

## Zaznavanje nepravilnega delovanja senzorjev v čistilni napravi odpadnih voda z uporabo adaptivne metode glavnih komponent

Mina Žele, Darko Vrečko, Đani Juričič

Institut Jožef Stefan, Odsek za sisteme in vodenje, Jamova 39, 1000 Ljubljana, Slovenija  
E-pošta: mina.zele@ijs.si

**Povzetek.** Namen prispevka je načrtati in ovrednotiti sistem za nadzor in odkrivanje napak senzorjev na pilotni čistilni napravi, ki deluje v Čistilni napravi Domžale-Kamnik. Čistilna naprava je tipičen nestacionaren proces, saj se zaradi vremenskih vplivov in motenj njeno delovanje spreminja dnevno, tedensko in mesečno. Dodatne težave pri čistilnih napravah predstavlja sinteza modela primerne natančnosti za potrebe napovedovanja nominalnega odziva procesa. Da bi se izognili zahtevnemu modeliranju na osnovi prvih principov, v delu predlagamo uporabo statističnih modelov oziroma analizo kolinearnosti med signali čistilne naprave. V prispevku bomo predstavili rekurzivno analizo glavnih komponent, s katero se lahko izognemo napačnim alarmom pri odkrivanju napak nestacionarnih procesov. S simulacijskim zgledom bomo ilustrirali odkrivanje napak senzorja koncentracije amonijevega dušika v drugem aerobnem reaktorju pilotne čistilne naprave.

**Ključne besede:** adaptivna analiza glavnih komponent, odkrivanje napak, čiščenje odpadnih voda

## Detection of sensor faults in a wastewater treatment plant by an adaptive principal component analysis

**Extended abstract.** Reliable measurements are a prerequisite for optimal wastewater plant operation and control. The paper presents design and validation of a system for sensor faults detection in a pilot plant of the Domžale-Kamnik Wastewater Treatment Plant (WWTP). WWTP operation is depended on daily, weekly and seasonal variations of the influent load and wastewater temperature. Constructing the first principle model to accurately predict the WWTP behaviour is a demanding task. For this purpose, statistical process monitoring (SPM) based on a principal component analysis (PCA) is applied. False alarms due to WWTP non-stationary processes are avoided by using adaptive PCA. It enables adaptation of a PCA model by updating scaling parameters of variables (mean and variance) and the covariance matrix recursively at each sampling time. In such a way the PCA model adapts to slow process changes while still being able to detect much faster sensor faults.

The recursive PCA was applied to a nonlinear model of a pilot plant. The following measurements were used to calculate the principal components: influent ammonia concentration, dissolved oxygen concentration in the first aerobic reactor tank, dissolved oxygen concentration and ammonia concentration in the second

aerobic reactor. The process dynamics was taken into account by extending the data matrix to include delayed signals. Faults were emulated by adding values to the measurement of the ammonia concentration in the second aerobic reactor. Results of the classical PCA and recursive PCA show that false alarms can be avoided by using recursive updating with an appropriate forgetting factor.

**Keywords:** recursive principal component analysis, fault detection, wastewater treatment plant

### 1. Uvod

Pravilno delovanje senzorjev je ključnega pomena za optimalno obratovanje biološke čistilne naprave odpadnih voda. Pri obratovanju čistilnih naprav se pogosto uporabljajo senzorji kisika, v zadnjem času pa tudi amonijevega dušika. Pri senzorjih lahko nastanejo različne napake, ki so posledica nabiranja usedlin, izpadov električnega toka in izklopov med rednim čiščenjem. Zadnji dve napaki je mogoče brez težav zaznati, saj se ponavadi kažejo kot padeč izhoda senzorja na vrednost nič. Nepravilno delovanje senzorjev zaradi nabiranja usedlin pa je kompleksnejši problem. V čistilnih napravah senzorje čistijo periodično (ponavadi enkrat na teden) ne glede na dejansko stanje. Omenjeni problem je še posebej kritičen tedaj, ko izhod senzorja predstavlja regulirano

veličino (senzor je uporabljen v povratni zanki), kar lahko pripelje do popolnoma neustreznega delovanja regulacijskega algoritma.

Razvoj analitičnega modela čistilne naprave, ki bi s primerno natančnostjo napovedoval nominalni odziv procesa, je izredno težaven postopek. Poleg časovne spremenljivosti in nelinearnosti so največji problem nemerljive komponente dotoka, ki bistveno vplivajo na procese čiščenja. Nemerljive motnje so tudi eden glavnih vzrokov, da trenutno najboljši modeli s stališča napovedovanja odziva procesa ne dosegajo več kot približno 50% natančnost. Veliko preprostejše so statistične metode odkrivanja napak, zato smo v prispevku uporabili statistične modele, ki temeljijo na analizi kolinearnosti med signali čistilne naprave. V čistilni napravi je na voljo veliko merjenih signalov, ki so medsebojno korelirani. Z metodo glavnih komponent lahko na osnovi medsebojnih korelacij merjenih signalov sklepamo na pravilno delovanje senzorjev [3,5,6,8]. Spreminjanja signala ne opazujemo neodvisno, pač pa relativno glede na spreminjanje drugih signalov, s katerimi je v korelaciji. Metoda analize glavnih komponent skrči število signalov na t.i. glavne komponente, ki so dejansko linearna kombinacija signalov in so medsebojno neodvisne. Glavne komponente zajamejo večino variance meritev, kar pomeni, da vsebujejo informacijo skrito v meritvah. Normalno delovanje procesa opisuje t.i. statistični model, ki ga tvorijo smeri glavnih komponent v prostoru meritev in varianca v smeri glavnih komponent. Motnje, napake na senzorjih in druge spremembe v procesu porušijo medsebojne korelacije med izmerjenimi veličinami (spremenijo se smeri glavnih komponent). Ko meritve rekonstruiramo iz glavnih komponent, se bo napaka na senzorju odražala na residualih in jo bomo lahko odkrili s statističnimi testi [5]. Dosedanje delo na področju spremljanja delovanja čistilnih naprav z uporabo analize glavnih komponent je bilo usmerjeno v odkrivanje motenj oziroma ugotavljanje stanja čistilne naprave, kar naj bi služilo kot podpora pri prilagajanju načina vodenja čistilne naprave [9, 10, 11]. Cilj našega dela pa je načrtati in ovrednotiti sistem za nadzor in odkrivanje napak senzorjev v pilotni čistilni napravi, ki je postavljena v Čistilni napravi Domžale-Kamnik. Kot je bilo že omenjeno, so okvare senzorjev v čistilni napravi pereč problem, zato bi s pravočasnim odkrivanjem napak lahko znatno izboljšali kvaliteto vodenja. Spremljanje delovanja procesa z analizo glavnih komponent temelji na predpostavki, da je proces stacionaren (statistične lastnosti signalov se ne spreminjajo) [3]. Problem nestacionarnosti čistilne naprave, ki je posledica spreminjajočih se vremenskih razmer, bomo rešili z uporabo t.i. adaptivne analize glavnih komponent [1, 7]. V literaturi avtorji poročajo o uspešni uporabi adaptivnega postopka za spremljanje delovanja čistilnih naprav, predvsem s stališča

odkrivanja motenj in ugotavljanja posebnih razmer (dež, temperatura) [9, 11].

V 1. poglavju bomo predstavili osnove analize glavnih komponent. V 2. poglavju bomo pokazali statistične teste za spremljanje delovanja procesa ( $T^2$  in SPE statistiko), ki izhajajo iz dekompozicije prostora signalov na podprostor glavnih komponent in podprostor, ki vsebuje šum. Rekurzivno analizo glavnih komponent bomo opisali v 4. poglavju. V 5. poglavju pa bodo predstavljeni simulacijski rezultati odkrivanja napak senzorja amonijevega dušika pilotne naprave v čistilni napravi Domžale-Kamnik.

## 2. Analiza glavnih komponent

V procesni industriji pogosto merimo veliko število signalov, ki so korelirani. To pomeni, da imamo opravka z redundantno informacijo, ki otežuje spremljanje delovanja procesa. Z analizo glavnih komponent korelirane signale transformiramo v prostor nižje dimenzije, ki vsebuje večino variance meritev, nove koordinate pa niso več korelirane [3, 5, 8]. Vzemimo matriko meritev  $X$  dimenzije  $(n \times m)$ , kjer  $m$  pomeni število merjenih signalov,  $n$  pa število vzorcev. Signali so normirani, kar pomeni, da imajo srednjo vrednost nič in varianco enako 1. Koordinate v novem prostoru oziroma t.i. matriko zadetkov  $T$  dobimo kot linearno kombinacijo signalov

$$T = XP \quad (1)$$

kjer je  $P \in \mathfrak{R}^{m \times m}$  transformacijska matrika. Vektor zadetkov v trenutku  $k$   $t(k)=[t_1(k), t_2(k), \dots, t_m(k)]^T$  dobimo z naslednjo transformacijo:

$$t(k) = P^T x(k), \quad (2)$$

pri čemer vektor meritev v trenutku  $k$   $x(k)=[x_1(k), x_2(k), \dots, x_m(k)]^T$  tvorijo elementi  $k$  vrstice matrike meritev  $X$ . Transformacijska matrika  $P$  vsebuje lastne vektorje  $p_i$  ( $i=1,2,\dots,m$ ) kovariančne matrike meritev in jo dobimo z dekompozicijo

$$R = cov(X) = \frac{X^T X}{n-1} = P \Sigma P^T. \quad (3)$$

$P \in \mathfrak{R}^{m \times m}$  je unitarna matrika  $PP^T = I$  in  $\Sigma \in \mathfrak{R}^{m \times m}$  je diagonalna matrika lastnih vrednosti kovariančne matrike v padajočem vrstnem redu ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ ). Lastni vektorji so baza novega koordinatnega sistema in lastne vrednosti predstavljajo varianco meritev v teh smereh. Prvi lastni vektor predstavlja smer, v kateri je varianca signalov največja, drugi lastni vektor smer, v kateri je največja varianca preostalega podprostora meritev, itd. Pri transformaciji v nov koordinatni sistem obdržimo samo prvih  $p$  lastnih

vektorjev  $\mathbf{P}_p \in \mathfrak{R}^{m \times p}$ , ki ustrezajo največjim lastnim vrednostim

$$\mathbf{T}_p = \mathbf{X}\mathbf{P}_p. \quad (4)$$

Optimalna izbira števila  $p$  je taka, da s  $p$  lastnimi vektorji zajamemo večino variance meritev, preostali  $m-p$  lastni vektorji pa tvorijo podprostor, ki vsebuje šum meritev. V literaturi zasledimo več načinov določanja števila lastnih vektorjev [7]. V praksi se pogosto uporablja mera CPV (cumulative percent variance), ki nam pove, kolikšen odstotek celotne variance meritev vsebuje prvih  $a$  lastnih vektorjev

$$CVP(p) = 100\% \sum_{j=1}^p \lambda_j / \sum_{j=1}^m \lambda_j. \quad (5)$$

Število glavnih komponent je izbrano tako, da mera CVP preseže neko vnaprej določeno vrednost, ki je ponavadi 95%. S  $p$  glavnimi komponentami lahko meritve rekonstruiramo kot vsoto

$$\mathbf{X} = \tilde{\mathbf{X}} + \mathbf{E} = \mathbf{T}_p \mathbf{P}_p^T + \mathbf{E} = \sum_{i=1}^p \mathbf{t}_i \mathbf{p}_i^T + \mathbf{E}, \quad (6)$$

kjer je  $\mathbf{t}_i$  i stolpec matrike  $\mathbf{T}$ . Prvi člen v vsoti je model PCA drugi del pa šum. Tako je prostor meritev razstavljen na dva ortogonalna prostora. Prvi ustreza sistematični varianci procesa, drugi pa šumu.

### 3. Statistično spremljanje delovanja procesa z analizo glavnih komponent

Model PCA tvorijo smeri lastnih vektorjev in variance meritev v smereh lastnih vektorjev. Določimo ga v t.i. fazi učenja iz podatkov normalno delujočega sistema. Pri spremljanju delovanja procesa oziroma v t.i. fazi odločanje, pa se meritve v vsakem trenutku vzorčenja projicirajo na lastne vektorje. Statistično spremljanje delovanja procesa temelji na predpostavki, da se med normalnim delovanjem procesa meritve preslikajo v določeno območje v prostoru zadetkov, ki ga določa model PCA. Ujemanje modela PCA in trenutne meritve testiramo z dvema statistikama:

- Hotellingova  $T^2$  statistika (ugotavljamo, ali je meritev znotraj predpisane envelope)

$$T^2(k) = \mathbf{t}(k)^T \boldsymbol{\Sigma}^{-1} \mathbf{t}(k) \quad (7)$$

Zgornja statistika ima F porazdelitev, ker je kovariančna matrika ocenjena iz končnega števila podatkov. Mejo zaupanja za  $\alpha$  % verjetnost dobimo kot

$$T_{p,n,\alpha}^2 = \frac{p(n-1)}{n-p} F_{p,n-p,\alpha}. \quad (8)$$

V zgornji enačbi je  $n$  število podatkov, ki smo jih uporabili za določitev modela PCA (kovariančne

matrike),  $p$  je število lastnih vektorjev, s katerimi zajamemo večino variance meritev in  $F_{n,n-p,\alpha}$  je meja zaupanja za F porazdelitev s stopnjama prostosti  $n$  in  $n-p$  ter  $\alpha$  % verjetnost.

- Statistika SPE (Q statistika) je vsota kvadratov elementov v posamezni vrstici matrike residualov. Testiramo, ali varianca meritev, ki ni zajeta z glavnimi komponentami, presega predpisano vrednost

$$SPE(k) = \mathbf{e}(k)^T \mathbf{e}(k) = \mathbf{x}(k)^T (\mathbf{I} - \mathbf{P}_p \mathbf{P}_p^T) \mathbf{x}(k). \quad (9)$$

V enačbi (9) smo upoštevali, da je vektor residualov enak  $\mathbf{e}(k) = \mathbf{x}(k) - \tilde{\mathbf{x}}(k) = \mathbf{x}(k) - \mathbf{P}_p \mathbf{t}(k)$ . Zgornja meja zaupanja je za  $\alpha$  % verjetnost podana v [2] in temelji na Gaussovi aproksimaciji kvadratične forme neodvisnih naključnih spremenljivk, ki sta jo predlagala Jensen in Solomon v [4].

$$SPE_{\alpha} = \theta_1 \left[ \frac{c_{\alpha} \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{1/h_0} \quad (10)$$

$c_{\alpha}$  je meja zaupanja normalne porazdelitve za  $\alpha$  % verjetnost,  $\theta_i = \sum_{j=p+1}^m \lambda_j^i$  za  $i=1,2,3$  in  $h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2}$ .

### 4. Adaptivna analiza glavnih komponent

Metodo analize glavnih komponent za spremljanje delovanja procesa lahko uporabljamo samo za stacionarne procese. V praksi pa se proces čiščenja odplak ponavadi počasi, a nenehno spreminjajo predvsem zaradi zunanjih vremenskih vplivov. Spreminjanje procesa se kaže kot sprememba srednjih vrednosti meritev, sprememba variance meritev in sprememba korelacij med spremenljivkami. Problem nestacionarnosti rešujemo z adaptivnim postopkom, ki omogoča prilagajanje srednjih vrednosti, varianc in kovariančne matrike meritev počasnim spremembam procesa. Tehnično to pomeni, da se pri odločanju omejimo na končni interval  $[t-T, t]$ , namesto da bi upoštevali vse podatke iz zgodovine. Rekurzivni postopek adaptivne analize glavnih komponent je opisan v [7].

Začetni model PCA zgradimo iz začetnega bloka podatkov  $\mathbf{X}_I \in \mathfrak{R}^{n_I \times m}$ , ki vsebuje  $m$  spremenljivk merjenih v  $n_I$  diskretnih trenutkih. Srednja vrednost meritev je podana v vektorju [7]

$$\boldsymbol{\mu}(I) = \frac{1}{n_I} \mathbf{X}_I^T \mathbf{1}_{n_I}, \quad (11)$$

kjer je  $\mathbf{I}_{n_I} = [1, 1, \dots, 1]^T \in \mathfrak{R}^{n_I}$ . Normiran blok podatkov izračunamo kot [7]

$$\mathbf{X}_I^0 = (\mathbf{X}_I - \mathbf{I}_{n_I} \boldsymbol{\mu}(l)^T) \mathbf{S}(l)^{-1}, \quad (12)$$

pri čemer je  $\mathbf{S}$  diagonalna matrika standardnih deviacij meritev  $\mathbf{S}(l) = \text{diag}(\sigma_1(l), \dots, \sigma_m(l))$ . Kovariančna matrika je

$$\mathbf{R}(l) = \frac{1}{n_I - 1} (\mathbf{X}_I^0)^T \mathbf{X}_I^0. \quad (13)$$

Z vsakim novim vzorcem signalov  $\mathbf{x}(k+1) = [x_1(k+1), x_2(k+1), \dots, x_m(k+1)]^T$  model PCA spreminjamo rekurzivno [7], kot prikazujejo naslednje enačbe:

$$\begin{aligned} \boldsymbol{\mu}(k+1) &= a\boldsymbol{\mu}(k) + (1-a)\mathbf{x}(k+1) \\ \sigma_i^2(k+1) &= a(\sigma_i^2(k) + \Delta\mu_i^2(k+1)) + \\ &+ (1-a)(x_i(k+1) - \mu_i(k+1))^2, \quad i = 1, 2, \dots, m \\ \mathbf{R}(k+1) &= \\ &= a\mathbf{S}^{-1}(k+1) (\mathbf{S}(k)\mathbf{R}(k)\mathbf{S}(k) + \Delta\boldsymbol{\mu}(k+1)\Delta\boldsymbol{\mu}(k+1)^T) \mathbf{S}^{-1}(k+1) \\ &+ (1-a)\mathbf{x}^0(k+1)(\mathbf{x}^0(k+1))^T. \end{aligned} \quad (14)$$

Pri tem je  $\Delta\boldsymbol{\mu}(k+1) = \boldsymbol{\mu}(k+1) - \boldsymbol{\mu}(k)$ ,

$\mathbf{x}^0(k+1) = (\mathbf{x}(k+1) - \boldsymbol{\mu}(k+1))\mathbf{S}(k+1)^{-1}$  je normiran vektor podatkov in  $\mathbf{S}(k+1) = \text{diag}(\sigma_1(k+1), \dots, \sigma_m(k+1))$ .  $a$  je faktor pozabljanja, s katerim uravnavamo dinamiko prilagajanja parametrov. Izberemo ga tako, da se model PCA prilagaja počasnim spremembam procesa. V vsakem koraku izračunamo tudi število glavnih komponent in meje zaupanja za  $T^2$  in statistiko SPE. Prekoračitev meje zaupanja ene izmed statistik je indikator za spremembo opazovanega procesa, zato se sproži alarm. Ko pa se model sčasoma prilagodi spremenjeni situaciji, alarm izzveni, čeprav se proces ni vrnil v normalno delujoče stanje. Opisnemu problemu se izognemo tako, da prilagajanje parametrov ustavimo ( $a$  postavimo na 1) takoj, ko statistiko SPE ali  $T^2$  prekoračita določeno mejo. Prilagajanje modela PCA

nadaljujemo, ko sta obe statistiki ponovno pod določeno mejo. Postopek je natančneje opisan z naslednjim algoritmom:


1. korak: Izberemo ustrezen faktor pozabljanja  $a = a_0$ .
2. korak: V vsakem trenutku vzorčenja z adaptivnim postopkom izračunamo statistiko SPE in  $T^2$  in ustrezne meje.
3. korak: Če je  $SPE > SPE_\alpha$  ali  $T^2 > T_{p,n,\alpha}^2$  potem je  $a = 1$ , sicer  $a = a_0$ .
4. korak: Nadaljujemo s korakom 2.

## 5. Odkrivanje napak senzorjev v čistilni napravi

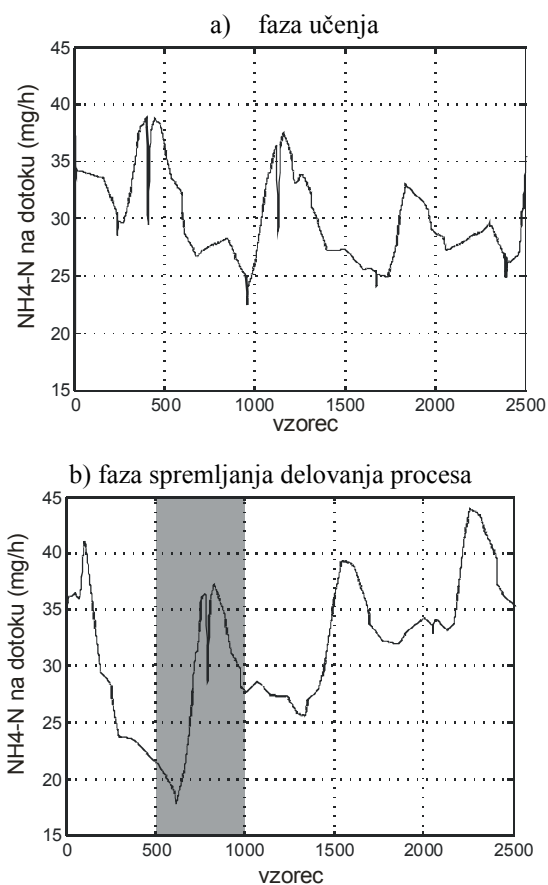
Rezultate odkrivanja napak z analizo glavnih komponent smo dobili s simulacijskimi poskusi z nelinearnim modelom pilotne čistilne naprave, ki je realiziran v programskem paketu GPS-X [2]. Shema pilotne naprave, ki je postavljena v Čistilni napravi Domžale-Kamnik, je prikazana na sliki 1. Na čistilni napravi se odpadna voda po mehanski stopnji čisti z aktivnim blatom (mikroorganizmi) po postopku MBBR (moving bed biofilm reactor). Pri analizi glavnih komponent smo uporabili naslednje signale (slika 1):

- koncentracijo amonijevega dušika na dotoku,
- koncentracijo raztopljenega kisika v prvem aerobnem reaktorju,
- koncentracijo raztopljenega kisika v drugem aerobnem reaktorju,
- skupni dotok zraka v oba reaktorja in
- koncentracijo amonijevega dušika v drugem aerobnem reaktorju.

Amonijev dušik na dotoku je dejanski izmerjeni signal in ima značilen vzorec periodičnih dnevnih sprememb (slika 2). Čas vzorčenja je dve minuti, število vseh vzorcev pa je 5040 (v enem tednu). Signal je nestacionaren, saj se njegove statistične lastnosti spreminjajo zaradi vpliva vremena. Napako na senzorju amonijevega dušika v drugem aerobnem reaktorju smo simulirali tako, da smo koncentraciji amonijevega dušika v reaktorju umetno dodali vrednosti, prikazane na sliki 3.



Slika 1: Shema pilotne čistilne naprave odpadnih voda  
Figure 1: A layout of the Wastewater Treatment Pilot Plant



Slika 2: Koncentracija amonijevega dušika na dotoku  
Figure 2: Influent ammonia concentration


Ker avtokorelacije signalov pri zakasnitvi  $T_s$  niso zanemarljive, moramo v matriko podatkov  $X$  dodati še zakasnjene signale z zakasnitvijo  $T_s$  [6] (matrika podatkov je vsebovala vsega skupaj 10 signalov). Približno polovico vzorcev (koncentracija amonijevega dušika na dotoku je na sliki 2 a)) smo uporabili za izračun začetnega modela PCA (enačbe (11), (12), (13)). Izkazalo se je, da s tremi glavnimi komponentami zajamemo več kot 95% variance meritev. Za preostale podatke (koncentracija amonijevega dušika na dotoku je prikazana na sliki 2 b)) smo sproti v vsakem trenutku vzorčenja izračunali statistiko  $T^2$  in SPE.

Na sliki 4 sta prikazani obe statistiki skupaj z mejami in ustrezni alarmi v primeru, ko smo ves čas (naslednjih 2540 vzorcev) uporabljali začetni model PCA. Jasno je razvidno, da nastopijo napačni alarmi, ki so posledica spremembe delovne točke procesa. Zaradi nelinearnosti procesa sprememba delovne točke spremeni medsebojne korelacije signalov in začetni model PCA ni več verodostojna slika dejanskih razmer.


Slika 5 prikazuje rezultate pri uporabi adaptivnega PCA modela, ki smo ga rekurzivno računali s faktorjem pozabljanja 0.9995 (časovna konstanta prilagajanja je približno 3 dni). Z adaptivnim PCA modelom smo na

osnovi obeh statistik detektirali napako senzorja. Statistika SPE v 535. vzorcu prekorači mejno vrednost, kar sproži alarm. Kot smo omenili že zgoraj, se alarm sproži, ko ena izmed statistik prekorači mejno vrednost. Hkrati se faktor pozabljanja postavi na 1, dokler se proces ponovno ne vrne v normalno delujoče stanje.

Pri uporabi adaptacije nimamo napačnih alarmov, saj se model PCA prilagaja spreminjanju procesa. Vendar pa je z opisanim rekurzivnim postopkom mogoče odkriti samo napake, ki nastanejo mnogo hitreje, kot je dinamika prilagajanja modela PCA. Omenjeni problem bomo poskušali rešiti v prihodnjih raziskavah.




Slika 3: Koncentracija amonijevega dušika v drugem aerobnem reaktorju  
Figure 3: Ammonia concentration in the second aerobic reactor



Slika 4: Analiza glavnih komponent (statistika  $T^2$  in ustrezna meja, označena s črtkano črto; Statistika SPE in ustrezna meja, označena s črtkano črto; alarm)

Figure 4: PCA analysis ( $T^2$  statistics and the threshold; SPE statistics and the threshold; alarm)



Slika 5: Adaptivna analiza glavnih komponent (statistika  $T^2$  in ustrezna meja, označena s črtkano črto; statistika SPE in ustrezna meja označena s črtkano črto; alarm)

Figure 5: Adaptive PCA analysis ( $T^2$  statistics and the threshold; SPE statistics and the threshold; alarm)

## 6. Sklep

V prispevku smo obravnavali odkrivanje napak senzorjev v biološki čistilni napravi z metodo analize glavnih komponent. Pri tem smo se omejili zgolj na odkrivanje napak, kar pomeni ugotavljanje prisotnosti napake, ne pa tudi njeno lokalizacijo. Proces čiščenja odpadnih voda je zaradi vremenskih motenj časovno spremenljiv. Poleg tega pri odkrivanju napak nastane problem ločevanja vpliva motnje od vpliva napak senzorjev na statistiki SPE in  $T^2$ . Omenjeni problem smo rešili z adaptivnim postopkom analize glavnih komponent. Le-ta omogoča sprotno prilagajanje statističnega modela počasnim spremembam procesa, s čimer se zmanjša število napačnih alarmov.

Pri simulacijskih poskusih z nelinearnim modelom čistilne naprave smo senzorju koncentracije amonijevega dušika v drugem aerobnem reaktorju umetno dodali napako. Izkazalo se je, da se v primeru izbrane napake s primerno izbiro faktorja pozabljanja pri rekurzivni analizi glavnih komponent lahko znebimo napačnih alarmov.

V prispevku je prikazan le prvi delni rezultat širše naloge, katere glavni cilj je sinteza in uporaba algoritma za nadzor delovanja senzorjev v Čistilni napravi Domžale- Kamnik.

## 7. Literatura

[1] N.B. Gallagher, B.M. Wise, S.W. Butler, D. White, G.G. Barna, Development and benchmarking of multivariate statistical process control tools for a semiconductor etch process: Improving robustness through model updating.

IFAC ADCHEM'97, str. 7883, Banff, Canada, June 1997.

[2] Hydromantis (2001). GPS-X – Technical Reference, GPS-X Version 4. Ontario, Canada.

[3] J. E. Jackson, G. S. Mudholkar, Control procedures for residuals associated with principal component analysis. *Technometrics*, Vol. 21, No. 3, str. 341-349, 1979.

[4] D. R. Jensen, H. Solomon, A gaussian approximation to the distribution of a definite quadratic form, *Journal of the American Statistical Association*, Vol 67, No.340, str. 898-902, 1972.

[5] J. V. Kresta, J. F. MacGregor, T. E. Marlin, Multivariate statistical monitoring of process operating performance. *The Canadian Journal of Chemical Engineering*, Vol. 69, str. 35-47, 1991.

[6] W. Ku, R. H. Storer, C. Georgakis, Disturbance detection and isolation by dynamic principal component analysis, *Chemometrics and Intelligent Laboratory Systems*, Vol. 30, str. 179-196, 1995.

[7] W. Li, H. H. Yue, S. Valle-Cervantes, S. J. Quin, Recursive PCA for adaptive process monitoring. *Journal of Process Control*, Vol. 10, str. 471-486, 2000.

[8] A. Negiz and A. Cinar, Statistical monitoring of multivariable dynamic processes with state-space models. *AIChE Journal*, Vol. 43, No. 8, str. 2002-2020, 1997.

[9] C. Rosen, A Chemometric Approach to Process Monitoring and Control With Application to Wastewater Treatment Operation, *PhD Thesis*, Lund University, Sweden, 2001.

[10] C. Rosen, J. Röttorp and J. Jeppsson, Multivariate on-line monitoring: challenges and solution for modern wastewater treatment operation, *Water Science & Technology*, Vol. 47, No.2, str. 171-181, 2003.

[11] M. J. Wade, R. Katebi, K. Gernaey, Improved monitoring of wastewater treatment plants using recursive principal component analysis, submitted to Water Research.

**Mina Žele** je diplomirala leta 1993, magistrirala leta 1996 in doktorirala leta 1998, vse na Fakulteti za elektrotehniko Univerze v Ljubljani. Trenutno je zaposlena na Institutu Jožef Stefan v Ljubljani. Ukvarja se z modeliranjem, identifikacijo in odkrivanjem napak.

**Darko Vrečko** je diplomiral leta 1998 in doktoriral leta 2003, oboje na Fakulteti za elektrotehniko Univerze v Ljubljani. Trenutno je zaposlen na Odseku za sisteme in vodenje na Institutu Jožef Stefan. Področje njegovega raziskovanja so vodenje, optimizacija in modeliranje bioloških čistilnih naprav za čiščenje odpadnih voda.

**Dani Juričič** je sodelavec Odseka za sisteme in vodenje Instituta Jožef Stefan. Ukvarja se predvsem z raziskavami in razvojem postopkov za zgodnje odkrivanje napak v sistemih. Zanimajo ga še številne druge teme, ki se nanašajo na vodenje v širšem pomenu, zlasti sinteza (poenostavljenih) modelov procesov.