

Metoda glavnih komponent pri odkrivanju in izolaciji napak: primer hidravličnega procesa in procesa fermentacije

Gregor Klančar, Igor Škrjanc

Univerza v Ljubljani, Fakulteta za elektrotehniko, Tržaška 25, 1000 Ljubljana, Slovenija

E-pošta: gregor.klancar@fe.uni-lj.si

Povzetek. V članku obravnavamo pristop k odkrivanju in izolaciji napak v delovanju procesov z uporabo statistične analize - metode glavnih komponent. Najprej razložimo teoretično ozadje metode glavnih komponent, ki je v osnovi preslikava vhodnih podatkov v nov podprostor ortogonalnih psevdospremenljivk. Nato razširimo metodo glavnih komponent na obravnavo dinamičnih sistemov. Podamo nekaj uveljavljenih mer, ki se uporabljajo pri sprotnem nadzoru delovanja procesa. Postopek odkrivanja in izolacije napak prikažemo na dveh praktičnih primerih: na laboratorijskem procesu treh rezervoarjev in na industrijskem šaržnem procesu fermentacije. V sklepu povzamemo glavne prednosti in slabosti obravnavanega pristopa ter nakažemo smernice za nadaljnje delo.

Ključne besede: odkrivanje napak, analiza glavnih komponent, nadzor procesa, statistična analiza, diagnostika

A Principal Component Analysis in Fault Detection and Isolation: Hydraulic and Fermentation Process Example

Extended abstract. Owing to the high level of automation, increased complexity of industrial processes causes higher possibilities of appearance of different faults and failures. Therefore, an efficient fault and failure detection system has to be implemented to have them detected and isolated at an early stage in operation when their effect is not yet harmful or when the product quality is not yet threatened.

In the paper, detection and isolation of the process faults and failures by using a principal component analysis (PCA) are addressed. The main idea is to determine a few significant combinations, i.e. principal components describing most of the data information of the original variables. An extension of the static PCA method to the dynamic one is implemented and then a common statistics from the values of many variables is generated. Efficient process monitoring is achieved by using score diagrams and two common statistical measures: the Mahalanobis distance and the Q measure. The proposed approach is illustrated on a three-tank test rig example and on a process of bacitracin fermentation.

Key words: fault detection, principal component analysis, process monitoring, statistical analysis, diagnosis

1 Uvod

Konkurenčne razmere na trgu zahtevajo od proizvajalcev boljšo kakovost in učinkovitost proizvodnje. Posledično je čedalje pomembnejša tudi zahteva po pravilnem delovanju različnih sistemov. Napake v delovanju lahko povzročijo poslabšanje kakovosti proizvodnje oziroma

celo izpad proizvodnje, kar je lahko povezano z visokimi stroški, je nevarno okolju ali celo neposredno ogroža zdravje in življenje ljudi (okvara senzorja v kemijskem reaktorju ali čistilni napravi, okvara jedrske elektrarne). Nepravilno delovanje poskušamo odkriti že na razvojni stopnji, postaviti diagnozo in napako odpraviti, ko so posledice zaradi nje še zanemarljive.

Napako v delovanju procesa lahko odkrijemo, če imamo zadostno informacijo [2]. Ta je lahko izražena v obliki dodatnih senzorjev. Analitično je lahko izražena s pomočjo matematičnih modelov procesa oziroma na podlagi statističnih lastnosti, ki jih dobimo iz zgodovine delovanja procesa. Prednost statističnih modelov je v tem, da ne zahteva matematičnega modela procesa v obliki ravnovesnih enačb, ki ga je pogosto težko dobiti.

V prispevku opisujemo pristop odkrivanja in izolacije napak v delovanju procesa z metodo glavnih komponent (Principal Component Analysis, PCA). Postopek bomo prikazali na dveh ilustrativnih primerih: na laboratorijskem procesu treh rezervoarjev in na industrijskem šaržnem procesu fermentacije.

2 Ozadje analize glavnih komponent

Analiza glavnih komponent (PCA) je metoda, ki omogoča obdelavo in prikaz množice podatkov, shranjenih v matriki X . Vrstice predstavljajo vzorčne vrednosti procesnih spremenljivk v določenih časovnih trenutkih, stolpci

pa vzorčene časovne poteke posameznih procesnih spremenljivk, ki jih pred tem normiramo (srednja vrednost nič in varianca ena). Matrika podatkov je prikazana v enačbi (1):

$$\mathbf{X} = \begin{bmatrix} x_1(1) & x_2(1) & \cdots & x_m(1) \\ x_1(2) & x_2(2) & \cdots & x_m(2) \\ \vdots & \vdots & \vdots & \vdots \\ x_1(n) & x_2(n) & \cdots & x_m(n) \end{bmatrix}, \quad (1)$$

kjer je n število časovnih vzorcev, m pa je število procesnih spremenljivk, ki jih merimo.

Metoda PCA preslika prostor vhodnih podatkov \mathbf{X} v podprostor ortogonalnih podatkov, ki je definiran z množico lastnih vektorjev variančno-kovariančne matrike podatkov

$$\mathbf{X}_{cov} = \mathbf{X}^T \mathbf{X} = \mathbf{P} \mathbf{D} \mathbf{P}^T. \quad (2)$$

Matrika preslikave \mathbf{P} je matrika lastnih vektorjev, ki jih uredimo po padajočih lastnih vrednostih (varianca vhodnih podatkov) v diagonalni matriki \mathbf{D} . Ortogonalne spremenljivke, imenovane zadetki, so torej notranji produkt merjenih spremenljivk in matrike preslikave, kar opišemo z enačbo:

$$\mathbf{T} = \mathbf{X} \mathbf{P}, \quad (3)$$

kjer \mathbf{T} pomeni matriko zadetkov. Matrika glavnih komponent \mathbf{P} je statistični model procesa, zadetki pa so psevdospremenljivke, ki nimajo realnega ozadja, saj so kombinacije stolpcev matrike \mathbf{X} [3].

Če sestavimo matriko \mathbf{P}_K tako, da vzamemo le nekaj prvih stolpcev oziroma lastnih vektorjev matrike \mathbf{P} , ki pomenijo večino variance oziroma informacije vhodnih podatkov matrike \mathbf{X} , dobimo aproksimirano matriko podatkov

$$\begin{aligned} \mathbf{T}_a &= \mathbf{X} \mathbf{P}_K \\ \mathbf{X}_a &= \mathbf{T}_a \mathbf{P}_K^T \end{aligned} \quad (4)$$

Matriko podatkov lahko zapišemo z reduciranim prostorom in ostankom

$$\mathbf{X} = \mathbf{T}_a \mathbf{P}_K^T + \mathbf{E}_X, \quad (5)$$

kjer indeks K označuje prvih k izbranih stolpcev \mathbf{P} , imenovanih glavne komponente prostora zadetkov, \mathbf{E}_X pa označuje matriko ostankov oziroma residualov, imenovanih tudi prostor šuma. Ta pomeni vse odkrite linearne relacije med stolpci vhodne matrike \mathbf{X} . Ravno ta zadnja lastnost analize glavnih komponent je najpomembnejša, saj omogoča eliminacijo kolinearnih podatkov in podatkov, ki imajo manjši vpliv.

2.1 Razširitev metode PCA

PCA je v osnovi statična metoda in jo je treba za analizo dinamičnih sistemov razširiti. Da se v prostoru šuma \mathbf{E}_X pojavijo tudi dinamične linearne relacije, ki opisujejo obravnavani proces, moramo vhodni matriki podatkov dodati še ustrezno število časovno zamaknjenih vhodnih podatkov:

$$\mathbf{X}(l) = \begin{bmatrix} \mathbf{X}_k & \mathbf{X}_{k-1} & \cdots & \mathbf{X}_{k-l} \end{bmatrix}. \quad (6)$$

Poiskati moramo torej linearne relacije med zamaknjenimi vhodnimi podatki \mathbf{X}_{k-i} . S primernim številom l (red sistema) zagotovimo, da se tako statične kot tudi dinamične komponente pojavijo v prostoru šuma. Za nelinearne sisteme lahko vrednost l preseže dejanski red sistema, saj tako dosežemo boljše prilaganje statističnega modela izmerjenim podatkom opazovanega sistema.

Število l določimo iterativno. Najprej obravnavamo statičen primer ($l=0$) in določimo število statičnih linearnih relacij, ki je enako razliki med številom vseh spremenljivk (stolpci $\mathbf{X}(l)$) in številom določenih glavnih komponent. V naslednjem koraku vzamemo $l=1$ ter določimo število na novo odkritih dinamičnih relacij. To dobimo tako, da od vseh spremenljivk odštejemo število glavnih komponent in število v predhodnih korakih odkritih relacij. Postopek končamo, ko z večanjem l ne odkrijemo nobene nove relacije.

2.2 Sprotni nadzor procesa

Metoda PCA zagotavlja redukcijo mnogoterega prostora podatkov v prostor ortogonalnih spremenljivk manjše dimenzije, kar omogoča učinkovitejši nadzor procesa [1,4].

Pogosto iz matrike podatkov generiramo skupno statistično oceno ali mero, ki jo nato opazujemo ter tudi grafično prikažemo. Skupna statistična ocena, ki definira odstopanje zadetkov opazovanega sistema od referenčnih zadetkov, se imenuje *Mahalanobisova razdalja*. Zapišemo jo z enačbo:

$$h_i = (\mathbf{x}_i - \mathbf{m}) \mathbf{S}^{-1} (\mathbf{x}_i - \mathbf{m})^T, \quad (7)$$

kjer je \mathbf{x}_i i -ta vrstica podatkov v matriki podatkov \mathbf{X} , \mathbf{m} je vektor srednjih vrednosti referenčnih podatkov, N je število referenčnih podatkov in \mathbf{S} je kovariančna matrika

$$\mathbf{S} = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{x}_i - \mathbf{m})^T (\mathbf{x}_i - \mathbf{m}) = \mathbf{P} \mathbf{D} \mathbf{P}^T. \quad (8)$$

Ker je prostor zadetkov osrediščen in skaliran na varianco ena, se Mahalanobisova mera v prostoru zadetkov poenostavi v:

$$h_i = \mathbf{t}_i \mathbf{D}^{-1} \mathbf{t}_i^T = \mathbf{t}_i \mathbf{t}_i^T, \quad (9)$$

kjer \mathbf{t}_i pomeni i -to vrstico zadetkov v matriki \mathbf{T} . Mera pomeni glavnino variance zadetkov.

Druga skupna statistična mera, ki omogoča spremljanje delovanja procesa, se imenuje *Hotellingova T^2 mera*. Definiramo jo z naslednjo enačbo:

$$d_i = (\mathbf{x}_i - \mathbf{m})(\mathbf{PDP}^T)^{-1}(\mathbf{x}_i - \mathbf{m})^T \frac{I(I - R)}{R(I^2 - I)}, \quad (10)$$

kjer je R število glavnih komponent referenčnega modela in I število šarž modeliranih v referenčnem modelu. V prostoru zadetkov se mera poenostavi v:

$$d_i = \mathbf{t}_i \mathbf{t}_i^T \frac{I(I - R)}{R(I^2 - I)}. \quad (11)$$


Ker se Hotellingova mera od Mahalanobisove razlikuje le za konstantni faktor, se bomo v nadaljevanju omejili le na eno od njih.

Tretja skupna statistična mera je *mera Q* , ki temelji na vsoti kvadratov residualov

$$\mathbf{q}_i = (\mathbf{x}_i - \mathbf{t}_i \mathbf{P}_K^T)^T (\mathbf{x}_i - \mathbf{t}_i \mathbf{P}_K^T). \quad (12)$$

Mera Q je merilo prilaganja trenutnih podatkov \mathbf{x}_i modelu \mathbf{P}_K . Obsega prostor šuma, ki pokriva linearne odvisnosti med spremenljivkami.

3 Odkrivanje napak pri procesu treh posod



Slika 1. Shema procesa Figure 1. Process scheme

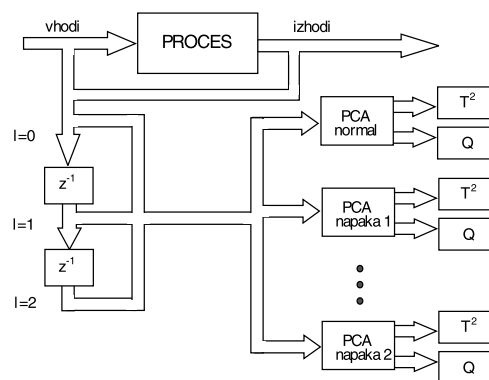
Sistem treh posod, ki ga prikazuje slika 1, je sestavljen iz posod T_1 do T_3 in zbirnega rezervoarja T_0 . Nivo v posodi T_1 uravnavamo z delovanjem črpalke P_1 , medtem ko se nivo v posodi T_3 uravnava z odprtjem servovalve V_5 (črpalka P_2 dela s konstantnimi obrati). Vsečina iz posod T_1 in T_3 se meša v posodi T_2 in nato vrača v posodo T_0 . Izhodi procesa so nivoji v vseh treh posodah, vhoda pa sta delovanje črpalke P_1 in odprtje ventila V_5 .

3.1 Zasnova sistema

Z namenom izolacije oziroma ugotovitve vzroka za nepravilno delovanje procesa smo poleg normalnega

načina delovanja obravnavali še delovanje ob prisotnosti določenih napak. Za vsak obravnavani način delovanja smo iz posnetih meritev določili model PCA, ki se je temu delovanju dobro prilagal. Za vsa druga delovanja pa se statistične lastnosti procesa spremenijo, glavnina podatkov torej ni več v smeri glavnih osi, kar se odraža z odklonom obeh mer, opisanih v podpoglavju 2.2. Simboličen prikaz zaznavanja in izoliranja napak podaja slika 2.

Pri meri Q pretvorimo prvotni prostor podatkov v prostor zadetkov z matriko \mathbf{P}_K (enačba (4)). Ta vsebuje le nekaj prvih lastnih vektorjev \mathbf{p}_i matrike \mathbf{P} , ki minimizirajo srednjo kvadratno napako preslikave.



Slika 2. Shema za zaznavanje in izoliranje napak Figure 2. Scheme for fault detection and isolation

Pri meri M (Mahalanobisova razdalja) pa sestavimo transformacijsko matriko tako, da le-ta pretvori prvotni prostor meritev v nov prostor nižje dimenzije, kjer naj bo ločljivost oziroma razdalja med vzorci iz različnih načinov delovanja čim večja. To lahko naredimo tako, da sestavimo transformacijsko matriko iz nekaj prvih lastnih vektorjev \mathbf{p}_i matrike \mathbf{P} , ki nosijo največjo ločilno informacijo [5], določeno z izrazom:

$$\mathbf{J}(i) = \frac{\mathbf{p}_i^T \mathbf{K}_b \mathbf{p}_i}{\lambda_i}, \quad (13)$$

kjer je λ_i lastna vrednost pripadajočega lastnega vektorja \mathbf{p}_i (zaradi skaliranja je enaka ena) in \mathbf{K}_b matrika razpršitve srednjih vrednosti M različnih načinov delovanja procesa:

$$\mathbf{K}_b = \frac{1}{M - 1} \sum_{j=1}^M (\mathbf{m}_j - \mathbf{m})(\mathbf{m}_j - \mathbf{m})^T, \quad (14)$$

kjer je \mathbf{m}_j srednja vrednost meritev določenega referenčnega ali prototipnega načina delovanja procesa, medtem ko je \mathbf{m} srednja vrednost trenutnega delovanja, za katerega določamo transformacijsko matriko.

3.2 Podatki za analizo

Na nelinearnem simulacijskem modelu treh posod smo posneli vhode in odzive v širši okolici delovne točke tako, da smo zajeli tudi nelinearnosti. Čas vzorčenja smo določili tako, da ta ni presegal 10% časa vzpona (5s) pri stopničastem vzbujanju. S postopkom, opisanim v podpoglavju 2.1, smo določili potrebno število (l) podvojenih, a zakasnenih stolpcov v matriki podatkov \mathbf{X} . Celoten postopek načrtovanja je viden iz tabele 1.

| Št. spremenljivk | l | Št. glavnih komponent | Št. novo odkritih linearnih relacij |
|------------------|-----|-----------------------|---|
| 5 | 0 | 4 | $1^I=5-4$ |
| 10 | 1 | 4 | $4^{II}=10-4-2 \cdot 1^I$ |
| 15 | 2 | 4 | $0^{III}=15-4-3 \cdot 1^I-2 \cdot 4^{II}$ |

Tabela 1. Postopek načrtovanja dinamične PCA
Table 1. Dynamic PCA design procedure

Ugotovimo, da je za načrtovanje dinamične PCA povsem dovolj prvi red ($l=1$), saj za $l > 1$ ne odkrijemo nobene nove relacije več.

3.3 Analiza glavnih komponent

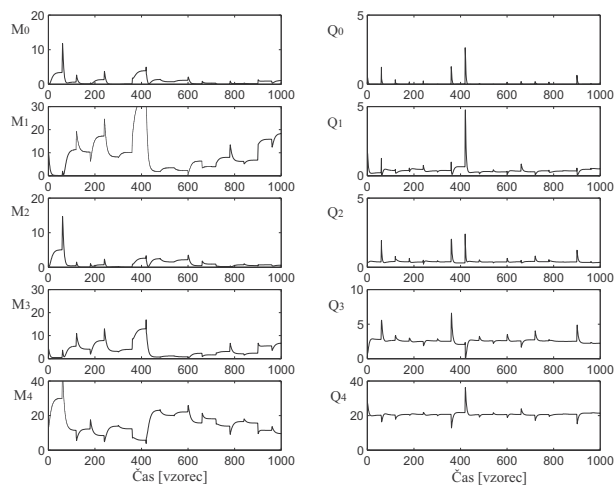
Za vsak način delovanja (glej sliko 2) določimo svoj model PCA. Iz tabele 1 razberemo, da prostor zadetkov povsem opišemo s štirimi glavnimi komponentami, ki pokrijejo več kot 95% variance vhodnih podatkov. Za izračun mere T^2 smo določili transformacijsko matriko iz le treh lastnih vektorjev iz matrike \mathbf{P} , ki niso bili enaki kot tisti v \mathbf{P}_K .

Na sliki 3 so prikazani časovni poteki obeh mer (M_i in Q_i), izračunanih za vse znane referenčne oziroma prototipne načine delovanja, ki so opisani z različnimi modeli PCA. Znani načini delovanja so bili normalno delovanje ($i=0$), puščanje posode T_1 ($i=1$), pristranskost senzorja nivoja v T_1 ($i=2$), obloge v črpalki P_2 ($i=3$) ter pristranskost senzorja nivoja v T_3 ($i=4$).

Na sliki 3 vidimo uspešnost postopka, saj je večji odklon od ničelne vrednosti povsod, razen pri Q_0 in M_0 , iz česar sklepamo, da proces deluje pravilno. Koničasti skoki so posledica nelinearnih relacij, ki smo jih pri metodi PCA aproksimirali z linearnimi.

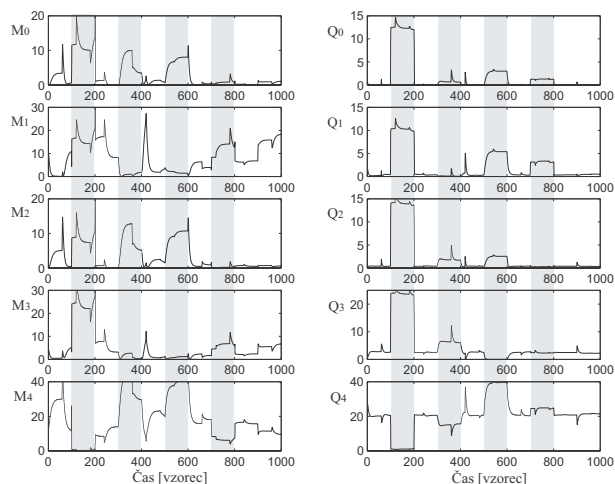
Da bi preverili pravilnost delovanja tudi pri drugih načinih delovanja, smo posneli odziv procesa na enako vzbujanje kot pri sliki 3, le da smo med delovanjem procesa povzročili različne napake (glej tabelo 2). Slika 4 prikazuje omenjeni primer.

Na sliki 4 opazimo, da zavzamejo mere najmanjšo vrednost pri tistih indeksih, ki ustrezajo trenutni napaki v delovanju. Pri nastopu napake pristranskosti senzorja nivoja v posodi T_3 (100 – 200 vzorec) zavzameja meri z



Slika 3. Mere pri normalnem delovanju procesa za primer vrednotenja

Figure 3. Measures at normal process operation, case of validation



Slika 4. Mere pri napakah v delovanju (področje delovanja napak je označeno zasenčeno)

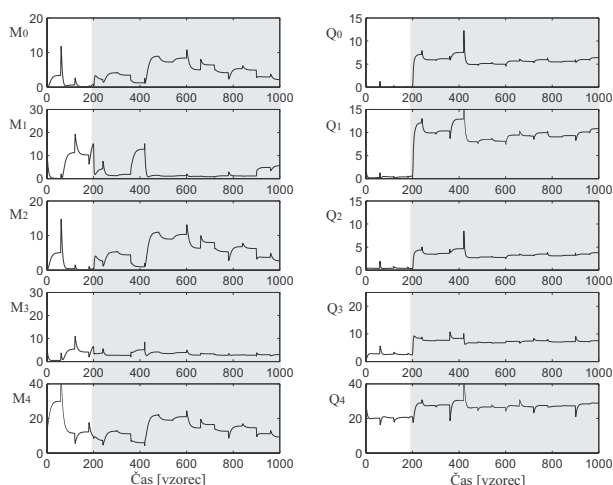
Figure 4. Common statistics at different operation modes (fault appearances are shaded)

indeksom $i=4$ najmanjšo vrednost, druge pa se močno odklonijo. To napako zaznamo z odklonom mer pri indeksu $i=0$, izoliramo (poimenujemo) pa jo s tem, da poiščemo indeks mer, ki se najmanj ali nič ne odklonijo.

Sistem za odkrivanje napak je neuporaben, če ni sposoben detektirati napačnega delovanja procesa pri nastopu neznane napake, torej tiste, katere pri načrtovanju še nismo poznali. Primer nastopa neznane napake ob dvestotem vzorcu prikazuje slika 5 (delna zamašitev ventila V_1). Vse mere se ob nastopu te neznane napake močno odklonijo oziroma ostanejo odklonjene. Sklepamo lahko, da je proces doletela neznana napaka in jo kasneje, ko nam jo uspe izolirati in identificirati, vključimo v naš sistem za odkrivanje napak.

| Nastop napake [vzorec] | Vrsta napake |
|------------------------|---------------------------------------|
| 100 – 200 | pristranskost senzorja v T_3 (3 cm) |
| 300 – 400 | puščanje posode T_1 |
| 500 – 600 | obloge v črpalki P_2 |
| 700 – 800 | pristranskost senzorja v T_1 (5 cm) |

Tabela 2. Časovna razporeditev napak na sliki 4
Table 2. Fault appearance in Figure 4



Slika 5. Nastop neznanе napake v delovanju procesa (področje delovanja napake je označeno zasenčeno)
Figure 5. Unknown fault appearance in the process (fault appearance is shaded)

4 Ločevanje uspešnih in neuspešnih šarž pri fermentaciji bacitracina

V nadaljevanju bo prikazan primer detekcije napak na industrijskem šaržnem procesu fermentacije bacitracina v tovarni Krka v Novem mestu [8]. Šaržni in semišaržni procesi so pomemben del procesne industrije. Uspešno delovanje šarže pomeni slediti določenemu receptu skozi celotno šaržo, od šarže do šarže. Temperaturni poteki in poteki pritiskov so regulirani s pomočjo regulatorjev, sekvenčno vodenje pa s pomočjo programabilnih logičnih regulatorjev.

Bacitracin je antibiotik, ki ga sintetizirajo nekateri sevi bakterij *Bacillus licheniformis* ter *Bacillus subtilis*. Sinteza bacitracina je dobro proučena in znana iz literature [8]. Gojišču z bakterijami dodamo škrob. Škrob je molekula, zgrajena iz številnih glukoz ($C_6O_6H_{12}$), ki jih lahko sprostimo iz škroba s hidrolizo. Glukoza služi kot vir ogljika (C) za bakterijsko rast in proces fermentacije. Dodamo tudi sojino moko, ki vsebuje veliko proteinov ter je vir ogljika (C) in dušika (N). V prvi fazi se v procesu presnove iz glukoze tvorijo različni produkti, med njimi tudi organske kisline, ki znižajo pH v gojišču. Če glukoze

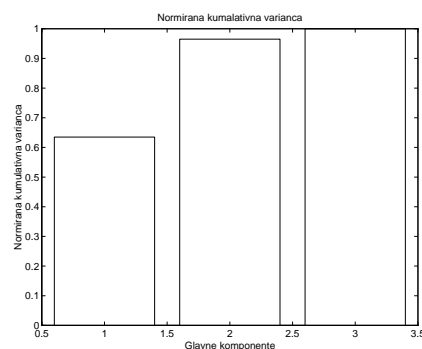
primankuje (če je hitrost porabe večja od hitrosti hidrolize škroba), se začne druga faza, kjer se kot vir ogljika uporablja tudi sojina moka, kar vodi do nastanka amoniaka (NH_3) in s tem dviga pH gojišča. Hkrati se sproži mehanizem tvorbe bacitracina. Prva faza je pomembnejša za razmnoževanje in rast bakterij, druga pa za rast gojišča in tvorbo bacitracina.

4.1 Meritve in podatki za analizo

Pri analizi podatkov smo obravnavali podatke, ki jih lahko merimo sprotno. Ti podatki so: temperatura v fermentorju, pH, O_2 in CO_2 v izstopnem zraku, pretok in tlak zraka, temperatura in relativna vlaga vstopnega zraka, naddlak v fermentorju ter frekvenca in moč mešala. Podatki iz meritev vsebujejo napake, ki so posledica merilne metode, naključnih napak, ki nastajajo pri meritvah, itd. Glede na naravo podatkov je statistična obdelava smiselna.

4.2 Analiza glavnih komponent procesa fermentacije


Analiza ustreznosti šarž je bila izvedena na šestih šaržah. Za te šarže so na voljo meritve, omenjene v podpoglavju 4.1. Z analizo glavnih komponent lahko ugotovimo, da je za primerno aproksimacijo treba upoštevati le dve glavni komponenti (slika 6). Po metodi eliminacije smo ugotovili, da sta glavni komponenti v veliki meri povezani z merjenima veličinama O_2 in CO_2 .



Slika 6. Normirana kumulativna varianca za prve tri glavne komponente
Figure 6. Normalized cumulative variance for the first three principal components

Diagrami zadetkov (t_1, t_2) za različne in enakomerne časovne intervale so prikazani na sliki 7. Vidimo, da so roji bolj ali manj izraziti in odvisni od časovnega intervala. Zadnji dve šarži tvorita razred, ki ne zadovoljuje zahteve produkcije. V diagramih zadetkov na slikah so zadelki za ti dve šarži označeni s križci, zadelki pri ostalih šaržah pa s krogi.

Iz slike 7 opazimo, da zadelki uspešnih in neuspešnih šarž tvorijo različne roje, predvsem v zadnjih treh



Slika 7. Diagrami zadetkov za posamezne časovne intervale
Figure 7. Score diagrams for different time intervals

časovnih intervalih je to bolj opazno (verjetno je v tem intervalu nastala napaka v procesu). Iz tega sledi, da bi lahko na podlagi Mahalanobisove mere spremljali delovanje procesa fermentacije bacitracina.

5 Sklep

Prispevek prikazuje uporabnost metode PCA pri odkrivanju in izolaciji napak v delovanju procesa. Predlagana je razširitev metode PCA za obravnavanje dinamičnih sistemov. Za sproti nadzor delovanja procesa sta bili uporabljeni dve meri: mera Q in Mahalanobisova razdalja, pri procesu fermentacije pa diagram zadetkov.

Rezultati potrjujejo uporabnost predlaganega postopka, pri čemer se moramo zavedati tudi njegovih omejitev. Občutljivost predlaganega sistema je nekoliko manjša kot občutljivost, ki jo lahko dosežemo z metodami, ki temeljijo na modelu procesa [2]. Metoda potrebuje za uspešno izolacijo napake učno množico podatkov z določeno napako v delovanju. Ti podatki niso vedno dostopni, še posebej če gre za napake v procesu, ki drastično spremenijo njegovo delovanje. V tem primeru si lahko pomagamo le s simulacijo na modelu, ki te napake upošteva.

Prednost uporabe metode glavnih komponent je v tem, da za njeno realizacijo ne potrebujemo modela procesa, temveč le zgodovino merjenih spremenljivk procesa. Metodo odlikuje tudi relativno preprosta realizacija.

6 Literatura

- [1] D. Dong, T. J. McAvoy, Batch Tracking via Nonlinear Principal Component Analysis, *AIChE Journal*, Vol. 42, No. 8, pp. 2199-2208, August 1996.
- [2] J. Gertler, *Fault Detection and Diagnosis in Engineering Systems*, Marcel Dekker, New York, 1998.
- [3] J. E. Jackson, *A User's Guide To Principal Components*, John Wiley & Sons, New York, 1991.
- [4] P. Nomikos, J. F. McGregor, Monitoring Batch Processes Using Multiway Principal Component Analysis, *AIChE Journal*, Vol. 40, No. 8, pp. 1361-1375, August 1994.
- [5] N. Pavešič, *Razpoznavanje vzorcev*, Fakulteta za elektrotehniko, Ljubljana, 2000.
- [6] *Statistics Toolbox User's Guide*, MathWorks, Natick, 1998.
- [7] I. Škrjanc, N. Hvala, Statična analiza procesa fermentacije, *IJS delovno poročilo 7829*, COBISS-ID 12981031.
- [8] M. R. Warnes, J. Glassey, G. A. Montague, B. Kara, On Data-Based Modelling Techniques for Fermentation Processes, *Process Biochemistry*, Vol. 31, No. 2, pp.147-155, 1996.

Gregor Klančar je diplomiral leta 1999 na Fakulteti za elektrotehniko Univerze v Ljubljani. Od leta 1999 se v Laboratoriju za modeliranje, simulacijo in vodenje na Fakulteti za elektrotehniko ukvarja s problematiko odkrivanja napak in vodenja večagentnih sistemov.

Igor Škrjanc je diplomiral leta 1988 na Fakulteti za elektrotehniko, magistriral leta 1992 in doktoriral leta 1996 na isti ustanovi. Njegovo raziskovalno delo je s področja mehke identifikacije, mehkega vodenja, adaptivnega vodenja, mehkega adaptivnega vodenja in prediktivnega vodenja.