie krokov 2 – 4 pre perturbáciu váhového koeficientu v negatívnom smere,
6. výpočet krokov 1 – 5 pre nasledujúce váhové koeficienty (w_I, w_D),
7. výpočet hodnoty gradientu


$$\frac{\partial e_k}{\partial w} = \frac{X_{t+1}^- - X_{t+1}^+}{\Delta}$$

kde Δ je veľkosť perturbácie a +/- indikuje pozitívny a negatívny smer perturbácie,


8. výpočet koeficientu učenia, α_k podľa vzťahu (12),
9. posun váhových koeficientov PID,
10. výpočet účelovej funkcie pre aktuálny krok iterácie k ,
11. ak $J_k <$ (akceptovateľná chyba) alebo počet iterácií $k > k_{\max} \Rightarrow$ prechod k bodu 12; inak skok na krok 1,
12. výpočet nového akčného zásahu ako odozvy neurónového regulátora PID,
13. aplikácia akčného zásahu na reálny proces.



Obr.5 Bloková schéma priameho inverzného riadenia



Obr.6 Riadenie koncentrácie biomasy pomocou priameho inverzného riadenia pre deterministický systém




Obr.7 Riadenie koncentrácie biomasy pomocou priameho inverzného riadenia, kde hodnota S_{in} je perturbovaná v rozsahu $\pm 20\%$


3. Simulačné výsledky

V záujme porovnania boli uskutočnené dva odlišné prístupy riadenia bioprocesu. Najskôr bol použitý inverzný model procesu pre neadaptívnu reguláciu (obr. 5). Trénovacia sada dát, generovaná matematickým modelom [5], bola použitá na získanie inverznej mapy procesu. Vstupy do neurónového regulátora (obr. 2) pozostávali z vopred nameraných údajov v poradí X_{k+1}, X_k a X_{k-1} . Počas regulácie bol najskôr pre výpočet merateľných veličín procesu použitý matematický model s rovnakými parametrami ako pri tréňovaní UNS. Výsledok regulácie pre tento deterministický systém pomocou priameho inverzného riadenia je znázornený na obr. 6. Pri druhom simulačnom experimente (obr. 7) bola hodnota koncentrácie substrátu vo vstupnom prúde S_{in} perturbovaná v rozsahu $\pm 20\%$. Výsledok experimentu potvrdzuje, že tento typ regulácie nie je vhodný pre systémy, na ktoré počas regulácie vplyvajú poruchy, alebo ak nie je známy perfektný model riadeného procesu.


Druhý prístup k riadeniu bioprocesu predstavuje aplikácia navrhnutého adaptívneho neurónového regulátora, kde UNS so štruktúrou na obr. 2 a s 5 neurónmi na skrytej vrstve bola pred-



Obr.8 Regulačný pochod s použitím on-line ladenia neurónového regulátora – deterministický systém



Obr.9 Adaptívne riadenie s použitím on-line ladenia neurónového regulátora, kde hodnota S_{in} je perturbovaná v rozsahu $\pm 20\%$



Obr.10 Nastavovanie P, I a D váhového koeficientu počas regulačnej fázy

trénovaná off-line. Počas regulačnej fázy bola štruktúra UNS modifikovaná tak, ako na obr. 3, pričom váhové koeficienty sa inicializovali na predtrénované hodnoty a počiatkové hodnoty váhových koeficientov PID sa nastavili na nulu. Počas regulácie boli adaptované len tri PID váhy na základe uvedeného algoritmu, zvyšné váhové koeficienty zostali konštantné na predtrénovaných hodnotách. Výsledky simulácií pre deterministický ako aj stochastický systém sú znázornené na obr. 8 a 9. Priebehy adaptívne nastavovaných váhových koeficientov PID sú vykreslené na obr. 10.

Záver

V článku je prezentovaná metóda nelineárneho adaptívneho riadenia na báze UNS, kde riadiaci systém v sebe zahŕňa on-line adaptáciu prahových neurónov a zaručuje priebeh regulácie bez trvalej regulačnej odchýlky aj pri výskyte nemerateľných porúch. Pre špeciálny typ architektúry systému riadenia bol navrhnutý algoritmus ladenia PID neurónov, pričom konvergencia algoritmu je zaručená vhodným výberom koeficientu učenia.

Kvalita navrhnutého systému riadenia bola simulačne testovaná na prípade riadenia nelineárneho biochemického procesu. Získané simulačné výsledky poukazujú na dobré regulačné a sledovacie schopnosti navrhovaného riadiaceho systému, pričom výhody použitia sú očividné najmä v procesoch s výskytom porúch alebo neurčitostí, keď nie je možné získať perfektný model procesu, ale máme k dispozícii čiastočnú informáciu o procese v podobe materiálových alebo energetických bilancií.

Tento príspevok vznikol s grantovou podporou VEGA MŠ SR a SAV pre projekt č. 1/8108/01 a 1/135/03.

Literatúra

[1] SCHUBERT, J., SIMUTIS, R., DORS, M., HAVLIK, I. AND LÜBBERT, A.: Bioprocess optimization and control: Application of hybrid modelling. *Journal of Biotechnology*, vol. 35, pp. 51–68, 1994.

[2] THOMPSON, M. L., KRAMER, A.: Modeling chemical processes using prior knowledge and neural networks. *American Institute of Chemical Engineering Journal*, vol. 8, no. 40, pp. 1328 – 1340, 1994.

[3] FEYO DE AZEVEDO, S., DAHM, B., OLIVEIRA, F. R.: Hybrid modelling of biochemical processes: A comparison with the conventional approach. *Computers chem. Engin.*, vol. 21, pp. S 751–S 756, 1997.

[4] FRANK, P. M.: *Introduction to system sensitivity theory*. Academic Press, New York 1978.

[5] MÉSZÁROS, A., BRDYS, M. A., TATJEWSKI, P., LEDNICKÝ, P.: Multilayer adaptive control of continuous bioprocesses using optimising control technique. Case study: Baker's yeast culture. *Bioprocess Engineering*, vol. 12, pp. 1 – 9, 1995.

[6] PHAM, D. T., OH, P. J.: Identification of plant inverse dynamics using neural networks. *Artificial Intelligence in Engineering*, vol. 13, pp. 309 – 320, 1999.

[7] HOO, K. A., SINZINGER, E. D., AND PIOVOSO, M. J.: Improvements in the predictive capability of neural networks. *Journal of Process Control*, vol. 12, pp. 193 – 202, 2002.

[8] ANDRÁŠIK, A.: On-line tuning of neural PID controller. Research report. Porto, 2002.

[9] KUSHNER, H. J. AND SANVICENTE, E.: Stochastic approximation methods for constrained systems with observation noise on the systems and constraints. In: *IFAC Symposium on Stochastic Control*, 1974.

Ing. Anton Andrášik
doc. Ing. Alojz Mészáros, CSc.
Ing. Ľubomír Šperka

44

Katedra informatizácie a riadenia procesov
FCHPT STU
Radlinského 9
812 37 Bratislava