

Nadzorni sistem za signal koncentracije kisika v čistilni napravi

Dejan Dovžan, Vito Logar, Igor Škrjanc
Fakulteta za elektrotehniko
Tržaška 25, Ljubljana
dejan.dovžan@fe.uni-lj.si

Fault Detection System for Oxygen Concentration in WWT process.

The paper presents an idea fault detection system that can be used for monitoring the oxygen concentration in a waste water treatment process. The system is able to detect abrupt fault caused by sensor fallout and estimate its output during the fallout. The core of the fault detection system is evolving fuzzy model identification method (eFuMo). The method is used to identify the fuzzy model, which describes the relations between signals and estimates the sensor outputs during their fallout. The proposed idea was tested on a real plant data.

Kratek pregled prispevka

V članku je predstavljena ideja za izgradnjo nadzornega sistema koncentracije kisika v čistilni napravi. Namen sistema je zaznati napako na signalu realnega senzorja in za čas napake na podlagi mehkega modela oceniti pravi izhod senzorja. Glavna komponenta nadzornega sistema je samorazvijajoča metoda za identifikacijo mehkega modela. Metoda nam omogoča sprotno izgradnjo in prilagajanje mehkega modela. Predlagan sistem je bil testiran na realnih podatkih, pridobljenih iz čistilne naprave. Sistem omogoča hitro zaznavanje izpadov senzorjev in oceno izhoda senzorja za čas izpada. Zaradi tega je možno brez hujših posledic senzor zamenjati tudi med samim delovanjem procesa.

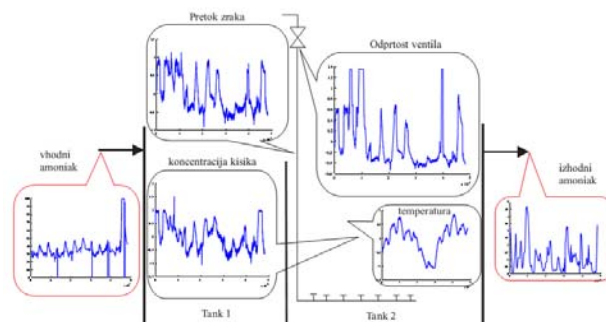
1 Uvod

Čistilne naprave so ene ključnih naprav, ki nam lahko zagotavljajo čistost voda. Pogosto se zgodi, da zaradi umazanije ali pa kakšnih drugih dejavnikov senzorji izpadejo. Za brezkrbno delovanje čistilne naprave in zagotavljanje konstantne kvalitete očiščene vode bi bilo potrebno uvesti nadzorni sistem, ki spremlja merjene veličine čistilne naprave. Sistem, bi moral biti sposoben zaznati napako na senzorju in za čas, ko senzor ne deluje pravilno, oceniti njegov izhod. S tem opozori nadzornika na napako, hkrati pa zagotovi nemoteno delovanje čistilne naprave za čas izpada senzorja.

Proces čiščenja odpadnih voda je pogosto obravnavan v literaturi. Ukvarjajo se z izboljšavam na področju vodenja [1], estimacijo stanj [2], [3], [4] in sistemi za zaznavanje napak [5]. V članku je predlagana ideja za sistem zaznavanja napak. Ideja je bila preizkušena na primeru realnih signalov čistilne naprave. Cilj je, da bi sistem pokrtil vse merjene veličine v procesu, vendar je za enkrat to narejeno le za koncentracijo kisika v čistilni napravi. Glede na to, da je proces čiščenja odpadnih voda v splošnem nelinearen časovno spremenljiv proces [6], [7], smo za izgradnjo sistema za zaznavanje napak uporabili mehki model in algoritem sprotne identifikacije.

2 Opis problema

Proces čiščenja odpadnih voda je nelinearen sistem, ki je izpostavljen motnjam v dotoku in obremenitvi. Spreminja se tudi sestava odpadne vode, ki pride v čistilno napravo. Proces sestoji iz petih zaporedno vezanih reaktorjev, ki se iztekajo v desetplastni sekundarni tank, kjer se tvorijo usedline. Podrobnejši opis procesa najdemo v [8], [1]. Celoten proces lahko poenostavljeno opišemo z dvema tankoma [1]. Shema procesa je prikazana na Sliki 1.



Slika 1: Poenostavljena shema čistilne naprave

Merjene veličine so koncentracija amonijaka na dotoku, koncentracija amonijaka na izhodu čistilne naprave, koncentracija kisika v drugem tanku, pretok zraka ter odprtost ventila in temperatura v drugem tanku. Za izgradnjo sistema zaznavanja napak na signalu koncentracije kisika je potrebno modelirati odnose med odprtostjo ventila in pretokom zraka ter odnos med pretokom zraka in koncentracijo kisika. Zaradi nelinearne in spremenljive narave procesa smo izbrali mehki Takagi-Sugeno model za modeliranje relacij med signali ter eFuMo metodo za izgradnjo in prilagajanje modelov.

2.1 Mehki Takagi-Sugeno model in identifikacija

Ideja mehkega Takagi-Sugeno modela je, da nelinearni sistem lahko opišemo z večimi linearnimi modeli, ki proces opišejo v neki delovni točki. Z mehko združitvijo teh modelov dobimo nelinearno obnašanje mehkega modela. Za identifikacijo TS modela je potrebno vhodno-izhodni prostor procesa razdeliti na mehka območja, na katerih lahko definiramo veljavni linearni model, ki velja za to območje. Oblika linearnih lokalnih modelov za relacijo odprtost ventila – pretok zraka je podana z enačbo (1), za relacijo pretok zraka – koncentracija kisika pa z enačbo (2):

$$\phi(k+1) = a\phi(k) + bv_m(k) + r_1 \quad (1)$$

$$C_{O_2}(k+1) = cC_{O_2}(k) + dT(k) + e\phi(k) + r_2 \quad (2)$$

kjer je $\phi(k)$ pretok zraka, $v_m(k)$ odprtost ventila, $T(k)$ temperatura v drugem tanku ter $C_{O_2}(k)$ koncentracija kisika v drugem tanku, parametri a, b, r_1, c, d, e in r_2 določajo vpliv posamezne veličine. Določimo jih s pomočjo identifikacije.

Oba mehka modela sta identificirana s pomočjo eFuMo metode. Metoda je sestavljena iz dveh sklopov. V prvem sklopu se identificirajo mehka območja (roji), v drugem sklopu se identificirajo parametri lokalnih modelov. Obe identifikaciji potekata rekurzivno, kar pomeni, da se lahko mehki model prilagaja na spremembe v procesu. Parametri lokalnih modelov so identificirani s pomočjo mehkih rekurzivnih kvadratov [9]:

$$x_e(k) = [x_1(k), \dots, x_n(k), 1]^T \quad (3)$$

$$P_i(k+1) = \frac{1}{\lambda_r} \left(P_i(k) - \frac{\beta_i P_i(k) x_e(k) x_e^T(k) P_i(k)}{\lambda_r + \beta_i x_e^T(k) P_i(k) x_e(k)} \right) \quad (4)$$

$$\theta_i(k+1) = \theta_i(k) + P_i(k) \beta_i x_e(k) (y(k+1) - x_e^T(k) \theta_i(k)) \quad (5)$$

kjer je x_e vektor vhodnih signalov, P_i kovariančna matrika najmanjših kvadratov, β proženje roja pri dani vhodni sliki, θ označuje parametre lokalnega modela, y izhod procesa, i pa je indeks lokalnega modela oziroma roja. Proženje rojev izračunamo na podlagi Gausovih pripadnostnih funkcij:

$$\mu_{ik} = e^{-\frac{(x(k)-v_i)^T F_i^{-1} (x(k)-v_i)}{2}} \quad (6)$$

$$\beta_i = \frac{\mu_{ik}}{\sum_{i=1}^c \mu_{ik}} \quad (7)$$

Določanje mehkih območij eFuMo metoda opravi s pomočjo mehkega Gustafson-Kessel rojenja [10]. Rojenje temelji na računanju razdalj trenutne vhodne slike do centrov obstoječih rojev:

$$D_{ik}^2 = (x(k) - v_i)^T \det(F_i)^{\frac{1}{2}} F_i^{-1} (x(k) - v_i) \quad (8)$$

kjer je vektor $x(k)$ trenutna vhodna slika (podobno kot x_e), v_i center i -tega roja, F_i^{-1} pa inverz mehke kovariančne matrike. Vhodni sliki se nato določi pripadnost k posameznemu roju:

$$\mu_{ik} = \frac{1}{\left(\frac{D_{ik}}{\sum_{j=1}^c D_{jk}} \right)^{\frac{1}{\eta-1}}} \quad (9)$$

in popravimo pozicije centrov rojev (en. 10, 11, 12) ter kovariančno matriko roja (en.13).

$$v_i(k) = v_i(k-1) + \Delta v_i \quad (10)$$

$$\Delta v_i = \frac{\mu_{ik} (x(k) - v_i(k-1))}{s_i(k)} \quad (11)$$

$$s_i(k+1) = s_i(k) + \mu_{ik} \quad (12)$$

$$F_i(k) = \gamma \frac{s_i(k-1)}{s_i(k)} F_i(k) + \frac{\mu_{ik}}{s_i(k)} (x(k+1) - v_i(k))(x(k+1) - v_i(k))^T \quad (13)$$

Podrobnejšo izpeljavo metode najdemo v [10] in [11].

Poleg rekurzivne identifikacije parametrov lokalnih modelov in rojev ima eFuMo metoda ugrajene mehanizme za dodajanje, odstranjevanje, deljenje in združevanje rojev.

Dodajanje rojev temelji na razdalji trenutne vhodne slike do obstoječih rojev. Če je ta razdalja večja od določenega pragu, se doda nov roj. Odstranjevanje rojev temelji na njihovih podpornih množicah. V primeru, da ima en od rojev podporno množico precej manjšo od povprečne podporne množice, je ta roj odstranjen iz strukture. Deljenje rojev temelji na podlagi napake mehkega modela. Za vsak korak učenja se izračuna napaka mehkega modela, ki se glede na proženje posameznega roja razdeli med roje. Ko napaka enega od rojev preseže določen prag, se ta roj deli na dva nova roja. Združevanje rojev poteka na podlagi sosednosti in podobnosti lokalnih modelov. Roja se združita, če je proženje prvega roja v drugem in obratno večje od določenega pragu. Združita se tudi, če je napaka med lokalnima modeloma prvega in drugega roja, kjer sta prvi in drugi roj sosednja roja, manjša od določenega pragu. Podroben opis mehanizmov združevanja in inicializacijskih vrednosti najdemo v [12].


2.2 Sistem za zaznavanje napak in oceno izhoda senzorja

Sistem temelji na podlagi mehkih modelov, ki opisujejo relacije med signali, ki vplivajo na


koncentracijo kisika v zadnjem tanku. Mehki modeli se prilagajajo stanju v procesu. S tem dobimo točnejšo oceno izhoda sensorja. Sistem deluje na primerjavi med dejanskim merjenim signalom in ocenjenim signalom. Ko napaka preseže določeno vrednost se proži alarem. Prag pri katerem se proži alarem je določen kot:

$$p = 1,4 \sum_{i=1}^c \beta_i \sqrt{F_{i,n,n}} \quad (14)$$

kjer je $F_{i,n,n}$ zadnji element kovariančne matrike i -tega roja (varianca izhoda). Alarem se ugasne, ko vrednost napake pade pod polovico praga za proženje alarma. Sistem v času zaznanega alarma vrača ocenjeno vrednost izhoda. Ko alarem ni prisoten sistem vrne dejansko merjeno vrednost.




Slika 2: Signal pretoka zraka



Slika 3: Signal koncentracije kisika

Na sliki 2 je prikazan potek signala za pretok zraka, na sliki 3 pa potek signala koncentracije kisika. Z rdečo črtkano črto je prikazan izhod nadzornega sistema (izhod mehkega sensorja), s črno črto dejanske meritve, z modro črto pa signal s simulirano napako. Izpad sensorja na obeh signalih je bil simuliran, tako da smo za nek interval vrednosti sensorja postavili na nič. Vsi signali na slikah 2 in 3 so normirani s srednjo vrednostjo in standardno deviacijo. Na signalu pretoka zraka je bil izpad sensorja simuliran za vzorce od 38000 do 43000, na signalu koncentracije kisika pa od 35000 do 43000. Signal alarma je prikazan na sliki 4. Sistem prične s spremljanjem procesa, ko so mehki modeli dovolj dobro naučeni. Vidimo, da je izhod sistema spremljanja do vzorca 8000 nič. Ti vzorci so uporabljeni za začetno sprotno učenje mehkega modela.




Slika 4: Signal pretoka zraka

Rezultati kažejo na to, da kljub izpadu obeh sensorjev lahko s sistemom dobro ocenimo potek signalov. Povprečna relativna napaka med ocenjenim signalom in dejanskim signalom med izpadom je 0,018 za signal pretoka zraka in 0,075 za signal koncentracije kisika.

Na sliki 5 je prikazano število rojev, ki jih imata mehki model za oceno pretoka zraka (zgornji graf) in mehki model za oceno koncentracije kisika (spodnji graf). Vidimo, da se število rojev večja oziroma manjša s časom. Ko sistem prične s spremljanjem procesa ima mehki model za oceno pretoka zraka 5 rojev,

mehki model za oceno koncentracije kisika pa 3 roje.



Slika 5: Število rojev mehkega modela

3 Sklep

Zgrajen sistem za nadzor koncentracije kisika je sposoben zaznati izpad senzorja in v času izpada nadomestiti njegovo vrednost z ocenjeno. Sistem deluje tudi v primeru izpada senzorjev obeh veličin, tako koncentracije kisika kot tudi pretoka zraka. Z vgrajevanjem predlaganega sistema bi lahko izboljšali regulacijo naprave v času izpada senzorja, hkrati pa bi lahko naprava nemoteno delovala tudi v času menjave starega senzorja z novim.

4 Literatura

[1] D. Vrečko, N. Hvala, M. Strazar, The application of model predictive control of ammonia nitrogen in an activated sludge process, *Water Science and Technology*, 2011, št. 5, str. 1115 – 1121.

[2] G. Bavdaž, N. Hvala, J. Kocijan, Đ. Juričič, Nelinearni algoritem za estimacijo stanj in identifikacijo parametrov šaržnega biološkega

procesa, *Elektrotehniški vestnik*, 2001, let. 68, str. 57 – 63.

- [3] D. Cecil, M. Kozłowska, Software sensors are a real alternative to true sensors, *Environmental Modelling and Software*, 2010, let. 25, str. 622 – 625.
- [4] C. K. Yoo, I-B. Lee, Soft sensor and adaptive model-based dissolved oxygen control for biological wastewater treatment processes, *Environmental Engineering Science*, 2004, let. 21, št. 3, str. 331 – 340.
- [5] M. W. Lee, S. H. Hong, H. Choi, J-H. Kim, D. S. Lee, J. M. Park, Real time remote monitoring of small scaled biological wastewater treatment plants by a multivariate statistical process control and neural network-based software sensors, *Process Biochemistry*, 2008, let. 43, št. 10, str. 1107 – 1113.
- [6] O. A. Z. Sotomayor, S. W. Park, C. Garcia, Software sensor for on-line estimation of the microbial activity in activated sludge systems, *ISA Transactions*, 2002, let. 41, št. 2, str. 127 – 143.
- [7] C. F. Lindberg, Control and estimation strategies applied to activated sludge process, *Doktorska disertacija*, Uppsala University, Stockholm, Švedska, 1997.
- [8] D. Dovžan, V. Logar, N. Hvala, I. Škrjanc, Zaznavanje napak in spremljanje čiščenja odpadnih voda na podlagi mehkega modela, *Elektrotehniški vestnik*, 2011, let. 78, št. 3, str. 142 – 146.
- [9] P. P. Angelov, D. P. Filev, An approach to on-line identification of Takagi-Sugeno fuzzy models, *IEEE Transactions on Systems Man and Cybernetics - Part B*, 2004, let. 34, št. 1, str. 484 – 498.
- [10] D. Dovžan, I. Škrjanc, Recursive clustering based on a Gustafson-Kessel algorithm, *Evolving systems*, 2011, let. 2, št. 1, str. 15 – 24.
- [11] D. Dovžan, I. Škrjanc, Recursive fuzzy c-means clustering for recursive fuzzy identification of time-varying processes, *ISA transactions*, 2011, let. 50, št. 2, str. 159 – 169.
- [12] D. Dovžan, V. Logar, I. Škrjanc, Solving the sales prediction problem with fuzzy evolving methods, V: *International Joint Conference on Neural Networks (IJCNN 2012), the IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2012) and the IEEE Congress on Evolutionary Computation (IEEE CEC 2012)*, June 10-15, Brisbane, Australia, 2012, str. 308 – 315.