

Tvorba neuro-fuzzy modelov metódou Anfis

Anna Vasičkaninová, Monika Bakošová, Jan Dvoran

Väčšina procesov chemickej technológie sú procesy zložité, nelineárne, s dopravným oneskorením. Napriek tomu, že je známe množstvo rôznych nelineárnych identifikačných metód, v posledných desaťročiach sa v tejto oblasti stále viac uplatňujú prístupy, ktoré vedú k tvorbe neuro-fuzzy modelov. Ak sú k dispozícii namerané údaje, možno metódou Anfis navrhnuť fuzzy inferenčný systém typu Takagi-Sugeno. Uvedený spôsob identifikácie je aplikovaný na vytvorenie modelu rektifikačnej kolóny na delenie binárnej zmesi benzén – toluén.

Úvod

Pri simuláciách, analýze a návrhu systémov majú dôležité miesto modely; vytvorenie matematického modelu býva prvým krokom, ktorý sa musí vykonať pred návrhom regulátora. Z modelu sa získavajú informácie o stave systému v procese riadenia. Modely obyčajne vznikajú na základe pochopenia fyzikálnych zákonitostí a interakcií v skúmanom systéme [4]. Zložitosť modelu závisí od toho, aký presný model potrebujeme. Veľa informácií o modeli sa dá ťažko zapísať vo forme algebraických či diferenciálnych rovníc, ale rozvíjajú sa aj metódy, ktoré dokážu zaviesť tieto informácie do modelu. Významné miesto tu patrí metódam, založeným na princípoch fuzzy modelovania a fuzzy logiky [1], [6], [8], [10].

V súčasnosti patrí k najviac používaným systémom na univerzitách a výskumných pracoviskách systém Matlab americkej firmy MathWorks. Obsahuje množstvo stále sa vyvíjajúcich aplikačných knižníc, umožňuje okrem numerických výpočtov aj simulácie v prostredí Simulink a vizualizáciu výsledkov. Na riešenie konkrétnych fuzzy problémov slúži v Maltabe Fuzzy Logic Toolbox [2], [9].

Fuzzy modely

Matematický model, vytvorený pomocou fuzzy množín, sa volá fuzzy model. V takomto modeli sú vzťahy medzi premennými reprezentované pravidlami v tvare *ak – potom*. V závislosti od štruktúry pravidla sa používajú dva hlavné typy modelov: model typu Mamdani a model typu Takagi-Sugeno.

Model typu Mamdani

$$R_i : \text{Ak } x \text{ je } A_i \text{ potom } y \text{ je } B_i \quad i = 1, 2, \dots, k \quad (1)$$

A_i a B_i sú lingvistické premenné antecedentu a konsekventu pravidla R_i , reprezentované fuzzy množinami, k je počet pravidiel.

Model typu Takagi-Sugeno

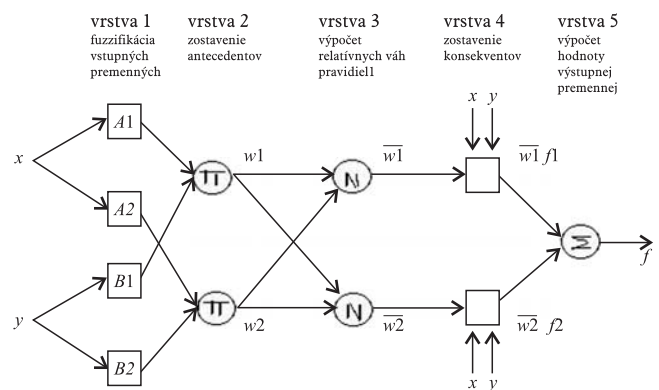
Tento model je vhodný v prípade identifikácie z nameraných údajov.

$$R_i : \text{Ak } x \text{ je } A_i \text{ potom } y = a_i^T x + b_i \quad i = 1, 2, \dots, k \quad (2)$$

Definícia antecedentu pravidla ostáva rovnaká, konsekvent je vyjadrený ako lineárna funkcia vstupných premenných.

Anfis (Adaptive Network-based Fuzzy Inference System)

Anfis (obr. 1) je päťvrstvová dopredná neurónová sieť, ktorej výsledkom je fuzzy inferenčný systém typu Takagi-Sugeno [5], [7].



Obr.1 Architektúra siete Anfis

Vrstvu 1 tvoria adaptívne uzly, každý uzol predstavuje lingvistickú hodnotu vstupnej premennej.

Vrstvu 2 tvoria neadaptívne uzly, ktoré iba násobia prichádzajúce signály a na výstupe tak poskytujú váhu w pravidiel, ktorých antecedent je daný kombináciou lingvistických hodnôt jednotlivých premenných.

Vrstvu 3 tvoria neadaptívne uzly, ktoré poskytujú na výstupe pomer váhy jednotlivých pravidiel a súčtu váh všetkých pravidiel \bar{w} .

Vrstvu 4 tvoria adaptívne uzly, ktorých prenosové funkcie sú dané požadovaným tvarom konsekventu. Môžu byť konštantné alebo lineárne.

Vrstvu 5 tvorí jeden neadaptívny uzol, ktorý počíta celkový výstup ako súčet všetkých vstupných signálov.

Na tréningovanie siete používa Anfis hybridnú učiacu metódu. Parametre v antecedente pravidla (určujúce funkcie príslušnosti vstupných premenných) sú optimalizované gradientovou metódou, parametre konsekventu (konštanty alebo koeficienty lineárnej funkcie) sa počítajú metódou najmenších štvorcov.

Postup výpočtu metódou ANFIS v Matlabe

1. Inicializácia fuzzy systému: príkazy *genfis1* alebo *genfis2*
2. Zadanie parametrov potrebných na učenie: počet iterácií (epochy), tolerancia (chyba).
3. Začiatok procesu učenia: príkaz *anfis*; pri dosiahnutí zadanej tolerancie sa výpočet končí.
4. Overenie správnosti výpočtu s nezávislými údajmi.

Destilačná kolóna

V Simulinku bol vytvorený model etážovej rektifikačnej kolóny na delenie zmesi benzén – toluén [3], [8]. Kolóna má 25 etáží, nástreková etáž je 14., účinnosť varáka je 100 %, účinnosť etáží je 60 %.

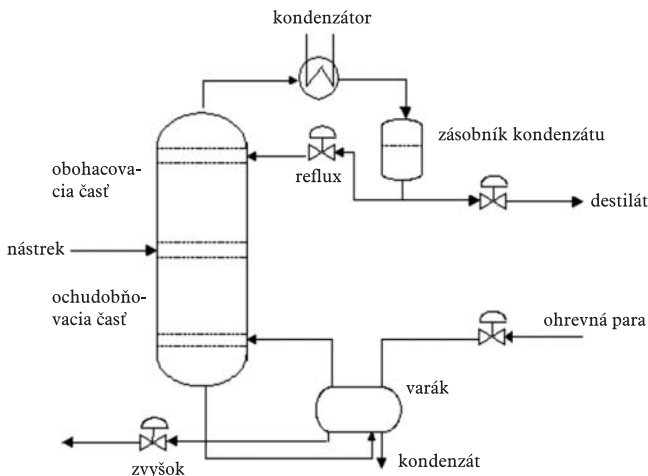
Rovnica Murpreeho účinnosti pre i -tu etáž:

$$\eta_k = \frac{y_k - y_{k-1}}{y_k^e - y_{k-1}} \quad k = 0, \dots, 25 \quad (3)$$

Rovnovážna krivka v tvare

$$y_k^e = \frac{a + cx_k + ex_k^2}{1 + bx_k + dx_k^2} \quad k = 0, \dots, 25 \quad (4)$$

má pre zmes benzén – toluén koeficienty $a = 0,0021567456$, $b = 0,82112327$, $c = 2,3066176$, $d = -0,39916116$, $e = -0,88823513$.



Obr.2 Schéma destilačnej kolóny

Zjednodušený matematický model kolóny je vytvorený na základe materiálových bilancii zložiek a tvorí ho 27 nelineárnych diferenciálnych rovníc.

Rovnica prchavejšej zložky v ochudobňovacej časti kolóny pre i -tu etáž:

$$H_i \frac{dx_i}{dt} = Vy_{i-1} + (L + F)x_{i+1} - Vy_i - (L + F)x_i \quad (5)$$

Rovnica prchavejšej zložky pre k -tu nástrekovú etáž kolóny:

$$H_k \frac{dx_k}{dt} = Vy_{k-1} + Lx_{k+1} + Fx_f - Vy_k - (L + F)x_k \quad (6)$$

Rovnica prchavejšej zložky v obohacovacej časti kolóny pre j -tu etáž:

$$H_j \frac{dx_j}{dt} = Vy_{j-1} + Lx_{j+1} - Vy_j - Lx_j \quad (7)$$

Pri 100 % účinnosti varáka:

$$H_w \frac{dx_w}{dt} = -Vy_0 + (L + F)x_1 - Wx_w \quad (8)$$

Pri úplnej kondenzácii pár v kondenzátore:

$$H_d \frac{dx_d}{dt} = Vy_n - (L + D)x_d \quad (9)$$

kde x_w je molový zlomok prchavejšej látky vo zvyšku, H_w je molová zádrž varáka, x_d je molový zlomok prchavejšej látky v destiláte, H_d je molová zádrž kondenzátora. Platí:

$$y_n = x_d$$

Molové prietoky sú viazané vzťahmi:

$$F = D + W \quad V = L + D \quad L + F = V + W$$

prietok nástreku F	22,5 kmol.h ⁻¹
molový zlomok destilátu x_D	0,667
molový zlomok nástreku x_F	0,23
zádrž kvapalnej fázy vo varáku H_0	1 kmol
zádrže kvapalnej fázy na etážach H_i , $i = 1, \dots, 25$	0,1 kmol
zádrž kvapalnej fázy v kondenzátore H_d	0,2 kmol
prietok kvapalnej fázy L	22,26 kmol.h ⁻¹
prietok parnej fázy V	30 kmol.h ⁻¹
prietok destilátu D	7,74 kmol.h ⁻¹


Tab.1 Parametre kolóny použité na simuláciu

Etáže sú číslované zdola nahor, varák má index 0, prvá etáž 1 atď. Koncentrácia destilátu je $x_D = x_{26}$, koncentrácia zvyšku je $x_w = x_1$.


Parametre kolóny sú uvedené v tab. 1.

Prechodová charakteristika bola simulovaná pre zmenu molového prietoku kvapalnej fázy L z hodnoty $L^s = 22,26$ kmol.h⁻¹ na hodnotu $L = 24,26$ kmol.h⁻¹. Namerané hodnoty zloženia destilátu boli použité na získanie neuro-fuzzy modelu kolóny typu Takagi-Sugeno metódou Anfis.


Pri tvorbe modelov boli použité rôzne typy a rôzny počet funkcií príslušnosti. Presnosť modelov dokumentujú obr. 3 – 8. Na všetkých obrázkoch je čiernou farbou znázornené namerané zloženie destilátu x_D a modrou farbou x_D ako výstup z T-S modelu. Na obr. 3 je T-S model tvorený tromi pravidlami, na výpočet pa-




Obr.3 Porovnanie koncentrácie x_D (modrá: nameraná, čierna: model)




Obr.4 Porovnanie koncentrácie x_D (modrá: nameraná, čierna: model)



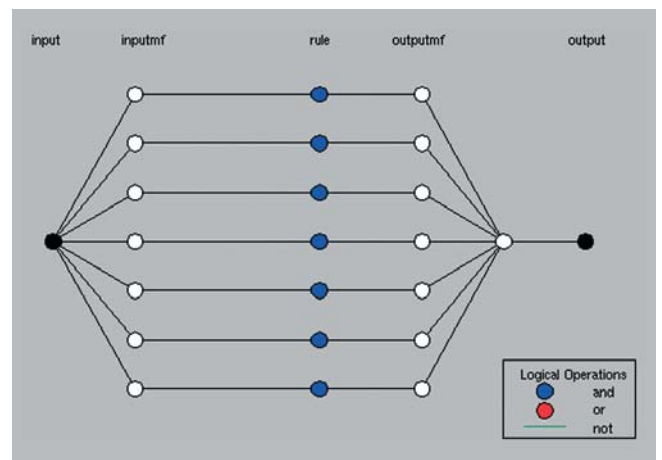
Obr.5 Porovnanie koncentrácie x_D
(modrá: nameraná, čierna: model)




Obr.8 Porovnanie koncentrácie x_D
(modrá: nameraná, čierna: model)




Obr.6 Porovnanie koncentrácie x_D
(modrá: nameraná, čierna: model)



Obr.9 Štruktúra Anfis



Obr.7 Porovnanie koncentrácie x_D
(modrá: nameraná, čierna: model)



Obr.10 Proces inferencie

parametrov premisných častí pravidiel boli použité trojuholníkové funkcie príslušnosti; na obr. 4 je T-S model tvorený tromi pravidlami, na výpočet parametrov premisných častí pravidiel boli použité trojuholníkové funkcie príslušnosti; na obr. 5 bola pri výpočte použitá metóda subtraktívneho zhlukovania, T-S model tvoria štyri pravidlá; na obr. 6 je T-S model tvorený štyrmi pravidlami, na výpočet parametrov premisných častí pravidiel boli použité lichobežníkové funkcie príslušnosti; na obr. 7 T-S model

tvorí sedem pravidiel, na výpočet parametrov premisných častí pravidiel boli použité gaussovské funkcie príslušnosti; na obr. 8 je T-S model tvorený siedmimi pravidlami, na výpočet parametrov premisných častí pravidiel boli použité trojuholníkové funkcie príslušnosti. Na ilustráciu je na obr. 9 uvedená konkrétna štruktúra Anfis pre sedem pravidiel s gaussovskými funkciami príslušnosti z obr. 7, príslušné pravidlá sú znázornené na obr. 10.

Gaussovská funkcia príslušnosti

$$\mu(x_i) = e^{-\frac{(x_i - c)^2}{2\sigma^2}} \quad (10)$$

má dva parametre (σ , c), ktoré určujú tvar a pozíciu funkcie príslušnosti. Tieto parametre sú uvedené v tab. 2. V tab. 3 sú uvedené parametre a_i , b_i konštantnej časti T-S modelu v tvare (2).

x	
σ_i	c_i
0,151	-0,0008
0,154	0,323
0,146	0,662
0,143	0,998
0,142	1,332
0,141	1,666
0,141	2,000

Tab.2 Parametre gaussovských funkcií príslušnosti

a_{ii}	b_i
0,99	0,665
0,29	0,744
0,11	0,808
0,05	0,837
0,02	0,863
0,005	0,886
-0,01	0,918

Tab.3 Parametre konsekventnej časti pravidiel

Záver

Vytvorenie modelu typu Takagi-Sugeno je založené na rozdelení stavového priestoru na jednotlivé oblasti a na ich linearizácii pomocou lokálnych lineárnych modelov. Takáto štruktúra modelu sa značne blíži fyzikálnemu charakteru systému a tieto modely sa už aj v minulosti ukázali byť vhodné na aplikáciu fuzzy riadenia.

Podakovanie

Tento príspevok vznikol s grantovou podporou VEGA MŠ SR a SAV pre projekty č. 1/1046/04 a 1/3081/06.

Literatúra

- [1] BABUŠKA, R.: Fuzzy Modelling and Identification, PHD Thesis, Delft, 1996.
- [2] BAKOŠOVÁ, M., J. BALEJA AND A. VASIČKANINOVÁ: MODELTOOL 1.0 – A MODEL TOOLBOX FOR MATLAB/SIMULINK. V Proc. 7. Int. Scientific-Technical Conf. Process Control 2006, University of Pardubice, Kouty nad Desnou, Czech Republic, s. 115, 2006

[3] BAKOŠOVÁ, M. AND M. ONDROVIČOVÁ: Adaptive control of distillation column – a case study. In: Prep. 13th Int. Congress of Chem. and Process Engineering CHISA '98. CD ROM No. 527, Magicware, Ltd., Prague, 1998

[4] FIKAR, M. AND J. MIKLEŠ: Identifikácia systémov. Bratislava, STU. s. 114, ISBN 80-227-1177-2, 1999

[5] JANG, S. R.: Adaptive-Network-Based Fuzzy Inference Systems, IEEE Trans. Systems, Man & Cybernetics 23, p. 665 – 685, 1993

[6] NAUCK, D., F. KLAWONN AND R. KRUSE: Foundations of neuro-fuzzy systems. John Wiley & Sons, Great Britain. Able, B.C. (1956). Nucleic acid content of microscope. Nature 135, p. 7 – 9, 1997

[7] SUGENO, M. AND K. TANAKA: Successive Identification of a Fuzzy Model and its Application to prediction of a Complex System. Fuzzy Sets and Systems. 1991, Vol. 42, p. 315 – 334

[8] VASIČKANINOVÁ, A. AND M. BAKOŠOVÁ: Fuzzy controller design for distillation column.. V Proc. 16. Int. Congress of Chemical and Process Engineering CHISA 2004. ISBN 80-86059-40-5., 2004.

[9] VASIČKANINOVÁ, A. AND M. BAKOŠOVÁ: Fuzzy modeling and identification of the chemical technological processes. V Proc. 5th MATHMOD Vienna, AGRESIM – Verlag, Vienna, 2006, zv. 1, str. 348, 2006.

[10] ZADEH, L. A.: Fuzzy sets. Inf. & Control 8, p. 338 – 353, 1965

Ing. Anna Vasičkaninová
doc. Ing. Monika Bakošová, CSc.
doc. Ing. Jan Dvoran, CSc.

49

STU FCHPT
Ústav informatizácie, automatizácie a matematiky
Radlinského 9, 81237 Bratislava
e-mail: anna.vasickaninova@stuba.sk
monika.bakosova@stuba.sk
jan.dvoran@stuba.sk