

Vođenje procesa izmjene topline temeljeno na modelu procesa

KUI 20/2005.
Prispjelo 7. srpnja 2004.
Prihvaćeno 2. ožujka 2005.

N. Bolf

Sveučilište u Zagrebu, Fakultet kemijskog inženjerstva i tehnologije
Zavod za mjerenja i automatsko vođenje procesa, Savska c. 16/5a, 10 000 Zagreb, Hrvatska
tel: + 385 1 4597 151; faks: + 385 1 4843 556; e-mail: bolf@fkit.hr

Prikazana je metoda vođenja stupnjevito povezanih procesa izmjene topline sa zadatkom strogog održavanja vrijednosti izlazne varijable unutar zadanih granica.

Kapljevina niskog vrelišta ulazi u sljedeći stupanj procesa, pri čemu je potrebno precizno održavanje temperature u blizini vrelišta, uz zahtjev da se vrijednosti izlazne varijable mijenjaju unutar granica $\pm 0,3$ °C od vrijednosti temperature u radnoj točki.

Tradicionalno vođenje ostvareno automatskom stabilizacijom temperature dopunjeno je originalno zamišljenim vođenjem stupnjevito povezanih procesa izmjene topline. Vođenje na unaprijednom načelu ostvareno je primjenom inverznog statičkog modela procesa. Projektirani sustav za vođenje procesa u dva stupnja pokazao se fleksibilnijim i djelotvornijim prilikom promjena opterećenja (tereta) u odnosu na vođenje procesa standardnim metodama. Poboljšanje vođenja ostvareno je primjenom generičkog neuralnog modela procesa razvijenog pomoću neuralne mreže.

Ključne riječi: *Izmjenjivač topline, dinamički model procesa, neuralna mreža, vođenje generičkim modelom*

Uvod

Regulacija temperature u većini procesa obično je jednostavna za izvedbu. Međutim, postoje procesi u kojima je precizna regulacija temperature vrlo važna, a izvedba sustava za vođenje nije jednostavna za provedbu. Primjeri su regulacija temperature vrlo egzotermnih kemijskih reakcija, pojedinih procesa destilacije i kristalizacije ili šaržnih sterilizatora.

Tijekom proteklih godina ostvaren je velik napredak na području mjerenja temperature, statističke analize, računalnog vođenja i teorije vođenja. Dobro razumijevanje i odgovarajuća primjena novih tehnologija može donijeti velike koristi. Bolja regulacija temperature znači veću sigurnost, veću djelotvornost i kvalitetu konačnog proizvoda.¹

U ovom radu prikazuje se razvoj metode vođenja pomoću generičkog modela procesa kojim se ostvaruju poboljšanja vođenja procesa što ih karakteriziraju velike vremenske konstante i zadržke. Model procesa izgrađen je pomoću neuralne mreže. Razvijena metoda eksperimentalno je provjerena na laboratorijskom izmjenjivaču topline u kojem je potrebna precizna regulacija temperature na uskom temperaturnom području.

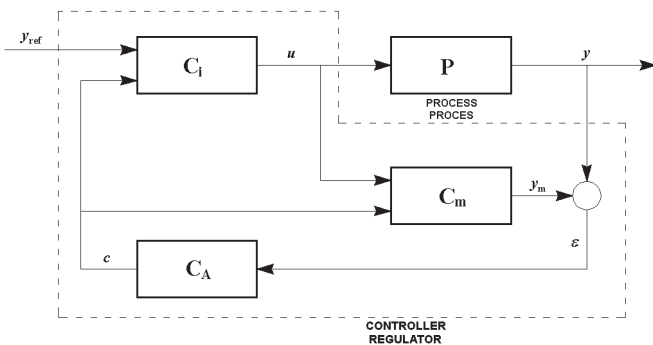
Vođenje procesa temeljeno na modelu (engl. *model-based control* – MBC) podrazumijeva model procesa što je eksplicitno ugrađen unutar algoritma za vođenje. U primjeni automatskog vođenja modeli procesa služe se za ugađanje regulatora te kod projektiranja inferencijskih regulatora (regulatora kod kojih se primjenjuju sekundarna mjerenja). Kod dinamičkog optimiranja modeli se primjenjuju za pred-

viđanje vladanja procesa, proračun regulacijskog djelovanja i za određivanje točke lokalnog optimuma. Pri primjeni, uz postojeća ograničenja u procesu, glavni je ekonomski kriterij. Strategija vođenja kemijskih procesa tradicionalno se razvija pomoću jednostavnih linearnih dinamičkih modela procesa. Premda su takvi modeli često zadovoljavajući, postoji mnogo procesa za koje linearni modeli nisu dovoljno dobar temelj za projektiranje vođenja. Istodobno, povećanjem djelotvornosti procesnih računala zahtijevima za boljim vođenjem nelinearnih procesa može se udovoljiti primjenom naprednih strategija vođenja.²

Na slici 1 dan je načelni prikaz vođenja temeljenog na modelu procesa. Pomoću modela procesa regulator proračunava upravljačko djelovanje potrebno da se vođena varijabla vlada na željeni način. Oznaka C_i označuje inverzni model procesa kojim se računa regulacijsko djelovanje potrebno da se odabrani izlazi procesa dovedu do željene ili optimalne vrijednosti. Ako je model savršen i ne postoje ograničenja, ostvareno je valjano vođenje. Ipak, u praksi niti jedan model nije savršen pa je nužan određen oblik povratne korekcije. Razlika e , između modela y_m i izlaza iz procesa y služi za ugađanje povratnog djelovanja regulatora c u bloku C_A . Odabir strukture modela, algoritma vođenja, mehanizma ugađanja i parametara dovela je do niza različitih izvedbi regulatora. Struktura modela od primarnog je značenja, pa se prema vrsti modela izvodi i klasifikacija.³

Raznovrsne tehnike vođenja temeljenog na modelu kao što su dinamičko matično vođenje (engl. *dynamic matrix control* – DMC),⁴ modelsko algoritamsko vođenje (engl. *model algorithmic control* – MAC)⁵ i vođenje temeljeno na unu-

tarnjem modelu (engl. *internal model control* – IMC)⁶ pokazale su se djelotvornim u industrijskoj primjeni. Vođenje temeljeno na generičkom modelu (engl. *generic model control* – GMC) omogućuje da se linearni i nelinearni modeli procesa ugrade izravno u strukturu algoritma vođenja. Na taj se način ostvaruje bolje vođenje jer se u algoritam vođenja ugrađuju precizniji modeli procesa. Lee i Sullivan⁷ prikazali su temeljna načela primjene regulatora koji omogućuju upotrebu nelinearnih matematičkih modela za aproksimiranje vladanja procesa. Tehnika GMC u praksi se primjenjuje za regulaciju vrijednosti pH, regulaciju procesa destilacije i sušenja te procesa u kemijskim reaktorima i visokim pećima.^{8,9}



Slika 1 – Osnovna zamisao vođenja temeljenog na modelu procesa

Fig. 1 – The basic concept of model-based control

Klasično vođenje temeljeno na generičkom modelu

Dinamički model procesa može se opisati skupom diferencijalnih jednadžbi:

$$\dot{\mathbf{y}} = f(\mathbf{y}, \mathbf{u}, \mathbf{d}, t, \Theta) \quad (1)$$

pri čemu je \mathbf{y} vektor izlaza procesa, \mathbf{u} vektor ulaza procesa, \mathbf{d} vektor poremećaja, t vrijeme i Θ vektor parametara modela. Općenito, f iskazuje nelinearnu funkcionalnu ovisnost. U prikazanom sustavu pretpostavlja se da je broj ulaza i izlaza procesa isti, no metoda nije ograničena samo na takve sustave.⁷

Druga komponenta algoritma definira se kao referentni sustav $\mathbf{r}(\mathbf{y})$. Referentni sustav definira željenu brzinu promjene izlazne varijable $\dot{\mathbf{y}}_{\text{ref}}$:

$$\mathbf{r}(\mathbf{y}) = \dot{\mathbf{y}}_{\text{ref}} = \mathbf{K}_1(\mathbf{y}_{\text{ref}} - \mathbf{y}) + \mathbf{K}_2 \int_0^{t_k} (\mathbf{y}_{\text{ref}} - \mathbf{y}) dt, \quad (2)$$

pri čemu je t_k trenutno vrijeme, a \mathbf{K}_1 i \mathbf{K}_2 su parametri kojima se opisuje željeno vladanje procesa.

Tako formuliranim jednadžbama želi se postići:⁸

- (a) da se sustav što prije dovede do radne točke,
- (b) da se ukloni preostalo regulacijsko odstupanje (offset).

Vođenjem je, dakle, potrebno osigurati da brzina promjene izlazne varijable prati željenu referentnu trajektoriju:

$$\dot{\mathbf{y}} = \dot{\mathbf{y}}_{\text{ref}} \quad (3)$$

Iz jednadžbi (1) i (2) dobiva se:


$$f(\mathbf{y}, \mathbf{u}, \mathbf{d}, t, \mathbf{Q}) = \mathbf{K}_1(\mathbf{y}_{\text{ref}} - \mathbf{y}) + \mathbf{K}_2 \int_0^{t_k} (\mathbf{y}_{\text{ref}} - \mathbf{y}) dt \quad (4)$$

Pravilo vođenja koje je potrebno proračunati u svakom diskretnom koraku za upravljive ulaze, \mathbf{u} , predstavlja skup nelinearnih algebarskih jednadžbi.

Ako postoji neslaganje između vladanja predviđenog modelom procesa i vladanja realnog procesa, ono će se kompenzirati integracijskim djelovanjem regulatora. Integracijski član, osim što osigurava korekciju nesavršenosti modela, uklanja i preostalo regulacijsko odstupanje.

Opis i matematički model procesa

Na slici 2 pojednostavljeno je prikazan dvostupnjeviti izmjenjivač topline kao procesni prostor u kojem se provodilo eksperimentalno istraživanje.¹⁰ Eksperimentalni postav odabran je na temelju simulacijskog istraživanja koje je pokazalo da će izvedba procesa u dva stupnja omogućiti ostvarenja zadanih kriterija. Upravljive ulazne varijable su snage grijala P_{H1} i P_{H2} te protok rashladne kapljavine kroz zavojnicu/plašt q_{J1} . Izlazne varijable koje je potrebno održavati na referentnim vrijednostima su temperatura kapljavine u izmjenjivaču topline T-1, T_{T1} i temperatura kapljavine na izlazu iz zavojnice u izmjenjivaču topline T-2, T_{S2o} . Glavna poremećajna varijabla jest protok kapljavine kroz sustav q_L . Protok kapljavine utječe na toplinsku akumulaciju u oba spremnika te ovisi o tlaku u sljedećem stupnju procesa. Ostale poremećajne varijable su: oscilacije temperature pojne kapljavine na ulazu u izmjenjivač topline T-1, T_{T1i} i protok pojne kapljavine q_{T1i} . Strukturni prikaz modela procesa što opisuju uzročno-posljedično djelovanja karakterističnih veličina prikazan je na slici 3.

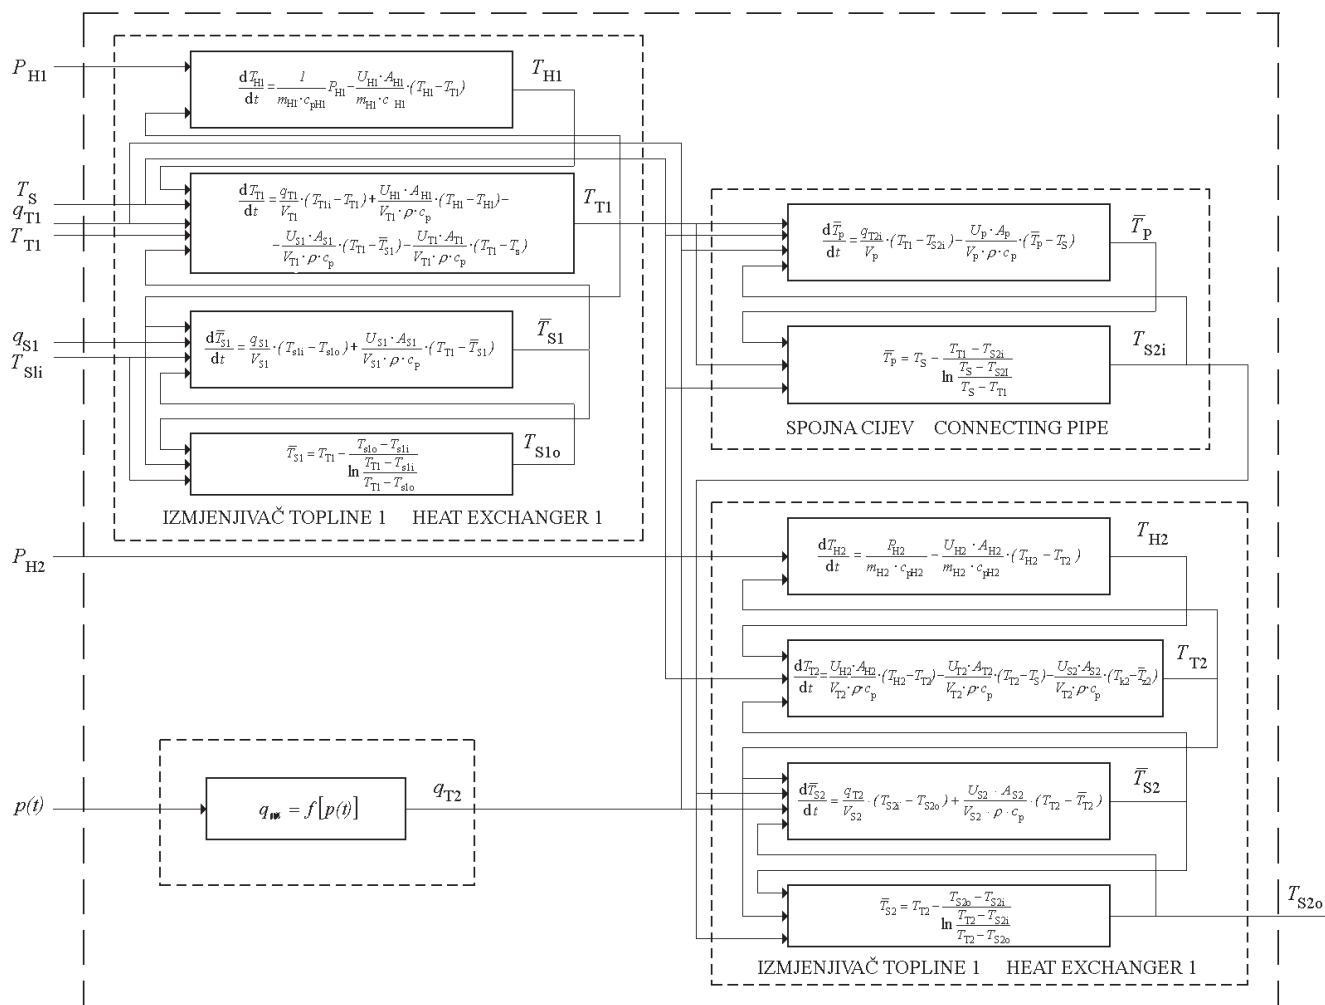


Slika 2 – Prikaz dvostupnjevito izmjenjivača topline

Fig. 2 – Two-stage heat exchanger

Sustav za vođenje procesa

Procesi izmjene topline u oba stupnja odvijaju se u spremnicima što su opremljeni rashladnom zavojnicom i plaštom, električnim grijalima i mješalima. Laboratorijski ure-



Slika 3 – Strukturni prikaz modela dvostupnjevitoz izmjenjivača topline
 Fig. 3 – Structural scheme of the two-stage heat exchanger model

đaj opremljen je odgovarajućim osjetilima, mjernim pretvornicima i izvršnim spravama koji su povezani sa suvremenom jedinicom za vođenje (Honeywell UMC-800).¹⁰

Standardne metode vođenja procesa

U prvom je koraku istraživana mogućnost reguliranja temperature u jednom stupnju, uz standarnu PID regulaciju i upravljanje snagom grijala. Sustav je zatim nadograđen regulacijskim krugom za protok rashladnog medija. Time je ostvorena primjena tzv. "split" ("duplex") tehnike vođenja. Regulacijski krug za održavanje stalne razine kapljevine u spremniku zasebno je izveden i ugođen.

Unaprijedno vođenje

Daljnijm istraživanjem vođenja procesa ostvorena je jedinica koja djeluje unaprijedno. Kao potpora vođenju služi inverzni statički model procesa kojim se određuje referentna vrijednost regulirane temperature u prvom stupnju $T_{T1,ref}$. Model je izveden unaprijednom statičkom neuralnom mrežom. Ovaj oblik unaprijednog djelovanja može se prikazati sljedećom ovisnosti:

$$T_{T1,ref} = f(q_L, T_{S2o,ref}, P_{H2}) \tag{5}$$

Generički neuralni model

Dinamički neuralni modeli mogu biti interno ili eksterno rekurentni. Interno rekurentni modeli jesu sustavi diferencijalnih jednadžbi čije je parametre potrebno odrediti. U literaturi postoji niz metoda za njihovo učenje ("on-line" i "off-line"). Te su metode relativno kompleksne jer moraju savladati niz praktičnih problema kao što je moguća numerička nestabilnost ili problem gubitka informacija o vremenski udaljenim karakteristikama (nestajanje gradijenata).¹¹

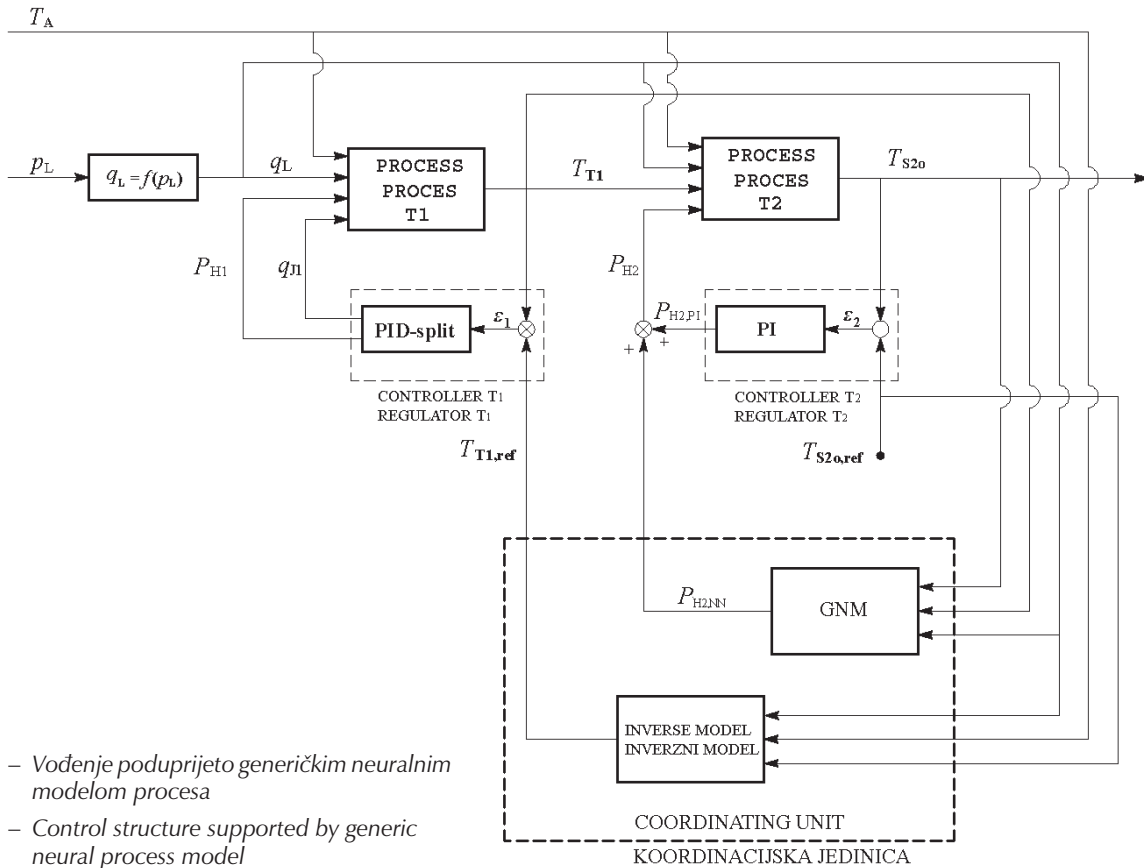
Stoga je jednostavnije primijeniti eksterno rekurentni dinamički neuralni model.¹¹ Takav se model naziva još neuralni model u prostoru stanja ili kanonski neuralni model,^{12,13} a matematički se opisuje kao:

$$\frac{dx}{dt} = f(x, u) \tag{6}$$

Neuralna mreža daje desnu stranu izraza (6) kao funkciju varijabli stanja i ulaznih varijabla, slika 5.


Vođenje generičkim neuralnim modelom

Budući da se mjerenjem dobivaju vrijednosti varijabli stanja u pojedinim vremenskim intervalima, za učenje mreže vre-



Slika 4 – Vođenje poduprieto generičkim neuralnim modelom procesa

Fig. 4 – Control structure supported by generic neural process model



Slika 5 – Kontinuirana eksterno rekurentna neuralna mreža

Fig. 5 – Continuous external recurrent neural network

menske se trajektorije deriviraju. Prije toga se obrađuju pomoću funkcije "spline". Mreža potom uči statičku relaciju jednom od standardnih metoda jer je sustav opisan jednadžbom (6) autonoman.¹¹

Za održavanje vođene varijable na konstantnoj vrijednosti, pri upotrebi neuralnog modela, potrebno je udovoljiti sljedećem uvjetu:

$$\frac{dx_i}{dt} = f_i(x, u) = 0 \tag{7}$$

Kako bi se ostvarilo vođenje generičkim neuralnim modelom, potrebno je odabrati elemente vektora u , kojim će se održavati x , te izraziti eksplicitno u_i iz izraza (7). Pri primjeni unaprijedne neuralne mreže algoritmom povratnog propagiranja analitički se definira derivacija izlaza mreže s obzirom na određeni ulaz:^{11,14}

$$\frac{d[f_i(x, u)]}{du_i} = g_i(x) \tag{8}$$

Preuređivanjem i dodavanjem korekcije konačno se dobiva:

$$u_i = u_i^o + \int_{f_i^o(x, u)}^{f_i(x, u)} \frac{1}{g_i(x)} d[f_i(x, u)] \tag{9}$$

$$\left[1 + K_1(x_i - x_i^{ref}) + \int_0^{t_k} K_2(x_i - x_i^{ref}) dt \right]$$

Vođenje se u praksi provodi pomoću algoritma koji je dan u diskretnom obliku tako da se u svakom diskretnom koraku n prijašnjoj vrijednosti upravljačke veličine dodaje izračunata korekcija za sljedeći vremenski interval:

$$u(n) = u(n-1) + \Delta u(n). \tag{10}$$

Vrijednost korekcije čini razliku upravljačkog djelovanja između dva uzastopna diskretna koraka:

$$u(n) = \Delta u^{NN}(n)[1 + K_1 \Delta \varepsilon(n) + K_2 \varepsilon(n) \Delta t(n)], \tag{11}$$

pri čemu su:

$$\varepsilon(n) = x_k^{ref} - x_k(n) \tag{12}$$

$$\varepsilon(n-1) = x_k^{ref} - x_k(n-1) \tag{13}$$

$$\Delta \varepsilon(n) = \varepsilon(n) - \varepsilon(n-1) \tag{14}$$

Za proračun korekcije na temelju neuralnog modela rabi se odgovarajući element Jacobijeve matrice:

$$J_i \approx \frac{\Delta f_k}{\Delta u_i} \approx g_{ki} \tag{15}$$

$$g_{ki} = \sum_j w_{ji} f_j (1 - f_j) \sum_k w_{kj} f_k (1 - f_k) \delta_{kk} \tag{16}$$

pri čemu su w maseni faktori, f prijenosna funkcija neurona, a δ je Kronckerova funkcija za k -ti ulazni neuron. Indeksi i, j i k predstavljaju redom ulazni, skriveni i izlazni sloj mreže. Kao prijenosna funkcija služi logistička funkcija koja se može opisati:¹¹

$$f_p(\text{net}_p) = \frac{1}{1 + e^{-\text{net}_p}} \quad (17)$$

$$\text{net}_p = \sum x_{p-1} w_{p-1} + w_{0p-1} \quad (18)$$

$$x_p = f_p(\text{net}_p) \quad (19)$$

Promjena upravljačkog djelovanja računa se kao:

$$\Delta u^{\text{NN}}(n) = u^{\text{NN}}(n) - u^{\text{NN}}(n-1) \quad (20)$$

$$u^{\text{NN}}(n) = \frac{f_k^{\text{ref}} - f_k(n-1)}{g_{ki}(n)} + u^{\text{NN}}(n-1) \quad (21)$$

$$u^{\text{NN}}(n-1) = \frac{f_k(n-1) - f_k(n-2)}{g_{ki}(n-1)} + u^{\text{NN}}(n-2) \quad (22)$$

Proračun započinje za vrijednosti $n = 0$ i $n = 1$ s unaprijed zadanim konstantnim vrijednostima upravljačke varijable.

Izgradnja modela neuralne mreže

Za izgradnju neuralne mreže primijenjeno je kaskadno učenje što se temelji na metodi "cascade-correlation learning". Učenje mreže počinje bez skrivenih neurona (procesnih elemenata). Jedinice veze su izravne veze između ulaznog i izlaznog sloja. Skrivene jedinice se zatim dodaju jedna po jedna. Skriveni neuroni primaju ulaze iz svih prethodnih skrivenih neurona, kao i iz ulaznog vektora. Drugim riječima, skriveni sloj ima kaskadne veze.¹⁵

Osnovni oblik kaskadno-korelacijskog algoritma poučavanja djeluje na sljedeći način:

1. Poučavanje izravnih 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 sljedeći koraci:

- Učenje novoga 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 poučavanje stabilizira, ili nakon zadanog broja iteracija, poučavanje se zaustavlja za dolazeće veze na taj procesni element. U ovoj točki se za skriveni procesni element kaže da je "prihvaćen";
- Povezivanje novo prihvaćene skrivene jedinice na sve neurone u izlaznom sloju i iniciranje težina tih veza;
- Učenje masenih faktora svih veza od ulaznog sloja, biasa i prihvaćenih skrivenih jedinica do izlaznog sloja.

Iteracija se ponavlja sve dok kriterij izvedbe mreže (npr. RMS pogreška na skupu podataka za testiranje) više ne pokazuje poboljšanje.

Za primjenu vođenja generičkim modelom i izgradnju neuralne mreže iskorištena su prethodno provedena eksperimentalna istraživanja dinamičkog vladanja procesa. Ulaze

u mrežu čine: protok procesne kapljevine q_L , trenutačna temperatura kapljevine u prvom stupnju T_{T1} , trenutačna temperatura na izlazu iz drugog stupnja T_{s20} , i upravljačko djelovanje regulatora u drugom stupnju P_{H2} . Izlaz je vremenska derivacija trenutačne temperature na izlazu iz drugog stupnja. Skriveni sloj mreže čini 19 neurona. Interval uzorkovanje podataka iz procesa je 5 sekundi. Parametri izgrađene neuralne mreže dani su u tablici 1. Usporedba eksperimentalnog odziva i odziva dobivenog modelom neuralne mreže na karakteristične promjene protoka q_L , dana je na slici 6.

Model je ugrađen u strukturu algoritma za vođenje. Upravljačkom signalu koji dolazi iz neuralne mreže pribraja se PI djelovanje jedinice za vođenje koje služi za korekciju nekonzistentnosti modela i realnog procesa, slika 4. Djeluje se na snagu grijala P_{H2} , u drugom stupnju T-2.

Tablica 1 – Parametri neuralne mreže

Table 1 – Neural network parameters

dT_{s20}	Avg. Abs.	Max. Abs.	RMS	Broj zapisa Records
Ukupno Overall	0,012705	0,390636	0,023078	1630
Učenje Training	0,012471	0,390636	0,023281	1140
Testiranje Testing	0,013248	0,267649	0,022597	490

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;

Eksperimentalni rezultati

Pri istraživanju postavljeni su strogi uvjeti održavanja temperature na izlazu iz izmjenjivača topline, $T_{s20,ref,min} < T_{s20,sp} < T_{s20,ref,max}$, uz zahtjev da se vrijednosti izlazne veličine mijenjaju unutar granica $\pm 0,3$ °C od vrijednosti temperature u radnoj točki. Radna točka iznosila je 35 °C. Sustav čini pet regulacijskih krugova – regulatori temperature u oba stupnja, regulatori protoka pojne kapljevine i rashladne vode. Zasebno je izveden i ugođen regulacijski krug što se brine o održavanju stalne razine u prvom stupnju.

U svrhu proučavanja dinamičkog vladanja procesa izazvane su skokomične promjene protoka procesne kapljevine kroz sustav q_L , različitih iznosa i smjerova na cijelom radnom području, slika 7.

Zatim je istraženo vođenje procesa izmjene topline u jednom stupnju uz primjenu standardnog regulatora PID i primjenom "split"-tehnike. "Split"-tehnika vođenja obuhvatila je regulaciju snage grijala i kaskadnu regulaciju protoka rashladne vode q_{H1} pomoću regulacijskog ventila. Temperaturni odzivi prikazani su na slikama 8 i 9. Vidljivo je da primjenom tih metoda još nisu zadovoljeni zadani kriteriji.

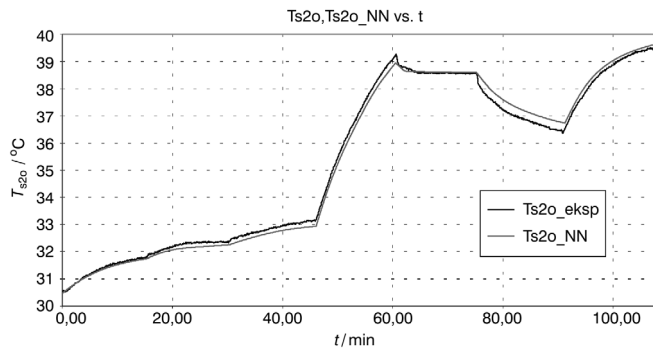
Unaprijedni model, kojim se zadaje vrijednost radne točke u prvom stupnju ovisno o stanju toplinske akumulacije u

drugom stupnju, softverski je ugrađen u jedinicu za vođenje, kako je prikazano na slici 4. Primijenjeni modeli neuralnih mreža razvijeni su pomoću programskog paketa *Neural Ware-Predict*. Modeli mreža pretočeni su u *Visual Basic* program na PC-u, koji komunicira s regulatorom Honeywell UMC-800, slika 12.

Iz ostvarenih eksperimentalnih rezultata, slika 10, vidljiva su poboljšanja dobivena upotrebom inverznog neuralnog modela procesa. Oscilacije vođene varijable smanjene su


na minimum, a pri karakterističnim promjenama ulazne varijable ostvaren je brži odziv uz manje vršne vrijednosti.

U zadnjem koraku istraživanja izgrađeni generički neuralni model ugrađen je u strukturu jedinice za vođenje. Odziv karakterističnih varijabli procesa primjenom vođenja generičkim modelom prikazan je na slici 11. Na slici je vidljivo da su oscilacije i vršne vrijednosti tom metodom još manje, pa se postiglo djelovanje koje udovoljava postavljenim kriterijima.




Slika 6 – Usporedba odziva realnog procesa i odziva neuralnog modela

Fig. 6 – Comparison of real process and neural model response




Slika 9 – Odziv temperature kod "split" vođenja u jednom stupnju

Fig. 9 – Controlled temperature response using one-stage split control




Slika 7 – Promjene protoka, q_L

Fig. 7 – Flow changes, q_L




Temperatura u prvom stupnju
Temperature response in the first stage




Slika 8 – Odziv temperature kod vođenja procesa u jednom stupnju (PID)

Fig. 8 – Controlled temperature response using one-stage process (PID)




Temperatura u drugom stupnju
Temperature response in the second stage

Slika 10 – Odzivi kod "split-unaprijednog" vođenja + PID
Fig. 10 – Temperature responses using split-feedforward + PID control




Temperatura u prvom stupnju
Temperature response in the first stage



Temperatura u drugom stupnju
Temperature response in the second stage

Slika 11 – Odziv kod "split-unaprijednog" vođenja + PI-GNMC
Fig. 11 – Temperature responses using split-feedforward + PI-GNMC



Slika 12 – Povezivanje regulatora i PC-a radi primjene neuralne mreže
Fig. 12 – Controller and PC communication for neural network implementation

Zaključak

U ovom radu je prikazana primjena neuralnog generičkog vođenja na primjeru izmjenjivača topline. Izgrađeni dvo-stupnjeviti izmjenjivač topline na kojem se provodilo ekperimentalno istraživanje i razvijeni sustav za vođenje procesa izmjene topline u dva stupnja pokazao se prikladnim za vođenje toplinskih procesa u kojima je potrebno ostvariti stroge kriterije održavanja temperature.

Metoda vođenja ostvarena primjenom neuralnog generičkog modela relativno je jednostavna za primjenu. Generičkim neuralnim modelom moguće je modelirati složene i vrlo nelinearne procese koje je teško opisati standardnim

modelima, pa primjena neuralne mreže nalazi svoje opravdanje. Daljnja se istraživanja, prema tome, mogu usmjeriti prema procesima čije se ponašanje može opisati eksterno rekurentnom neuralnom mrežom.

ZAHVALA

Ekperimentalni rad potpomognut je sredstvima tehnološkog projekta TP-01/0125-07 "Distribuirani laboratorij za daljinsko vođenje procesa i za poučavanje" što ga je financiralo Ministarstvo znanosti i tehnologije Republike Hrvatske. Zahvaljujem suradnicima Projekta na raspravama i pomoći pri izvedbi eksperimentalnog uređaja i razvoju sustava za vođenje. Posebno zahvaljujem kolegi Ivici Jerbiću i dr. Darku Gosaku na pomoći pri razvoju algoritma i eksperimentalnom radu.

Popis kratica i simbola List of abbreviations and symbols

- A površina izmjene topline, cm^2
heat exchange area, cm^2
- C_p specifični toplinski kapacitet, $\text{Jkg}^{-1}\text{K}^{-1}$
specific heat capacity, $\text{Jkg}^{-1}\text{K}^{-1}$
- d vektor poremećaja
disturbance vector
- e vektor pogreške
error vector
- f_j prijenosna funkcija neurona
neuron transfer function
- H_{T1}, H_{T2} grijalo u posudi T-1 i T-2
Heater in the vessel T-1 and T-2
- K_1, K_2 vektori parametara GMC regulatora
GMC controller parameter vectors
- m masa, kg
mass, kg
- P_{H1} snaga grijala u prvom stupnju, W
heater power in the first-stage, W
- P_{H2} snaga grijala u drugom stupnju, W
heater power in the second-stage, W
- p_L tlak tereta, Pa
load pressure, Pa
- $r(y)$ vektor trajektorije referentne vrijednosti
referent trajectory vector
- t vrijeme, s
time, s
- T_{T1} temperatura kapljevine u posudi T-1, °C
liquid temperature in the vessel T-1, °C
- T_{T1i} temperatura pojne kapljevine na ulazu T-1, °C
feeding liquid temperature T-1, °C
- T_{S20} temperatura kapljevine na izlazu iz zavojnice u T-2, °C
liquid temperature at the spiral exit in T-2, °C
- u vektor ulaza procesa
process input vector
- U ukupni koeficijent prijenosa topline, $\text{Jmin}^{-1}\text{cm}^{-2}\text{K}^{-1}$
overall heat transfer coefficient, $\text{Jmin}^{-1}\text{cm}^{-2}\text{K}^{-1}$

x	vektor stanja procesa process state vector
x_p	ukupni ulaz u neuron overall input to the neuron
y	vektor izlaza procesa process output vector
y_p	izlaz iz neurona neuron's output
\dot{y}_{ref}	vektor željene brzine promjene izlazne varijable desired output variable change vector
q_{J1}	volumni protok rashladne kapljevine, $\text{dm}^3\text{min}^{-1}$ cooling liquid volume flow rate, $\text{dm}^3\text{min}^{-1}$
q_L	volumni protok procesne kapljevine kroz sustav, $\text{dm}^3\text{min}^{-1}$ process liquid volume flow rate through the system, $\text{dm}^3\text{min}^{-1}$
q_{T1i}	volumni protok pojne kapljevine, $\text{dm}^3\text{min}^{-1}$ feeding liquid volume flow rate, $\text{dm}^3\text{min}^{-1}$
w_{ji}	težinski koeficijent mreže network weight factor
$\delta_{kk'}$	Kronckerova funkcija Kroncker's function
ε	signal pogreške regulatora controller error signal
ρ	gustoća kapljevine, gdm^{-3} liquid density, gdm^{-3}
Θ	vektor parametara modela model parameter vector

Literatura References

1. *E. P. Daugherty*, ed., *Temperature Control Principles for Process Engineers*, Hanser Verlag, 1994.
2. *R. M. Ansari & M. O. Tade*, *Nonlinear Model-based Process Control*, Springer-Verlag, 2000.
3. *B. Liptak* ed., *Instrument Engineers' Handbook, Third Edition: Process Control*, CRC Press, New York, 1995.
4. *D. W. Cutler & B. L. Ramaker*, *Joint Automatic Control Conference Preprints, Paper WP5-B*, San Francisco, 1980.
5. *R. K. Mehra, R. Rouhani, J. Eterno, J. Richalet & A. Rault*, *Engineering Foundation Conference on Chemical Control II*, 1982. pp. 287-310.
6. *C. E. Garcia & M. Morari*, *Ind. Eng. Chem. Proc. Des. Dev.* **21(2)** (1982) 308.
7. *P. L. Lee & G. R. Sullivan*, *Generic Model Control*, *Comp. Chem. Eng.* **(6)** (1988) 573.
8. *P. L. Lee*, *Nonlinear Process Control: Applications of Generic Model Control*, Springer-Verlag, *Advances in Industrial Control Series*, 1993.
9. *M. Ishida & J. Zhan*, *AIChE. J.* **41** (1995) 2333.
10. *N. Bolf*, *Prilagodljivo koordinirano vođenje složenih procesa*, Doktorska disertacija, Sveučilište u Zagrebu, 2003.
11. *D. Gosak*, *Optimalno vođenje diskontinuiranog procesa rektifikacije primjenom neuralne mreže*, Doktorska disertacija, Sveučilište u Zagrebu, 2003.
12. *T. Hrycej*, *Neurocontrol*, John Wiley, New York, 1997.
13. *S. Haykin*, *Neural networks: a Comprehensive Foundation*, Prentice Hall, New Jersey, 1999.
14. *C. M. Bishop*, *Neural Network for Pattern Recognition*, Oxford University Press, 1995.
15. *Neuralware*, *Neural Computing, A Technology Handbook for Professional II/Plus and NeuralWork Explorer*, 1996., pp. NC-74 - NC-78.

SUMMARY

Model-based Control of Heat Exchange Process

N. Bolf

Control of cascade-connected heat exchangers aiming to firmly maintain the value of output variable within set boundaries has been researched in this paper. Traditional control realized through automatic stabilization of the temperatures has been extended with originally designed control system by setting the set points using model based control.

A warm liquid with a low boiling point is fed into a distillation column where precise maintenance of the temperature of the fed liquid close to boiling point is required. In the first stage, the liquid is heated up to a temperature close to the desired output value, and in the second stage the final value is obtained within a permitted range of ± 0.3 °C around the set-point. When the pressure change occurs in the distillation column, the disturbance produces undesirable material and heat imbalance.

In order to solve the task, a traditional process control has been conducted, thus gathering the data needed for neural network application. Improvement in traditional process control has been made through an application of neural network that represents an inverse process model behaving in a feed forward principle. In order to realize improvement in performance of the control system, a process control method has been developed using generic model control based on the neural network model of the process.

*University of Zagreb, Faculty of Chemical
Engineering and Technology
Savska cesta 16, 10000 Zagreb, Croatia*

*Received July 7, 2004
Accepted March 2, 2005*