

Ivica Jerbić, Hrvoje Pavelić, Nenad Bolf

ISSN 0350-350X
GOMABN 46, 2, 149-168
Izvorni znanstveni rad / Original scientific paper
UDK UDK 681.513.7/.8 : 681.513.7 : 681.513.8

SOFTVERSKI SENZOR ZA VOĐENJE PROCESA U DEBUTANIZERSKOJ KOLONI

Sažetak

Zakonska regulativa nalaže čvrsta ograničenja specifikacije produkata i emisije iz rafinerijske prerade. Za djelotvorno vođenje procesa potrebno je mjeriti velik broj procesnih veličina te instalirati sve veći broj skupih mjernih i analitičkih instrumenata. Moguće rješenje ovog problema je u primjeni softverskih senzora, tj. modela procesa za predviđanje varijabli koje se ne mijere kontinuirano.

U ovom radu prikazano je projektiranje softverskog senzora primjenom neuronske mreže za nadgledanje kvalitete produkta i vođenje procesa u debutanizerskoj koloni u INA-Rafineriji naftе Sisak na temelju raspoloživih procesnih mjerjenja. Vođenje procesa u debutanizerskoj koloni vrlo je važno u rafinerijskoj proizvodnji zbog održanja kvalitete proizvoda.

Razrađena je metoda predviđanja sadržaja C_5 frakcije u ukapljenom naftnom plinu (UNP) i tlaka para po Reidu (RVP) u stabiliziranom FCC benzinu primjenom inferencijskih modela. Softverski senzor rješava problem vremenske zadrške radi laboratorijske analize, što omogućuje «on-line» nadziranje i praćenje kvalitete produkta. Svrha je voditi proces tako da udio C_5 frakcije u UNP-u bude manji od 2 %, a RVP bude na željenoj vrijednosti (50 kPa). Istraživanje vladanja procesa provedeno je simulacijski, a dobiveni rezultati validirani su usporedbom s eksperimentalnim podacima.

Uvod

U mnogim procesima i postrojenjima teško je kontinuirano i pouzdano mjeriti ključne procesne veličine. Vođenje takvih procesa ovisi o laboratorijskim analizama koje su vrlo često dugotrajne. Iz tih razloga pojavila se potreba za integracijom intelligentnih softvera i mikroprocesora pomoću kojih bi se pratio velik broj fizikalnih, kemijskih i

biokemijskih varijabli. Razvoj suvremenih inteligentnih osjetila koji se temelje na novim metodama analitičke kemije i modernim elektroničkim uređajima uporabom optičkih vlakana i poluvodiča za kontinuirano mjerjenje procesnih veličina danas je vrlo aktivno područje istraživanja. Kao alternativa tim skupim instrumentima i uređajima moguće je na temelju lako mjerljivih sekundarnih veličina, kao što su temperatura, tlak i protok, zaključivati o stanju teško mjerljivih veličina određivanjem njihovih funkcijskih veza [1]. U tu svrhu razvijeno je područje inferencijskog mjerjenja i vođenja, odnosno primjena softverskih senzora.

U radu je primijenjen model softverskog senzora kod procesa u debutanizerskoj koloni kako bi se omogućilo kontinuirano praćenje sadržaja C₅ frakcije ugljikovodika u ukapljenom naftnom plinu (UNP) i tlaka para po Reidu (RVP) u stabiliziranom FCC benzинu.

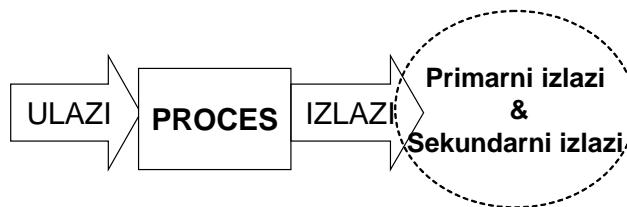
Softverski senzori

Softverski senzor definira se kao model, analitički ili empirijski, koji služi za procjenu nemjerljivih stanja procesa na temelju dostupnih mjerjenja ulaznih i izlaznih veličina. Sve ključne veličine u procesu ne mogu se mjeriti u stvarnom (realnom) vremenu, odnosno dovoljno brzo da bi se koristili za automatsko vođenje procesa. Za to postoji više razloga:

- Neke metode analitičkih mjerjenja nisu dovoljno automatizirane da pruže točno i pouzdano mjerjenje. Rezultate ovakvih mjerjenja dobivamo samo povremeno iz laboratorijskih određivanja.
- Postoje određena svojstva proizvoda koja se ne mogu određivati iz karakteristika poluproizvoda u pogonu.
- Trošak instaliranja senzora prevelik je da bi se opravdao potencijalnim koristima koje donosi.
- Senzor ne može pružiti informaciju pravodobno (npr. analizator može imati veliko "mrtvo" vrijeme, ili je smješten dalje od samog procesa, dugo vrijeme obrade podataka).

Nedostatak pravodobnog mjerjenja ključnih veličina otežava automatsko vođenje, ali ne znači da ga je uvijek nemoguće provesti. Dodatne informacije mogu se dobiti mjerjenjima veličina (sekundarne veličine) koje, iako ne daju savršenu indikaciju ključne veličine koja se ne mjeri (primarna veličina), omogućuju korisne zaključke.

Slika 1: Sustavski ulazno-izlazni prikaz procesa



Metode razvoja softverskih senzora

Pri razvoju softverskih senzora cilj je naći funkciju vezu između primarnog izlaza i sekundarnih ulaza i izlaza. U većini slučajeva, budući da se radi o složenim kemijskim procesima, teško je primijeniti temeljne matematičke modele, stoga se češće primjenjuju modeli koji se razvijaju na temelju eksperimentalnih podataka pomoću linearnih vremenskih nizova, umjetnih neuronskih mreža i genetičkih algoritama. Najčešće se koriste estimatori što se temelje na linearnim modelima procesa. Dvije su osnovne grupe estimatora: modelski i nemodelski. Od modelskih estimatora najviše se primjenjuje Kalmanov filter, koji daje optimalno predviđanje veličina uz pretpostavku da su procesni i mjerni šumovi Gaussovi bijeli šumovi. Estimatori što ne zahtijevaju prethodno poznavanje modela procesa temelje se na poznavanju ulazno-izlaznih podataka, te tehnikama multivarijantne statistike, kao što su tehnika analize glavnih komponenata (engl. *Principal Component Analysis, PCA*) i tehnika parcijalnih najmanjih kvadrata (engl. *Partial Least Squares, PLS*). [2]

Linearni estimatori ne daju dobre rezultate kad se radi s nelinearnim procesima, pa je za procjenu veličina kod vrlo složenih procesa primjereno koristiti nemodelske estimatori. Ovi se estimatori dobivaju na osnovi ulazno-izlaznih podataka dobivenih iz procesa. Najčešće se koriste proširenja nelinearnih metoda multivarijantne statistike, tj. razvijaju se nelinearna analiza glavnih komponenata (engl. *non-linear principal component analysis, NLPCA*) i nelinearne metode parcijalnih najmanjih kvadrata (engl. *non-linear parcial least squares, NLPLS*) te njihove kombinacije s regresijskim tehnikama od kojih su najznačajnije regresija glavnih komponenata (engl. *Principal Component Regression, PCR*) i regresija parcijalnih najmanjih kvadrata (engl. *Partial Least Squares Regression, PLSR*).

Zadatak projektiranja nemodelskog estimatora sastoji se od odabira najbolje strukture estimatora, u skladu sa specifičnostima zadatka koji se rješava i postavljenim zahtjevima za kvalitetom procjene procesne veličine. Pri odabiru strukture nemodelskih estimatora sve se češće primjenjuju metode umjetne inteligencije, među kojima je najčešća primjena umjetnih neuronskih mreža, zbog njihova svojstva univerzalne aproksimacije nelinearnih funkcija [2,3].

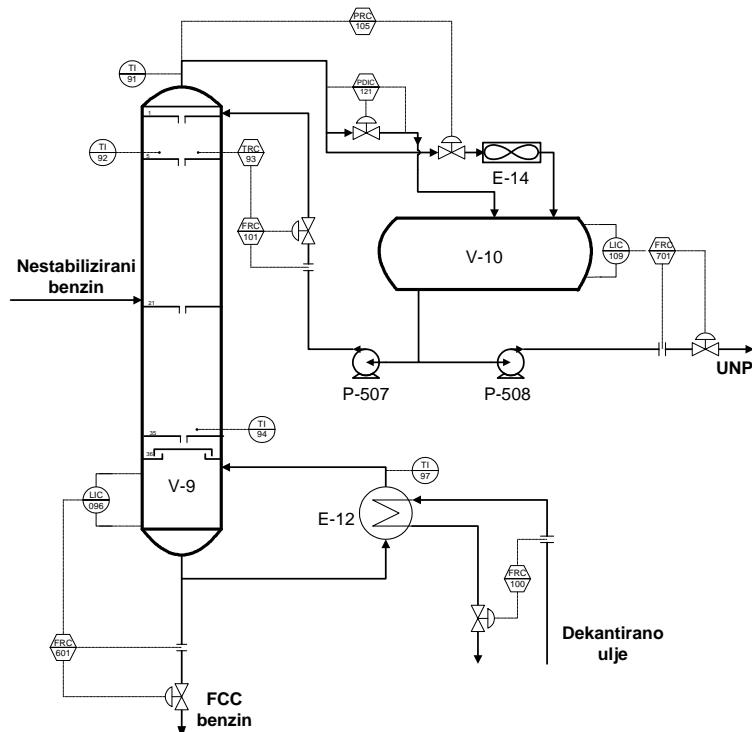
Primjena softverskih senzora u procesnoj industriji

Primjena softverskih senzora za predviđanje teško mjerljivih procesnih veličina iznimno je financijski i tehnički zanimljiva. Posebno je to slučaj u procesnoj industriji, gdje obično postoji veliki broj veličina koje se kontinuirano i brzo mijere, a koje mogu poslužiti kao ulazni signali za softverski senzor. Isto tako, procesi u kemijskoj industriji obično imaju relativno sporo dinamičko vladanje s velikom vremenskom zadrškom, a budući da se softverski senzor realizira u računalu, može procjenjivati veličine unaprijed, mnogo prije stvarnog izlaza iz procesa. Na taj način je moguća primjena prediktivnog vođenja, odnosno moguće je djelovati na proces prije nego što se javi posljedica zbog pojave poremećaja [4].

Eksperimentalni dio

Ispitivanja su provedena na debutanizerskoj koloni koja je dio plinsko-koncentracijske sekcije FCC postrojenja u Rafineriji nafte Sisak. Njezina uloga je stabilizacija FCC benzina, odnosno odvajanje ukapljenog naftnog plina (UNP), koji se pretežito sastoji od C₃ i C₄ ugljikovodika. Shema procesa prikazana je na slici 2.

Slika 2: Prikaz debutanizerske kolone



Kolona se napaja nestabiliziranim FCC benzinom, a produkti su ukapljeni naftni plin (UNP) i stabilizirani FCC benzin. UNP se dodatno obrađuje na DEA i MEROX postrojenju i nakon toga postaje komercijalni proizvod. Drugi produkt, FCC benzin, služi kao komponenta za namješavanje motornih benzina. Ovisno o zahtijevanoj kvaliteti motornih benzina, dodatno se obrađuje na MEROX postrojenju ili na Sulf-X procesu.

Proces u debutanizerskoj koloni potrebno je voditi tako da sadržaj C₅ frakcije u UNP-u bude manji od 2 % zbog zadovoljavanja specifikacije o kvaliteti UNP-a, dok je tlak para po Reidu (RVP) FCC benzina potrebno održavati na vrijednostima (70-85 kPa) određenim sezonskim specifikacijama o kvaliteti motornih benzina. Iznimno,

kada FCC benzin ide na obradu na Sulf-X proces, potrebno je vrijednost RVP održavati ispod 50 kPa zbog konstrukcijskih ograničenja stripner kolone i kolone za ekstraktivnu destilaciju Sulf-X procesa.

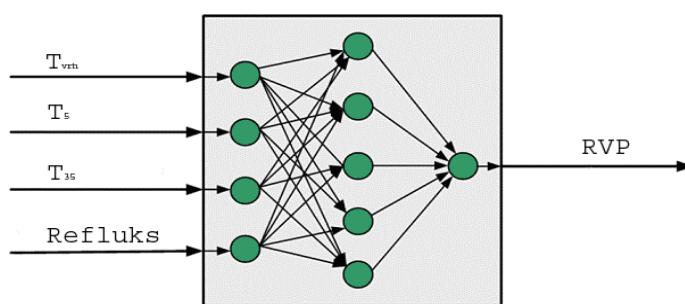
Varijable kojima se održava zahtijevana kvaliteta produkata su temperatura vrha i dna kolone, temperature karakterističnih tavana kao i protok refluksa. Temperatura 5. tavana kolone održava se regulatorom temperature TRC-93 koji je kaskadno povezan s regulatorom protoka refluksa FRC-101. Temperatura dna kolone, odnosno 35. tavana održava se reguliranjem protoka grijućeg medija kroz rebojler dna kolone. Poremećajne varijable su varijacije protoka, temperature i sastava nestabiliziranog benzina koji napaja kolonu.

Rezultati i rasprava

Neuronski model softverskog senzora

Neuronski modeli soft-senzora razvijeni su na temelju raspoloživih procesnih mjerena i laboratorijskih analiza te softverskog simulacijskog modela. Procesne varijable na postrojenju mjere se kontinuirano i zapisuju u memoriju DCS sustava te postoji raspoloživa baza podataka temperatura i protoka. Da bi se kontinuirano pratila kvaliteta produkata, razvijena su dva neuronska modela softverskog senzora; jedan za predviđanje sadržaja C_5 frakcije u UNP-u, a drugi za predviđanje RVP vrijednosti stabiliziranog FCC benzina. Struktura neuronske mreže za predviđanje RVP-a prikazana je na slici 3. Mrežu čine ulazni i izlazni slojevi te skriveni sloj s pet procesnih jedinica. Ulazi u mrežu su temperatura vrha kolone, T_v , temperatura 5. tavana, T_5 , temperatura 35. tavana, T_{35} , te protok refluksa, a mreža predviđa RVP vrijednost stabiliziranog FCC benzina. Analogno tome, izvedena je i mreža za predviđanje udjela C_5 u UNP-u. Baze podataka za sadržaj C_5 u UNP-u te tlak para po Reidu FCC benzina limitirane su dinamikom laboratorijskih analiza. Stoga je razvijen softverski simulacijski model pomoću kojega su generirani dodatni podaci kojima su mreže poučavane i testirane.

Slika 3: Struktura primjenjene neuronske mreže za predviđanje RVP-a



U pripremi podataka prije učenja neuronske mreže provedeni su sljedeći koraci:

- generiranje dodatnih podataka na temelju simulacijskog istraživanja;
- priprema i normiranje podataka za učenje mreže.

Za učenje je korištena statička unaprijedna neuronska mreža, a učenje je provedeno primjenom adaptivne gradijentne metode opisane u literaturi [5].

Kaskadno učenje neuronske mreže

Kaskadno učenje temelji se na Cascade-Correlation Learning paradigmii [5]. Učenje počinje bez skrivenih procesnih elemenata. Jedine veze su direktnе veze između ulaznog sloja (i biasa) i izlaznog sloja. Skrivenе jedinice dodaju se jedna po jedna. Skriveni procesni elementi primaju ulaze iz svih prethodnih skrivenih procesnih elemenata, isto kao i iz ulaznog vektora; drugim riječima, skriveni sloj ima kaskadne veze.

Osnovni oblik kaskadno-korelacijskog algoritma učenja djeluje na slijedeći način:

1. Učenje direktnih veza od ulaznog sloja i biasa do izlaznog sloja. Poučava se za unaprijed definiran broj iteracija, ili sve dok se RMS izlazne pogreške ne stabilizira.
2. Iteracijski se izvode slijedeći koraci:
 - Učenje novog skrivenog neurona da bi se maksimirala korelacija između njegovog izlaza i iznosa ostatka pogreške na izlazu za trenutačni vektor koji se poučava. Skrivena jedinica koja još nije uvježbana naziva se kandidatom. Kad se učenje stabilizira, ili nakon zadanog broja iteracija, učenje se zaustavlja za dolazeće veze na taj procesni element. U ovoj točki se za skriveni procesni element može reći da je «prihvaćen» (engl. *tenured*).
3. Povezivanje novo prihvачene skrivenе jedinice na sve neurone u izlaznom sloju, i nasumice iniciranje težina tih veza;
 - Učenje svih težinskih koeficijenata svih veza od ulaznog sloja, biasa i prihvaćenih skrivenih jedinica do izlaznog sloja. Učenje se odvija prema unaprijed definiranom broju iteracija ili sve dok se RMS izlazne pogreške ne stabiliziraju.

Iteracija se ponavlja sve dok izvedba mreže (npr. RMS pogreška računata za skup podataka za testiranje) više ne pokazuje poboljšanje.

Na slici 4 prikazan je dio rezultata testiranja neuronskog modela za predviđanje RVP vrijednosti FCC benzina. Radi se o podacima koji su korišteni za učenje, odnosno izgradnju modela neuronske mreže. Očekivano, rezultati pokazuju vrlo dobro slaganje. U tablicama 1 i 2 dani su statistički pokazatelji modela neuronskih mreža. U ovom kontekstu, skup za učenje je skup podataka korištenih za ugađanje parametara modela. Skup za testiranje koristi se u fazi izgradnje modela procesa da bi se spriječilo "pretreniranje" (engl. *overfitting*). Skup za validiranje se koristi kao dodatni nezavisni skup za ocjenu valjanosti modela softverskog senzora. Svi faktori u ovoj tablici izračunati su s obzirom na eksperimentalne vrijednosti izlaza. Prije učenja, realne fizikalne vrijednosti transformirale su se u interne normirane

vrijednosti prikladne za obradu neuronskom mrežom. Dobiveni izlazi transformiraju se u realne izlaze primjenom inverzne transformacije.

Tablica 1: Statistički parametri modela neuronske mreže za predviđanje C₅ u UNP-u

C ₅ u UNP-u	Br. podataka	Avg. Abs.	Max. Abs.	RMS	Conf. Int. (95%)
Učenje	96	0,10106	1,152207	0,2917485	0,576
Testiranje	77	0,101553	1,152207	0,2957075	0,586
Validiranje	19	0,099062	1,126737	0,2751214	0,579

Tablica 2: Statistički parametri modela neuronske mreže za predviđanje RVP-a FCC benzina

RVP FCC	Br. podataka	Avg. Abs.	Max. Abs.	RMS	Conf. Int. (95%)
Učenje	96	0,05574	0,12725	0,06647	0,13121
Testiranje	77	0,05368	0,12725	0,06405	0,12691
Validiranje	19	0,06408	0,12203	0,0755	0,15875

pri čemu su:

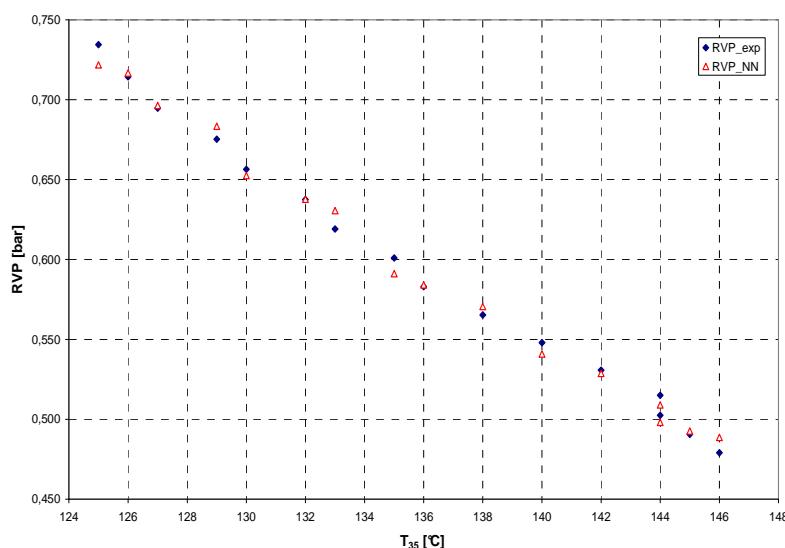
Avg. Abs. - srednja apsolutna pogreška između ciljanog izlaza i predviđanja mrežom;

Max. Abs. - maksimalna apsolutna pogreška između ciljanog izlaza i predviđanja mrežom;

RMS - korijen srednje kvadratne pogreške između ciljanog izlaza i predviđanja mrežom;

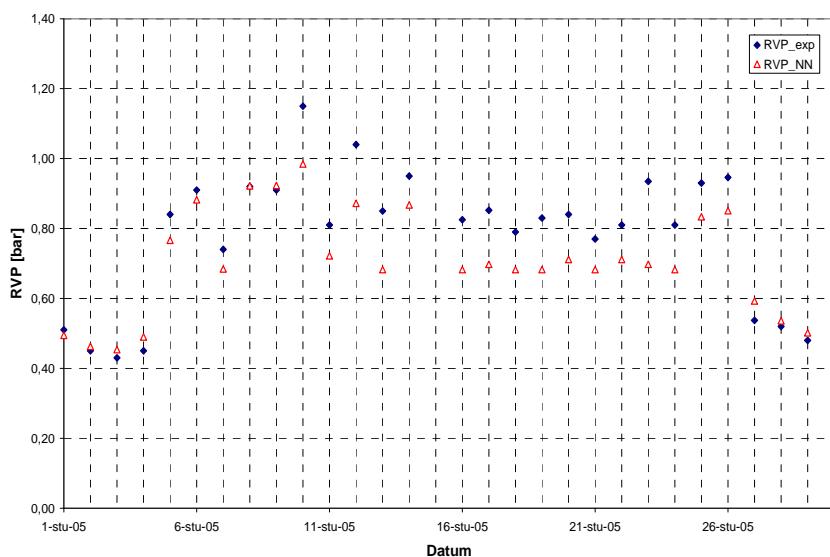
Conf. Interval – područje unutar kojeg se predviđani izlaz javlja u 95 % slučajeva.

Slika 4: Rezultati testiranja softverskog senzora za predviđanje RVP vrijednosti FCC benzina

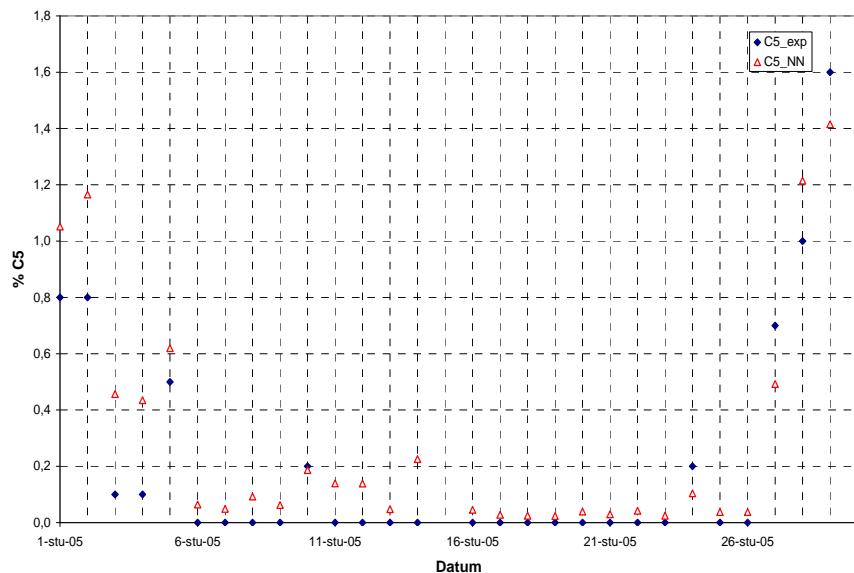


Razvijeni neuronski modeli softverskih senzora dodatno su provjereni eksperimentalnim podacima iz baze podataka DCS sustava i tako dobiveni rezultati uspoređeni su s odgovarajućim rezultatima laboratorijskih analiza. Podaci su uzeti iz analiza provedenih tijekom mjeseca studenog 2005. godine. Slika 5 prikazuje usporedbu eksperimentalnih rezultata dobivenih laboratorijskom analizom i rezultata dobivenih softverskim senzorom za predviđanje RVP vrijednosti stabiliziranog FCC benzina. Vidljivo je da model softverskog senzora dobro slijedi trend promjene vrijednosti RVP-a, ali da su prisutna određena odstupanja. Ta odstupanja mogu se objasniti nesavršenošću simulacijskog modela, kao i činjenicom da se najviše dostupnih podataka iz laboratorijskih analiza nalazi na području oko 50 kPa. Mreža, stoga, ima bolja aproksimacijska svojstva upravo pri tim vrijednostima. Analogno, na slici 6 prikazana je usporedba za softverski senzor koji predviđa sadržaj C₅ frakcije u UNP-u. Najviše dostupnih podataka iz laboratorijskih analiza bilo je na vrijednostima u području od 0 - 0,2 % C₅ stoga je razumljivo da se mrežom bolje aproksimiraju niže vrijednosti sadržaja C₅ frakcije. Statistički parametri procjene oba modela neuronskih mreža prikazani su u tablici 3.

Slika 5: Usporedba eksperimentalnih rezultata dobivenih laboratorijskom analizom i rezultata dobivenih softverskim senzorom za RVP FCC benzina



Slika 6: Usporedba eksperimentalnih rezultata dobivenih laboratorijskom analizom i rezultata dobivenih softverskim senzorom za sadržaj C₅ frakcije u UNP-u



Tablica 3: Statistički parametri kod validiranja modela

	Broj podataka	Avg. Abs.	Max. Abs.	RMS	Stand. devijacija
RVP	29	0,08	0,24	0,5660	0,1050
C ₅	29	0,1	0,4	0,8396	0,1559

Zaključak

U ovom radu opisani su modeli softverskih senzora primjenom neuronskih mreža. U svrhu procjene veličina koje se ne mogu kontinuirano mjeriti u procesu razvijena su dva modela softverskih senzora - prvi za predviđanje sadržaja C₅ frakcije u ukapljenom naftnom plinu i drugi za predviđanje vrijednosti tlaka para po Reidu stabiliziranog FCC benzina.

Razvijeni modeli pokazali su da se neuronska mreža može primijeniti kao «inteligentni» senzor u procesu koji može pouzdano i zadovoljavajuće precizno, na temelju sekundarnih mjerjenja, procjenjivati vrijednost primarne veličine u procesu. Razvoj inferencijskih senzora i njihova primjena ne zahtijevaju velika ulaganja, jer se inferencijski senzor realizira kao programski modul u računalu, koji na temelju lako

mjerljivih veličina i dostupnih ulaznih veličina predviđa vrijednosti teško mjerljivih procesnih veličina.

Izgrađeni softverski senzori mogu poslužiti u dalnjem istraživanju i optimiranju procesa jer se na toj osnovi mogu razviti metode inferencijskog vođenja. Te metode mogu se relativno jednostavno primijeniti u sustavu za automatsko vođenje procesa i u slučaju kad vođene veličine, kao što je ovdje slučaj, nije moguće mjeriti kontinuirano. Isto tako, moguće je razmotriti primjenu softverskih senzora i kod drugih rafinerijskih procesa u svrhu unapređenja vođenja procesa i postizanja zahtijevane kvalitete produkata.

Zahvala

Autori se zahvaljuju dipl. ing. Miloradu Đukiću, rukovoditelju proizvodnje INA-Rafinerije nafte Sisak, na stručnoj pomoći.

Literatura / References:

1. MARTIN, G. D., Consider Soft Sensors, *Chem. Eng. Prog.*, July 1997., pp. 66–70, 1997.
2. PETROVIĆ I., DOMIJAN P., JELAVIĆ M., Estimation of Lube Oil Viscosities on a Vacuum Distillation Column, *ICIT 2003*, Maribor, pp. 265-270, 2003.
3. BOLF, N., JERBIĆ, I., Primjena umjetnih neuronskih mreža pri identificiranju i vođenju procesa, *Kem. Ind. Vol 56*, br.11, 2006.
4. BOLF, N., GLASNER M., JERBIĆ I., Application of Soft Sensors and Inferential Control in Chemical & Biochemical Process Control, *Proceeding of the International Conference "Intelligent Control Systems"*, Brno, Czech Republic, pp. 194-198, 2005.
5. Neuralware, *Neural Computing - A Technology Handbook for Professional II/Plus and NeuralWorks Explorer*, NeuralWare Inc., Pittsburgh, USA, 2001.

UDK	ključne riječi	key words
681.513.7/8	neuronska mreža	neural network
681.513.7	samoučeći sustav vođenja	selflearning control system
681.513.8	samoorganizirajući sustav vođenja	selforganizing control system

Autori / Authors:

Ivica Jerbić*, Hrvoje Pavelić**, Nenad Bolf ***

*INA Rafinerija Nafte Sisak, A. Kovačića 1, 44000 Sisak, ivica.jerbic@ina.hr

**UOP Limited, 'Liongate', Ladymead, Guildford, Surrey GU1 1AT, England,
hrvoje.pavelic@uop.com

***Fakultet kemijskog inženjerstva i tehnologije, Zavod za mjerenja i automatsko vođenje procesa, Marulićev trg 19, 10 000 Zagreb, bolf@fkit.hr

Primljeno / Received:

18.7.2006.

Ivica Jerbić, Hrvoje Pavelić, Nenad Bolf

ISSN 0350-350X
GOMABN 46, 2, 149-168
Izvorni znanstveni rad / Original scientific paper
UDK UDK 681.513.7/.8 : 681.513.7 : 681.513.8

SOFT SENSOR FOR DEBUTANIZER COLUMN PROCESS CONTROL

Abstract

Law regulations dictate restrictions of product quality specifications and refinery emissions. Measurement of great number of process variables and installing new expensive process analyzers is necessary for efficient process control. Possible solution of this problem is application of soft-sensors i.e. the process model that is used for variable estimations which are not measured in continuous manner.

This paper describes soft-sensor design for product quality monitoring and process control of debutanizer column of INA Oil Refinery Sisak. Neural network model is developed based on available process measurement with the purpose of product quality monitoring and process control enhancement.

Method of estimation of pentane fraction in liquefied petroleum gas (LPG) and Reid vapour pressure of stabilized FCC gasoline using inferential model is elaborated. Soft-sensor deals with lag of laboratory analysis and provides on-line product quality monitoring. The aim is to control process in debutanizer column thus pentane fraction in LPG is kept under 2 mass percent and RVP of FCC gasoline on desired value (50 kPa). The investigation involves the simulation study and validation of achieved results by comparison with the experimental data.

Introduction

In many processes and plants, it is difficult to continuously and reliably measure the key process values. Control of such processes is dependent on laboratory analyses which are usually time-consuming. For this reason, there is a need for the integration of intelligent software and microprocessors in order to monitor a number of physical, chemical and biochemical variables. The development of modern intelligent sensors based on new methods of analytical chemistry and modern

electronic devices using optical fibres and semi-conductors for continuous measurement of process values, today constitutes a most active research area. As an alternative to these costly instruments and devices, it is possible – based on easily measurable secondary values, such as temperature, pressure, and flow, to derive conclusions on the condition of difficultly measurable values, by determining their functional ties [1]. For this purpose, the area of inferential measurement and control has been developed; in other words: the application of software sensors.

In the present paper, we have applied the model of software sensor for the process in debutanizer column in order to enable continuous monitoring of pentane content in LPG and RVP values in stabilized FCC gasoline.

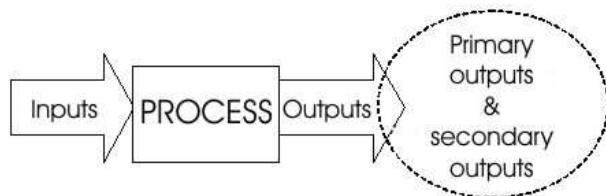
Soft Sensors

Soft sensor is defined as a model - analytical or empirical, serving for the estimation of unmeasurable process states, based on the available measurements of input and output values. All key values in the process cannot be measured in real time i.e. fast enough in order to be used for automatic process control. There are several reasons for this:

- Some methods of analytical measurements are not automatized enough in order to offer precise and accurate measurements. The results of such measurements are obtained only occasionally from the laboratory.
- There are some product properties which cannot be determined from the properties of semi-products at the plant.
- The costs of installing sensors are too high to be justified by potential benefits brought about by the sensor.
- The sensor cannot offer timely information (e.g. analyzer may have considerable “dead” time or be located away from the process itself, long data processing time).

The lack of timely measurement of key values renders automatic control difficult, but this does not mean that it is always impossible to perform. Additional information may be obtained by measuring values (secondary values) which, although they do not provide a perfect indication of the key value not being measured (primary value), do provide useful conclusions, Figure 1.

Figure 1: Systematic input-output process scheme



Soft Sensors Development Methods

When developing soft sensors, the purpose is to find the functional connection between the primary output and the secondary inputs and outputs. In most cases, since we are dealing with complex chemical processes, it is difficult to apply fundamental mathematical models, so that more frequently applied are the models developed on the basis of experimental data, using linear temporal sequences, artificial neural networks, and genetic algorithms. Most frequently used are estimators based on linear process models. Two basic groups of estimators are: model and non-model. Out of model estimators, most frequently applied is the Kalman's filter, providing an optimal estimation of values assuming that the process and measurement noise is Gauss's white noise. Estimators not requiring preliminary knowledge of the process model are based on knowing the input-output data, and techniques of multivariate statistics, such as the *Principal Component Analysis – PCA* and the *Partial Least Squares – PLS* techniques. [2]

Linear estimators do not provide good results when it comes to non-linear processes, so that – in case of estimating values in very complex processes, it is more appropriate to use non-model estimators. These estimators are obtained on the basis of input-output data from the process. Most frequently used are the extensions of nonlinear techniques of multivariate statistics i.e. developed are the non-linear *Principal Component Analysis (NLPCA)* and the nonlinear technique of *Partial Least Squares (NPLS)* and their combinations with regression techniques, the most significant being the *Principal Component Regression – PCR* and the *Partial Least Squares Regression - PLSR*.

The task of designing a non-model estimator consists in choosing «the best structure» of the estimator, in keeping with specific tasks to be resolved and the set requirements for the quality of estimating the process value. When choosing the structure of non-model estimators, growingly frequent is the application of artificial intelligence methods and techniques, the most frequent among which is the application of artificial neural networks, due to their property of universal approximation of non-linear functions [2,3].

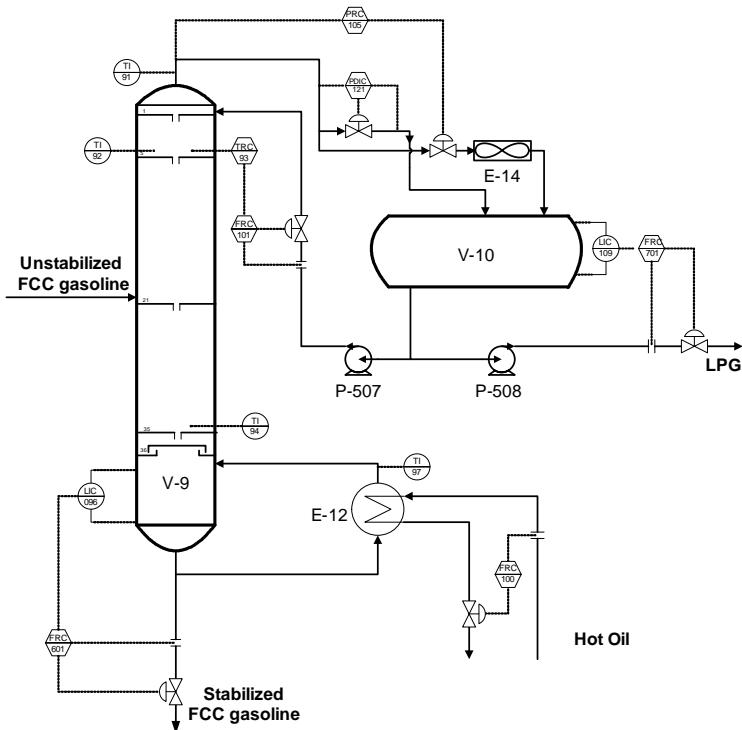
Application of Soft Sensors in Process Industry

The application of soft sensors for estimating difficultly measurable process values is extremely interesting in terms of both cost-effectiveness and technology. This is particularly true of the process industry, where there is usually a large number of values measured continuously and quickly, while they may serve as input signals for the soft sensor. Also, processes in chemical industry usually have relatively slow dynamic behaviour with a major temporal delay, and, since the soft sensor is being realized in a computer, it may estimate values in advance, much before the real process output. In this way it becomes possible to apply predictive control i.e. to influence the process before there are consequences due to disturbances [4].

Experimental Part

Debutanizer column is located within the gas-concentration section of the FCC plant at Refinery Sisak. Its role is to stabilize FCC gasoline i.e. isolate liquefied petroleum gas (LPG) - consisting mostly of C₃ and C₄ fraction - from the FCC gasoline. The process outline is given in Figure 2.

Figure 2: Debutanizer column P&I diagram



The column is filled by unstabilized FCC gasoline, with products being LPG and stabilized FCC gasoline. LPG is additionally treated at DEA and MEROX plants, after which it becomes a commercial product. The other product, FCC gasoline, serves as a component for blending motor gasoline. Depending on the required motor gasoline quality, it is additionally treated on either MEROX plant or Sulf-X process.

Debutanizer must be controlled in the way keeping the content of C₅ fraction in LPG less than 2 %, in order to meet the specification on the quality of LPG, while the vapour pressure according to Reid (RVP) of the FCC gasoline must be kept on values (70-85kPa) determined by seasonal specifications on the quality of motor gasoline. Exceptionally, when FCC gasoline is being subjected to the Sulf-X

process, RVP value must be kept below 50kPa due to structural limitations of the stripper column and the column for extraction distillation at the Sulf-X process.

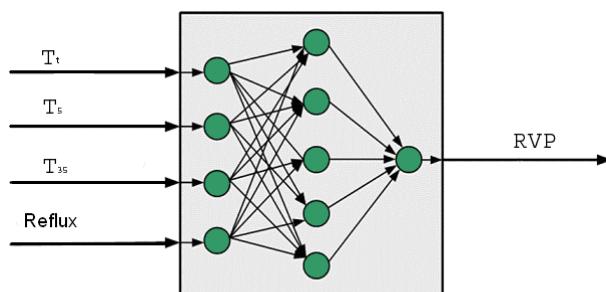
The variables used to maintain required quality of products are temperature of the column top and bottom, temperature of characteristic column trays and reflux flow. The temperature of the column's 5th tray is maintained by regulator of temperature TRC-93, cascadedly connected with reflux flow regulator FRC-101. Bottom column temperature, i.e. that of the 35th tray, is maintained by regulating the flow of the heating medium through the column bottom reboiler. Distress variables are the variations in flow, temperature and composition of the unestabilized gasoline filling the column.

Results and Discussion

Neural soft sensor model

Neural soft sensor models have been developed based on the available process measurements and laboratory analyses, and the soft simulation model. Process variables at the plant are measured continuously and logged in the memory of the DCS system, so that there is an available data base on temperature and flow. In order to continuously monitor the quality of products, two neural models of the soft sensor have been developed; one for estimating the content of C₅ fraction in LPG, and the other for estimating the RVP value of the stabilized FCC gasoline. The structure of neural network for estimating RVP is shown in Figure 3.

Figure 3: Structure of applied neural network for RVP prediction



The network consists of input and output layers plus a hidden layer with five process units. Neural inputs are: top column temperature, T_v , 5th tray temperature, T_5 , 35th tray temperature, T_{35} , and reflux flow, while the network estimates RVP value of the stabilized FCC gasoline. Accordingly, a network has been elaborated for estimating the share of C₅ in LPG. Databases for the content of C₅ in LPG and RVP of the FCC gasoline have been limited by the dynamics of laboratory analyses. That is why a software simulation model has been developed, generating additional data used for learning and testing networks.

Preparing data before instructing the neural networks, the following has been made:

- generating additional data based on simulated research;
- preparation and standardization of data for network instruction.

Used for learning was the static advanced neural network, while learning was performed by applying adaptive gradient method described in the references [5].

Cascade learning of neural network

Cascade learning is based on the Cascade-Correlation Learning paradigm [5]. Learning begins without hidden process elements. The only links are the direct links between the input layer (and bias) and the output layer. Hidden units are being added one by one. Hidden process elements accept inputs from all the previous hidden process elements, same as from the input vector – in other words – the hidden layer has cascade links.

The basic form of the cascade-correlation learning algorithm functions in the following manner:

1. Learning direct links from the input layer and bias to the output layer. Instructed is a previously defined number of iterations, or until the output error RMS is stabilized.
2. Iteration steps are as follows:
 - Learning a new hidden neuron in order to maximize correlation between its input and the amount of remaining error at the output for the current vector being learned. The hidden unit, not yet trained, is called a candidate. When learning is stabilized, or after a given number of iterations, learning is stopped for the links coming to the process element in question. At this particular point, the hidden process element may be said to be tenured;
3. The linking of the newly accepted hidden unit to all neurons in the output layer, and a random initiation of the said links' weight;
 - Learning all weight coefficients of all the links from the input layer, bias, and the adopted hidden units to the output layer. Learning evolves according to the previously defined number of iterations or until the output error RMS is stabilized.

Iteration is being repeated until neural network performance (e.g. RMS error calculated for a set of testing data) no longer shows improvement.

Figure 4 shows a part of the results of testing the neural model for estimating the RVP value of the FCC gasoline. They are data used for learning i.e. building of the neural network model. As expected, the results show quite good matching. Tables 1 and 2 provide statistical indicators of the neural network model. In this sense, the instruction set is the set of data used for tuning the parameters of the model. The testing accumulation is used as a part of building the model of the process in order to prevent "overfitting". The validation set is used as an additional independent set for evaluating the soft sensor model. All the factors in the Table have been calculated taking into account experimental output values. Before training, real

physical values were transformed into internal normalized values, suitable for processing using neural network. The obtained outputs are transformed back into real outputs, by applying inverse transformation.

Table 1: Statistical parameters of neural network-based model for pentane fraction in LPG prediction

C ₅ in PG	Records	Avg. Abs.	Max. Abs.	RMS	Conf. Int. (95 %)
Training	96	0.10106	1.152207	0.2917485	0.576
Testing	77	0.101553	1.152207	0.2957075	0.586
Validation	19	0.099062	1.126737	0.2751214	0.579

Table 2: Statistical parameters of neural network-based model for RVP of FCC gasoline prediction

RVP of FCC gasoline	Records	Avg. Abs.	Max. Abs.	RMS	Conf. Int. (95 %)
Training	96	0.05574	0.12725	0.06647	0.13121
Testing	77	0.05368	0.12725	0.06405	0.12691
Validation	19	0.06408	0.12203	0.0755	0.15875

where:

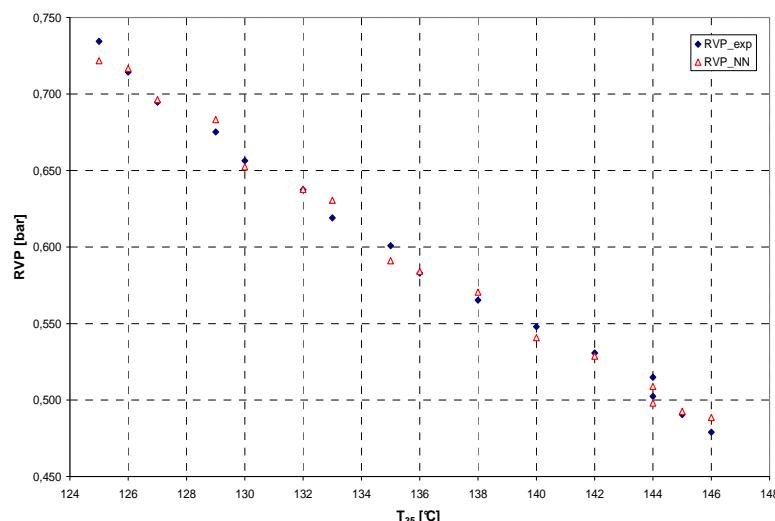
Avg. Abs. - average absolute error between targeted output and neural computing;

Max. Abs. - maximum absolute error between targeted output and neural computing;

RMS - root mean square error between targeted output and neural computing;

Conf. Interval - area within which estimated outcome appears in 95 % of the cases.

Figure 4: Results of soft sensor testing for RVP of FCC gasoline prediction



Developed neural models of soft sensors were additionally validated using experimental data from the data base of DCS system. Thus obtained results were compared with the matching results obtained by laboratory analyses. The data were taken from analyses performed in the course of November, 2005. Figure 5. shows a comparison between experimental results obtained through laboratory analysis and results obtained using soft sensor for estimating RVP value of stabilized FCC gasoline. It may be observed that the model of the soft sensor follows well the trend of RVP value change, but that there are also certain aberrations. These aberrations may be explained by the less than perfect simulation model, as well as by the fact that most available data from the laboratory analyses are in the area of about 50 kPa. The network therefore has better approximation properties precisely with these values. Accordingly, Figure 6. shows a comparison for the soft sensor predicting the content of C₅ fraction in LPG. Most available data from laboratory analyses were ranging around value 0, which is why it is understandable that the network is better at approximating lower values of the C₅ fraction content. Statistical parameters of validating both models are shown in Table 3.

Figure 5: Comparison of experimental and soft sensor-based results for RVP of FCC gasoline

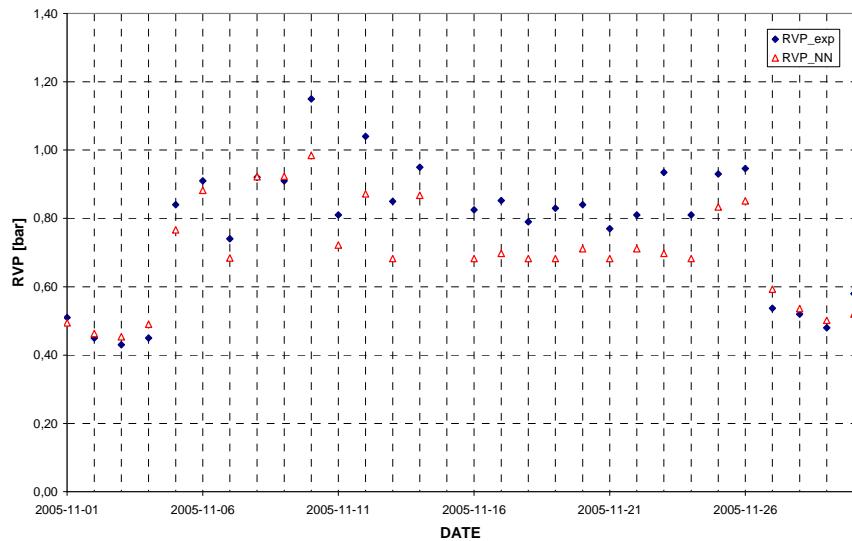


Figure 6: Comparison of experimental and soft sensor-based results for pentane fraction in LPG

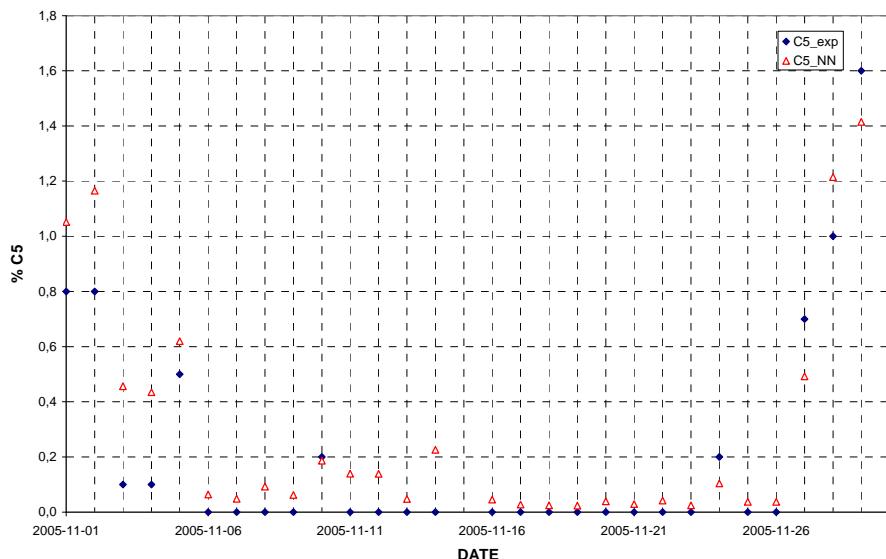


Table 3: Statistical parameters of model validation

	Records	Avg. Abs.	Max. Abs.	RMS	Standard deviation
RVP	29	0,08	0,24	0,5660	0,1050
C ₅	29	0,1	0,4	0,8396	0,1559

Conclusion

The paper develops models of soft sensors by applying neural networks. For the purpose of estimating values that cannot be continuously measured in the process, two models of soft sensors have been developed – the first for estimating the content of C₅ fraction in LPG, and the other for estimating RVP value of the stabilized FCC gasoline.

The developed models have shown that neural network may be applied as an «intelligent» sensor in the process, capable of reliably and quite accurately – based on secondary measurements – estimating the value of the primary unit within a process. The development of inferential sensors and their application do not require any major investments, since the inferential sensor is realized as a software module

within the computer, estimating – based on easily measured values and available input values – the values of hardly measurable process values.

Constructed soft sensors may serve for further process research and optimization, since – based on it – it is possible to develop methods of inferential control. These control methods may relatively easily be incorporated into the system for automatic process control even in cases when – as is the case here – the controlled variables cannot be measured continuously. Also, there is the possibility of application on other refinery processes as well, sharing similar problems.

Acknowledgement

The authors wish to thank Mr. Milorad Đukić, grad. eng. and Production Manager of INA-Oil Refinery Sisak, for his expert assistance.

Literatura / References:

1. MARTIN, G. D., Consider Soft Sensors, *Chem. Eng. Prog.*, July 1997., pp. 66–70, 1997.
2. PETROVIĆ I., DOMIJAN P., JELAVIĆ M., Estimation of Lube Oil Viscosities on a Vacuum Distillation Column, *IC/T 2003*, Maribor, pp. 265-270, 2003.
3. BOLF, N., JERBIĆ, I., Primjena umjetnih neuronskih mreža pri identificiranju i vođenju procesa, *Kem. Ind.* Vol 56, br.11, 2006.
4. BOLF, N., GLASNER M., JERBIĆ I., Application of Soft Sensors and Inferential Control in Chemical & Biochemical Process Control, *Proceeding of the International Conference "Intelligent Control Systems"*, Brno, Czech Republic, pp. 194-198, 2005.
5. Neuralware, *Neural Computing - A Technology Handbook for Professional II/Plus and NeuralWorks Explorer*, NeuralWare Inc., Pittsburgh, USA, 2001.

UDK	ključne riječi	key words
681.513.7/8	neuronska mreža	neural network
681.513.7	samoučeći sustav vođenja	selflearning control system
681.513.8	samoorganizirajući sustav vođenja	selforganizing control system

Autori / Authors:

Ivica Jerbić*, Hrvoje Pavelić**, Nenad Bolf***

*INA Rafinerija Nafte Sisak, A. Kovačića 1, 44000 Sisak, ivica.jerbic@ina.hr

**UOP Limited, 'Liongate', Ladymead, Guildford, Surrey GU1 1AT, England,
hrvoje.pavelic@uop.com

***Fakultet kemijskog inženjerstva i tehnologije, Zavod za mjerenja i automatsko vođenje procesa, Marulićev trg 19, 10 000 Zagreb, bolf@fkit.hr

Primljeno / Received:

18.7.2006.