

UMĚLÉ NEURONOVÉ SÍTĚ V ŘÍZENÍ PROCESŮ

ARTIFICIAL NEURAL NETWORKS IN PROCESS CONTROL

Petr Doležel, Ivan Taufer¹

Anotace: Cílem tohoto příspěvku je demonstrovat možnosti uplatnění jednoho z typů neuronových sítí na konkrétním příkladu řízení kontinuálního bioreaktoru. V analogii s postupy klasických metod regulace bude nejprve popsána tvorba dynamického neuronového modelu a tento model bude následně použit při návrhu řízení bioreaktoru metodou regulace s vnitřním modelem modifikovanou tak, aby mohla využít umělou neuronovou síť jak pro tvorbu modelu soustavy, tak pro regulátor.

I když veškerá demonstrace postupů použitých v tomto příspěvku bude prováděna na modelu kontinuálního bioreaktoru, je zřejmé, že uvedená metodika může najít využití v celé řadě jiných oblastí.

Klíčová slova: Umělé neuronové sítě, kontinuální bioreaktor, regulace s vnitřním modelem

Summary: There is demonstrated one possibility of artificial neural networks usage in process control, in this paper. First, it is shown how to create dynamic neural model of a plant, then its inverse neural model and in the end, these models are used to synthesise the Internal Model Control network.

Although this procedure is demonstrated on the example of continual bioreactor control, it can be applied to many other spheres.

Key words: Artificial Neural Networks, Continual Bioreactor, Internal Model Control

1. ÚVOD

Je známo, že biologické systémy mohou řešit složité problémy různého druhu pomocí mnoha funkcí svých nervových soustav, přičemž mezi jednu z nejpozoruhodnějších a zároveň nejocenenějších se řadí schopnost učení. Organismy se učí pomocí soustavy biologických neuronů spojených mezi sebou dendrity a axony. Umělá neuronová síť je zjednodušený matematický model biologické neuronové sítě. Podobně jako nervový systém, je schopna i umělá neuronová síť zpracovat široké množství vstupních dat za dodržení požadovaných výstupů, ovšem tuto schopnost se nejprve musí naučit (natrénovat). Správně natrénované umělé neuronové sítě jsou pak užitečné a nezdá se, že by se používaly v mnoha oborech lidského bádání.

Neuronové sítě se v historii svého vývoje vyskytly na obou pólech zájmu veřejnosti. Vlny jejich rozvoje i útlumu závisely především na technologických možnostech a rozvoji výpočetní techniky. Využití umělých neuronových sítí je široké, je však nutno k nim

¹ Ing. Petr Doležel, Univerzita Pardubice, Fakulta elektroniky a informatiky, Katedra řízení procesů, Čs. Legií 565, 532 10 Pardubice, tel.: +420 775 327 981, e-mail: st10100@student.upce.cz

Prof. Ing. Ivan Taufer, DrSc., Univerzita Pardubice, Fakulta elektroniky a informatiky, Katedra řízení procesů, Čs. legií 565, 532 10 Pardubice, tel.: +420 466 037 123, e-mail: Ivan.Taufer@upce.cz

přístupovat realisticky a vědět, že řadu problémů je vhodnější řešit jinými metodami. Podrobnější popis umělých neuronových sítí nalezne čtenář např. v [1].


Na konkrétním technologickém procesu – provozu kontinuálního bioreaktoru – je v tomto článku snahou ukázat možnost aplikace umělých neuronových sítí v řízení nelineárních systémů. Pro simulační experimenty je použit konkrétní model kontinuálního bioreaktoru popsany v [2].

2. POPIS BIOREAKTORU

2.1. Úvod

Bioreaktor je zařízení, ve kterém dochází k přeměně látek biochemickou reakcí pomocí enzymů nebo mikroorganismů (tzv. fermentace). Fermentačně se získávají například antibiotika (penicilin, streptomycin), kyselina citrónová, kyselina mléčná, vitaminy (kyselina askorbová, riboflavin), steroidy (kortison, hydrokortison), či alkoholy (ethanol, butanol). Dále se používá pro biologické čištění odpadních vod.

2.2. Popis průtočného bioreaktoru



Zdroj: Autor


Obr. 1 - Technologické schéma bioreaktoru

Kontinuální bioreaktor je válcová nádoba vertikálně rozdělená na několik pater. Vstupem je substrát zředěný vodou, který se probublává aeračním plynem, produktem je pak biomasa kultivovaná uvnitř bioreaktoru. Schéma bioreaktoru je uvedeno na obr. 1.

Aerační plyn na vstupu i plyny na výstupu jsou sterilizovány průchodem přes membrány. Zvláštním způsobem se musí zpracovávat i jiné odpadní látky zvláště kvůli obsahu mikroorganismů a substrátu, které by se mohly rozšířit do životního prostředí.

Pracovní proces bioreaktoru (hodnota koncentrace biomasy na výstupu) se reguluje teplotou bioreaktoru, průtokem suroviny a aeračního plynu, změnou *pH* prostředí a regulací otáček míchadla.

Z hlediska regulace lze na kontinuální bioreaktor nahlížet jako na dynamický systém schématicky znázorněný na obr. 2.



Zdroj: Autor

Obr. 2 - Blokové schéma bioreaktoru

Vstupní veličinou je *průtok suroviny* δ , Výstupy pak *koncentrace biomasy* na výstupu z bioreaktoru χ , *koncentrace substrátu* na výstupu z bioreaktoru σ a *koncentrace kyslíku* na výstupu z bioreaktoru ω . Proces bioreakce také ovlivňují další parametry procesu - *počáteční koncentrace substrátu* (na vstupu do bioreaktoru) σ^0 , *rovnovážná koncentrace kyslíku* ω^0 , *objemový koeficient* K a *fyzilogický koeficient* a . Všechny parametry byly vhodně upraveny tak, aby byly bezrozměrné.

Samotný proces fermentace v bioreaktoru pak lze obecně podle [2] popsat například soustavou nelineárních diferencních rovnic prvního řádu

$$\begin{aligned} \chi(k) &= \varphi_1[\chi(k-1), \sigma(k-1), \omega(k-1), \delta(k-1)] \\ \sigma(k) &= \varphi_2[\chi(k-1), \sigma(k-1), \omega(k-1), \delta(k-1)] \\ \omega(k) &= \varphi_3[\chi(k-1), \sigma(k-1), \omega(k-1)] \end{aligned} \quad (1)$$


Pro ilustraci nelineárního chování bioreaktoru je na obr. 3 pro zvolené parametry $\sigma^0 = 10$, $\omega^0 = 10$, $K = 250$, $a = 4000$ uvedena statická charakteristika bioreaktoru jako závislost ustálených hodnot výstupů χ , σ , ω na průtoku suroviny δ .

Z uvedeného obrázku je patrná výrazná nelinearita provozu kontinuálního bioreaktoru, proto by řízení tohoto procesu klasickými metodami mohlo přinést určité problémy.

3. ŘÍZENÍ BIOREAKTORU

3.1. Úvod

Existuje několik metod řízení, které při svém návrhu počítají s výrazně nelineární soustavou, většinou však spadají do oblasti adaptivního řízení. V následujících odstavcích bude však popsána metoda využívající schopnosti neuronových sítí aproximovat nelineární procesy stejně jednoduše jako lineární.

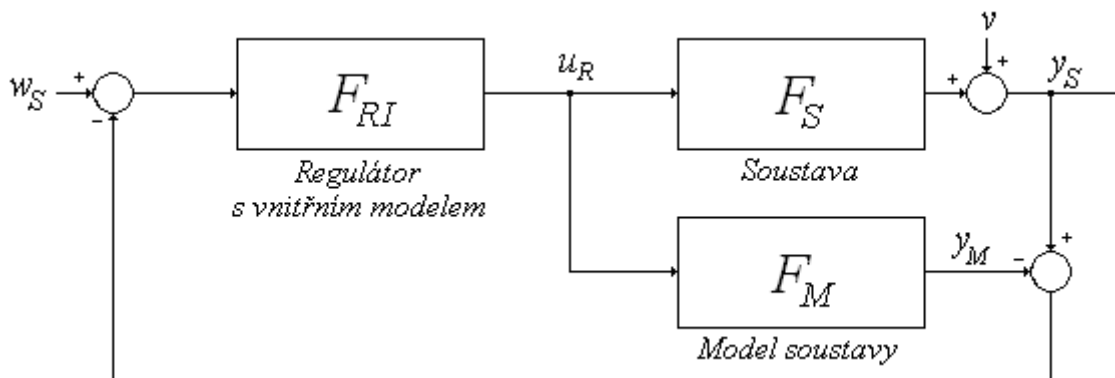


Zdroj: Autor

Obr. 3 - Statická charakteristika bioreaktoru

3.2. Řízení s vnitřním modelem

Řízení s vnitřním modelem (IMC – z angl. *Internal Model Control*) je metoda založená na schématu uvedeném na obr. 4.



Zdroj: Autor

Obr. 4 - Schéma řízení metodou IMC

Regulátor se nastavuje takovým způsobem, aby se jeho přenos F_{RI} blížil inverznímu přenosu řízené soustavy - rovnice

$$F_{RI} = \frac{1}{F_S} \tag{2}$$

Pro regulovanou veličinu y_S podle obr. 4 platí rovnice

$$y_S = \frac{F_{RI} \cdot F_S}{1 + F_{RI} \cdot (F_S - F_M)} \cdot w_S + \frac{1 - F_{RI} \cdot F_M}{1 + F_{RI} \cdot (F_S - F_M)} \cdot v \quad (3)$$

Za předpokladu platnosti rovnice (2) a úspěšného sestavení modelu soustavy ($F_S \approx F_M$) přejde rovnice (3) do jednoduchého tvaru (4).

$$y_S = 1 \cdot w_S + 0 \cdot v \quad (4)$$

Regulovaná veličina y_S tedy ihned nabude žádané hodnoty a porucha v regulovanou veličinu vůbec neovlivní. Rovnice (4) platí pouze za ideálních podmínek, ovšem při použití neuronových sítí při tvorbě modelu s přenosem F_M i regulátoru s přenosem F_{RI} se lze v diskretní oblasti její platnosti přiblížit. Bližší informace o metodě IMC jsou uvedeny v [3].

3.3. Tvorba neuronového modelu bioreaktoru a jeho inverze

Při návrhu řízení je třeba zvolit akční a regulovanou veličinu soustavy. Za akční veličinu byl zvolen *průtok suroviny* δ (jediná možnost), za regulovanou veličinu pak z praktického hlediska nejvýznamnější výstupní veličina *koncentrace biomasy* χ . Vztah výstupní a vstupní veličiny lze pak podle [2] popsat nelineárními diferenční rovnicí

$$\chi(k+1) = \varphi[\chi(k), \delta(k)] \quad (5)$$

Rovnice (5) tvoří předobraz k uspořádání trénovací množiny pro učení dynamického neuronového modelu bioreaktoru. Trénovací množina byla získána takovým způsobem, že na vstup bioreaktoru byl přiveden signál z generátoru náhodných čísel s rovnoměrným rozložením s rozsahem hodnot rovným povolenému rozsahu vstupu do bioreaktoru: $\delta \in \langle 0; 0,826446 \rangle$. Perioda změny vstupu byla zvolena 10 s. Během experimentu pak byly veškeré hodnoty δ , χ měřeny v dobách násobků periody vzorkování $T_s = 1$ s. Experiment trval 2000 vteřin. Získané hodnoty byly seřazeny do tabulky 1 tak, aby odpovídaly rovnici (5).

Tab. 1 – Trénovací množina pro dynamický model

k	Množina vstupních dat		Množina výstupních dat
	$\chi(k)$	$\delta(k)$	$\chi(k+1)$
1	$\chi(1)$	$\delta(1)$	$\chi(2)$
2	$\chi(2)$	$\delta(2)$	$\chi(3)$
...
N-2	$\chi(N-2)$	$\delta(N-2)$	$\chi(N-1)$
N-1	$\chi(N-1)$	$\delta(N-1)$	$\chi(N)$

Takto seřazená trénovací množina byla použita při syntéze vícevrstvé umělé neuronové sítě *Levenbergovým – Marquardtovým algoritmem učení*, postup je uveden např. v [2].

Pokud lze tedy řízenou soustavu popsat v diskrétní oblasti diferenční rovnicí (5), její inverzi by mohla podle [4] vyjadřovat rovnice (6).

$$\delta(k) = \varphi^{-1}[\chi(k+1), \chi(k)] \quad (6)$$

V rovnici (6) je zjevně porušena kauzalita výpočtu, ale to nebrání offline natrénování neuronové sítě aproximující funkci φ^{-1} . Pouze se musí trénovací množina dat seřadit podle tabulky 2.

Tab. 2 - Trénovací množina pro inverzní model

k	Množina vstupních dat		Množina výstupních dat
	$\chi(k+1)$	$\chi(k)$	$\delta(k)$
1	$\chi(2)$	$\chi(1)$	$\delta(1)$
2	$\chi(3)$	$\chi(2)$	$\delta(2)$
...
N-2	$\chi(N-1)$	$\chi(N-2)$	$\delta(N-2)$
N-1	$\chi(N)$	$\chi(N-1)$	$\delta(N-1)$

Pomocí takto seřazené trénovací množiny byl analogickým způsobem vytvořen po neuronovém modelu soustavy i její inverzní neuronový model. Nyní již stačí z obdržených modelů sestavit regulační obvod.

3.4. Syntéza regulačního obvodu

V předchozím odstavci byl tedy získán neuronový model bioreaktoru a následně jeho inverzní model, čímž byly obdrženy všechny potřebné systémy pro syntézu regulačního obvodu na obr. 4. Je však třeba vyřešit otázku podrobného zapojení datových toků. Co se týče zapojení přímovazební větve regulačního obvodu, je možno použít následující postup.

Pokud je řízená soustava popsána nelineární diferenční rovnicí (5) a pro obdržený inverzní neuronový model platí rovnice (6), je možno položit požadavek (7), tedy je požadováno, aby regulovaná veličina dosáhla žádané hodnoty po jednom kroku.

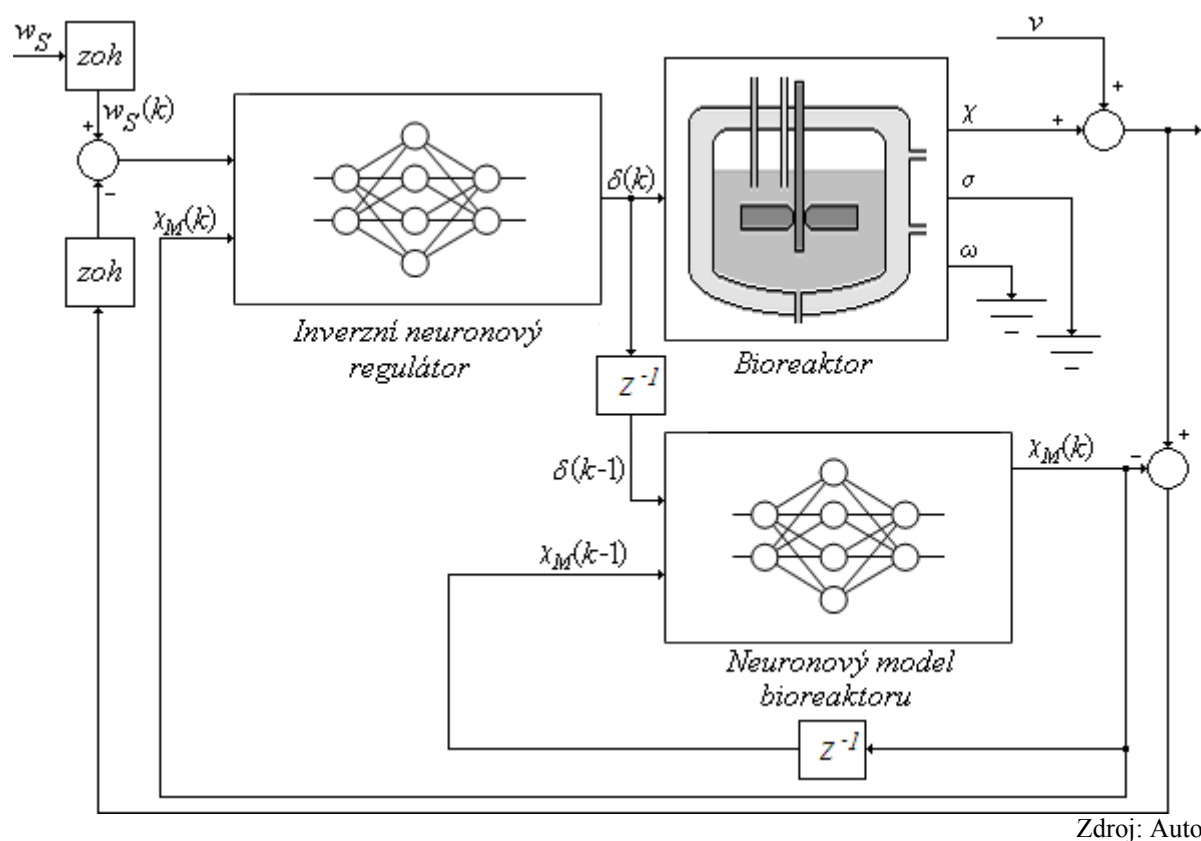
$$\chi(k+1) = w_s(k) \quad (7)$$

Tento požadavek je přiveden na vstup inverzního neuronového modelu a rovnice (6) přejde na rovnici

$$\delta(k) = \varphi^{-1}[w_s(k), \chi(k)] \quad (8)$$

V rovnici (8) již není na rozdíl od rovnice (6) porušena kauzalita výpočtu.

Zbývá ještě vyřešit, odkud bude vedena veličina $\chi(k)$ ze vztahu (8) do inverzního regulátoru. Nabízí se změřit ji na výstupu z regulované soustavy, ale tato může být zatížena chybou měření a poruchami, zatímco při předpokladu dostatečně přesného modelu soustavy není vypočtená hodnota $\chi_M(k)$ těmito chybami zkreslena, proto byla použita tato veličina. Výsledné zapojení pro bioreaktor je znázorněno na obr. 5.




Zdroj: Autor

Obr. 5 - Řízení bioreaktoru metodou IMC za použití umělých neuronových sítí

Pro ilustraci regulačních schopností metody byla provedena simulace regulačního pochodu s modelem bioreaktoru podle [2] s parametry uvedenými v odstavci 2.2 pro zvolený průběh žádané hodnoty w_S a poruchy v na výstupu. Akční veličina δ na vstupu do bioreaktoru byla omezena na interval povolených hodnot $(0; 0,826446)$. Omezení akční veličiny by však nemělo způsobit výrazné problémy. Simulace byla provedena z ustáleného stavu pro $\chi = 7$. Výsledný průběh je uveden na obr. 6.

Z regulačního pochodu na obr. 6 je patrné, že regulovaná veličina χ sleduje žádanou hodnotu podle požadovaného vztahu (7) všude tam, kde akční veličina δ nedosahuje své krajní povolené hodnoty. V tomto případě se regulační pochod zpomalí, ale k žádnému výraznému zhoršení nedochází. Obdobná je reakce na poruchy. Regulační pochod také vykazuje drobnou regulační odchylku způsobenou nedokonalostí inverzního modelu, což potvrzuje domněnku, že regulace s vnitřním modelem sice odstraní chyby způsobené poruchami a nepřesným modelem regulované soustavy, nedokáže ale odstranit chyby způsobené nepřesností inverzního regulátoru. Proto je třeba při syntéze regulačního obvodu dbát na obzvláště přesný inverzní model.



Zdroj: Autor

Obr. 6 - Průběh simulace regulačního pochodu

4. ZÁVĚR

V článku byla na příkladu regulace provozu bioreaktoru prezentována metoda IMC modifikovaná tak, aby mohla využít neuronovou síť jak pro model soustavy, tak pro regulátor. Na simulaci byly demonstrovány výhody metody (rychlá reakce na změnu žádané hodnoty i na poruchu), tak některé nevýhody (trvalá regulační odchylka, nutnost rozsáhlého experimentálního sběru dat). Pro použití v praxi bude třeba metodu prohloubit například o integrační složku regulátoru a možnost zvýšit robustnost za cenu pomalejší reakce regulace.

POUŽITÁ LITERATURA

- [1] HAYKIN, S. *Neural Networks*. New Jersey : Prentice Hall, 1999. 845 s. ISBN 0-13-273350-1
- [2] DOLEŽEL, P. *Umělé neuronové sítě v modelování a řízení kontinuálního bioreaktoru* [Diplomová práce]. Pardubice : Univerzita Pardubice, 2008. 110 s.
- [3] RIVERA, E. D.; MORARI, M.; SKOGESTAD, S. Internal Model Control: PID Controller Design, *Industrial & Engineering Chemistry Process Design and Development*, 1986, vol. 25, s. 252-265. ISSN 0196-4305
- [4] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – základy teorie a aplikace (10), *CHEMagazín*, 2008, roč. XVII, č. 1, s. 35-37. ISSN 1210-7409

Recenzent: doc. Ing. František Dušek, CSc.
Univerzita Pardubice, FEI, Katedra řízení procesů