

Željka Ujević Andrijić, Romano Karlović, Nenad Bolf, Ivana Šarlija

ISSN 0350-350X

GOMABN 52, 2, 110-121

Izvorni znanstveni rad / Original scientific paper

MODELI ZA KONTINUIRANU PROCJENU SADRŽAJA BENZENA U REFORMATU

Sažetak

U rafinerijskim postrojenjima je radi ograničenja sadržaja benzena u gorivima neophodno kontinuirano pratiti sadržaj benzena u lakom i teškom reformatu. Kako je procesni analizator koji procjenjuje sadržaj benzena često u kvaru, razvijeni su modeli softverskih senzora za kontinuiranu procjenu sadržaja benzena u reformatu. Softverski senzori razvijeni su primjenom viševeličinskih linearnih metoda identifikacije procesa. Razvijeni su linearni dinamički modeli: model konačnog impulsnog odziva [engl. Finite Impulse Response (FIR)] i model izlazne pogreške [engl. Output Error (OE)]. Za pronalaženje najbolje strukture dinamičkih modela primijenjeni su genetički algoritmi, čime su nadograđene i poboljšane postojeće metode razvoja modela softverskih senzora. Razvijeni modeli pokazali su zadovoljavajuću točnost pri usporedbi s rezultatima s postrojenja na skupu podataka za vrednovanje modela. Na postrojenju su implementirani FIR i OE model za procjenu sadržaja benzena u lakom reformatu.

Ključne riječi: softverski senzor, linearni dinamički model, identifikacija

Uvod

Jedan od čestih problema koji se javlja kod motrenja i vođenja procesa je nemogućnost kontinuiranog mjerenja i analize ključnih procesnih veličina, posebice sastava procesnih struja i svojstava proizvoda. Troškovi primjene i održavanja on-line analizatora mogu biti iznimno visoki. Kao alternativa, moguće je na temelju lako mjerljivih veličina u procesu zaključivati o stanju teško mjerljivih veličina određivanjem njihovih funkcijskih veza. U tu svrhu razvijeno je područje inferencijskog mjerenja i vođenja, odnosno primjena softverskih senzora.

Razvoj softverskih senzora područje je velikog interesa pri čemu se, većinom na osnovi empirijskih modela, mogu predviđati stanja procesa koja je teško ili nemoguće mjeriti. Navedena tehnika razvijena je u posljednjih nekoliko godina i postala je naširoko korišteno rješenje. Ona koristi on-line lako mjerive varijable za predviđanje neke kvalitete proizvoda kroz određene pristupe modeliranju, kao što je osnovno modeliranje, statističko modeliranje, modeliranje primjenom umjetne inteligencije, itd.

Kako je distribuirani sustav za vođenje instaliran u većini kemijskih postrojenja, mnoge procesne varijable mogu se mjeriti i pohraniti u realnom vremenu (Ma et al., 2009). Velike količine mjernih podataka pohranjenih u bazama podataka upućuju na primjenu identifikacije modela sive ili crne kutije. Uobičajena procedura razvoja softverskih senzora uključuje (Fortuna et al., 2007):

1. odabir mjernih podataka iz baze podataka
2. predobradu i filtriranje podataka
3. odabir strukture modela i regresora
4. razvoj modela
5. vrednovanje (validiranje) modela

Pri modeliranju realnih sustava mogu se koristiti različite strukture modela. Jedan od mogućih pristupa je započeti s jednostavnom strukturom modela i postupno povećavati njezinu složenost. Odabir regresora i optimalne strukture modela je ključan korak za performanse softverskih senzora (Kadlec et al., 2009). U području industrijskih primjena, u središtu pozornosti je parametarska (polinomna) struktura modela. Pri razvoju dinamičkih polinomnih modela, red modela se mora unaprijed odrediti. Red modela se može definirati kao broj koeficijenata polinoma iz odabrane strukture modela. Mrtvo vrijeme predstavljeno brojem uzoraka prije nego što izlaz reagira na promjenu ulaza također mora biti određeno. Ovisno o odabranoj strukturi modela, potrebno je odrediti i dodatni set parametara.

U slučaju modela s više ulaza s različitim vremenskim zadržkama, određivanje navedenog skupa parametara može postati vrlo složen zadatak. Najčešće se stoga primjenjuje nezgrapan postupak metode pokušaja i pogreške. Za prevladavanje problema odabira najboljeg reda modela, kao i kašnjenja u svakom ulazu i drugih podesivih parametara, u ovom radu se koristio genetički algoritam (GA).

Primarna primjena softverskih senzora razvijenih u ovoj studiji je privremena zamjena mjerne opreme, bilo tijekom održavanja ili u drugim razdobljima nedostupnosti mjerne opreme. Prikazan je razvoj modela konačnog impulsnog odziva (FIR) te modela izlazne pogreške (OE). Budući da FIR i OE modeli ne zahtijevaju prošle uzorke mjerenog izlaza, prilikom provjere valjanosti podataka mogu koristiti kao redundantni partneri mjernih uređaja.

Identifikacija modela

Linearni polinomni dinamički modeli su u mnogim slučajevima dovoljni za primjenu u industrijskim procesima (Ljung, 1999). Jedan od najčešće korištenih dinamičkih parametarskih modela je FIR model koji predstavlja linearnu regresiju nad prošlim mjernim uzorcima ulaznih signala:

$$\hat{y}(t) = \sum_{i=1}^{nu} \mathbf{B}_i(q) \cdot u_i(t - nk_i) \quad (1)$$

$$\hat{y}(t) = \mathbf{B}_1(q) \cdot u_1(t - nk_1) + \dots + \mathbf{B}_2(q) \cdot u_2(t - nk_2) + \mathbf{K} + \mathbf{B}_{nu}(q) \cdot u_{nu}(t - nk_{nu}) \quad (2)$$

gdje je:

q – operator vremenskog pomaka,

$$\mathbf{B}_1(q) = b_{1,1} + b_{1,2}q^{-1} + \mathbf{K} + b_{1,nb_1}q^{-nb_1+1}, \quad (3)$$

$$\mathbf{B}_2(q) = b_{2,1} + b_{2,2}q^{-1} + \mathbf{K} + b_{2,nb_2}q^{-nb_2+1}, \quad (4)$$

$$\dots$$

$$\mathbf{B}_{nu}(q) = b_{nu,1} + b_{nu,2}q^{-1} + \mathbf{K} + b_{nu,nb_{nu}}q^{-nb_{nu}+1}, \quad (5)$$

nu – broj ulaza sustava,


$\hat{y}(t)$ – izlaz modela (predviđeni izlaz) u vremenu t ,

$u_i(t)$ – i -ti ulaz u vremenu t ,

nk_i – vremenska zadržka za i -ti ulaz,

nb_i – broj prošlih vrijednosti ulaza.

Koeficijenti polinoma $\mathbf{B}_i(q)$ mogu se odrediti pomoću metode najmanjih kvadrata ili metode pomoćnih varijabla. Blok dijagram na slici 1 prikazuje strukturu FIR modela.



Slika 1: Blok dijagram FIR modela

Nešto proširena varijanta FIR modela je OE model.


Prediktor OE modela u skraćenom obliku dan je izrazom:

$$\hat{y}(t) = \mathbf{B}(q)u(t - nk) + [\mathbf{I} - \mathbf{F}(q)]\hat{y}(t) \quad (6)$$

$$\mathbf{F}(q) = \mathbf{I} + \mathbf{F}_1q^{-1} + \mathbf{F}_2q^{-2} + \dots + \mathbf{F}_{nf}q^{-nf}, \quad (7)$$

gdje je nf broj uzoraka prije predviđenih vrijednosti izlaza.

Blok dijagram sa slike 2 predstavlja strukturu OE modela.



Slika 2: Blok dijagram OE modela

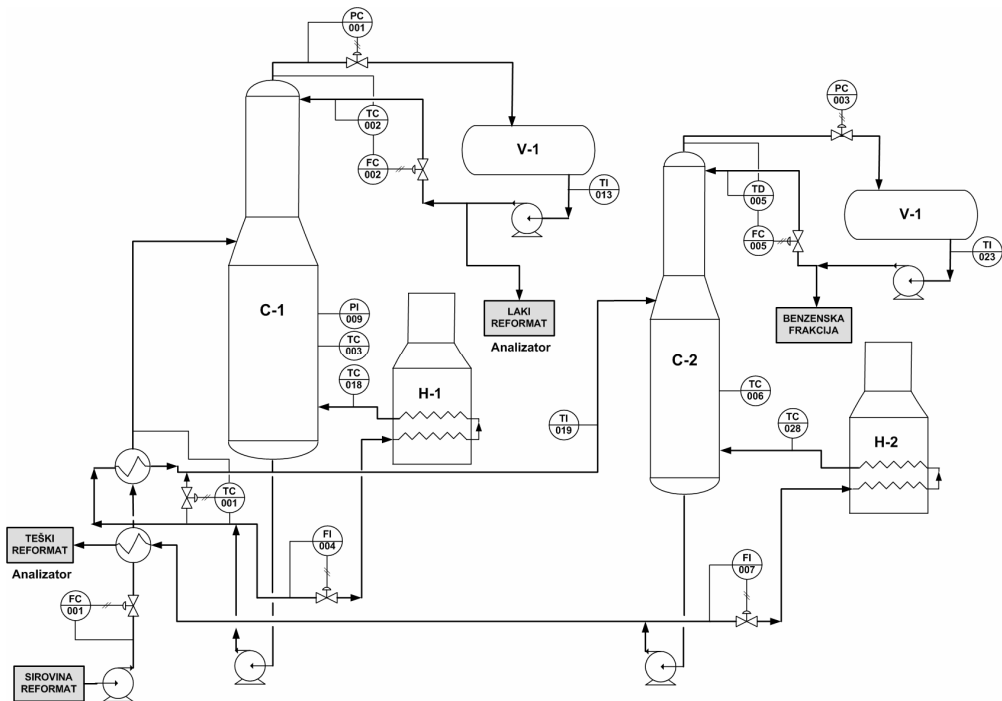
Red od FIR i OE modela (tj. parametri nb , nf i nk) se određuje genetičkim algoritmom. Genetički algoritmi (GA) predstavljaju metodu globalnog optimiranja koja ima visoki potencijal za pronalaženje globalnog optimuma funkcije cilja. U računalnoj simulaciji evolucija počinje od stvaranja populacije nasumično generiranih jedinki. U svakoj generaciji ocjenjuje se primjerenost (funkcija cilja) svake jedinke. Jedinke su stohastički odabrane iz trenutačne populacije na temelju njihove primjerenosti i izmijenjene (rekombinirane-križane i mutirane) kako bi formirale novu populaciju. Nova populacija se koristi u sljedećim iteracijama algoritma. Algoritam se završava kada je dostignut maksimalno postavljen broj generacija ili je postignuta zadovoljavajuća razina primjerenosti (Affenzeller et al., 2009).

Opis procesa

Oko 70-85 % benzena dobivenog u rafinerijskim procesima nalazi se u reformatu iz procesa katalitičkog reformiranja. Katalitički reformat se u kolonama razdijeli na laki reformat, teški reformat i benzenom bogatu frakciju. Iako benzen ima visoki oktanski broj i visoke kalorijske vrijednosti, sadržaj benzena u gornjem produktu kolone C-1, odnosno lakom reformatu ograničen je na 2,7 % masenog udjela, što je manje od 2 vol %. Razlog ograničenju je zbog toga što je benzen prekursor za nastajanje cikloheksana, neželjene komponente benzina u procesu izomerizacije (niski oktanski broj). Također, europske norme za emisije ispušnih plinova (poput EURO IV i EURO V) i MSAT (engl. *Mobile Source Air Toxics*) propisi ograničavaju količinu benzena u benzinu zbog pogubnog utjecaja na okoliš.

Dakle, potrebno je kontinuirano mjerenje sadržaja benzena u reformatu. Problem kontinuirane procjene pomoću procesnih analizatora je što su takvi uređaji pored redovitog često na održavanju zbog kontaminacije sustava za uzorkovanje te što ih je potrebno često umjeravati.

Na slici 4 prikazano je postrojenje za frakcionaciju reformata, s varijablama korištenim za razvoj softverskog senzora. Frakcioniranje lakog reformata (proizvod vrha) se odvija u koloni C1. Frakcioniranje benzenom bogate frakcije (proizvod vrha) iz teškog reformata (proizvod dna) odvija se u koloni C2.



Slika 4. Postrojenje za frakcionaciju reformata

Na osnovi razgovora s tehnolozima s postrojenja, te primjenom Pearsonovih koeficijenta, PCA i PLS analize, odabrane su sljedeće kontinuirano mjerene varijable kao ključne ulazne varijable za procjenu sadržaja benzena u lakom reformatu:

Ulaz 1: temperatura na ulazu u C1, TC-001;

Ulaz 2: temperatura na dnu C1, TC-018;

Ulaz 3: temperatura u C1, TC-003;

Ulaz 4: tlak u C1, PI-009 i

Ulaz 5: protok refleksa , FC-002.

Razvoj softverskih senzora

Procesni podaci kontinuirano mjerenih ulaznih varijabli dobiveni su iz procesne baze podataka u neprekidnom trajanju od tri tjedna, s vremenom uzorkovanja od pet minuta u skladu s dinamikom procesa. Predobrada podataka uključila je otkrivanje podataka koji nedostaju i uklanjanje ekstremnih podataka (engl. *outlier*). Vrijednosti izlazne varijable (sadržaj benzena, vol. %) uzete su iz perioda kada je on-line analizator radio, s vremenom uzorkovanja od dvadeset minuta. Broj ulaznih podataka (uzorkovanih svakih pet minuta) mora odgovarati broju izlaznih podataka, što je zahtijevalo dodatne izlazne podatke. Te vrijednosti su generirane pomoću MARS (*Multivariate Adaptive Regression Splines*) algoritma. Mjerni podaci su također detrendirani (uklonjen je linearni trend iz podataka - pomoću metode najmanjih kvadrata i oduzimanjem tih vrijednosti od izmjerenih vrijednosti uzoraka) i filtrirani pomoću Loess filtra (eng. *locally weighted scatterplot smoothing*).

Nakon predobrade, 6500 podataka podijeljeno je u dva skupa podataka, prvih 4500 za razvoj modela te preostalih 1500 podataka na vrednovanje modela. Za razvoj modela softverskih senzora korišteni su MATLAB-ovi System identification toolbox i Global Optimization toolbox.

A. Optimizacija reda modela korištenjem GA

Budući da je područje pretraživanja optimalnih vrijednosti parametara (tj. broj mogućih rješenja) jako veliko, u svrhu pronalaženja optimalnih parametara iz tablice 1 korišteni su GA. Podesivi parametri (FIR i OE modela) i njihovi rasponi prikazani su u tablici 1. Mjerni opsezi parametara izabrani su na temelju iskustva operatora prilikom promatranja dinamike procesa.

Tablica 1: Podesivi parametri FIR i OE modela

Parametar	Opis	Minimalna vrijednost	Maksimalna vrijednost
<i>nb</i>	Broj prošlih uzoraka ulaza (u svakom modelu postoji 5 <i>nb</i> parametara na temelju 5 ulaza).	1	8
<i>nk</i>	Zadržska ulaza (5 <i>nk</i> parametara na temelju 5 ulaza).	0	15
<i>nf</i>	Broj prošlih vrijednosti predviđenog izlaza.	1	5

Tablica 2 prikazuje ukupan broj parametara koje treba odrediti za pojedini model s 5 ulaza i pripadajući prostor pretraživanja, odnosno ukupan broj mogućih kombinacija parametara. Cilj je iz milijardi mogućih kombinacija parametara pomoću GA pronaći onu kombinaciju koja će najbolje (ili što bliže najboljem) opisati dinamiku procesa.

Važni parametri GA, prikazani u tablici 3, odabrani su na temelju iskustva, kao i racionalnog vremena izračuna. U GA, svaka jedinka u populaciji predstavlja skup mogućih redova modela.

U predloženom GA, u svakoj generaciji od 50 jedinki, 34 jedinke stvorene su postupkom križanja, 15 jedinki je stvoreno mutacijom, a preostala 1 jedinka je elitna jedinka (jedinka s najnižom vrijednosti funkcije cilja iz prethodne generacije). Algoritam završava nakon što je provedeno 60 generacija (iteracija).

Tablica 2: Broj parametara u modelu i prostor pretraživanja

Model	Broj parametara	Prostor pretraživanja
FIR	$5nb + 5nk = 10$	$8^5 \cdot 16^5 = 3,4360 \cdot 10^{10}$
OE	$5nb + 5nk + 5nf = 15$	$8^5 \cdot 16^5 \cdot 5^5 = 1,0737 \cdot 10^{14}$
HW	$5nb + 5nk + 5nf + 6n = 21$	$8^5 \cdot 16^5 \cdot 5^5 \cdot 13^6 = 5,1827 \cdot 10^{20}$

Tablica 3: Parametri GA

Parametar	Vrijednost / Svojstvo
Veličina populacije	50
Broj generacija	60
Broj računanja funkcije cilja	3000
Selekcija	Jednoliko slučajno
Križanje	Križanje u svim točkama
Mutacija	Jednolika
Vjerojatnost mutacije	0,1
Skaliranje funkcije cilja	Po redoslijedu
Broj "elitnih jedinki"	1
Udio križanja	0,7

B. Kriteriji vrednovanja modela i definiranje funkcije cilja

Modeli se vrednuju na temelju statističkih veličina kao što su FIT, FPE i RMS. Funkcija prikladnosti (FIT) modela izračunava se kako slijedi:

$$FIT = \left(1 - \frac{\sqrt{\sum_{i=1}^n (y_i - y_i)^2}}{\sqrt{\sum_{i=1}^n (y_i - y_m)^2}} \right) \cdot 100 \quad (8)$$

y je mjereni izlaz, \hat{y} predviđeni izlaz modela, a y_m je srednja vrijednost od y . 100% odgovara savršenom poklapanju.

FPE kriterij (engl. *Final Prediction Error*) predstavlja kompromis između točnosti modela, izražene točnošću procijenjenih parametara i složenosti modela. Prema teoriji H. Akaike-a, najtočniji model ima najmanji FPE (Verhaegen i Verduin, 2007).

FPE se definira sljedećom jednadžbom:

$$FPE = V \left(1 + \frac{2d}{n} \right), \quad (9)$$

gdje je V funkcija gubitka, d je broj procijenjenih parametara, a n je broj vrijednosti u skupu podataka za razvoj modela.

Funkcija gubitka, V (engl. *loss function*) definira se sljedećom jednadžbom :

$$V = \det \left(\frac{1}{n} \sum_1^n \varepsilon(t, \theta_n) (\varepsilon(t, \theta_n))^T \right), \quad (10)$$

gdje θ_n označava procijenjene parametre, a ε je pogreška izlaza. Srednja kvadratna pogreška, RMS (engl. *Root mean square error*) kao često korišteni kriterij za vrednovanje modela je također prikazana u rezultatima:

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (11)$$

FIT treba imati čim veću vrijednost, a FPE i RMS kao pogreške čim manju vrijednost.

U rezultatima je prikazana i srednja vrijednost apsolutne pogreške:

$$e_{MAE} = \frac{1}{n} \cdot \sum_{i=1}^n \left| \hat{y}_i - y_i \right|. \quad (12)$$

Definiranje funkcije primjerenosti (funkcije cilja) je važan element pri optimiranju GA (Dam i Saraf, 2007). Budući da je preliminarno istraživanje pokazalo da FIT i FPE nisu u korelaciji, ali su često korišteni kriteriji za procjenu valjanosti modela, oni su integrirani u jednu funkciju cilja, kako slijedi:

$$y = (100 - FIT) + 1000 \cdot FPE + 100 \cdot RMS \quad (13)$$


Za postavljanje višekriterijske funkcije cilja koristila se metoda težinskih suma gdje je funkcija cilja linearna kombinacija svih težinskih kriterija (Venkataraman, 2009; Deb, 2009).

Rezultati

Tablica 4 prikazuje mjerno područje i osnovne statističke veličine ulaznih varijabla i izlazne varijable. Na slici 5 prikazano je 6000 mjernih podataka ulaznih varijabla i izlazne varijable.

Tablica 4: Deskriptivna statistika podataka

	Broj uzoraka	Srednja vrijednost	Medijan	Minimum	Maksimum	Stand. devijacija
Ulaz 1, °C	6000	107,40	100,98	89,83	125,35	10,43
Ulaz 2, °C	6000	175,49	175,49	168,80	177,65	0,48
Ulaz 3, °C	6000	125,95	125,74	120,74	138,76	1,66
Ulaz 4, bar	6000	2,02	2,02	1,96	2,09	0,032
Ulaz 7, t/h	6000	41,60	41,31	28,65	62,74	4,01
Izlaz, vol. %	6000	1,20	1,27	0,50	1,89	0,29



Slika 5. Prikaz ulaznih i izlazne varijable

Svi sljedeći rezultati izračunati su i prikazani na setu za validaciju modela koji se sastoji od 1500 podataka. Parametri *nb*, *nf* i *nk* procijenjeni su minimizacijom funkcije cilja (13) pomoću GA postupka, kao što je objašnjeno prije. Koefficienti polinoma $\mathbf{B}_i(q)$ i $\mathbf{F}_i(q)$ procijenjeni su pomoću optimizacijskih metoda integriranih u MATLAB System Identification Toolbox-u. Parametri najboljih dobivenih modela prikazani su u vektorskom obliku u tablici 5. Svojstva dobivenih FIR i OE modela prikazana su u tablici 6.


Tablica 5: Procijenjeni red modela korištenjem GA kao optimizacijske tehnike

	FIR	OE
<i>nb</i>	[6 7 8 8 8]	[6 1 2 3 3]
<i>nk</i>	[5 3 15 5 15]	[1 8 7 9 13]
<i>nf</i>	/	[1 1 2 2 1]

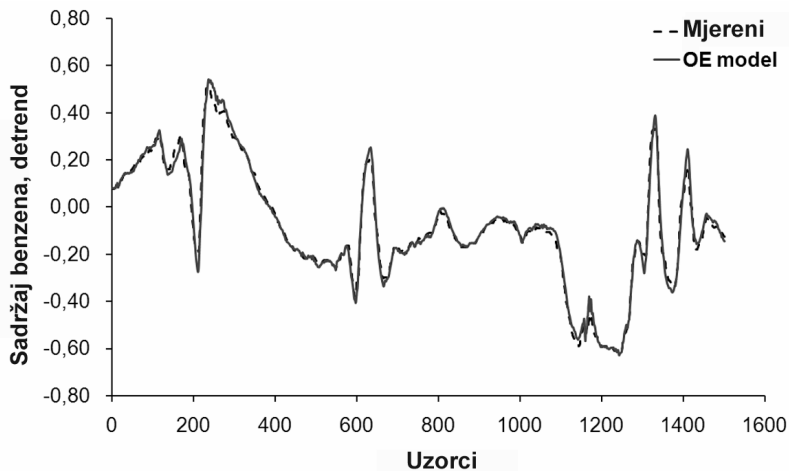
Tablica 6: Svojstva modela

	FIT	FPE	RMS	ϵ_{MAE}
FIR	78,895	0,0064	0,0517	0,0391
OE	90,267	0,0023	0,0239	0,0171

FIR model iako ima relativno jednostavnu strukturu modela, daje zadovoljavajuće rezultate na skupu za vrednovanje modela. U usporedbi s FIR modelom, OE model daje bolje rezultate, s nižim redom modela (niži *nb*) kako se i očekivalo, jer se u obzir uzimaju predviđene prošle vrijednosti izlaza modela.



Slika 6. Usporedba vrijednosti s analizatora i vrijednosti dobivenih FIR modelom



Slika 7: Usporedba vrijednosti s analizatora i vrijednosti dobivenih OE modelom


Slike 6 i 7 prikazuju usporedbu izlaza FIR te OE modela i mjenog izlaza pomoću analizatora na validacijskom skupu podataka. Može se vidjeti da se oba izlaza modela vrlo dobro poklapaju sa podacima za provjeru modela. Također, pripadne statističke vrijednosti FIT, FPE i RMS pokazuju da se eksperimentalni podaci i vrijednosti dobivene modelima u velikoj mjeri slažu.

OE model je očito dao bolje rezultate, ali može postati nestabilan jer ovisi o prošlim vrijednostima izlaza modela. U slučaju kada je neki od ulaza nedostupan iz bilo kojeg razloga te u prestanku rada postrojenja potrebno je određeno vrijeme da OE model opet počne točno računati izlaz. Stoga, preporučljivo je implementirati i FIR model jer je stabilniji zbog svoje strukture i samim time pouzdaniji od OE modela.

FIR i OE modeli ugrađeni su u modul za naprednu regulaciju unutar distribuiranog sustava za vođenje (DCS). Izvedba je provedena pomoću CL (*Control language*) programa u kojem se izračunava vrijednost sadržaja benzena iz polinomskog dinamičkog modela. Tako dobivene nove procesne točke pohranjuju se u procesnoj bazi podataka (PHD) odakle su dostupne operatorima i tehnolozima s postrojenja kao numeričke vrijednosti ili kao trend.

Valjanost primijenjenih modela trenutačno se ne može u potpunosti ispitati na postrojenju, jer je procesni analizator sadržaja benzena (čiju svrhu sada obavlja model) dulje vrijeme izvan funkcije. Rezultati dobiveni modelom se, stoga, uspoređuju s laboratorijskim analizama koje se provode jedan-dva puta dnevno.

Kao što se može vidjeti sa slike 8, implementirani FIR model daje zadovoljavajuće rezultate u usporedbi s laboratorijskim analizama sadržaja benzena. U budućnosti treba napraviti fino podešavanje modela čim procesni on-line analizator opet stupi u funkciju.



Slika 8: Usporedba vrijednosti iz laboratorija i vrijednosti dobivenih FIR modelom

Zaključak

Razvijeni su linearni dinamički modeli za procjenu sadržaja benzena u lakom reformatu. Da bi se izbjegla metoda pokušaja i pogreške, GA metoda je predložena za određivanje reda modela, što čini razvoj softverskih senzora sustavnijim. Izabrani modeli pokazuju zadovoljavajuću podudarnost s eksperimentalnim podacima, čime se dokazuje da se mogu koristiti za *on-line* procjenu sadržaja benzena u lakom reformatu. Opisani postupak pokazuje da se GA može na zadovoljavajući način primijeniti za optimiziranje podesivih parametara ulazno-izlaznih polinomnih modela. FIR i OE model se mogu uspješno implementirati na postrojenju kao softverski senzori za kontinuirano predviđanje sadržaja benzena u reformatu.

Literatura

1. M. Ma, J. Ko, S. S. Wang, M. Wu, S. Jang, S. Shieh, D. S. Wong, *Development of adaptive soft sensor based on statistical identification of key variables*, Control Eng. Pract. 2009, 17, 1026.
2. L. Fortuna, S. Graziani, A. Rizzo, M.G. Xibilia, *Soft Sensors for Monitoring and Control of Industrial Processes* (Advances in Industrial Control), Springer, London, 2007.
3. B. Kadlec, B. Gabrys, S. Strandt, *Data-Driven Soft Sensors in the Process Industry*, Comput. Chem. Eng. 2009, 33, 795.
4. L. Ljung, *System Identification: Theory for the User*; Prentice Hall: New Jersey, 1999.
5. M. Affenzeller, S. Winkler, S. Wagner, A. Beham, *Genetic Algorithms and Genetic Programming - Modern Concepts and Practical Applications*; Taylor & Francis Group: Boca Raton, 2009.
6. M. Verhaegen, V. Verduin, *Filtering and System Identification*; Cambridge Univ. Press: New York, 2007.
7. M. Dam, D. N. Saraf, *Design of neural networks using genetic algorithm for on-line property estimation of crude fractionator products*, Comput. Chem. Eng. 2006, 30, 722.
8. P. Venkataraman, *Applied optimization with MATLAB programming*; John Wiley&Sons: New York, 2009.
9. K. Deb, *Multi-objective optimization using evolutionary algorithms*; John Wiley&Sons: New York 2009.

Autori

Željka Ujević Andrijić¹, Romano Karlović², Nenad Bolf¹, Ivana Šarlija², e-adresa: zujevic@fkit.hr

¹ Fakultet kemijskog inženjerstva i tehnologije, Sveučilište u Zagrebu, Zagreb, Hrvatska

² INA Industrija nafte d.d., Sektor Rafinerija nafte Rijeka

Primljeno: 01.10.2012.

Prihvaćeno: 05.02.2013.