

Modeliranje in zaznavanje napak na sistemu HVAC

Goran Andonovski, Igor Škrjanc
Fakulteta za elektrotehniko, Univerza v Ljubljani
Tržaška cesta 25, 1000 Ljubljana
goran.andonovski@fe.uni-lj.si, igor.skrjanc@fe.uni-lj.si

Modeling and fault detection of the HVAC system

This article presents a model of the HVAC (heating, ventilation, and air conditioning) system and moreover, a fault detection method is presented. The model consists sub-models of different subsystems of the HVAC system, such us: heater, cooler, recuperator etc. The model parameters are optimized based on the real data acquired from the real process. Furthermore, using the HVAC model we generated learning and testing data for different faults which can occur on the HVAC system. We have detected the faults using the principal component analysis (PCA) method and with the evolving cloud-based method.

Kratek pregled prispevka

V tem članku je predstavljeno modeliranje klimatskega sistema HVAC (ang. (heating, ventilation, and air conditioning) na osnovi realnih podatkov ter zaznavanje različnih napak na modelu. Model je sestavljen iz več podmodelov, ki predstavljajo posamezne gradnike celotnega sistema, kot so: grelec, hladilnik, rekuperator in podobno. Parametri modelov so optimizirani na osnovi podatki pridobljenih iz realnega procesa. Nato smo s pomočjo modela generirali učne in testne množice podatkov za različne napake, ki se lahko pojavijo na sistemu HVAC. Teh napak smo zaznali z metodo glavnih komponent (PCA) in z napredno samorazvijajočo se metodo na osnovi oblakov podatkov.

1 Uvod

Sodobni industrijski obrati so tipično zelo kompleksni in sestavljeni iz različnih dinamičnih podprocesov. Pogosto obratujejo v različnih obratovalnih pogojih in pod spremenljivimi zunanji vplivi. Ne glede na to, ali gre za zelo velike in kompleksne procese ali pa za majhne in enostavne, so zahteve v industriji za varnejše in zanesljivejše delovanje vedno večje. Pri tem metode spremljanja procesov oziroma metode zaznavanja napak igrajo pomembno vlogo. Klasične metode spremljanja procesov temeljijo le na spremljanju posameznih (merljivih) spremenljivk, če so znotraj predhodno opredeljenih meja. Vendar spremljanje procesov lahko znatno izboljšamo, če upoštevamo več merjenih spremenljivk, ki so nam na voljo, in sicer v kombinaciji z naprednimi in inteligentnimi metodami.

Na področju zaznavanja napak spadajo metode, ki lahko odkrijejo, če se je pojavila napaka v sistemu, in določajo čas, v katerem se je napaka pojavila. Metode zaznavanja napak lahko razdelimo v tri večje skupine: (i) metode na podlagi matematičnih modelov procesa [1, 2], (ii) statistične metode [3–5] in (iii) metode na podlagi podatkov (ang. *data-based methods*) [6–9].

V prvo skupino spadajo metode, ki temeljijo na matematičnem modelu in zahtevajo osnovno znanje o fizikalnem ozadju procesa. Metode, ki spadajo v to skupino, so bile uporabljene na različnih industrijskih aplikacijah. Slabost teh metod je ta, da ne upoštevajo vpliva motenj, lezenja parametrov in uporabljajo le *a priori* znanje o napakah. Druga skupina metod temelji na statističnih analizah podatkov procesa [3]. Te metode uporabljajo shranjene podatke za pridobitev znanja o procesu, ko je ta v normalnem delovanju oziroma, ko se pojavi napaka. Najbolj osnovne metode so: analiza glavnih komponent (PCA, ang. *principal component analysis*) [10, 11], metoda delnih najmanjših kvadratov (PLS, ang. *partial least squares*) [12] in metoda neodvisnih komponent (ICA, independent component analysis) [5]. V tretjo skupino se bomo osredotočili na metode, ki uporabljajo tok podatkov oziroma še bolj natančneje se bomo posvetili metodam s samorazvijajočo se strukturo

in adaptivnimi parametri. Metoda za zaznavanje napak na podlagi samorazvijajočega se deljenja prostora na Gaussove roje je predstavljena v [7]. V [8] je predstavljena metoda za zaznavanje napak, ki temelji na načelu TEDA (ang. *typicality and eccentricity data analytics*) [9].

V tem prispevku bomo najprej predstavili proces ter pripadajoči model klimatskega sistema [13]. Model je sestavljen na osnovi matematičnih modelov posameznih elementov klimatskega sistema, kot so model grelnika, hladilnika, rekueratorja in podobno. Predstavljeni pod-modeli so uporabljeni za gradnjo skupnega modela. Parametri modelov so bili nastavljeni na osnovi realnih podatkov pridobljenih iz realnega procesa. Zato model predstavlja digitalni dvojček realnega procesa.

V eksperimentalnem delu prispevka smo primerjali dve metodi zaznavanja napak na modelu HVAC. Prva metoda, ki spada v skupino statističnih metod, je metoda glavnih komponent (PCA). Metoda PCA poišče linearna razmerja med spremenljivkami ter omogoči preslikavo osnovnih podatkov v prostor glavnih komponent, katerega osi so med seboj ortogonalne. Spremenljivke meritev v novem prostoru so med seboj nekorelirane. Metoda je uporabna, ko imamo opravka z visoko-dimenzionalnimi podatki, saj omogoča predstavitev podatkov z manjšim številom spremenljivk. Druga metoda uporablja statistične informacije o procesu, ki jih pridobi s sprotnem učenjem na osnovi toka podatkov (ang. *data stream*), v kombinaciji z mehanizmom samorazvijanja. To nam omogoča bolj fleksibilno prilagajanje parametrov metode in na ta način lahko zajamemo ne-stacionarne in dinamične procese.

V tem prispevku je v poglavju 2 najprej predstavljen model klimatskega sistema ter možne napake, ki se lahko pojavijo na sistemu. Nato v poglavju 3 so predstavljeni uporabljeni metodi za zaznavanje napak na sistemu HVAC. V poglavju 4 so podani rezultati zaznavanja različnih napak z obema metodama. Na koncu v poglavju 5 je podan zaključek ter glavne ugotovitve.

2 Model sistema HVAC

Klimatski sistemi za pripravo zraka (ang. *heating ventilation and air conditioning*, HVAC) so del skora vsakega industrijskega objekta. Za napredno upravljanje in detekcijo napak v delovanju takega sistema so potrebni dobri modeli posameznih elementov ter sistema kot celote. Tipični elementi sistema za pripravo zraka so ventilatorji, cevi, ventili, grelni in hladilni elementi ter mešalniki zraka. V [13] je predstavljenih več matematičnih modelov posameznih elementov. Za nekatere osnovne elemente je podanih več modelov, opisane so razlike med njimi ter njihove pomanjkljivosti. Model celotnega klimatskega sistema je bil realiziran v programskem okolju Matlab.

Shema realnega klimatskega sistema HVAC je predstavljena na sliki 1. Za podan sistem smo pridobili merjene podatke v obdobju sedmih mesecev (junij 2016 – december 2016). Pridobljene podatke smo uporabili za nastavljanje parametrov modela HVAC, da smo dobili čim boljše ujemanje med modelom in realnim sistemom.

2.1 Predvidene napake na sistemu HVAC

V tem podpoglavju je predstavljen koncept za zaznavanje tipičnih napak v klimatskem sistemu. Za potrebe testiranja v poglavju 3 so generirani testni podatki – simulacijski teki, kjer se v različnih časovnih intervalih pojavljajo različne napake v delovanju sistema, ki naj jih detektorji uspešno zaznavajo in prepoznavajo. Predvidene so napake na različnih signalih (na strani aktuatorjev in senzorjev):

- ventil rekuperatorja,
- ventil grelca,
- ventil hladilnika,
- ventil vlažilca,
- dovodni ventilator,
- odvodni ventilator,
- temperatura grelnega medija, ter
- temperatura hladilnega medija.

Predvidimo tudi več vrst napak na zgorajnavedenih signalih:

- zakasnen signal,
- premik signala po amplitudi,
- izpad komunikacije,
- odpoved HVAC elementov.

3 Zaznavanje napak na sistemu HVAC

V tem poglavju bo opisan postopek zaznavanja napak z dvema metodama, PCA in metodo na osnovi oblakov z mehanizmom samorazvijanja. Obe metodi potrebujeta dve množici podatkov za vsako napako. Za izgradnjo in testiranje detektorjev napak potrebujemo množico učnih in testnih podatkov, ki jih v našem primeru generiramo s pomočjo simulacije modeliranega sistema.

3.1 Metoda glavnih komponent

Za gradnjo detektorjev različnih napak smo preizkusili metodo analiza glavnih komponent. Metoda PCA definira transformacijsko matriko \mathbf{P} , ki preslika vhodnih podatkov \mathbf{X} v matriko zadetkov \mathbf{T} [13]. Drugače povedano, gre za transformacijo (rotacijo) osi koordinatnega sistema v nov ortogonalni sistem, ki rezultira v največji kovarianci podatkov glede na novo izbrane osi. To lahko opišemo z enačbo:

$$\mathbf{T} = \mathbf{X}\mathbf{P} \quad (1)$$

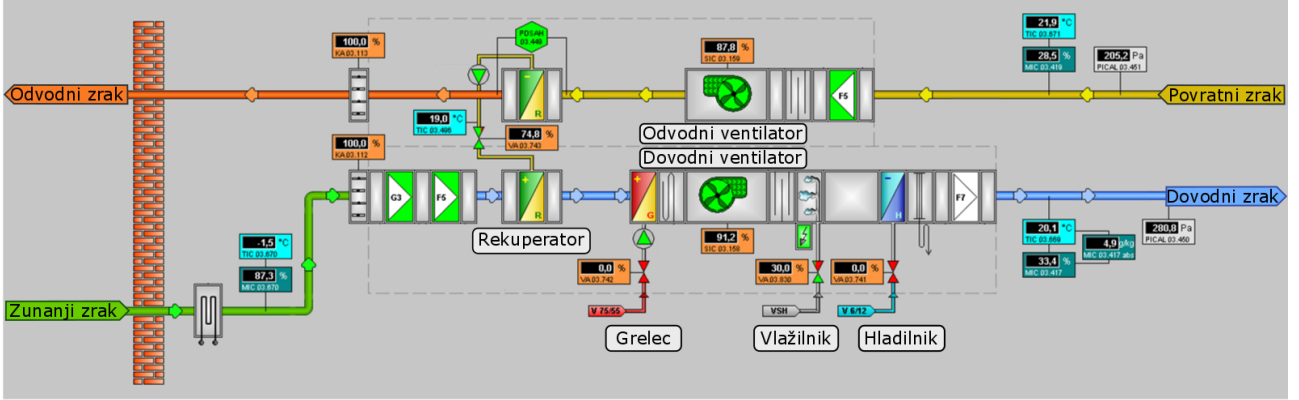
Matrika glavnih vektorjev \mathbf{P} predstavlja statističen model procesa in nima realnega ozadja, saj je sestavljen iz psevdospremenljivk. Lahko sestavimo delno matriko (model) glavnih lastnih vektorjev \mathbf{P}_s , tako da vzamemo le stolpce matrike \mathbf{P} , ki nosijo večino variance oziroma informacije vhodne matrike \mathbf{X} . Na ta način dobimo aproksimirano matriko podatkov:

$$\mathbf{T}_s = \mathbf{X}\mathbf{P}_s \quad (2)$$

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

Z zanemarjenjem nekaj komponent, smo izgubili del informacije o osnovnih meritvah. To lahko zapišemo z matriko ostankov (residualov) \mathbf{E}_X , ki jo imenujemo tudi prostor šuma. Sedaj lahko matriko podatkov zapišemo z naslednjo enačbo:

$$\mathbf{X} = \mathbf{X}_s + \mathbf{E}_X = \mathbf{T}_s\mathbf{P}_s^T + \mathbf{E}_X \quad (4)$$



Slika 1: Shema realnega sistema HVAC.

Matriko šuma (residualov) bomo kasneje uporabili za zaznavanje napak. V [13] je metoda PCA predstavljena bolj podrobno.

3.2 Samorazvijajoča se metoda

Metoda za zaznavanje napak, ki bo razložena v nadaljevanju, je zasnovana na osnovi samorazvijajočim se mehkim modelom AnYa, ki temelji na izračunu lokalnih gostot (ang. *local density*). Model AnYa je sestavljen iz mehkih pravil:

$$\mathcal{R}^i : \text{IF } (\mathbf{x}_k \sim X^i) \text{ THEN } \mathbf{x}_k \in \text{Class}^i \quad (5)$$

kjer je $\mathbf{x}_k = [\mathbf{x}_k(1), \mathbf{x}_k(2), \dots, \mathbf{x}_k(m)]$ m -dimenzionalen vhodni vektor. Operator \sim je izražen kot mera pripadnosti trenutnega vzorca \mathbf{x}_k k obstoječim oblakom X^i . Mera pripadnosti predstavlja lokalna gostota vzorca in se izračuna z naslednjo enačbo:

$$\gamma_k^i = \frac{1 + T^i}{1 + (\mathbf{x}_k - \mu_{M^i}^i)^T (\mathbf{x}_k - \mu_{M^i}^i) + T^i}, \quad i = 1, \dots, c \quad (6)$$

kjer je $\mu_{M^i}^i$ srednja vrednost i -tega oblaka, ter T^i je skalar in se izračuna z naslednjo enačbo:

$$T^i = \frac{M^i - 1}{M^i} \text{trace}(\mathbf{A}^i \boldsymbol{\Sigma}_{M^i}^i) \quad (7)$$

V enačbi (7) je potrebno izračunati še kovariančno matriko podatkov $\boldsymbol{\Sigma}$. V [14] so avtorji predlagali rekurziven način izračuna kovariančne matrike z

naslednjim algoritmom:

$$M^i \leftarrow M^i + 1 \quad (8)$$

$$\mu_{M^i}^i \leftarrow \frac{M^i - 1}{M^i} \mu_{M^i - 1}^i + \frac{1}{M^i} \mathbf{x}_k \quad (9)$$

$$\mathbf{S}_{M^i}^i \leftarrow \mathbf{S}_{M^i - 1}^i + (\mathbf{x}_k - \mu_{M^i - 1}^i)(\mathbf{x}_k - \mu_{M^i}^i)^T \quad (10)$$

$$\boldsymbol{\Sigma}_{M^i}^i \leftarrow \frac{1}{M^i - 1} \mathbf{S}_{M^i}^i \quad (11)$$

kjer so začetna stanja $M^i = 0$, $\mu_0^i = \mathbf{x}_1$ in $\mathbf{S}_0^i = 0$. V [15] je predstavljen podroben opis metode in način, kako jo uporabimo v praksi.

3.3 Zaznavanje napak

Za gradnjo detektorja napak pri obeh metodah smo izbrali pristop pri katerem se v koraku učenja detektorju podata dve množici podatkov. Prva množica predstavlja delovanje procesa HVAC brez napak ter druga množica podatkov predstavlja obdobje, ko je prisotna napaka, ki jo želimo zaznati. V fazi vrednotenja imamo eno množico podatkov, ki vsebuje področje normalnega delovanja kot tudi področje z napako.

3.3.1 Faza učenja

V fazi učenja zgradimo detektor napake z dvema setoma podatkov. Z metodo PCA določimo transformacijsko matriko \mathbf{P} za oba seta podatkov. Potem sledi izbor glavnih komponent, kjer izbrane komponente predstavljajo 95% skupne variance (podrobno je opisano v [13]). V primeru samorazvijajočega se modela pa na osnovi oba seta podatkov zaznamo oblake, ki predstavljajo normalno delovanje procesa in oblake, ki predsta-

vljajo napako.

3.3.2 Faza vrednotenja

V fazi ovrednotenja, kot smo že omenili zgoraj, potrebujemo eno množico podatkov, ki vsebuje področje normalnega delovanja in prisotnost napake. V primeru samorazvijajočega se modela na osnovi oblakov za vsak podatek \mathbf{x}_k iz testnega seta podatkov izračunamo maksimalno gostoto oblakov brez napake in z napako. Z naslednjo funkcijo, ki je pravzaprav del posledičnega dela enačbe (2.4), lahko vsak podatek razvrstimo kot normalno delovanje ali napako:

$$Napaka = \begin{cases} 1, & \max_i \gamma_k^i(X_{F=0}^i) < \max_i \gamma_k^i(X_{F=1}^i) \\ 0, & \text{sicer} \end{cases} \quad (12)$$

kjer 1 pomeni, da smo odkrili napako, medtem ko 0 pomeni normalno obratovanje procesa.

Ovrednotenje obeh metod je bilo izvedeno s pomočjo matriko zamenjav, kot ocena robustnosti metode:

$$ACC = \frac{TP + TN}{total\ samples} \times 100 [\%] \quad (13)$$

kjer je TP število pravilno zaznanih vzorcev in TN število napačno zaznanih vzorcev.

4 Rezultati

V eksperimentalnem delu smo izbrali tri različne napake, ki se lahko pojavijo na sistemu HVAC, kot je prikazano na tabeli 1. Za vsako na-

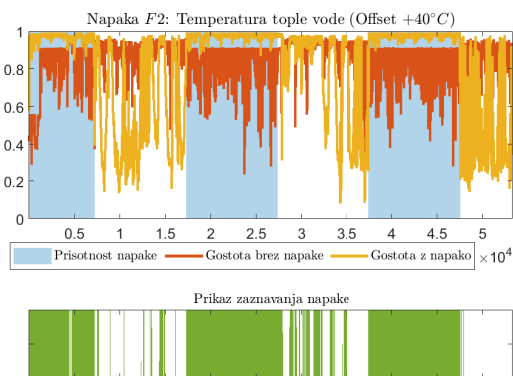
Tabela 1: Seznam testiranih napak.

Napaka	Opis signala	Tip napake
F1	Temperatura hl. medija +40°C	
F2	Ventil grelca	100 %
F3	Ventil rekuperatorja	100 %

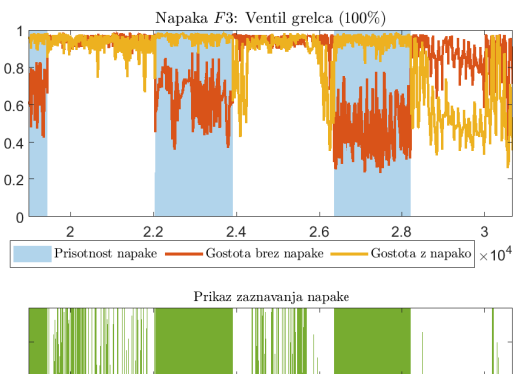
pako smo s pomočjo simulatorja generirali učne in testne množice podatkov.

Na slikah 2, 3 in 4 so prikazani rezultati zaznavanja napak (testna množica podatkov) s pomočjo samorazvijajočim se modelom na osnovi oblakov.

Na teh slikah je najprej predstavljena primerjava med maksimalno gostoto oblakov brez napake in maksimalno gostoto oblakov z napako. Nato z enačbo (12) določimo ali je trenutne vzorec napaka ali normalno obratovanje. Kar prikazuje drugi graf na slikah. V tabeli 2 so prikazani rezultati uspešnosti zaznavanja napak za obe metodi, kjer eCB je okrajšava za metodo na osnovi oblakov. Iz tabele je razvidno, da samorazvijajoči se model dosega boljše rezultate in so primerni za uporabo na realnem sistemu.



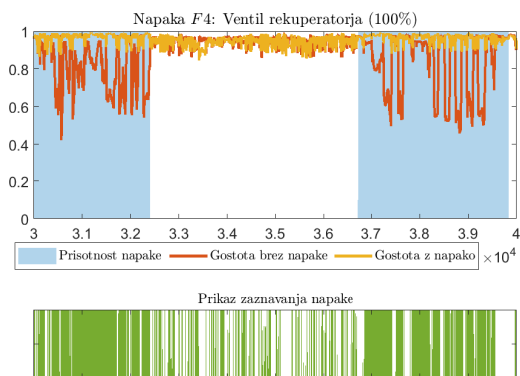
Slika 2: Rezultati zaznavanja napake F1.



Slika 3: Rezultati zaznavanja napake F2.

Tabela 2: Prikaz uspešnosti zaznavanja napak (ACC [%])

	F1	F2	F3
PCA	86.59	73.35	67.90
eCB	89.03	75.76	69.04



Slika 4: Rezultati zaznavanja napake F3.

5 Zaključek

V tem delu smo predstavili model klimatskega sistema, kot tudi dve različni metodi za zaznavanje napak na tem sistemu. Prva metoda, metoda glavnih komponent, temelji na statistični analizi podatkov in transformacijo (preslikavo) prostora podatkov v prostor glavnih komponent. Druga metoda s sprotnim učenjem na osnovi podatkov pridobiva novo znanje o procesu in razdeli prostor na oblake podatkov. Obe metodi smo testirali na treh različnih napakah, ki se lahko pojavijo na sistemu HVAC. Rezultati so pokazali, da obe metodi dajejo približno enake rezultate

Zahvala

Delo je bilo izvedeno v sklopu programa GO-STOP (OP20.00361), ki ga delno financirata Republika Slovenija – Ministrstvo za izobraževanje, znanost in šport ter Evropska Unija – Evropski sklad za regionalni razvoj.

Literatura

- [1] P. M. Frank. Fault diagnosis in dynamic systems using analytical knowledge-based redundancy - A survey and some new results. *Automatica*, zv. 26, št. 3, str. 459–474, 1990.
- [2] G. Klančar, a. Juričić in R. Karba. Robust fault detection based on compensation of the modelling error. *International Journal of Systems Science*, zv. 33, št. 2, str. 97–105, 2002.
- [3] S. J. Qin. Statistical process monitoring: basics and beyond. *Journal of Chemometrics*, zv. 17, št. 8-9, str. 480–502, 2003.
- [4] G. Klančar in I. Škrjanc. Metoda glavnih komponent pri odkrivanju in izolaciji napak: primer hidravličnega procesa in procesa fermentacije. *Elektrotehniški vestnik*, zv. 69, št. 5, str. 311–316, 2002.
- [5] Y. Zhang in S. J. Qin. Improved Nonlinear Fault Detection Technique and Statistical Analysis. *AICHE Journal, Process Systems Engineering*, zv. 54, št. 12, str. 3207–3220, 2008.
- [6] F. Serdio, E. Lughofer in sod. Fault detection in multi-sensor networks based on multivariate time-series models and orthogonal transformations. *Information Fusion*, zv. 20, št. 1, str. 272–291, 2014.
- [7] A. Lemos, W. Caminhas in F. Gomide. Adaptive fault detection and diagnosis using an evolving fuzzy classifier. *Information Sciences*, zv. 220, str. 64–85, 2013.
- [8] C. G. Bezerra, B. S. J. Costa in sod. An evolving approach to unsupervised and Real-Time fault detection in industrial processes. *Expert Systems with Applications*, zv. 63, str. 134–144, 2016.
- [9] P. Angelov. Anomaly Detection Based on eccentricity analysis. V *IEEE Symposium on Evolving and Autonomous Learning Systems (EALS)*, str. 1–8. Orlando, FL, USA, 2014.
- [10] W. Li, H. Yue in sod. Recursive PCA for adaptive process monitoring. *Journal of Process Control*, zv. 10, str. 471–486, 2000.
- [11] G. Klančar. Fault Detection and Isolation by means of Principal Component Analysis. V *Cybernetics & Informatics Eurodays: Young Generation Viewpoint : PhD Workshop.*, str. 1–6. Institute of Information Theory and Automation, Marianska, Czech Republic, 2000.
- [12] G. Li, S. J. Qin in D. Zhou. Geometric properties of partial least squares for process monitoring. *Automatica*, zv. 46, št. 1, str. 204–210, 2010.
- [13] Ž. Stržinar. *Modeliranje in zaznavanje napak v klimatskih sistemih*. Master thesis, University of Ljubljana, 2017.
- [14] S. Blažič, P. Angelov in I. Škrjanc. Comparison of Approaches for Identification of All-data Cloud-based Evolving Systems. V *2nd IFAC Conference on Embedded Systems, Computer Intelligence and Telematics CESCIT 2015*, str. 129–134. Maribor, Slovenia, 2015.
- [15] G. Andonovski, S. Blažič in I. Škrjanc. Evolving fuzzy model for fault detection and fault identification of dynamic processes. V E. Lughofer in M. Seyed-Mouchaweh (Uredniki), *Predictive Maintenance in Dynamic Systems*, str. 269—285. Springer International Publishing, 2019.