

Analiza proizvodnih podatkov za nadzor in upravljanje kvalitete izdelkov

Miha GLAVAN, Matej GAŠPERIN, Matej VIDMAR, Maks TUTA, Stojan KOKOŠAR, Đani JURIČIĆ, Andrej BRLOŽNIK

Izvleček: Zajeti proizvodni podatki predstavljajo bogat vir informacij. A vendar se v proizvodnih obratih pogosto ne izkoriščajo, saj se operaterji proizvodnje velikokrat ne zavedajo njihovega uporabnega potenciala. V članku je prikazano, kako je mogoče izkoristiti proizvodne podatke za iskanje proizvodnih spremenljivk, ki najmočnejše vplivajo na kvaliteto izdelkov, in kako lahko proizvodne modele, identificirane na podlagi proizvodnih podatkov, izkoristimo za realizacijo naprednih tehnik nadzora in vodenja proizvodnje. Praktična uporaba predstavljenih tehnik je prikazana na primeru analize proizvodnih podatkov iz podjetja Kolektor KFH.

Ključne besede: kvaliteta izdelkov, proizvodni podatki, vplivne proizvodne spremenljivke, matematični modeli

■ 1 Uvod

V sodobnih produkcijskih sistemih se srečujemo z nepričakovanimi ustavitvami in izpadi kvalitete izdelkov. Do teh pojavov pogosto prihaja brez vidnega zunanjega vzroka, čeprav je proces že dlje časa normalno deloval. Posledice se kažejo v izgubah v proizvodnji in zmanjšani učinkovitosti, kar pomeni manjši dobiček.

V želji po večanju konkurenčnosti proizvajalci čedalje več sredstev vlagajo v vodenje kvalitete proizvodnje na podlagi modelov procesa. Na ta način je mogoče z boljšim razumevanjem procesa bolje napovedovati in s tem obvladovati njegovo

obnašanje. Seveda pa so sodobni proizvodni sistemi preveč kompleksni, da bi jih lahko natančno opisali z enačbami, ki neposredno opisujejo fizikalno ozadje proizvodnega sistema. Po drugi strani pa so z razvojem informacijske tehnologije na razpolago vedno bolj obsežne podatkovne baze, ki odražajo pretekla stanja proizvodnega obrata. Da bi izkoristili znanje, skrito v tej veliki množici zajetih podatkov, vnaprej predpostavimo, da lahko zvezo med vhodi in izhodi opišemo s stohastičnim modelom iz nekega nabora v splošnem nelinearnih struktur.

Članek se bo osredotočil na problem iskanja uporabnega znanja iz preteklih proizvodnih podatkov ali meritev, pridobljenih iz testnih preizkušanj proizvodnje. Prikazan bo način, kako lahko izpostavimo ključne proizvodne spremenljivke, ki najmočnejše vplivajo na kvaliteto izdelkov. Predstavljeno pa bo tudi, kako lahko matematične modele uporabimo za neposreden nadzor in upravljanje kvalitete izdelkov.

■ 2 Iskanje vplivnih proizvodnih spremenljivk

V prvem koraku analize bi želeli na podlagi proizvodnih podatkov izpo-

staviti ključne proizvodne spremenljivke. S takšnim skrčenim naborom pomembnih spremenljivk bi močno olajšali delo operaterjem proizvodnje, saj bi lahko le-ti bolje razumeli proizvodni proces ter se posvetili optimalni nastavitvi ožjega kroga parametrov. S tem bi pospešili uvažanje novih izdelkov, lažje odpravili proizvodne motnje ter dolgoročno izboljšali kvaliteto izdelkov.

Izbor najpomembnejših spremenljivk pa predstavlja tudi osnovo za razvoj ustreznih matematičnih modelov. Pri modeliranju se pomembnost redukcije vhodnih veličin modela kaže predvsem v izboljšanju natančnosti modela, odstranitvi za predikcijo nepomembnih vhodov (medsebojno odvisnih ali šumnih vhodov), reševanju problema majhnega števila učnih podatkov, povečani preglednosti modelne strukture in lažji fizikalni analizi modela.

Pri matematičnem modeliranju pogosto uporabljamo metode, ki lahko zgolj na podlagi analize podatkov raziščejo relacije med vhodno-izhodnimi veličinami, s čimer lahko poiščemo najbolj informativne vhodne spremenljivke za opis dinamike izhoda modela. Metode za izbiro vhodnih spremenljivk mo-

Miha Glavan, univ. dipl. inž., dr. Matej Gašperin, univ. dipl. inž., oba Institut Jožef Stefan, Ljubljana; Matej Vidmar, univ. dipl. inž., Kolektor Group d.o.o.; Maks Tuta, univ. dipl. inž., Kolektor Sinabit, d. o. o., Stojan Kokošar, univ. dipl. inž., Kolektor Sinabit d.o.o.; prof. dr. Đani Juričić, univ. dipl. inž., Institut Jožef Stefan, Ljubljana; mag. Andrej Brložnik, univ. dipl. inž., Kolektor KFH d.o.o.

delov lahko v splošnem razdelimo na tri večje razrede [1, 2]: filtrirne (ang. *filter methods*), ovojne (ang. *wrapper*) in vgrajene metode (ang. *embedded*).

Med *filtrirne metode* štejemo tiste, kjer je korak izbire vhodnih spremenljivk ločen od gradnje končnega modela. Z njimi prefiltriramo potencialne vhodne spremenljivke, s čimer že pred modeliranjem izločimo za napovedovanje nepomembne spremenljivke. Posledično so te metode neodvisne od uporabljene metodologije za modeliranje in večinoma temeljijo na statističnih testih in na uporabi poenostavljenih modelnih struktur. *Ovojne metode* pa neposredno izkoristijo izbrano metodologijo modela za ovrednotenje prediktivnih sposobnosti posameznega nabora vhodnih spremenljivk. Takšno izbiro vhodov lahko predstavimo kot problem optimizacije strukture modela, kjer skozi optimizacijo ovrednotimo in primerjamo vse ali zgolj del vseh potencialnih kombinacij vhodnih spremenljivk. Kot optimalni niz vhodnih spremenljivk izberemo tisto kombinacijo vhodov, s katero dobljeni model dosega najboljšo

ustrezno potencia, saj je potrebno poiskati, ne zgolj vplivne vhodne spremenljivke, temveč tudi primerne časovne zakasnitve le-teh.

3 Nadzor in upravljanje proizvodnje na podlagi modela

Na model procesa lahko gledamo kot na povezavo med veličinami, na katere lahko vplivamo (manipulativne spremenljivke – U), in končno kvaliteto izdelkov – Q (glej sliko 1). Takšen model lahko podrobneje razčlenimo na dva ločena podsklopa, kjer prvi sklop M_1 opisuje relacijo med manipulativnimi spremenljivkami (U) in proizvodnimi spremenljivkami (x). Proizvodne spremenljivke (x) se tako nanašajo na notranja stanja proizvodnega procesa, katerih vrednosti pridobimo iz izmerjenih signalov procesa. Podsklop M_2 pa opisuje relacijo med proizvodnimi spremenljivkami (x) in končno oceno kvalitete izdelka (Q).

Neposredno opisovanje fizikalnih zakonitosti med proizvodnimi veli-


ki omogočajo veliko prilagodljivost [3]. Različne strukture matematičnih modelov se med seboj razlikujejo po kompleksnosti vhodno-izhodnih preslikav, ki so jih sposobne opisati. Zato je glede na kompleksnost obravnavanega problema potrebno izbrati primerno metodologijo. Izbrano univerzalno modelno strukturo je potrebno tudi prilagoditi obravnavanemu problemu, kar pomeni, da je potrebno prilagoditi proste parametre modela tako, da je model sposoben čim bolj natančno opisati karakteristične odzive proizvodnega procesa. Takšni prilagoditvi fleksibilne modelne strukture rečemo identifikacija modelov.

S pomočjo matematičnih modelov, ki so bili identificirani s pomočjo preteklih proizvodnih podatkov, lahko bolj učinkovito pomagamo operaterju proizvodnje. Načini, kako lahko izkoristimo takšne modele proizvodnih procesov, pa bodo predstavljeni v naslednjih poglavjih.

3.1 Detekcija odstopanj v procesu

Model proizvodnega procesa lahko uporabimo za avtomatsko spremljanje stanja in detekcijo proizvodne napake. Shematska zasnova takšnega sistema je prikazana na sliki 2.


Glede na trenutne vrednosti manipulativnih spremenljivk (U) matematični



Slika 1. Shema matematičnega modela procesa

kvaliteto napovedi. Vsebovane metode za izbiro relevantnih spremenljivk pa so neposredno povezane z učenjem končnega modela. Že med učenjem modela so tako nepomembne spremenljivke postopoma izločene iz modela (npr. regularizacija, obrezovanje nevronske mreže itd.).

Problem izbire vhodov se za dinamične sisteme razširi na izbiro reda modela, se pravi, kolikšno število zakasnenih vhodnih in izhodnih podatkov je potrebno upoštevati na vходу modela in tudi kolikšna je primerna časovna zakasnitev signalov. S tem se problem izbire najvplivnejših vhodnih spremenljivk



Slika 2. Zasnova sistema za avtomatsko detekcijo odstopanj


činami predstavlja izjemno zahtevno nalogo že za preproste proizvodne sisteme. Zato je smiselno, da uporabimo pristop matematičnega modeliranja, kjer iščemo model iz neke splošne družine modelnih struktur,

ni model vzporedno s proizvodnim procesom izračuna napovedi za nominalne vrednosti proizvodnih spremenljivk (x) in kvaliteto izdelkov (Q). Na podlagi trenutne razlike med de-

janskimi in napovedanimi vrednostmi (e_x, e_y) lahko sklepamo, da proces poteka brez napak. Če pa so te vrednosti nad vnaprej določeno mejo pa sistem opozori operaterja ali vzdrževalca o napaki.


3.2 Nastavljanje manipulativnih spremenljivk

Drugi primer uporabe modelov predstavlja uvedba sistema za izračun vrednosti manipulativnih spremenljivk. Takšen sistem s pomočjo inverznega modela proizvodnega procesa določi primerne nastavitve vhodnih (manipulativnih) spremenljivk procesa U , glede na želene vrednosti opazovane karakteristike kvalitete. Sistem je mogoče nadgraditi tudi v celovit sistem za avtomatsko vodenje in spremljanje stanja proizvodnega procesa, kjer upoštevamo tudi korekcijo modela. Shema takšnega nadgrajenega principa je prikazana na sliki 3.



Slika 3. Shema sistema za izračun vrednosti manipulativnih spremenljivk

Glede na želeno karakteristiko kvalitete izdelkov z inverznim modelom izračunamo vrednosti manipulativnih spremenljivk. Te vrednosti uporabimo pri procesu ter kot vhod v model procesa. Sprotno spremljanje vrednosti razlik med napovedano in izmerjeno vrednostjo proizvodnih veličin daje informacijo o morebitnih odstopanjih procesa od predhodno identificiranega modela. Odstopanje upoštevamo pri izračunu vhodnih spremenljivk tako, da kompenziramo morebitna lezenja v procesu. Enega izmed takšnih pristopov kompenzacije lezenja v procesu predstavlja neposredna korekcija referenčnih vrednosti (Q_{ref}, x_{ref}), glede na odstopanje modela od izmerjenih vrednosti (e_x, e_y).



Slika 4. Koncept celostnega vodenja proizvodnje

3.3 Uporaba modelov na ravni proizvodnje

V prejšnjem podpoglavju predstavljen princip vodenja končne kvalitete izdelkov proizvodnega procesa pa je mogoče razširiti za uporabo na ravni celotne proizvodnje. Za takšne namene so Zorzut s sod. [4] predstavili koncept celostnega vodenja proizvodnje. Predstavljeni koncept vodenja ni omejen zgolj na opazovanje končne kvalitete produktov posameznega proizvodnega procesa, temveč stremi k celostni optimizaciji proizvodnje, kjer upoštevamo raznolike aspekte proizvodne učinkovitosti.

Ideja temelji na vpeljavi kazalnikov učinkovitosti proizvodnje (ang.

Production Performance Indicators - pPI), ki se izračunavajo iz izmerjenih proizvodnih spremenljivk in imajo nalogo strnjenega (agregiranega) prikaza ekonomsko relevantnih informacij o trenutnem stanju proizvodnje. Eden izmed takšnih kazalnikov bi lahko tudi ocenjeval kvaliteto končnih izdelkov, v splošnem pa želimo zaobjeti raznoliko ekonomsko relevantno stanje celotne proizvodnje (kvaliteta, produktivnost, stroški obratovanja). S povratno zanjnim vodenjem takšnih proizvodnih kazalnikov težimo k realizaciji zahtev višjega poslovnega nivoja, pri čemer regulator predlaga potrebne korekcije nastavitve proizvodnje, da bi dosegli optimalnejše obratovalne pogoje in ustrezno realizirali poslovne cilje.

Shematski prikaz realizacije celostnega vodenja na podlagi matematičnega modela (M), ki je sposoben napovedovati dinamiko kazalnikov pPI, je prikazan na sliki 4. Regulator s pomočjo napovedi modela ($\hat{K}_M$), trenutnih vrednosti kazalnikov učinkovitosti proizvodnje (K) in zadanih ekonomskih ciljev (K^*) poišče optimalne nastavitve procesnih spre-


menljivk. Vodja proizvodnje s tem pridobi uporabno informacijo o potrebnih prilagoditvah referenčnih vrednosti vodenja na nižjem nivoju in prilagoditvi preostalih prostih manipulativnih spremenljivk (K_u , K_u). Na podlagi takšnih priporočil operater proizvodnje lažje poišče optimalnejši režim obratovanja proizvodnje.

■ 4 Testni primer kosovnega proizvodnega procesa v podjetju Kolektor KFH

Iskanje vplivnih proizvodnih spremenljivk ter uporaba proizvodnih modelov bo prikazana na procesu kalupnega brizganja jermenic v podjetju Kolektor KFH. Po končanem brizganju jermenic se v ohlajeni izdelek vtisneta dva ležaja, kakor je prikazano na sliki 5.

Najprej želimo na podlagi analize izmerjenih podatkov proizvodnega procesa ugotoviti, katere proizvodne spremenljivke brizganja izdelkov ($\mathbf{x}$) najmočneje vplivajo na končno kvaliteto produkta. Kvaliteto izdelka v podjetju ocenjujejo s silo vtiskanja spodnjega ležaja jermenice ($\mathbf{Q}$), katera mora ležati znotraj vnaprej predpisanega tolerančnega območja. Ker pa operaterji ne morejo direktno vplivati na spremenljivke brizganja, saj so le-te zgolj izmerjena notranja stanja procesa, nas bo zanimalo tudi, kako primerno nastaviti manipulativne spremenljivke ($\mathbf{U}$), da bomo dosegli želeno kvaliteto izdelkov (povezava med $\mathbf{U}$ in $\mathbf{x}$).

Za dani proizvodni proces ni bilo na voljo reprezentativnih proizvodnih



Slika 6. Razvrščanje proizvodnih spremenljivk po pomembnosti, kjer smo upoštevali ocene različnih filtrirnih metod. S svetlimi okvirji so označene srednje vrednosti ocen, s črno barvo pa je predstavljena porazdelitev ocen (črni okvir označuje prvi in tretji kvartil, krogec mediano, črte pa minimalno in maksimalno vrednost).

podatkov iz dejanskega obratovanja, zato je bilo za namene iskanja vplivnih proizvodnih spremenljivk izvedeno testiranje. Izvedenih je bilo 20 različnih testov z različnimi nastavitvami manipulativnih spremenljivk, kjer je bilo proizvedenih 384 izdelkov (pri vsakem brizganju sta bila izdelana dva izdelka).

4.1 Izbira relevantnih proizvodnih spremenljivk

Izmed vseh potencialnih spremenljivk brizganja ($\mathbf{x}_1, \dots, \mathbf{x}_{20}$), želimo izpostaviti tiste, ki imajo resnično najmočnejši vpliv na končno oceno kvalitete izdelkov. Za izbiro najvplivnejših proizvodnih spremenljivk smo preizkusili dva načina. Pri

prvem smo upoštevali rezultate različnih filtrirnih metod [5], pri drugem načinu pa smo preizkusili ovojno metodo, kjer optimiziramo model linearne strukture s postopnim dodajanjem proi-

zvodnih spremenljivk (ang. *forward selection*).

V splošnem so filtrirne metode računsko manj zahtevne in so tako primerne za hitro oceno pomembnosti velikega števila potencialnih spremenljivk in za analizo obsežnejših podatkovnih nizov. Ker je pri obravnavanju proizvodnega procesa pričakovati močan medsebojni vpliv proizvodnih spremenljivk je potrebno upoštevati takšne metode, ki lahko pri oceni vplivnosti posameznih spremenljivk upoštevajo prispevek preostalih spremenljivk, izbranih že v prejšnjih korakih. Za iskanje najvplivnejših proizvodnih spremenljivk smo upoštevali rezultate več različnih filtrirnih metod (parcialna korelacijska analiza, parcialna skupna informacija, Gamma Test in postopna gradnja modela, ki je linearen v parametrih). Za podrobnejšo predstavitev uporabljenih metod glej [5]. Na podlagi njihovih ocen o pomembnosti vhodov, želimo ugotoviti katere izmed proizvodnih spremenljivk je večina izmed metod spoznala za najvplivnejše. Na sliki 6 so prikazani združeni rezultati, kjer smo proizvodne spremenljivke uredili po padajoči



Slika 5. Levo: jermenice po končani operaciji brizganja. Desno: prerez jermenice z vtisnjenim ležajem.

oceni vplivnosti na kvaliteto produkta, ki je temeljila na povprečni oceni pomembnosti različnih metod. Iz rezultatov izbire vidimo, da je bil zaznan prevladujoč vpliv spremenljivke x_8 , izstopal pa je tudi vpliv nekaterih preostalih (x_{11} , x_6 , x_1).


Preizkusimo tudi ovojno metodo postopnega dodajanja vhodnih spremenljivk v linearen model, kjer začnemo z enim vhomom ter nato postopoma dodajamo vhodne spremenljivke, ki v danem koraku najbolj minimizirajo napako napovedi modela. Napako modela ocenjujemo na podlagi 10-stopenjske križne validacije (ang. *cross-validation*), kjer ocenjujemo srednjo kvadratno napako predikcije (MSE – Mean Squared Error), ki je definirana z

$$MSE = \frac{1}{N} \sum_{i=1}^N (Q_i - \hat{Q}_i)^2.$$

V enačbi N predstavlja število vzorcev, Q_i je izmerjena vrednost izhodne veličine (v našem primeru ocena kvalitete) za i -ti izdelek in $\hat{Q}_i$ je z modelom napovedana vrednost. Dodatno pa tudi preverjamo linearno korelacijo med vhodnimi spremenljivkami, kjer močno korelirane spremenljivke izločimo iz izbire. Med spremenljivkama x_5 in je bilo zaznati močno linearno odvisnost, zato je bil x_5 izločen. Izbrane pa so bile naslednje spremenljivke: x_8 , x_6 , x_{20} , x_{11} , x_4 .

4.2 Vrednotenje izbranih proizvodnih spremenljivk

Izbiri najpomembnejših vplivnih proizvodnih spremenljivk ovrednotimo z linearnim modelom in križno validacijo. Podatke naključno razdelimo v 10 skupin, nato pa za vsako izmed skupin identificiramo model, ki ga testiramo na podlagi podatkov testirane skupine, model pa je bil identificiran na podatkih iz preostalih skupin. Takšno križno validacijo ponovimo z različnim naključnim razvrščanjem v skupine. Testiramo dobljene modele, kjer na vhomu modela postopoma poveču-




Slika 7. Vrednotenje proizvodnih spremenljivk, ki so bile identificirane kot najvplivnejše. Na sliki je prikazana ocena pogreška napovedi linearne modela (MSE), pri čemer postopoma povečujemo število upoštevanih proizvodnih spremenljivk na vhomu modela.

jemo število upoštevanih proizvodnih spremenljivk ter opazujemo kvaliteto napovedovanja (ocena MSE).


Iz slike 7 vidimo, da z dodajanjem proizvodnih spremenljivk, ki so bili spoznani za najbolj vplivne, napaka modela pada. To je še posebej izraženo pri ovojni metodi, kjer smo neposredno iskali minimum pogreška modela. Iz primerjave obeh pristopov izbire relevantnih proizvodnih spremenljivk je razviden prevladujoči vpliv proizvodnih spremenljivk x_8 ter x_6 .

4.3 Identifikacija modela proizvodnega procesa

Pri identifikaciji modelov je smiselno najprej preizkusiti preprostejše modelne strukture in če-le te ne zadostujejo, je potrebno poseči po bolj kompleksnih metodologijah. Za identifikacijo proizvodnega modela bomo tako uporabili preprosto linearno regresijo, kjer bo napoved spodnje sile vtiskanja ležaja temeljila zgolj na dveh najvplivnejših proizvodnih spremenljivkah: x_8 in x_6 . Da bi lahko preverili natančnost napovedi tudi za področja za katera



Slika 8. Napoved sile vtiska ležajev na podlagi proizvodnih spremenljivk x_8 in x_6 . Z rdečo barvo je označena napoved modela, z modro pa dejanska izmerjena vrednost.



Slika 9. Napoved proizvodnih spremenljivk x_8 , x_6 na podlagi manipulativnih spremenljivk u_1 , u_2 , u_3 , u_5 , u_6 . Z rdečo barvo je označena napoved modela, z modro pa dejanska vrednost.

model ni bil neposredno prilagojen, za vsakega izmed proizvodnih testov identificiramo nov model. Vsak model je identificiran na preostalih podatkih (testih), ovrednoten pa je na testu, kateri je bil izpuščen iz učnih podatkov. Prvi model tako identificiramo na podlagi podatkov iz testov 2 do 20, natančnost njegove napovedi pa testiramo na podatkih testa 1. Enako vrednotenje izvedemo še za preostale teste. Združeni rezultati vrednotenja kvalitete napovedi končne kvalitete izdelkov Q je prikazana na sliki 8. Vidimo, da lahko že takšen močno reducirani linearni model precej natančno napoveduje obnašanje sile vtiska ležajev tudi za ekstremna področja obratovanja, za katera ni bil neposredno prilagojen (npr. testi označeni z T2, T6, T19, T20).

Ker pa operater ne more neposredno prilagajati proizvodnih spremenljivk, bi bilo potrebno poiskati tudi relacijo med manipulativnimi spremenljivkami brizganja in najplavnejšima proizvodnima spremenljivkama x_8 in x_6 . Uporabimo pet manipulativnih spremenljivk, katere smo spreminjali tekom testiranja proizvodnje. Ponovno uporabimo linearno regresijo, kjer modele testiramo po posameznih testih, identificiramo pa jih na vseh preostalih podatkih. Slika 9 prikazuje napoved proizvodnih spremenljivk na podlagi manipulativnih spremenljivk.

Pri tem pa je potrebno poudariti, da imamo za opis relacije med manipulativnimi in proizvodnimi spremenljivkami izjemno malo raznolikih podatkov (20 različnih vhodnih kombinacij),


zato je tudi napoved relativno ne-natančna. Vsak izmed proizvodnih testov je sicer bil izveden z različno vhodno kombinacijo, vendar bi za natančnejšo analizo takšne relacije potrebovali dosti več podatkov z raznolikimi kombinacijami manipulativnih spremenljivk. Primerne podatke bi lahko neposredno pridobili z uporabo podatkov normalnega proizvodnega obratovanja, ki bi bili pridobljeni v nekem daljšem obratovalnem obdobju.

4.4 Uporaba modela


Ko imamo razvit primeren proizvodni model, ga lahko uporabimo za detekcijo odstopanj v procesu ali pa za sprotno prilagajanje proizvodnega procesa glede na želeno vrednost ocene kvalitete izdelkov.

4.4.1 Detekcija odstopanj v procesu

Model proizvodnega procesa uporabimo na način, ki je bil predstavljen na sliki 2. Spremljanje razlike med napovedanimi in izmerjenimi veličinami nam dodatno omogoča tudi lokalizacijo napake. Če prag preseže vrednost e_x je do napake prišlo na relaciji med manipulativnimi vhodi in spremenljivkami brizganja (npr. sprememba šarže ali kvalitete surovine, napake na orodju, itd.), ter če je prag presegla vrednost e_y , je vzrok napake potrebno iskati v operaciji vtiska ležajev. Pomembna lastnost sistema je tudi, da njegovo delovanje ni pogojeno z vpeljavo sledljivosti proizvodnje po kosih. Če namesto trenutne vredno-



Slika 10. Primerjava dejanske (rdeča) in napovedane (modra) porazdelitvene funkcije $f(Q)$ za silo vtiska ležajev za proces brez napake (levo) in s simulirano napako (desno)



Slika 11. Porazdelitve sile vtiska spodnjega ležaja in želene vrednosti

sti proizvodnih veličin spremljamo njihovo porazdelitev znotraj posamezne serije, lahko pogrešek modela izračunamo tudi iz razlike med trenutno porazdelitveno funkcijo in napovedjo porazdelitvene funkcije z uporabo Kullback-Leibler razdalje. Primer porazdelitvenih funkcij za silo vtiskanja ležajev za proces brez napake in z simulirano napako, je prikazan na *sliki 10*.

4.4.2 Nastavljanje manipulativnih spremenljivk

Že tekom izvedbe testnih serij pa smo tudi preizkusili pristop nastavljanja manipulativnih spremenljivk. Na podlagi podatkov prvih dvanajstih testov proizvodnje je bil identificiran linearni model. Model smo uporabili za izračun različnih naborov vrednosti manipulativnih spremenljivk (**U**), pri katerih smo želeli, da bo sila vtiska spodnjega ležaja enaka 550 N. Na podlagi modelov izračunani nabori manipulativnih spremenljivk so bili nato preizkušeni

na proizvodnem procesu na podatkih testov 14 do 18. *Slika 11* prikazuje porazdelitev dejanske sile vtiska spodnjega ležaja pri teh testnih serijah. Vidimo, da je mogoče že s precej enostavnim modelom proizvodnega procesa napovedati potrebne nastavitve manipulativnih spremenljivk.

■ 5 Zaključek

Testni primer analize podatkov iz podjetja Kolektor KFH je demonstriral, kako lahko s preprosto analizo podatkov učinkovito izpostavimo ključne proizvodne spremenljivke ter nato realiziramo vodenje in nadzor proizvodnega procesa.

Iz primera vidimo, da proizvodni podatki predstavljajo pomemben vir informacij, ki omogočajo vpeljava dodatnih izboljšav v proizvodni proces. Posledično lahko stremimo k enostavnejšemu prilagajanju proizvodnje novim obratovalnim razmeram ter dolgoročno optimalnejšemu obratovanju proizvodnega procesa.

Viri

- [1] May, R., Dandy, G., in Maier, H.: Review of Input Variable Selection Methods for Artificial Neural Networks, *Artificial Neural Networks – Methodological Advances and Biomedical Applications, InTech*, 2011.
- [2] Guyon, I. in Elisseeff, A.: An Introduction to Variable and Feature Selection, *J. Mach. Learn. Res.*, 3, str. 1157-1182, 2003.
- [3] Ljung, L.: System Identification: Theory for the User, Prentice Hall PTR, Upper Saddle River, New Jersey, USA, 1999
- [4] Zorzut, S., Jovan, V., Gradišar, D., Mušič, G.: Closed-loop control of a polymerisation plant using production performance indicators (PIs), *International journal of computer integrated manufacturing*, 2009.
- [5] Gradišar, D., Glavan, M.: Input variable selection algorithms for HPC, *Proceedings of the International Conference on Industrial Technology*, Atene, Grčija, str. 71-76, 2012.

Analysis of Production Data for Product Quality Control

Abstract: Data gathered in the production process represent a useful source of information. But in production plants these data are still rarely exploited as the production operators often do not recognise their practical value. This article demonstrates how to effectively employ production data in order to identify the production variables with the strongest influence on the quality of the final product. Moreover, it shows how data-based models of the production process can be used for advanced control techniques. The practical use of the data analysis is shown for a case study of the company Kolektor KFH.

Keywords: product quality, production data, influential production variables, empirical models

Zahvala

Projekt L2-2338 (B) je bil financiran s strani Javne agencije za raziskovalno dejavnost Republike Slovenije in podjetja Kolektor KFH.