

Modeliranje z nevronskimi mrežami za namene vodenja proizvodnje

Miha Glavan, Dejan Gradišar
Institut "Jožef Stefan"
Jamova 39, Ljubljana
miha.glavan@ijs.si

Neural network based modelling for production control

In this paper we present a modelling approach for the purposes of a production optimization. Using the holistic production control concept economic goals in a form of production performance indicators (pPI) are controlled. To realize such a control of a production, an adequate model is needed, which should be able to predict future behaviour of production performance indicators. Due to complexity of production processes it is reasonable to use black-box modelling techniques, where a model representing a pPIs dynamics can be found from the historical production process data. This paper represents modelling approach with employment of neural networks, as they are able to learn a nonlinear input-output mapping from an example. Model development is demonstrated on the case study of Tennessee Eastman process, where model for prediction of the costs, production and quality is found only on the basis of the production process data.

Kratek pregled prispevka

Celostno vodenje proizvodnje predstavlja koncept optimizacije proizvodnje, kjer na podlagi zaprto-zančnega vodenja kazalnikov učinkovitosti proizvodnje (pPI) dosežemo zadane cilje proizvodnje s čim nižjimi stroški. Za realizacijo takšnega vodenja je potrebno poiskati primeren model, ki bo sposoben napovedovati prihodnje obnašanje kazalnikov proizvodnje. Zaradi kompleksnosti proizvodnih procesov je smiselna uporaba principa modeliranja črnih-škatel, kjer bi zgolj na podlagi preteklih operativnih podatkov proizvodnje sklepali na dinamiko proizvodnje. V tem prispevku smo za modeliranje uporabili nevronske mreže, saj lahko znanje o nelinearni vhodno-izhodni preslikavi pridobijo že z učenjem na primerih. Iskanje modela je prikazano na testnem primeru Tennessee Eastman procesa, kjer zgolj na podlagi proizvodnih podatkov procesa pridobimo model za napovedovanje stroškov, produktivnosti in kvalitete.

1 Uvod

Konkurenčnost globalnega trga je spremenila način proizvodjanja, saj se sedaj ne izdeluje več na zalogo, temveč je ekonomsko bolj upravičeno hitro prilagajanje proizvodnje glede na tržno povpraševanje. Vodja proizvodnje mora tako na podlagi trenutno dostopnih podatkov in razpoložljivih virov določiti optimalni proizvodni urnik, ki bo poskrbel za ekonomsko učinkovitost proizvodnje, hkrati pa bo zagotavljal delovanje znotraj procesnih omejitev. Tipični proizvodni sistemi imajo ogromno število procesnih spremenljivk, ki vplivajo na skupno učinkovitost proizvodnje. Naloga vodje proizvodnje je spremljati vso to veliko količino informacij in sprejemati najprimernejše ukrepe. Zaradi preobremenjenosti s podatki ter hkratne potrebe po hitrih reakcijah, takšne odločitve večinoma niso optimalne.

Pogosto se za analizo in nadzor proizvodnje uporablja orodja MES (*ang. Manufacturing Execution System*), ki so sposobna zajemanja velike količine procesnih podatkov in poskrbeti za njihovo ustrezno prikazovanje. Vodja proizvodnje s pomočjo analize preteklih procesnih meritev in trenutnega proizvodnega stanja, definira popravke procesnih nastavitvev. S tem skuša doseči optimalno obratovalno stanje, ki bo uspelo realizirati definicije podane s strani poslovnega nivoja in, če je le mogoče, minimizirati proizvodne stroške. Pomanjkljivost sistemov MES je šibka podpora za optimizacijo in vodenje proizvodnje, saj je analiza preteklih proizvodnih podatkov pogosto omejena na iskanje najboljših preteklih tekov proizvodnje. Tipično je interpretacija rezultatov analize precej kompleksna, kjer je nujno podrobno poznavanje procesnih karakteristik, da se lahko iz rezultatov analize pridobi uporabno znanje ali nasvete kako reagirati za dosego boljših proizvodnih rezultatov.

Koncept celostnega vodenja proizvodnje (*ang. Holistic Production Control - HPC*) predstavlja nekakšno nadgradnjo MES orodij,

kjer bi lahko s podrobnejšo analizo preteklih proizvodnih podatkov, realizirali povratno-zančno vodenje ekonomskih proizvodnih ciljev. Implementacija takšnega vodenja bi lahko služila vodji proizvodnje, kot podporno orodje pri odločanju ali pa celo za neposredno povratno-zančno vodenje.

Optimizacijska sposobnost celostnega vodenja je močno odvisna od kvalitete uporabljenega modela. Procesni model bi moral biti preprost in pridobljen zgolj iz analize preteklih procesnih podatkov, a vendar zadosti natančen pri napovedovanju systemske dinamike. V tem prispevku se bomo osredotočili na vprašanje, kako poiskati primeren model.

V naslednjem poglavju bo podrobneje predstavljen koncept celostnega vodenja proizvodnje. Problem modeliranja bo prikazan v tretjem poglavju. Četrto poglavje pa bo na testnem simulacijskem proizvodnem sistemu prikazal iskanje modela primerne za optimizacijo proizvodnje.

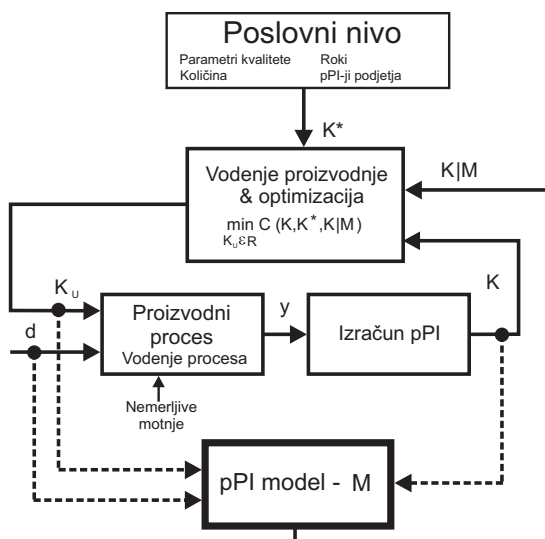
2 Celostno vodenje proizvodnje

Tipično imamo opravka s proizvodnimi sistemi, katerih končna ekonomska učinkovitost je odvisna od ogromnega števila procesnih spremenljivk. Ideja HPC temelji na vpeljavi kazalnikov učinkovitosti proizvodnje (*ang. Production Performance Indicators - pPI*), ki se izračunavajo iz proizvodnih spremenljivk in imajo nalogo strnjenege (agregiranega) prikaza ekonomsko relevantnih informacij o trenutnem stanju proizvodnje. S povratno-zančnim vodenjem takšnih kazalnikov lahko direktno sledimo predpisom višjega poslovnega nivoja, kjer regulator ustrezno prilagaja referenčne vrednosti procesnih spremenljivk, da zagotovi optimalne obratovalne pogoje in ustrezno realizacijo poslovnih ciljev.

Eden izmed načinov vodenja kazalnikov pPI predstavlja prediktivno vodenje z modelom, ki lahko iz procesnih meritev napove obnašanje proizvodnih kazalnikov. Shematski prikaz realizacije HPC z modelom pPI je prikazan na

sliki 1. Prediktivni regulator bi na podlagi trenutnih proizvodnih kazalnikov (K), napovedi modela kazalnikov proizvodnje ($K|M$) in zadanih ekonomskih ciljev (K^*) poiskal optimalne nastavitve procesnih spremenljivk. Regulator vpliva na proizvodnjo s primerno spremembo referenčnih vrednosti vodenja na nižjem nivoju in s preostalimi prostimi manipulativnimi spremenljivkami procesa (K_U).

Koncept celostnega vodenja proizvodnje je bil prvič obširneje predstavljen v delu Zorzut-a s sod. [9], kjer je bila njegova uporaba prikazana za primer optimizacije šaržne proizvodnje.



Slika 1: Koncept celostnega vodenja proizvodnje

2.1 Modeliranje za namene celostnega vodenja proizvodnje

Za celostno vodenje proizvodnje, ki predvideva prediktivni princip vodenja, potrebujemo precej robusten model, ki bo zadosti natančno predvidel obnašanja proizvodnih kazalnikov. Proizvodni procesi so tipično preveč kompleksni, da bi zgolj z opisom osnovnih fizikalnih relacij med procesnimi spremenljivkami lahko definirali kompleksno dinamiko procesa. Koncept razvoja modela za celostno vodenje proizvodnje bi tako moral biti dovolj hiter in brez potrebe po poglobljeni analizi procesa, zato se je smiselno omejiti na modeliranje po principu črnih škatel. Modeli bi

bili tako pridobljeni na podlagi poglobljene analize preteklih proizvodnih podatkov.

Nelinearno modeliranje črne škatle temelji na ideji, da bi nekakšno univerzalno in fleksibilno vhodno-izhodno preslikavo $g(\varphi, \theta)$ prilagajali toliko časa, da bi čim bolj posnemala podatkovni niz s katerim takšno preslikavo učimo.

Vhodno-izhodno preslikavo lahko ločimo na dve različni preslikavi. S prvo definiramo vektor regresorjev θ , ki predstavlja časovno zakasnjene vhode, izhode ali napake modela, s čimer razširimo uporabo tudi za dinamične sisteme. Z drugo preslikavo $g(\varphi, \theta)$ pa je opisana dinamika modela in predstavlja povezavo med regresorji ter izходом modela.

Univerzalno vhodno-izhodno preslikavo dobimo s parametrizacijo družine funkcij [7]:

$$g(\varphi, \theta) = \sum_{k=1}^n \alpha_k g_k, \quad \theta = [\alpha_1 \dots \alpha_n]^T \quad (1)$$

Kjer g_k predstavlja bazno funkcijo, ki jo razvijemo iz neke osnovne funkcije. Takšno prilagodljivo preslikavo predstavljajo tudi nevronske mreže. Izkazalo se je, da vnaprejšnja nevronska mreža s sigmoidno bazno funkcijo in enim skritim nivojem predstavlja univerzalni aproksimator [4]. Takšna nevronska struktura je tako teoretično sposobna posnemanja poljubne vhodno-izhodne preslikave, pri čemer predstavlja največji problem, kako poiskati primerne parametre za želeno preslikavo.

Nevronske mreže učimo na podlagi vzorčnega procesnega odziva, kjer parametre mreže iterativno prilagajamo tako, da se odziv modela čim bolj približa odzivu realnega sistema. Seveda pa samo posnemanje učnega signala še ne pomeni, da se bo takšen model dobro obnesel tudi na podobnih primerih, saj lahko pride do prenaučenosti na učni signal. Takrat se model nauči tudi znanja prisotnega v učnem signalu, ki ne predstavlja karakteristične procesne dinamike. Uveljavile so se različne metode, s katerimi takšno prenaučenost modelov preprečujemo. Najpogosteje se uporabljajo metode za predčasna zaustavitvev

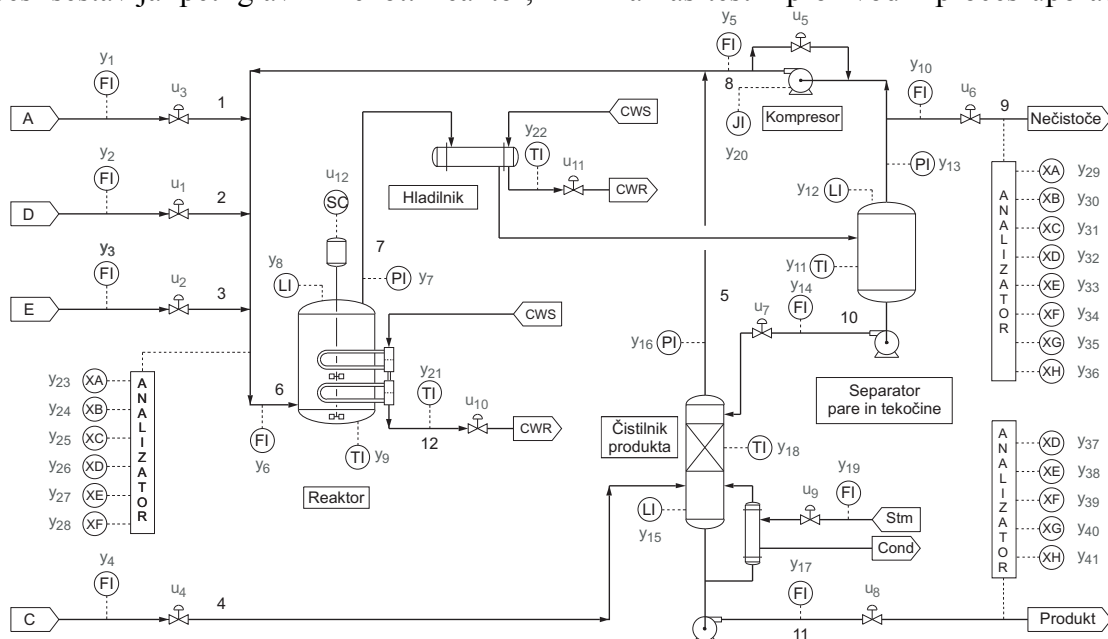
učenja, kjer s križno validacijo na testni signal ugotovimo kdaj predčasno zaustaviti učenje. Metode, kot so na primer regularizacija in obrezovanje mrež, pa poskrbita za zmanjšanje ali pa za popolno odstranitev manj pomembnih parametrov modela, s čimer se poveča sposobnost modelov, prenesti naučeno znanje o procesni dinamiki tudi na signale, ki niso bili direktno uporabljeni v procesu gradnje modela.

V našem primeru smo za modeliranje uporabili nevronska mrežo z enim skritim nivojem in vnaprejšnjo strukturo mreže, kjer povezave med nevroni potekajo izključno od vhoda modela proti izhodu. Uporabljeni sta bili aktivacijski funkciji hiperbolični tangens, za skriti in linearna funkcija za izhodni nivo.

3 Primer modeliranja z nevronskimi mrežami

Modeliranje proizvodnega procesa za namene celovitega vodenja proizvodnje bo prikazano na testnem simulacijskem procesu procesa Tennessee Eastman (TE). V delu [1] sta Downs in Vogel predstavila kompleksen model kemičnega procesa TE, za namene testiranja in primerjavo novih načinov vodenja.


Proces sestavlja pet glavnih enot: reaktor,



Slika 2: Proizvodna shema procesa Tennessee Eastman

hladilnik, separator pare in tekočine, čistilnik

produkta in povratni kompresor (glej sliko 2). Kemični del procesa vsebuje 8 komponent, od tega štiri reaktante (A, C, D, E), dva produkta (G in H), stranski produkt (F) in inertno komponento (B). V reaktorju potekajo naslednje eksotermne in ireverzibilne kemijske reakcije:



Za izhod surovin iz kemičnega procesa poskrbita dve odvodni cevi, ena za produkt (mešanica G in H komponente) in ena za nečistoče. Proces ima 12 manipulativnih spremenljivk in 41 merljivih procesnih spremenljivk.

3.1 Definicija kazalnikov učinkovitosti proizvodnje

Z ustrezno definicijo kazalnikov, ki se izračunavajo iz proizvodnih meritev, lahko na strnjen način prikažemo za poslovni nivo relevantne informacije. S takšnimi kazalniki definiramo merljive cilje vodenja proizvodnje na različnih področjih procesne učinkovitosti.

Za naš testni proizvodni proces uporabimo v

literaturi že predlagane kazalnike, ki se direktno

nanašajo na pomembne proizvodno-ekonomske informacije: *stroški, produktivnost in kvaliteta*.

Definicija stroškov je bila že predlagana skupaj s predstavitvijo procesa [1] in predstavlja oceno predvidenih enournih stroškov proizvodnje, glede na trenutne procesne meritve. Enačba 3 prikazuje stroškovno cenilko v enotah $\$/h$, kjer prva vrstica enačbe ocenjuje vloženo delo (delo kompresorja in poraba pare); druga vrstica ovrednoti izgubo komponent D, E, in F v odvodni cevi produkta; zadnji dve vrstici pa se nanašata na izgubo vsake posamezne komponente, ki zupušča proces v odvodni cevi za nečistoče.

$$C = 0,0318 \cdot y_{19} + 0,0536 \cdot y_{20} + 0,0921 \cdot y_{17} [22,06 \cdot y_{37} + 14,56 \cdot y_{38} + 17,89 \cdot y_{39}] + 0,04479 \cdot y_{10} [2,209 \cdot y_{29} + 6,177 \cdot y_{31} + 22,06 \cdot y_{32} + 14,56 \cdot y_{33} + 17,89 \cdot y_{34} + 30,44 \cdot y_{35} + 22,94 \cdot y_{36}] \quad (3)$$

Kazalnik za produktivnost definiramo s procesno meritvijo y_{17} , ki predstavlja količino produkta, ki zupušča proces skozi odtočno cev iz čistilnika produkta.

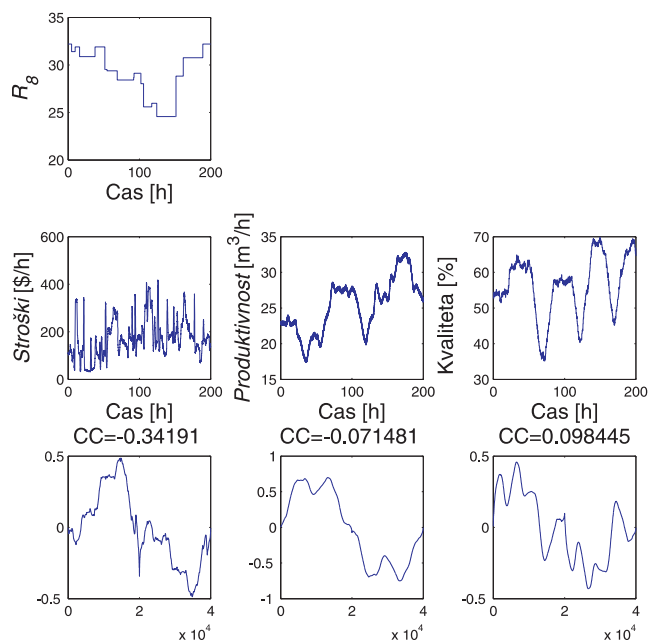
Kvaliteto procesa pa lahko ocenimo z meritvijo y_{40} , ki meri odstotek produkta G v odvodni cevi za produkt. Definicija kvalitete se direktno nanaša na proizvodno zahtevo, da želimo kot proizvod procesa točno določeno razmerje med obema produktoma (G/H).

3.2 Izbira najvplivnejših vhodnih spremenljivk

Proces TE je sam po sebi nestabilen, zato smo naše vodenje na nižjem nivoju temeljili na delu Skogestad-a s sod. [6]. Da bi lahko na procesu TE prikazali koncept celovitega vodenja proizvodnje, je bilo potrebno shemo nižje-nivojskega vodenja ustrezno prilagoditi. Iz povratno-zančnega vodenja je bilo tako potrebno odstraniti zanke, ki so direktno regulirale produktivnost in kvaliteto. S tem smo nalogo vodenja produktivnosti in kvalitete predstavili na višji nivo, ki bo s prediktivnim vodenjem skrbel za realizacijo zahtev poslovnega nivoja.

Na stabilizirani proces Tennessee Eastman lahko sedaj vplivamo preko nastavljanja devetih referenčnih vrednosti vodenja na nižjem nivoju. Da bi zmanjšali kompleksnost problema vodenja in identifikacije ustreznega modela, z analizo vhodov izberemo zgolj najvplivnejše vhode.

Opravljen je bil vhodno-izhodna analiza s križno korelacijo, kjer je bil testiran vpliv vsakega vhodnega signala na vse izbrane kazalnike proizvodnje. Izvedli smo simulacijski test, kjer smo vsakega izmed vhodnih signalov s časom naključno spreminjali. V naslednjem koraku je bila izvedena križna korelacija med vhodno-izhodnimi podatki iz simulacije (npr. glej sliko 3).

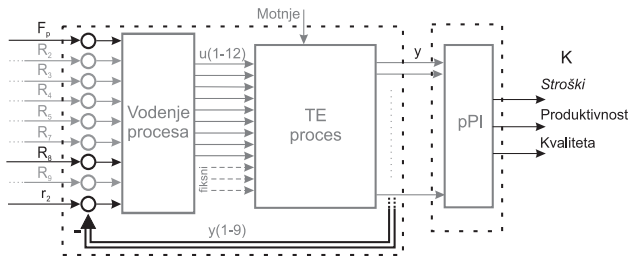


Slika 3: Križna korelacija vhoda R_8

Po končanem testiranju vseh kombinacij, so bile najdene najmočnejše povezave med naslednjimi signali:

- F_p – produktivnost in stroški,
- R_8 – stroški,
- r_2 – kvaliteta.

Število manipulativnih spremenljivk smo tako zreducirali na zgolj tri najvplivnejše glede na opazovane kazalnike proizvodnje (slika 4).



Slika 4: Shema procesa TE z nižje-nivojskim vodenjem in izračunom kazalnikov učinkovitosti

3.3 Modeliranje z nevronskimi mrežami

Ker za obravnavani proces ne moremo zagotoviti realnih preteklih procesnih podatkov, smo z ročnim nastavljanjem referenčnih vrednosti nižje-nivojskega vodenja ustvarili reprezentativne signale, na katerem bo temeljila naša identifikacija sistema. Proizvodni proces smo simulirali na časovnem obdobju 800 ur, od katerih smo podatke za prvih 400 ur uporabili za identifikacijo nevronskega modela, naslednjih 200 ur podatkov pa je služilo za validacijo dobljenih mrež. Izbran je bil vzorčni čas $T_s = 0,25$ h, saj se s takšnim časom izvajajo meritve kvalitete.

Omejili smo se na delo z nevronske strukturo z zgolj enim izhodom, zato naš model razčlenimo na tri nevronske modele z enim izhodom in tremi izbranimi vhodi.

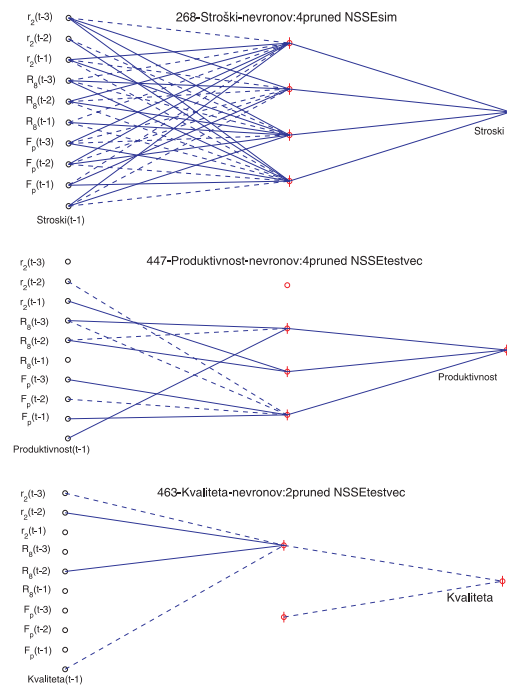
Za izbiro regresorjev smo uporabili Lipschitzovo funkcijo [5], ki zgolj na podlagi vhodno-izhodnih podatkov analizira gladkost preslikave glede na potencialni red modela. Glede na Lipschitzovo analizo vhodnega signala smo tako izbrali eno časovno zakasnitev izhodnega signala in tri zakasnitve za vsakega izmed vhodov.

Učenje nevronske mreže smo izvedli z Levenberg-Marquardt optimizacijsko metodo s predčasnim zaustavitvenim kriterijem in hkratno regularizacijo. Reprezentativna sposobnost nevronske mreže je odvisna od števila uporabljenih nevronov v skritem nivoju. Ker optimalnega števila ne moremo predhodno predvideti, smo preizkusili večje število nevronske strukture. Na koncu smo še za vse nevronske mreže izvedli optimizacijo nevronske strukture, kjer smo jih obrezali po metodi OBS

(ang. *Optimal Brain Surgery* [3]) in s tem odstranili manj pomembne povezave med nevroni.

Za poenostavitev in avtomatizacijo načrtovanja celostnega vodenja proizvodnje se razvija grafični vmesnik [2]. V tem delu predstavljeno modeliranje je bilo izvedeno z omenjenim programom, ki je poskrbel za iskanje primernih nevronske mreže in omogoča njihovo neposredno primerjavo. Grafični vmesnik je razvit za okolje Matlab, kjer smo za manipulacijo nevronske mreže uporabili orodje [8].


Izmed vseh naučenih in obrezanih nevronske modele smo nato s preverjanjem na validacijski signal izbrali naslednje optimalne nevronske mreže:




Slika 5: Nevronski modeli za napovedovanje stroškov, produktivnosti in kvalitete

Izbrane modele smo nato preizkusili še na testnem signalu, ki je predstavljal zadnjih 200 ur našega zajetega signala. Odzivi nevronske mreže za 20 koračno predikcijo so prikazani na slikah 6-8, kjer črtkana črta predstavlja odziv nevronskega modela, polna pa izmerjen odziv procesa TE. Vidimo, da model črne škatle dobro posplošuje naučeno znanje, tudi za signale, ki niso bili direktno uporabljeni pri njegovem


učanju. Prava kvaliteta modela pa se bo pokazala šele v naslednjem koraku, kjer bomo pridobljeni model uporabili za zaprto-zančno vodenje proizvodnih kazalnikov.



Slika 6: Predikcija stroškov za 20 korakov



Slika 7: Predikcija produktivnosti za 20 korakov



Slika 8: Predikcija kvalitete za 20 korakov

4 Zaključek

Kazalniki učinkovitosti proizvodnje predstavljajo učinkoviti način zmanjšanja velike količine zajetih procesnih podatkov. Za enostavnejšo doseganje zastavljenih poslovnih ciljev in dodatno stroškovno optimizacijo bi po konceptu celostnega vodenja proizvodnje lahko realizirali njihovo zaprto-zančno vodenje.

V procesu implementacije takšnega vodenja bi bilo najprej potrebno izbrati reprezentativne kazalnike, ki bi bili primerni za neposredno vodenje. V naslednjem koraku bi zaradi poenostavitve, morali poiskati zgolj tiste spremenljivke, ki najmočneje vplivajo na izbrane kazalnike. Za uporabo prediktivnega vodenja je potrebno poiskati še primeren model,

ki bi lahko zadosti natančno predvidel obnašanje kazalnikov. Na realne preslikave vhodov na izhod bi sklepali zgolj iz preteklih procesnih podatkov, zato smo se omejili na modeliranje po principu črnih škatel.

Iskanje modela je bilo prikazano na simulacijskem procesu Tennessee Eastman, kjer smo za modeliranje uporabili nevronske mreže. Pridobljeni model bomo v naslednjem koraku implementacije vgradili v ustrezen regulator, ki bo poskrbel za dinamično prilagajanje referenčnih vrednosti vodenja na nižjem nivoju, da bi dosegali želene rezultate v obliki zelenih vrednosti kazalnikov proizvodnje.

5 Literatura

- [1] J. J. Downs, E. F. Vogel, A plant-wide industrial process control problem, *Computers & Chemical Engineering*, zvezek 17, št. 3, str. 245–255, 1993.
- [2] M. Glavan, D. Gradišar, Modelling toolbox for holistic production control, *Proceedings of the 11th International PhD Workshop on Systems and Control*, Veszprém, Hungary, str. 86–91, 2010.
- [3] B. Hassibi, D. G. Stork, S. C. R. Com, Second Order Derivatives for Network Pruning: Optimal Brain Surgeon, v *Advances in Neural Information Processing Systems 5*, Morgan Kaufmann, str. 164–171, 1993.
- [4] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, Upper Saddle River, NJ, druga izdaja, 1999.
- [5] X. He, H. Asada, A new method for identifying orders of input-output models for nonlinear dynamic systems, v *American Control Conference*, str. 2520–2523, 1993.
- [6] T. Larsson, K. Hestetun, E. Hovland, S. Skogestad, Self-Optimizing Control of a Large-Scale Plant: The Tennessee Eastman Process, *Industrial & Engineering Chemistry Research*, zvezek 40, št. 22, str. 4889–4901, 2001.
- [7] L. Ljung, *System identification: theory for the user*, Prentice Hall PTR, Upper Saddle River, NJ, USA, druga izdaja, 1999.
- [8] M. Nørgaard, “Neural network based system identification toolbox,” Tech. Report 00-E-891, Department of Automation, Technical University of Denmark, 2000.
- [9] S. Zorzut, V. Jovan, D. Gradišar, G. Mušič, Closed-loop control of a polymerisation plant using production performance indicators (PIs), *Int. Journal of Computer Integrated Manufacturing*, str. 1128–1143, 2009.