

Nelinearni proizvodni model sistema Tennessee Eastman

Dejan Gradišar*, Juš Kocijan*+

* Institut Jožef Stefan, Jamova 39, 1000 Ljubljana

+ Univerza v Novi Gorici, Vipavska 13, 5000 Nova gorica

E-pošta: dejan.gradisar@ijs.si

Nonlinear production model of TE system

The efficiency of the production process control can be improved with the decision support systems. In order to develop a production control system an appropriate model is needed. The efficiency of the production process is usually observed by proper performance measurements (performance indicators – PI). Based on these variables appropriate decisions about how to control the production system are done. In this paper a production model was developed for the well-known Tennessee Eastman process. With an input-output analysis only the most influential manipulative variables are selected. As some non-linearities are observed, neural network tool is used to define a production model.

1 Uvod

Vodenje proizvodnega sistema je zahtevna naloga, potrebna so različna znanja, izkušnje in obvladovanje ogromne količine informacij. V samem proizvodnjem podjetju nastopa ogromno podatkov, iz katerih pa je nato potrebno izluščiti prave (koristne) informacije. Stanje in učinkovitost proizvodnega procesa običajno spremljamo preko kazalnikov učinkovitosti in na osnovi le-teh se izvajajo navodila, kako upravljati proces preko različnih manipulativnih vhodnih spremenljivk [7]. Da bi lahko načrtali tak sistem vodenja, bi potrebovali model, ki bi povzema lastnosti procesa za namene proizvodnega vodenja.

Model industrijskega procesa Tennessee Eastman (TE), ki sta ga predstavila Downs in Vogel [1], predstavlja simulacijsko okolje realnega kemijskega procesa. Na področju raziskav vodenja proizvodnje (angl. *plant-wide control*) se ta simulacijski model industrijskega procesa pojavlja zelo pogosto [5, 6]. V našem primeru uporabimo to simulacijsko okolje, da predstavimo problematiko vodenja proizvodnih sistemov in predvsem kako določiti za to potreben model.

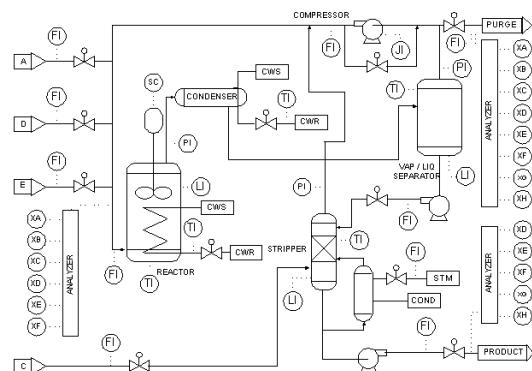
V nadaljevanju je najprej na kratko predstavljen proces TE in podan pogled na proces s stališča proizvodnega vodenja. V nadaljevanju je predstavljena vhodno-izhodna analiza, kjer so bili izbrani le trije najbolj vplivni manipulativni signali. Analiza nelinearnosti posameznih povezav pokaže potrebo po uporabi orodja nevronskih mrež za določitev proizvodnega modela. Na koncu so predstavljeni še zaključki in komentarji.

2 Proces TE

Model industrijskega procesa TE sta predstavila Downs in Vogel [1]. Proses sestavlja pet glavnih enot: reaktor, shranjevalnik produktov, separator pare in tekočine, ločevalnik produkta in reciklirni kompresor. Shema procesa je predstavljen na sliki 1.

Proizvodnjo produktov opišemo s štirimi eksotermnimi, irreverzibilnimi reakcijami, predstavljenimi z enačbo (1). Glavna produkta procesa sta komponenti G in H , nastaja pa tudi stranski produkt, komponenta F .

$$\begin{aligned} A(g) + C(g) + D(g) &\rightarrow G(1) \\ A(g) + C(g) + E(g) &\rightarrow H(1) \\ A(g) + E(g) &\rightarrow F(1) \\ 3D(g) &\rightarrow 2F(1) \end{aligned} \quad (1)$$



Slika 1: Shema procesa Tennessee Eastman.

Na procesu imamo 41 merilnih signalov in 12 manipulativnih spremenljivk. Podrobnejši opis procesa in vseh prisotnih spremenljivk je predstavljen v [1, 3].

Naša študija sloni na modelu, ki je dostopen na Rickerjevi spletni strani [4]. Študirali smo delovanje procesa v načinu 1 (*Mode 1*), kjer je razmerje med komponentama G in H določeno kot 50/50.

2.1 Proizvodni model

Želimo modelirati TE proces za namen proizvodnega vodenja. Pri spremeljanju celotne proizvodnje se ne spuščamo na nivo posameznih naprav, pač pa obravnavamo proizvodnjo kot celoto in preučujemo posamezne vidike uspešnosti proizvodnje. Na proizvodnem nivoju

običajno reguliramo proces proizvodnje, tako da so izpolnjeni različni proizvodno-ekonomski kriteriji. Eden izmed možnih pristopov je uporaba proizvodnih kazalnikov učinkovitosti [7]. V pričujočem delu smo kot kazalnike učinkovitosti delovanja proizvodnje izbrali: *Stroški, Produktivnost in Kvaliteto produktov*. Izračun kazalnikov učinkovitosti smo povzeli po [1].

Proizvodni stroški (*Costs*) so določeni z enačbo (2):

$$\begin{aligned} \text{total costs} = & 0.0536 \frac{\$}{kWh} Y_{20} + 0.0318 \frac{\$}{kg} Y_{19} + \\ & 44.79 \frac{k\text{mol h}^{-1}}{k\text{scmh}} Y_{10} \cdot [0.02 \frac{\$}{\text{kmol}} Y_{29} + 0.06 \frac{\$}{\text{kmol}} Y_{31} + \\ & 0.22 \frac{\$}{\text{kmol}} Y_{32} + 0.14 \frac{\$}{\text{kmol}} Y_{33} + 0.178 \frac{\$}{\text{kmol}} Y_{34} + \\ & 0.304 \frac{\$}{\text{kmol}} Y_{35} + 0.229 \frac{\$}{\text{kmol}} Y_{36}] + 4.54 \cdot X MV_8 \\ & \cdot [0.22 \frac{\$}{\text{kmol}} Y_{37} + 0.145 \frac{\$}{\text{kmol}} Y_{38} + 0.178 \frac{\$}{\text{kmol}} Y_{39}] \end{aligned} \quad (2)$$

kjer oznaka Y predstavlja 41 merilnih signalov. V prvem delu enačbe (2) so predstavljeni obratovalni stroški kompresorja, v drugem delu so stroški dela s paro, v tretjem so vsebovani stroški čiščenja in na koncu še izgube med proizvodnjo.

Produktivnost procesa (*Production*) je ocenjena preko merilnega signala *Stripper underflow (Steam 11)*, enačba (3):

$$\text{Production} = Y_{17} \quad (3)$$

Kvaliteta (*Quality*) pa je določena preko merilne veličine, ki predstavlja odstotek komponente G v produktu G component, enačba (4):

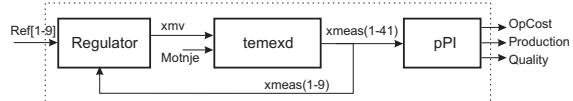
$$\text{Quality} = Y_{40} \quad (4)$$

Na nižjem nivoju vodenja je bila uporabljena regulacija, ki jo je predstavil Larsson s sod. [2]. Izmed 41 merljivih spremenljivk so izbrali 9, ki jih regulirajo. Pri tem so predpostavili, da lahko ostale tri manipulativne spremenljivke brez posledic nastavimo na konstantne vrednosti. Izbrani regulacijski signali so predstavljeni v tabeli 1, v kateri so predstavljena tudi njihova območja delovanja, skupaj z njihovimi srednjimi vrednostmi.

Tabela 1: Regulacijski signali, povzeto po [2].

SP	Regulacijski signal	Območje (Mode 1)
R_1	Y_{17} – Production (m^3)	[18 – 37] (22.89)
R_2	Y_{15} – Stripper level (%)	[30 – 100] (50)
R_3	Y_{12} – Separator level (%)	[30 – 100] (50)
R_4	Y_8 – Reactor level (%)	[50 – 100] – (65)
R_5	Y_7 – Reactor pressure (kPa)	[- – 2985] (2800)
R_6	Y_{40} – Mole % G in product	[0 – 100] (53.8)
R_7	Y_{31} – %C in Purge	[0 – 100] (13.1)
R_8	Y_5 – Recycle rate (kscmh)	[18 – 33] (32.2)
R_9	Y_9 – Reactor temp. ($^{\circ}\text{C}$)	[- – 150] (122.9)

Iz vidika proizvodnega vodenja imamo tako sistem z devetimi vhodi (*Ref*), s katerimi želimo vplivati na potek proizvodnje tako, da zagotovimo čim boljše vrednosti kazalnikov. Shema takega proizvodnega sistema je prikazana na sliki 2.



Slika 2: Shema proizvodnega modela.

3 Modeliranje proizvodnega modela

3.1 Vhodno-izhodna analiza

Za lažje načrtovanje vodenja takega procesa bi bilo primerno reducirati vhodne (manipulativne) spremenljivke na enako število, kot imamo izhodov. V ta namen smo izvedli vhodno-izhodno analizo. Sistem analiziramo tako, da preučujemo vpliv posameznih vhodov na vsakega izmed treh izhodov (kazalnike pPI). Med tem, ko spremojamo izbrani vhod, ostale vhode držimo na srednjih vrednostih (tabela 1). Poteki vhodnih signalov so določeni glede na omejitve, ki so predstavljene v tabeli 1. Poleg tega je potrebna posebna pazljivost pri izvajanjju teh eksperimentov, saj lahko hitro sistem privedemo do nedovoljenih notranjih stanj, ki povzročijo samozaustavitev tovarne.

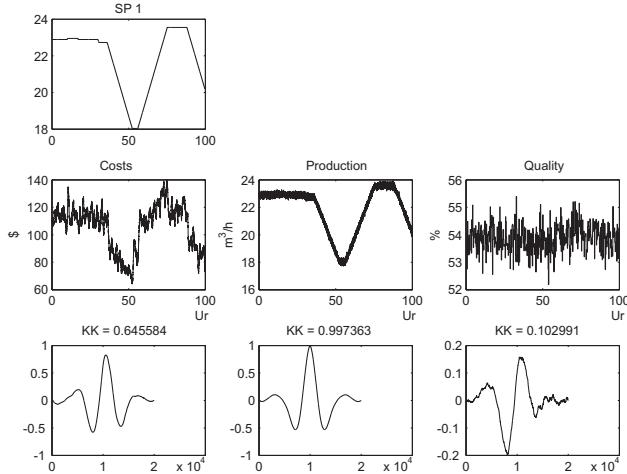
Obstaja več metod, ki na statistični osnovi določajo korelacijo med vhodnim in izhodnim signalom. Uporabili smo križno korelacijo, enačba (5). Križna korelačijska funkcija podaja stopnjo podobnosti med dvema signaloma. Poleg tega, smo določali tudi korelačijske koeficiente (KK), ki podajajo kvatitativno mero podobnosti med dvema signaloma.

$$(f * g)(k) = \sum_{i=-\infty}^{\infty} f^*(i)g(k+i) \quad (5)$$

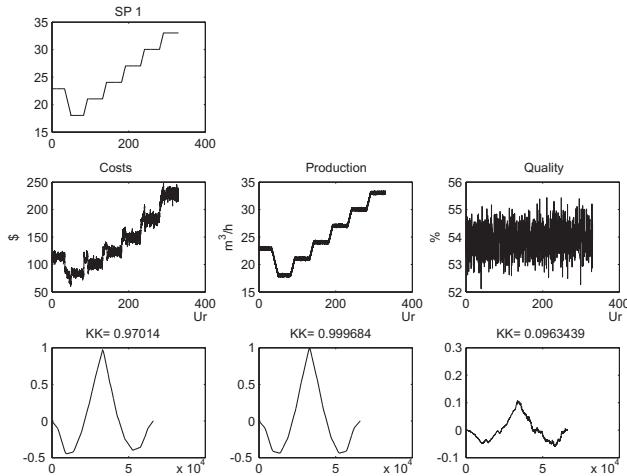
Za primer je na sliki 3 prikazan odziv posameznih izhodov, ko spremojamo prvi vhodni signal (R_1). Pod vsakim izhodnim signalom lahko opazimo tudi korelačijsko funkcijo, skupaj s korelačijskim koeficientom. Opazimo lahko, da korelačijska funkcija in koeficient kažeta na precej močno povezano na relaciji med vhodnim signalom in kazalnikoma *Production* in *Costs*.

Preko omenjene analize opazimo predvsem visoko stopnjo ujemanja med sledečimi vhodnimi in izhodnimi povezavami: a) $\text{Production} \leftrightarrow \text{Production \& Costs}$, b) $\text{Mole \% G in product} \leftrightarrow \text{Quality \& Costs}$ in c) $\text{Recycle rate} \leftrightarrow \text{Costs}$.

V nadaljevanju smo se tako usmerili na poudarjeno analizo teh povezav. Preden se lotimo modeliranja je seveda potrebno preveriti linearnost sistema. Nelinearnost procesa lahko prikažemo tako, da prikažemo odzive procesa na enak vhodni signal v različnih področjih. V našem primeru sicer ni mogoče izvesti takega preizkusa prav v celotnem področju, saj lahko v določnem področju tak signal privede proces v nedovoljeno notranje stanje. Zopet prikažimo le test, ki se nanaša na vpliv vhodnega signala R_1 , slika 4. Opazimo lahko, da obstaja nelinearna povezava do kazalnika, ki označuje stroške (*Costs*). Ojačanje se za različna področja delovanja precej spreminja (do dvakratne vrednosti).



Slika 3: Spreminjanje vhodnega signala SP 1.



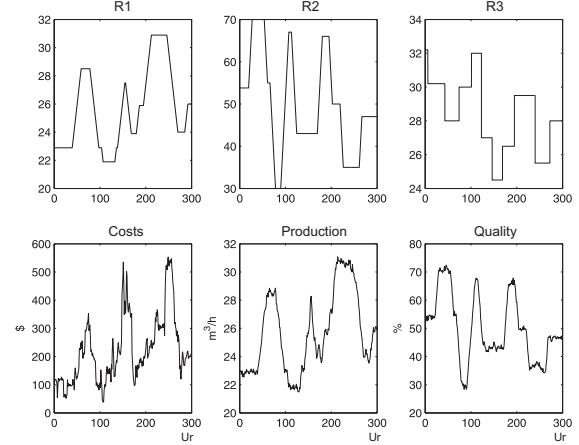
Slika 4: Spreminjanje vhodnega signala SP 1 – test lineranosti.

3.2 Model nevronske mreže

Ugotovili smo, da so nekatere vhodno-izhodne povezave nelinearne, tako moramo to upoštevati pri njihovem modeliranju. Kot primerno orodje za modeliranje neliniernih multivariabilnih dinamičnih sistemov se izkažejo nevronske mreže [8].

Učno množico (identifikacijske podatke), prikazana na sliki 5, smo dobili s simulacijskim modelom procesa. Sistem smo vzbujali z naključnimi signali spremenljive amplitude, tako da smo poskušali zaobjeti čimveč informacije o dinamičnem obnašanju procesa. Zopet so potekи vhodnih signalov določeni glede na omejitve iz tabele 1 ter tako, da sistem ne privedemo v nedovoljena notranja stanja.

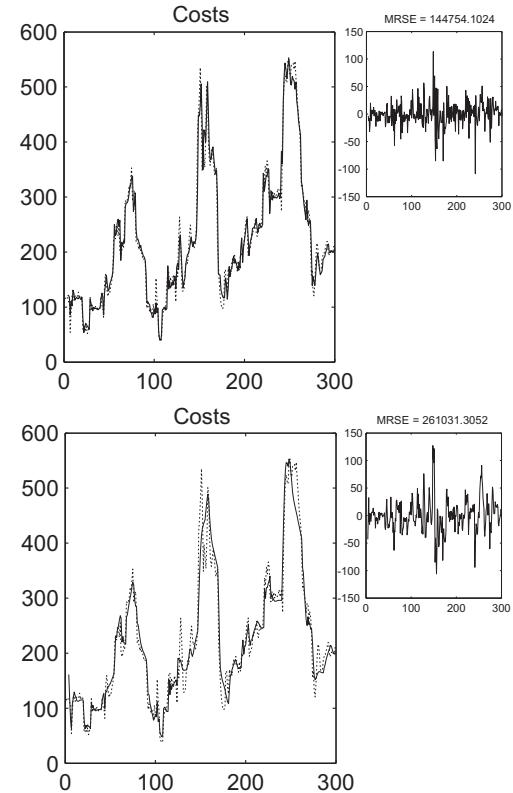
Pri identifikaciji smo uporabljali programsko opremo Neural Network Toolbox za Matlab [9]. Za vsak izhodni signal (*Production*, *Costs* in *Quality*), kjer na vsakega izmed njih vplivajo trije vhodni signali, zgradimo svojo mrežo. Odločili smo se za nevronske mreže z večnivojskim perceptronom, z enim skritim nivojem. Preden uporabimo podatke iz učne množice.



Slika 5: Učna množica.

Po iterativnem postopku identifikacije in vrednotenja smo izbrali naslednje nevronske mreže:

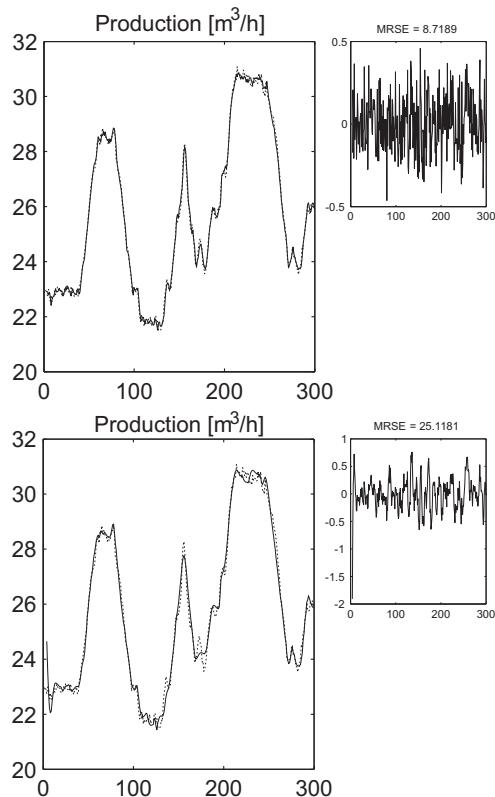
- Mreža do izhoda *Costs* – Slika 6. Uporabljeni sta bila dva nevrona, regresorji pa so določeni iz treh zaksnjih vhodnih in izhodnih vzorcev. Upoštevali smo tudi zaksnjitev enega vzorca.



Slika 6: Validacija – *Costs*. Eno- in več-koračna predikcija.

- Mreža do izhoda *Production* – Slika 7. Uporabljeni sta bila dva nevrona, regresorji pa so določeni iz štirih zaksnjih vhodnih in izhodnih vzorcev. Iz predhodne analize smo opazili direktno povezavo med kazalnikom *Production*

in vhodom R_1 , kar smo vnaprej upoštevali pri definiranju strukture mreže.



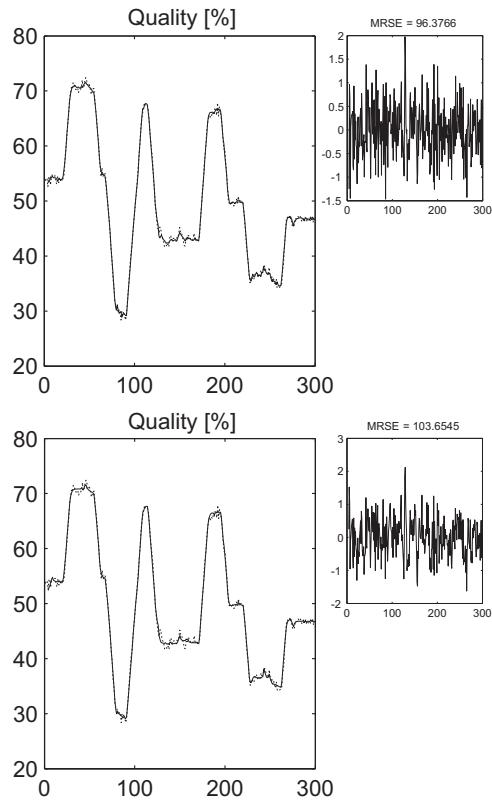
Slika 7: Validacija – *Production*. Eno- in več-koračna predikcija.

- Mreža do izhoda *Quality* – Slika 8. Uporabljena sta bila dva nevrona, regresorji pa so določeni iz treh zakanjenih vhodnih in izhodnih vzorcev. Upoštevali smo tudi zakasnitev enega vzorca. Iz predhodne analize mo opazili direktno povezavo med kazalnikom *Quality* in vhodom R_6 , kar smo vnaprej upoštevali pri definiranju strukture mreže.

Parametre mreže smo določili z Levenberg-Marquardtovo metodo. V grafih na slikah 6–8 so prikazani odzivi mrež na dane vhodne signale določene z enokoračno predikcijo (zgornji grafi) in nato še z simulacijo (spodnji grafi). Originalni signali so predstavljeni s prekinjeno črto. Modeli so ovrednoteni preko cenilki vsote kvadratov napake, ki so prikazani na grafih na desni strani slik.

4 Zaključek

V delu je predstavljena problematika modeliranja proizvodnih sistemov na nivoju proizvodnega vodenja. Na simualcijskem modelu procesa TE je bila izvedena analiza vhodnih in izhodnih povezav in na osnovi le-te je bil načrtovan model. Ker se je izkazalo, da imamo opravka z nelinearnimi povezavami, so bile pri tem uporabljeni nevronske mreže.



Slika 8: Validacija – *Quality*. Eno- in več-koračna predikcija.

Literatura

- [1] J. J. Downs and E. F. Vogel: A plant-wide industrial process control problem. *Computers & Chemical Engineering*, 17:3 (1993), 245–255.
- [2] Larsson, T. and Hestetun, K. and Hovland, E. and Skogestad, S.: Self-Optimizing Control of a Large-Scale Plant: The Tennessee Eastman Process. *Industrial & Engineering Chemistry Research*, 40:22 (2001), 4889–4901.
- [3] N.L. Ricker Optimal steady-state operation of the Tennessee Eastman challenge process. *Computers & Chemical Engineering* , 19:9 (1995), 949–959.
- [4] N.L. Ricker Tennessee Eastman Challenge Archive. <http://depts.washington.edu/control/LARRY/TE/download.html>, 2009.
- [5] P.R. Lyman and C. Georgakis: Plant-wide control of the Tennessee Eastman problem. *Computers & Chemical Engineering*, 19:3 (1995), 321–331.
- [6] Zhenhua Tian and Karlene A. Hoo: Multiple Model-Based Control of the Tennessee-Eastman Process. *Ind. Eng. Chem. Res.*, 44:9 (2005), 3187–3202.
- [7] S. Zorzut, D. Gradišar, V. Jovan, G. Mušič: Use of a procedural model in the design of production control for a polymerization plant. *IJAMT*, 2009 In Press.
- [8] K.S. Narendra, K. Parthasarathy: Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks*, 1 (1990), 4–27.
- [9] Matlab Neural Network Toolbox for Matlab. <http://www.mathworks.com/products/neuralnet>, 2009.