

Primjena umjetnih neuronskih mreža pri identificiranju i vođenju procesa

KUI – 23/2006.
Prispjelo 28. veljače 2005.
Prihvaćeno 10. siječnja 2006.

N. Bolf i I. Jerbić*

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

* INA d. d., Rafinerija nafte Sisak, A. Kovačića 1, 44 000 Sisak
e-mail: ivica.jerbic@ina.hr

Pri razvoju inteligentnih sustava u posljednjih dvadesetak godina ostvarena su brojna unapređenja inspirirana biološkim neuronskim sustavom. Istraživači s različitih znanstvenih područja kreirali su i primijenili umjetne neuronske mreže za rješavanje niza zadataka – od prepoznavanja uzoraka, predviđanja, dijagnosticiranja stanja, softverskih senzora, modeliranja i identificiranja, vođenja i optimiranja procesa itd.

Umjetne neuronske mreže pokazale su se korisnim u primjeni kod složenih kemijskih i biokemijskih procesa gdje standardnim metodama nije moguće uspješno modelirati procese i dobivene modele primijeniti za vođenje procesa. Danas, zahvaljujući intenzivnom razvoju teorije i praktične primjene neuronskih mreža, stoje na raspolaganju brojne strukture i algoritmi.

U radu je dan pregled primjene neuronskih mreža s težištem na identificiranju i vođenju procesa na polju kemijskog inženjerstva. Istaknuti su primjeri primjene kod prediktivnog, inverznog i prilagodljivog vođenja procesa.

Ključne riječi: *Neuronska mreža, identificiranje, modeliranje procesa, vođenje procesa*

Pojam i zamisao neuronske mreže

Umjetna neuronska mreža pojam je koji dolazi iz područja umjetne inteligencije izveden prema uzoru na neuronske mreže živih bića. Umjetne neuronske mreže apstraktne su simulacije realnog neuronskog sustava i alternativni pristup klasičnom von Neumannovom računalu. Temeljna svojstva su im samoorganiziranost i prilagodljivost, a posebice se ističu kao paralelna i distribuirana paradigma koja može biti robusnija i prikladnija od tradicionalnih modela.¹⁻³ U tablici 1 dana je usporedba klasičnog računala i biološkog neuronskog sustava.⁴

Građa i struktura bioloških neuronskih mreža


Ljudski mozak čini oko 10^{11} neurona povezanih u kompleksnu, ali djelotvornu mrežu. Svaki neuron je povezan s 10^3 do 10^4 drugih neurona. Ukupno postoji 10^{14} do 10^{15} međusobnih veza.

U osnovi se svaki neuron, kako je to prikazano slikom 1, sastoji od tri dijela:

- *tijela stanice*, koje sadrži nukleus s informacijama o narednim značajkama;
- *dendrita*, koji prenosi signale (impulse) s drugih neurona;
- *aksona*, koji prenosi signal do drugih neurona pri čemu se grana u vlakna;

Sinapse su funkcionalne jedinice između neurona koje oslobađaju neurotransmiter, pri čemu se odvija elektroke-

mijska reakcija. Signali se zatim dendritima prosljeđuju do tijela stanice, gdje se određuje prosjek svih signala. Signali mogu biti pobuđujući ili smirujući. Ako je prosječna vrijednost tijekom kratkog vremenskog intervala veća od granične vrijednosti, stanica generira niz impulsa koji se šalju preko aksona i sinapsi do drugih neurona.



Slika 1 – Prikaz biološkog neurona

Fig. 1 – Biological neuron

Unatoč relativno jednostavnoj građi neurona (zanemarujući način realizacije navedenih funkcija na biološkoj razini) i činjenici da se vrijeme generiranja i prijema impulsa mjeri u mikrosekundama, ljudski mozak kao organizirana jedinstvena mreža neurona postiže nevjerojatnu brzinu i sposobnost realiziranja raznovrsnih zadataka zahvaljujući paralelnosti rada neurona.⁵

Tablica 1 – Usporedba von Neumannovog računala i biološkog neuronskog sustava

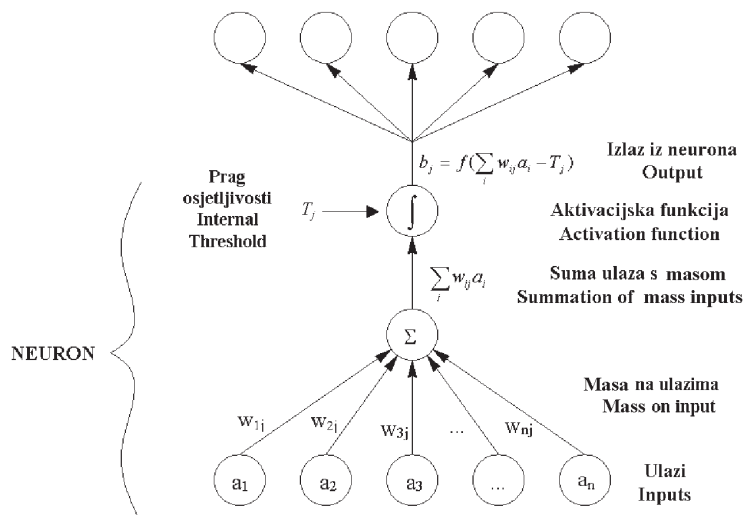
Table 1 – Comparison of von Neumann computer and biological neural system

	Von Neumannovo računalo Von Neumann computer	Biološki neuronski sustav Biological neural system
Procesor Processor	složen complex velika brzina high speed jedan ili nekoliko one or a few	jednostavan simple mala brzina low speed veliki broj a large number
Memorija Memory	odvojeno od procesora separate from a processor lokalizirana localized	integrirana u procesoru integrated into processor distribuirana distributed
Računanje Computing	centralizirano centralized sekvencijsko sequential pohranjeni programi stored programs	distribuirano distributed paralelno parallel sposobnost učenja self-learning
Pouzdanost Reliability	vrlo osjetljiva very vulnerable	velika robust
Ekspertiza Expertise	numeričke i simboličke manipulacije numerical and symbolic manipulations	problemi percepcije perceptual problems
Radna okolina Operating environment	dobro određena well-defined	slabo određena poorly defined

Razvoj teorije umjetnih neuronskih mreža

Spoznaja o građi i načinu funkcioniranja ljudskog mozga i neurona kao njegovih građevnih jedinica potaknula je istraživanje i razvoj umjetnih neuronskih mreža. Prve radove o umjetnim neuronskim mrežama objavili su McCulloch i Pitts.⁶ Oni su primjenjivali vrlo jednostavan model neurona koji, kao i biološki neuron, obrađuje signale putem sinaptičke i somatske operacije. Taj vrlo jednostavan model neurona nazvan je perceptron, a prikazan je slikom 2. Sinaptička operacija razumijeva množenje svakog ulaznog signala a_i s masenim koeficijentom w_i . Tako otežani ulazni signali zbrajaju se, a njihov zbroj uspoređuje se s pragom osjetljivosti neurona T_i (engl. *threshold, bias*). Ako je zbroj otežanih signala veći od praga osjetljivosti neurona, $\sum a_i w_i > T_i$, nelinearna aktivacijska funkcija f generira izlazni signal neurona b_j .

Početkom 60-ih dokazan je teorem o učenju perceptrona koji kaže da perceptron može naučiti sve što može predočiti.⁷ Predočivanje se odnosi na sposobnost opisa funkcije.



Slika 2 – Prikaz perceptrona

Fig. 2 – Perceptrone description

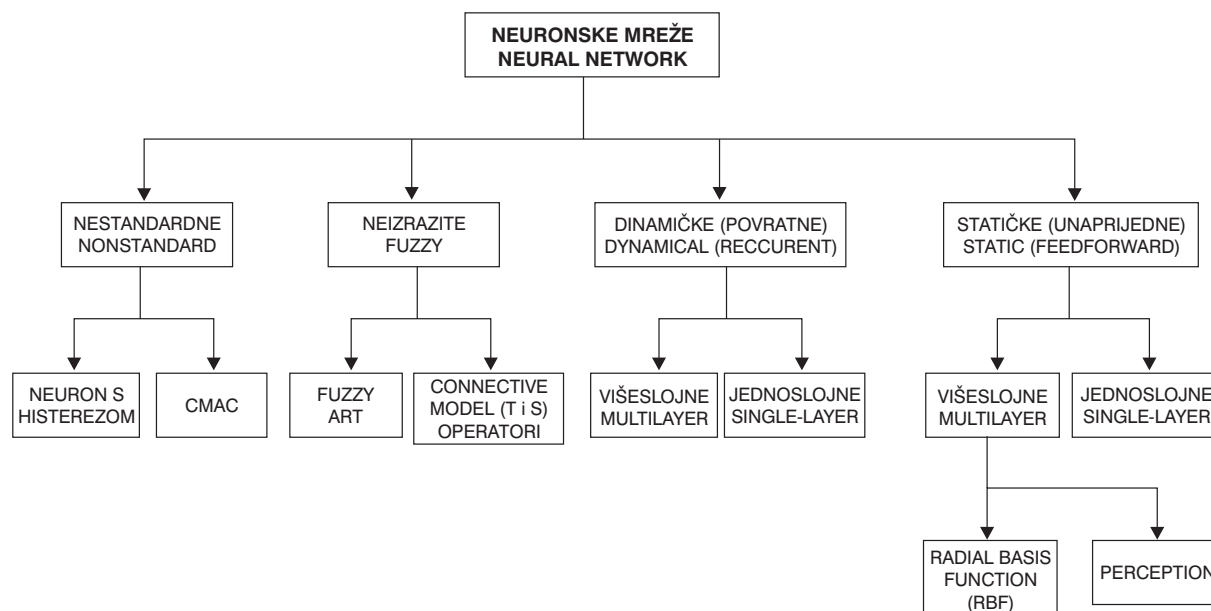
Pod učenjem se podrazumijeva postojanje sustavnog postupka za ugađanje parametara mreže radi ostvarivanja određene funkcije. Slijedila je stagnacija u istraživanjima kad je uočena nesposobnost perceptrona pri rješavanju jednostavnih zadataka, kao što je primjerice realizacija funkcije *isključivo ili*.⁸

Sredinom 80-ih otkriven je algoritam *povratnog prostiranja izlazne pogreške* (engl. *back-propagation algorithm*), koji je omogućio jednostavno učenje višeslojnih neuronskih mreža.⁹ Nakon otkrića tog algoritma razvijeni su i brojni drugi poboljšani postupci učenja. Paralelno s razvojem algoritama istraživane su i nove strukture neuronskih mreža. Danas, zahvaljujući intenzivnom razvoju teorije i praktične primjene neuronskih mreža, stoje nam na raspolaganju brojne strukture i algoritmi.⁵

Podjela neuronskih mreža

Istraživanje neuronskih mreža u području različitih znanstvenih disciplina rezultiralo je velikim brojem različitih vrsta neuronskih mreža. Međusobno se razlikuju prema modelima umjetnih neurona od kojih su građene, prema načinu organiziranja neurona u mreži i prema primijenjenom algoritmu učenja. Zbog velikog broja vrsta neuronskih mreža teško ih je sustavno klasificirati. Na slici 3 prikazana je klasifikacija prema Gupta & Rao, 1994.¹⁰

Sa strukturnog gledišta, neuronske mreže standardno se dijele na statičke unaprijedne (engl. *feedforward*) i dinamičke (povratne, engl. *feedback*), ovisno o modelu neurona od kojeg su građene te po načinu prostiranja signala kroz mrežu. Kao zasebne strukture izdvajaju su neizrazite neuronske mreže (engl. *fuzzy neural networks – FNN*) kod kojih je naglašeno integriranje koncepcija neizrazite logike i neuronskih mreža. Kao nestandardne strukture navode se neuronske mreže kod kojih neuroni imaju histereznu karakteristiku, te CMAC mreže (engl. *Cerebellar Model Articulation Controller*) koje aproksimiraju nelinearne funkcije na načelu kodiranja.¹¹



Slika 3 – Podjela umjetnih neuronskih mreža

Fig. 3 – Clasification of artificial neural networks

Neuroni se u neuronskoj mreži najčešće organiziraju u slojeve pa se razlikuju jednoslojne i višeslojne neuronske mreže. Za primjenu u identificiranju i vođenju nelinearnih dinamičkih procesa najčešće se rabe višeslojne statičke neuronske mreže. Od dinamičkih neuronskih mreža uglavnom se rabe višeslojne neuronske mreže s elementima zadržke (engl. *time delay neural networks*).¹¹

Neuronske mreže pri identificiranju procesa

Modeli procesa mogu se razviti iz fundamentalnih načela, kao što su zakoni očuvanja mase, energije te drugih kemijsko-inženjerskih relacija. U mnogim praktičnim primjerima u industriji postoji nedostatak poznavanja egzaktnih fizikalnih fenomena koji se javljaju u procesima, pa je prema tome fenomenološke modele teško razviti. Drugi način za praktično identificiranje procesa je pristup procesu kao "crnoj kutiji" (engl. "black box"), pri čemu se modeli temelje isključivo na eksperimentalnim podacima dobivenim iz procesa. Informacije o dinamičkom vladanju u obliku modela crne kutije često su dovoljne za kvalitetno vođenje procesa.¹² Tako se za model neuronskih mreža, u praktičnoj primjeni, navode sljedeće prednosti: sposobnost filtriranja (mala osjetljivost na šumove i nepotpune informacije), paralelna obrada informacija, mogućnost prilagodbe, mogućnost modeliranja viševeličkih sustava, prikladne za obradu nekompletnih i nekonzistentnih informacija.

Postupak identificiranja pomoću neuronske mreže

Identificiranje procesa pomoću neuronskih mreža načelno obuhvaća sljedeće korake:^{13,14}

1. Planiranje eksperimenta

Planiranje eksperimenta važan je korak budući da je potrebno donijeti odluku o vrsti i veličini ulaznih promjena,

području rada, veličini promjena ulaza, itd. Treba paziti da se ne utječe na kvalitetu produkta jer se ispitivanja odvijaju tijekom rada postojećeg procesa. Stoga treba obratiti pozornost na to koliko ulazi mogu varirati, a da se istodobno ulazne varijable mijenjaju dovoljno da bi dale korisnu informaciju o dinamičkom vladanju procesa.

2. Prikupljanje i obrada podataka

Kemijska postrojenja općenito su karakterizirana velikim vremenskim konstantama i vremenskim zadržkama, pa vrijeme za postizanje stacionarnog stanja može biti reda veličine više sati. Podatke dobivene iz procesa potrebno je filtrirati da bi se uklonile smetnje i varijabilnosti karakteristične za realna mjerenja. Pojedini suvremeni softverski alati te funkcije izvode automatski.

3. Odabir strukture modela neuronske mreže

Neuronska mreža ne zahtijeva da se funkcija specificira eksplicitno. Potrebno je specificirati samo strukturu mreže. Specifikacija obuhvaća broj neurona u ulaznom, skrivenom i izlaznom sloju mreže. Broj neurona u ulaznom i izlaznom sloju određuje se prema broju bitnih ulaznih i izlaznih varijabli u procesu.

Za formiranje ulaznih i izlaznih vektora neuronske mreže, pri dinamičkom modeliranju, uzimaju se prošle vrijednosti ulaza i izlaza. Broj prošlih vrijednosti ulaza ovisi o postojećoj zadržci u procesu, dok broj prošlih vrijednosti izlaza određuje red veličine procesa.

4. Učenje neuronske mreže i vrednovanje modela

U svrhu modeliranja, obrađeni eksperimentalni podaci dijele se u dva skupa: skup za učenje i skup za testiranje (validiranje). Podaci iz skupa za učenje stavljaju se u mrežu, a težinski koeficijenti kontinuirano se računaju. Proces se ponavlja sve dok pogreška ne bude manja od specificiranog odstupanja ili je dosegnut maksimalni broj iteracija. Težinski

koeficijenti dobiveni na kraju ovog postupka karakteriziraju model neuronske mreže.

Za provjeru dobivenog modela služi skup za testiranje, nezavisan od podatka primjenjenih pri učenju.

Primjena statičkih neuronskih mreža pri identificiranju procesa

Postupak identificiranja procesa čine dva dijela: određivanje regresijskog vektora $\varphi(k)$ i aproksimiranje nelinearne funkcije $f(k)$ koja opisuje ulazno-izlaznu dinamiku procesa s funkcijom $f_N(k)$. Odabirom strukture modela jednoznačno je određen i način kreiranja regresijskog vektora. Za drugi dio, simuliranje parametrizirane funkcije $f_N(k)$, može se općenito primijeniti bilo koji univerzalni aproksimator, pa tako i neuronske mreže.¹⁵

Učenje statičkih neuronskih mreža

Neuronska mreža potpuno je određena kad je uz njezinu strukturu definiran i algoritam učenja. Razvijen je velik broj algoritama učenja neuronskih mreža koje se mogu podijeliti u tri skupine:¹¹

Algoritmi koji se temelje na pogrešci, prikazani slikom 4a, (engl. *error-based algorithms*) imaju vanjsku referenciju ("učitelj") s kojom uspoređuju izlaz iz neuronske mreže generirajući signal pogreške. Ovo učenje naziva se i "nadzirano učenje" (engl. *supervised learning*). Pri identificiranju procesa primjenom neuronskih mreža najčešće se rabi ova skupina algoritama jer neuronska mreža nastoji aproksimirati nelinearnu funkciju za koju su, kod ulazno-izlaznog modela, poznate vrijednosti ulaza i željene izlazne vrijednosti. Željene izlazne vrijednosti predstavljaju vanjsku referenciju algoritma učenja.

Algoritmi koji se temelje na izlazu mreže (engl. *output-based learning algorithm*), slika 4b, naziva se još i "nenadgledano učenje" (engl. *unsupervised learning*) jer nema vanjski referentni signal, već se oslanja na lokalne informacije i interne signale.

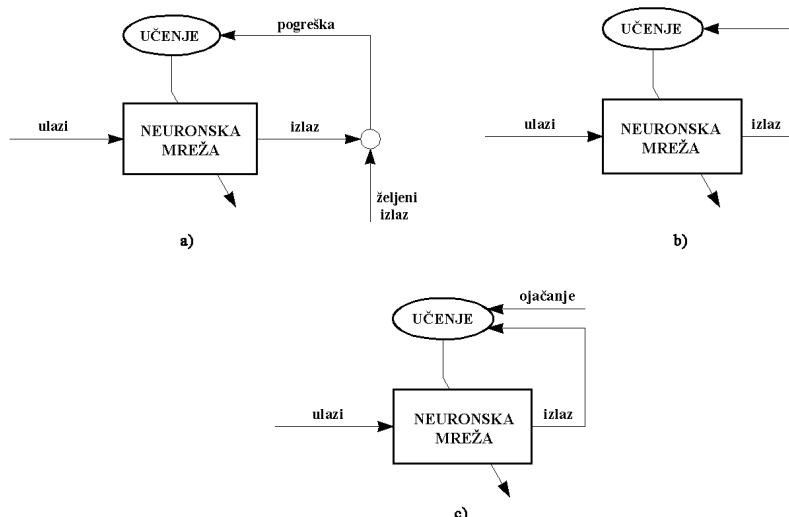
"Učenje s ojačanjem" (engl. *reinforcement learning*), slika 4c, učenje na osnovi tzv. signala ojačanja koji daje ocjenu vladanja neuronske mreže.

Ovisno o načinu određivanja smjera traženja minimuma, razlikuju se dvije osnovne kategorije: izravni i gradijentni algoritmi. Najčešće se upotrebljavaju postupci najbržeg spusta i Newtonovi postupci. Algoritmi učenja statičkih mreža prikazani su detaljno u literaturi.¹¹

Primjena unaprijednih neuronskih mreža za identificiranje dinamičkog vladanja procesa

Ulazno-izlazni modeli

Ulazno-izlazni model opisuje dinamičko vladanje sustava na temelju informacija o ulaznim i izlaznim veličinama procesa, uz pretpostavku da se novi izlazi mogu predvidjeti iz prethodnih ulaza i izlaza. Ako se nadalje pretpostavi da je sustav deterministički, vremenski invarijantan, s jednim ula-



Slika 4 – Prikaz algoritama učenja neuronskih mreža: a) na temelju pogreške, b) na temelju izlaza iz mreže, c) s ojačanjem

Fig. 4 – Learning algorithms of neural network: a) error-based, b) output-based c) reinforcement learning

zom i jednim izlazom, model se može prikazati na sljedeći način:


$$y_p(k) = f(y_p(k-1), y_p(k-2), \dots, y_p(k-n), u(k-l), u(k-2), u(k-m)), \quad (1)$$

pri čemu su $[u(k), y_p(k)]$ parovi ulaznih i izlaznih veličina sustava, n je broj prethodnih izlaza (što se naziva red sustava), a m je broj prethodnih ulaza. U praksi je m obično manji ili jednak n . Funkcija f može biti nelinearna funkcija što pridružuje prethodne ulaze i izlaze novim ulazima. Ako je sustav linearan, f je linearna funkcija, a jednadžba (1) može se napisati u obliku:

$$y_p(k) = a_1 y_p(k-1) + a_2 y_p(k-2), \dots, + a_n y_p(k-n) + b_1 u(k-1) + b_2 u(k-2), \dots, + b_m u(k-m) \quad (2)$$

pri čemu su a_i ($i = 1, 2, \dots, n$) i b_i ($i = 1, 2, \dots, m$) konstante.

Model opisan jednadžbom (2) prikazan je slikom 5.



Slika 5 – Prikaz osnovnog ulazno-izlaznog modela

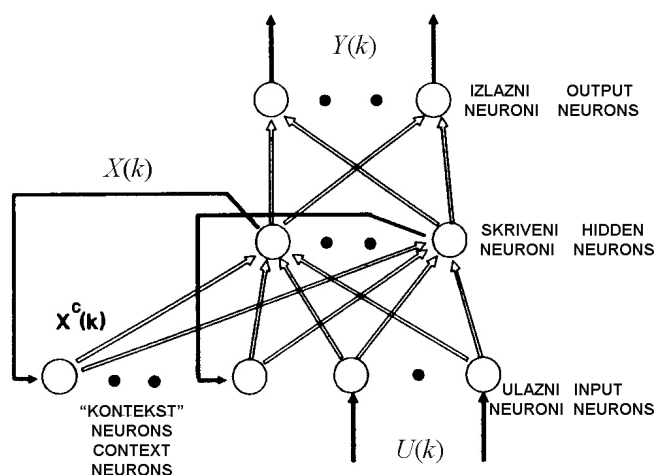
Fig. 5 – Basic input-output model

Primjena rekurentnih neuronskih mreža za identificiranje dinamičkog vladanja procesa

Kod unaprijednih mreža neuroni su povezani na takav način da svi signali putuju u jednom smjeru od ulaznih jedinica prema izlaznim. Kod rekurentnih mreža postoje i unaprijedne i povratne veze duž kojih se signali mogu propagirati u suprotnim smjerovima.^{16,17}

Rekurentne mreže moguće je podijeliti na potpuno i djelomično rekurentne. Potpuno rekurentne mreže mogu imati proizvoljni broj unaprijednih i povratnih veza, od kojih je sve moguće izvježbati. Povratne veze se formiraju putem skupa tzv. "kontekst" neurona koji se ne mogu uvježbati. "Kontekst" neuroni memoriraju prethodna stanja skrivenih neurona, pa tako izlazi iz mreže ovisi o akumuliranim prethodnim stanjima i trenutnim ulazima.¹⁸

Među postojećim rekurentnim mrežama, Elmanova mreža¹⁹ jedna je od jednostavnijih tipova koja se može uvježbati standardnim algoritmom učenja unatražnom propagacijom.⁹ Prikaz Elmanove mreže dan je na slici 6. Ulazni i izlazni neuroni veza su s okolinom. Ulazni neuroni su samo međuspremnici koji provode ulazne signale. "Kontekst" neuroni rabe se samo za memoriranje prethodnih aktivacija skrivenih neurona. Unaprijedne veze (neispunjene strelice) moguće je modificirati, a rekurentne veze (pune strelice) su fiksne.



Slika 6 – Strukturni prikaz Elmanove mreže
Fig. 6 – Structure of Elman network

Na slici 6 vanjski ulazi u mrežu prikazani su s $u(k)$, a izlazi iz mreže s $y(k)$. Aktivacije skrivenih neurona su $x(k)$. Izlazi "kontekst" neurona prikazani su sa $x^c(k)$. Slijedi:

$$x(k) = f\{w^{xc}x^c(k), w^{xu}u(k-1)\} \quad (3)$$

$$x^c(k) = x^c(k-1) \quad (4)$$

$$y(k) = w^{yx}x(k) \quad (5)$$

pri čemu su w^{xc} , w^{xu} i w^{yx} matrice težinskih koeficijenta, a f je nelinearna vektorska funkcija. Ako se uzimaju linearni skriveni neuroni, uz pretpostavku da su biasi skrivenih i izlaznih neurona jednaki nuli, jednadžbe (3) i (4) poprimaju sljedeći oblik:


$$x(k) = w^{xc}x^c(k) + w^{xu}u(k-1) \quad (6)$$

$$x^c(k) = x^c(k-1) \quad (7)$$

$$y(k) = w^{yx}x(k) \quad (8)$$

Jednadžbe (6) i (8) zapisi su dinamičkih sustava u prostoru stanja.

Velike brzine učenja uzrokuju oscilacije, a moguće su i nestabilnosti u postupku učenja. Iz tog je razloga uvedeno samopovezivanje (engl. *self-connection*) "kontekst" neurona tako kako je to opisano u literaturi.²⁰ Neuroni pritom dobivaju "inertnost", dobivajući na sposobnosti dinamičkog memoriranja, slika 7, pri čemu α iskazuje pojačanje vlastitih povratnih veza. Vrijednost α je obično između 0 i 1. Što je α bliže jedinici, "kontekst" neuron akumulira više prošlih izlaza. Budući da je red dinamičkog sustava povezan s brojem prošlih izlaza o kojima ovisi trenutni izlaz, uvođenje vlastitih povratnih veza u "kontekst" neurone omogućuje modeliranje sustava višeg reda.



Slika 7 – Struktura modificirane Elmanove mreže
Fig. 7 – Structure of modified Elman network

Primjena neuronskih mreža kod vođenja procesa

U teoriji vođenja sposobnost neuronskih mreža da modeliraju nelinearne sustave od velike je važnosti. Postoji niz standardnih metoda za analizu i sintezu nelinearnih regulatora za posebne klase nelinearnih sustava, ali nema opće primjenjive teorije za projektiranje nelinearnog vođenja. Stoga se sposobnost neuronskih mreža da predoče nelinearno vladanje najviše primjenjuje pri sintezi nelinearnih regulatora.

Do sada je objavljen čitav niz različitih načina sistematizacije razvijenih metoda vođenja. Prema *Ng*²¹ najbolja metoda klasifikacije je dvostruka podjela pri kojoj se metode dijele na metode vođenja isključivo neuronskom mrežom i hibridne metode vođenja tj. metode koje se zasnivaju na kombinacije neuronske mreže i klasičnih regulatora.¹²

Metode primjene neuronske mreže pri vođenju procesa

Primjenu neuronskih mreža za vođenje procesa prikladno je podijeliti u tri veće skupine ovisno o načelu primjene:^{22, 23}

- prediktivno vođenje (engl. *model predictive control – MPC*),
- vođenje pomoću inverznog modela procesa (engl. *inverse model-based control*) i
- prilagodljivo vođenje (engl. *adaptive control*).

Općenito, prediktivne metode vođenja imaju prednost zato što su stabilne, ali su računski zahtjevnije. Vođenje pomoću inverznog modela procesa jednostavnije je za primjenu, ali može dovesti do problema sa stabilnošću. Metode prilagodljivog vođenja s druge strane prikladne su za modele s promjenjivim parametrima, ali isto tako mogu imati problema sa stabilnošću.

Većina neuronskih mreža koje se primjenjuju su višeslojne unaprijedne mreže uključujući radijalno bazne funkcije (RBF). O njihovim prednostima i nedostacima postoji opširna literatura.^{24–28} Ostale mreže što se rabe su rekurentne i VQN (vector quantizing network).^{29–31} Prednost jedne strukture mreže nad drugima nije moguće jedinstveno ustvrditi. To u mnogome ovisi o primjeni, a razmatra se od slučaja do slučaja. Primjena obuhvaća široko područje kemijskih procesnih sustava. Najčešće se sreću destilacijske kolone i reaktorski sustavi (protočni kotlasti reaktor, biorektori i neutralizacijski reaktori). U pravilu se radi o viševeličinskim i nelinearnim sustavima.

1. Neuronske mreže pri prediktivnom vođenju

U toj metodi vođenja neuronske mreže služe kao model procesa u svrhu prediktivnog vođenja. To je vođenje u kojem se regulacijsko djelovanje određuje optimiranjem djelovanja regulacijskog kruga prema nekoj funkciji cilja u određenom vremenskom intervalu. U tom slučaju, neuronske mreže zamjenjuju fundamentalne modele.³²

Prediktivni algoritam vođenja u osnovi uključuje traženje minimuma odstupanja izlaza od radne točke uz zadani cilj i dana ograničenja. Ta metoda vođenja pokazala se, iako računski zahtjevnija, vrlo dobrom. Neuronske mreže prikladne su jer mogu predviđati izlazne vrijednosti više koraka unaprijed. Neuronska mreža predviđa za k koraka unaprijed vrijednost $y(t+k)$. Da bismo dobili optimalno regulacijsko djelovanje, definira se funkcija cilja, J :

$$J = \sum_{k=N_1}^{N_2} [e(t+k)]^2 + \sum_{i=1}^{N_3} [q_i \delta u(t+i)]^2, \quad (9)$$

pri čemu N_1 i N_2 definiraju predikcijski horizont, N_3 definira regulacijski horizont, e je pogreška između ciljane i predviđene vrijednosti, q je težinski koeficijent, a δu je promjena regulacijskog djelovanja.^{33–34}

Do sada je prikazano niz tehnika primjene modela neuronskih mreža, a najčešće se primjenjuje engl. *general predictive control* (GPC),³⁵ *dynamical matrix control* (DMC)³⁶ i *receding horizon control* (RHC).³⁷ U cjelini uzevši, te tehnike su vrlo slične, a razlika se javlja pri primjeni te pri formulaciji modela i ograničenja. U većini primjena prediktivnog vođenja upotrebljava se višeslojna unaprijedna mreža, dok se kod nekolicine rabe rekurentne i VQN mreže.^{38–43} Pregled primjene dan je u tablici 2.

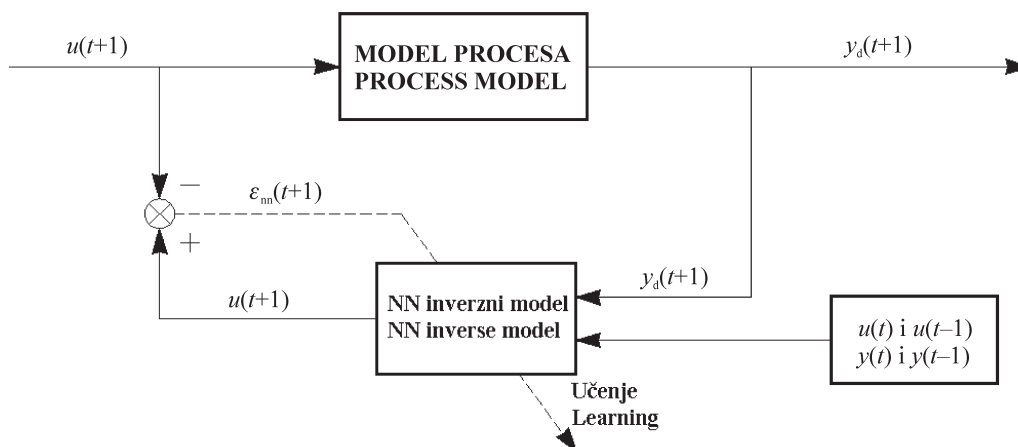
Tablica 2 – Primjeri primjene neuronskih mreža kod prediktivnog vođenja

Table 2 – Application of neural networks for predictive control

Vođena varijabla Control variable	Sustav System	Vrsta NM NN type	Referencije Reference
Sastav produkta Product composition	Destilacijska kolona Distillation column	Višeslojna Multilayer	44–46
		VQN VQN	47
	PKR CSTR	Višeslojna Multilayer	33, 48, 49
Dimenzije proizvoda Product dimensions	Rotacijski mlin Rolling mill	Višeslojna + RBF Multilayer + RBF	50
		Regulacija pH pH control	Neutralizacija Neutralization reactor
Kvaliteta produkta Product quality	Autoklava Autoclave	Višeslojna Multilayer	55
		Razina Level	Konusni spremnik Conical tank
Viševeličinsko vođenje Multivariable control	Isparivač Evaporator	Višeslojna Multilayer	56
		Rekurentna neizrazita Rucerent neuro-fuzzy	
Tlak Pressure	Destilacijska kolona Distillation column	Višeslojna Multilayer	58
		Temperatura Temperature	Kristalizacija Crystal process

2. Neuronske mreže pri vođenju pomoću inverznih modela procesa

Ovdje se, u načelu, primjenjuju dvije metode: izravno inverzno vođenje i interno modelsko vođenje (engl. *internal-model control – IMC*).



Slika 8 – Učenje neuronske mreže kao inverznog modela procesa
 Fig. 8 – Neural network training as inverse process model

Pri izravnom inverznom vođenju inverzni model djeluje kao regulator, a mreža uči inverzni model procesa, tj. predviđa ulaze potrebne za postizanje željenih izlaza iz procesa.⁵⁹ Na slici 8 prikazan je postupak učenja neuronske mreže kao inverznog modela procesa.

Ulaze u mrežu predočuju: prošli i trenutačni ulazi, $u(k - m) \dots u(k)$; prošli i trenutačni izmjereni izlazi, $y(k - n) \dots y(k)$ i željeni budući izlazi procesa, $y_m(k + 1)$.

Mreža predviđa budući ulaz $u_{NN}(k + 1)$, potreban za postizanje željenog budućeg izlaza, $y_m(k + 1)$. Inverzni model odgovara sljedećem funkcijskom odnosu:⁶¹⁻⁶²

$$\begin{matrix} u_{nn}(k + 1) = g[u(k - m) \dots u(k)], \\ y_m(k + 1), y(k - n) \dots y(k)] \end{matrix} \quad (10)$$

Postoji opširna literatura koja obrađuje zamisao primjene neuronskog inverznog modela pri vođenju procesa.^{16, 61-63}

Još robusniji i stabilniji način je nelinearno *interno modelsko vođenje* (engl. *Internal Model Control – IMC*), što predočuje proširenje linearne IMC metode.⁶⁴ Na temelju dinamičkog modela procesa, paralelno s procesom, sintetizira se regulator s povratnom vezom.^{13, 63}


Postoje i primjeri vođenja *generičkim modelom* (engl. *generic model control – GMC*), pri čemu na temelju modela procesa i referentna trajektorije, regulator slijedi zadanu trajektoriju.^{12, 65-66}

Velika većina radova unutar ove skupine primjenjuje višeslojnu unaprijednu neuronsku mrežu, a pregled je dan u tablici 3.

3. Neuronske mreže pri prilagodljivom vođenju

Premda je teorija prilagodljivih sustava temeljena na linearnim vremenski invarijantnim sustavima, zamisao i teorijska istraživanja imaju svoje mjesto i na polju neuronskih mreža.^{21-23, 77-80} Kao i kod drugih tehnika, neuronske mreže mogu se primijeniti pri prilagodljivom vođenju za nelinearne dinamičke sustave. Obično pri prilagodljivom vođenju postoje dva pristupa – izravni i posredni.

Izravno prilagodljivo vođenje (engl. *direct adaptive control*), ostvaruje se učenjem neuronske mreže tako da oponaša djelovanje postojećeg regulatora.^{60,81-83} Zamisao tog postupka prikazana je na slici 9. Neuronski regulator uči se traženjem minimuma pogreške učenja mreže, ϵ_{NN} , što čini razliku između izlaza iz regulatora, u , i izlaza iz neuronskog regulatora, u_{NN} . Takva struktura može se primijeniti u prilagodljivim sustavima za vođenje.⁸⁴



Slika 9 – Izravno prilagodljivo vođenje pomoću neuronske mreže
 Fig. 9 – Direct neural network-based adaptive control

Pri izravnom prilagodljivom vođenju nema eksplicitnog određivanja modela sustava. Umjesto toga parametri regulatora izravno se ugađaju tijekom rada (“on-line”) da bi se ostvarilo željeno vladanje i stabilnost regulacijskog kruga.⁸⁵

Pri *posrednom prilagodljivom vođenju*, neuronska mreža primjenjuje se za identificiranje modela nelinearnog procesa tijekom rada. Cilj je da izlaz procesa slijedi referentni izlaz. Regulacijsko djelovanje može se zatim izračunati s obzirom na željeno i ono izmjereno u procesu. Identifici-

T a b l i c a 3 – *Primjeri primjene neuronskih mreža kod inverznog vođenja*T a b l e 3 – *Application of neural networks for inverse control*

Vođena varijabla Control variable	Sustav System	Vrsta NM NN type	Referencije Reference
Sastav produkta Product composition	PKR CSTR	Višeslojna Multilayer	63, 67-68
	Destilacijska kolona Distillation column	Višeslojna Multilayer	69
Koncentracija produkta Product concentration	Neutralizacija Neutralization	Višeslojna Multilayer	67
	Polušaržni bioproc Fed-batch bioprocess	Višeslojna Multilayer	70
		Višeslojna Multilayer	65, 71
	PKR CSTR		
Regulacija pH pH control	Neutralizacija Neutralization reactor	Višeslojna Multilayer	54
		Radijalno bazne funkcije Radial basis function	54
Temperatura Temperature	PKR CSTR	Višeslojna + RBF Multilayer + RFB	65, 72-73
	PKR CSTR	Rekurentna Recurrent	74
	Peć za vapno Lime kiln	Višeslojna Multilayer	75
	Izmjenjivač topline Heat exchanger	Višeslojna Multilayer	76

ranje i vođenje odvijaju se simultano. Detalji o tom načinu vođenja dostupni su u literaturi.⁸⁶⁻⁸⁷

Većina primjena u ovoj skupini primjenjuje unaprijednu višeslojnu mrežu, tablica 4.

4. Industrijska primjena neuronskih mreža

U tablici 5 dani su primjeri industrijske primjene vođenja koje se temelji na modelu neuronske mreže. U većini primjera upotrebljavaju se višeslojne unaprijedne mreže. Poboljšanja koja se ostvaruju njihovom primjenom specifična su od slučaja do slučaja, no postoji i mnogo primjera gdje se upotreba neuronskih mreža nije mogla opravdati.^{22,96}

T a b l i c a 4 – *Primjeri primjene neuronskih mreža kod prilagodljivog vođenja*T a b l e 4 – *Application of neural networks for adaptive control*

Vođena varijabla Control variable	Sustav System	Vrsta NM NN type	Referencije Reference
Sastav produkta Product composition	PKR CSTR	Višeslojna + RBS Multilayer + RBS	80, 88
	Fermentacija Fermentation	Višeslojna Multilayer	89
Koncentracija produkta Product concentration	Neutralizacija Neutralization	Višeslojna Multilayer	90
	Neutralizacija Neutralization	Rekurentna Recurrent	90
	PKR CSTR	Višeslojna Multilayer	80
	Bioreaktor Bioreactor	Višeslojna Multilayer	91-92
Regulacija pH pH control	Neutralizacija Neutralization reactor	Višeslojna + RBS Multilayer + RBS	90, 93
Temperatura Temperature	PKR – izotermni CSTR – isothermal	Višeslojna Multilayer	94
	Polimerizacijski reaktor Polymerisation reactor	Višeslojna Multilayer	95
Razina Level	Spremnik Tank	Višeslojna Multilayer	91

Zaključak

U ovom radu dani su pregled i mogućnost primjene neuronskih mreža u kemijskom inženjerstvu za identificiranje i vođenja procesa. Karakteristika neuronskih mreža da mogu identificirati dinamiku nelinearnih procesa omogućuju široku primjenu kod vođenja procesa temeljenog na modelu. Pri tome treba istaknuti sljedeće činjenice:

– Neuronske mreže moguće je primijeniti u okviru već poznatih metoda nelinearnog vođenja;

– Premda je danas razvijen velik broj drugih vrsta mreža, najčešće se upotrebljavaju višeslojne unaprijedne mreže koje su se pokazale široko primjenjivima;

– U većini slučajeva radi se o primjeni na simulacijskoj i laboratorijskoj razini. Postoji stanovit broj primjena na pilot-postrojenjima i u industriji, obično primjenom neke od metoda prediktivnog vođenja, no broj objavljenih članaka, sudeći prema dostupnim nam bibliografskim bazama, još uvijek nije toliko velik.

Neuronske mreže pronašle su primjenu i na područjima kao što su *nadgledanje* i *dijagnostika* procesa.^{13,115–116} Za

T a b l i c a 5 – Primjeri industrijske primjene neuronskih mreža

T a b l e 5 – Industrial application of neural networks

Vođena varijabla Control variable	Metoda vođenja Control technique	Sustav System	Vrsta NM NN type	Referencije Reference
Sastav produkta Product composition	Prediktivno Predictive	Polimerizacijski reaktor Polymerisation reactor	Multilayer Višeslojna	97
Regulacija pH pH control	Prediktivno Predictive	Cijevni neutr. reaktor Tubular neut. Reactor	Višeslojna + RBF Multilayer + RBF	98
	IMC IMC	Neutralizacija Neutralization	Višeslojna + RBF Multilayer + RBF	99
	DMC DMC	Neutralization Neutralization	Višeslojna Multilayer	100
	Prilagodljivo Adaptive	Fermentor Fermentor	Rekurentna Recurrent	101
Temperatura Temperature	Direktno inverzno Direct inverse	Polušaržni reaktor Semi-batch reactor	Višeslojna Multilayer	102
	Prilagodljivo Adaptive	Peć Furnace	Višeslojna Multilayer	103
	GPC prilagodljivo GPC adaptive	Spremnik s grijanjem Heated tank	VQN mreža VQN network	104
	Prediktivno Predictive	Destilacijska kolona Distillation column	Višeslojna Multilayer	105
	IMC prilagodljivo IMC adaptive	Peć Oven	Višeslojna + RBF Multilayer + RBF	106
	Inverzno s GMC Inverse with GMC	Grijač Heater	Višeslojna Multilayer	107
	Inverzno s GMC Inverse with GMC	Izmjenjivač topline Heat exchanger	Višeslojna Multilayer	108
	Prediktivno Predictive	Reaktor s slojem kataliz. Packed bed reactor	Rekurentna Recurrent	109
	Prediktivno Predictive	Industrijska peć Furnace	Višeslojna Multilayer	110-111
Razina Level	Prediktivno Predictive	Dva spremnika u seriji Two tank in series	Višeslojna Multilayer	112
	Povratna veza Feedback control	Spremnik Tank system	Višeslojna Multilayer	51
	GPC prilagodljivo GPC adaptive	Dva spremnika u seriji Two tank in series	VQN mreža VQN network	113
Tlak Pressure	Prediktivno Predictive	Tlačna posuda Pressure vessel	Višeslojna Multilayer	114

kvantitativno predviđanje vrijednosti procesnih veličina koje su teško mjerljive^{117–122} i inferencijsko vođenje^{123–125} rabe se *softverski senzori i analizatori*.

Budućnost primjene neuronskih mreža ne leži samo u njihovoj eksplicitnoj upotrebi nego i u povezivanju s drugim naprednim tehnikama. Fuzija neuronskih mreža i neizrazite logike u obliku neizrazito-neuronskih mreža (engl. *neuro-fuzzy network*) jedna je od mogućnosti koja se već primjenjuje.¹²⁶ Drugo važno područje je hibridno modeliranje,^{12, 127–128} odnosno metode identificiranja koje se nadopunjuju s fenomenološkim modelima.

Literatura References

1. Special issue on neural networks, *IEEE Control Systems* **10** (2) (1990).
2. Special issue on neural networks, *IEEE Control Systems* **12** (2) (1992).
3. Special Issue on Artificial Neural Networks, *IEEE Trans. on System, Man, And Cybernetics* **28** (4) (1998).
4. *J. Jain, D. Mao*, *Computer*, March (1996) 31.
5. *M. Baotić*, Identifikacija i upravljanje nelinearnim vremenski promjenjivim procesima primjenom neuronskih mreža, Magistarski rad, Sveučilište u Zagrebu, 2000.

6. W. S. McCulloch, W. Pitts, *Bull. Math. Biophys.* **5** (1943) 115.
7. F. Rosenblatt, *Principles of neurodynamics*, Spartan Books, New York, 1962.
8. M. L. Minsky, S. Papert, *Perceptrons*, MIT Press, Cambridge MA, 1969.
9. D. Rumelhart, J. McClelland, *Parallel distributed processing: exploitations in the micro-structure of cognition*, Vol 1 & 2, Cambridge: MIT Press, 1986.
10. M. M. Gupta, D. H. Rao, eds., *Neuro-Control Systems, Theory and Applications*, IEEE Press, New York, 1994.
11. I. Petrović, *Identifikacija nelinearnih dinamičkih procesa statičkim neuronskim mrežama*, Doktorska disertacija, Sveučilište u Zagrebu, 1998.
12. D. Gosak, *Optimalno vođenje diskontinuiranog procesa rektifikacije primjenom živčevne mreže*, Doktorska disertacija, Sveučilište u Zagrebu, 2003.
13. J. C. Hoskins, D. M. Himmelblau, *Comp. Chem. Eng.* **12** (1995) 881.
14. S. Chen, S. A. Billings, *Int. J. Control* **56** (2) (1992) 319.
15. K. Hornik, *Neural Networks* **4** (1991) 251.
16. N. Bhat, T. J. McAvoy, *Comput. Chem. Eng.* **14** (4/5) (1992) 573.
17. K. S. Narendra, K. Parthasarathy, *IEEE Trans. on Neural Networks*, **1** (1) (1990) 4.
18. Y. You, M. Nikolaou, *AIChE Journal* **39** (10) (1993) 1654.
19. J. L. Elman, *Cognitive Science* **14** (1990) 179.
20. M. I. Jordan, *Proc. of the Annual Conf. of the Cogn. Sci. Soc.* (1986) 531.
21. G. W. Ng, *Application of neural network for adaptive control of nonlinear systems*, Research Studio Press, Taunton, 1997.
22. M. A. Hussain, *Artif. Intell. in Eng.* **13** (1999) 55.
23. D. R. Baughman, Y. A. Liu, *Neural Networks in Bioprocessing and Chemical Engineering*, Academic Press, San Diego, 1995.
24. B. Widrow, M. Lehr, *Proc. IEEE* **78** (9) (1990) 1415.
25. T. Poggio, F. Girosi, *Proc. IEEE* **78** (9) (1990) 1481.
26. A. J. Moran, C. T. Harston, R. M. Pap, *Handbook of neural computing applications*, Academic Press, London, 1990.
27. R. P. Lipmann, *IEEE ASSP Mag.* **4** (1987) 4.
28. S. Haykin, *Neural networks – a comprehensive foundation*, MacMillan, New York, 1994.
29. M. Caudill, C. Butler, *Understanding neural nets: computing explorations*, vol II. MA, MIT, Cambridge, 1992.
30. R. J. Mammone, Y. Zeevi, *Neural networks, theory and applications*, Academic Press, New York, 1993.
31. T. Karjala, D. M. Himmelblau, *AIChE J.* **40** (1994) 1865.
32. A. J. Morris, G. A. Montague, M. J. Willis, *Trans. Inst. Chem. Engng., UK – Part A* **72** (1994) 3.
33. M. J. Willis, C. DiMassimo, G. A. Montague, M. T. Tham, A. J. Morris, *IEE Proc. – Part D* **138** (1991) 256.
34. A. Saint-Donat, N. Bhat, T. J. McAvoy, *Int. J. Contr.* **54** (1991) 1453.
35. D. W. Clarke, C. Mohtadi, P. S. Tuffs, *Automatica* **23** (2) (1987) 137.
36. C. R. Cutler, B. L. Ramaker, *American Institute Chemical Engineers Meeting Proc.*, TX, Houston, 1979.
37. D. Q. Mayne, H. Michalska, *IEEE Trans. Auto Contr.* **35** (7) (1990) 814.
38. N. Bolf, *Prilagodljivo koordinirano vođenje složenih procesa*, doktorska disertacija, Sveučilište u Zagrebu, 2003.
39. J. Blum, P. Villard, A. Leuba, D. M. Himmelblau, *AIChE Annual Meeting*, Nov. (1992), Miami, FL.
40. J. B. Gomm, J. T. Evans, D. Williams, *Control Eng. Practice* **5** (1) (1997) 49.
41. M. Ishida, J. Zhan, *AIChE J.* **41** (1995) 2333.
42. J. Saint-Donat, N. Bhat, T. J. McAvoy, *Int. J. Control* **54** (6) (1991) 1453.
43. A. Tholudur, W. F. Ramirez, *AIChE Journal* **45** (8) (1999).
44. M. J. Willis, G. A. Montague, C. DiMassimo, M. T. Tham, A. J. Morris, *Automatica* **28** (6) (1992) 1181.
45. V. Gokhale, S. Horowitz, J. B. Riggs, *Ind. Engng. Chem. Res.* **34** (1995) 4413.
46. M. Lee, S. Park, *AIChE J.* **38** (2) (1992) 193.
47. L. Megan, D. J. Cooper, *Comput. Chem. Engng.* **19** (2) (1995) 171.
48. D. M. Psychogios, L. H. Ungar, *Ind. Engng. Chem. Res.* **30** (1991) 2564.
49. E. Hernandez, Y. Arkun, *Am. Contr. Conf.* **1**, Boston, (1990) 2454.
50. H. D. Sbarbaro, D. Neumerkel, K. Hunt, *IEEE Contr. Syst.* **13** (3) (1993) 631.
51. P. Langonet, *Conf. on Precision Processing Technology*, Netherlands (1993) 631.
52. B. Eikens, M. Karim, *Adv. Cont. Chem. Process (ADCHEM) Symp, Japan*, (1994) 125.
53. M. Pottmann, D. E. Seborg, *Comput. Chem. Engng.* **21** (9) (1997) 9650.
54. K. J. Hunt, D. Sbarbaro, *IEE Control Engineering Series*, London, 1992.
55. B. Joseph, F. W. Hanratty, *Ind. Engng. Chem. Res.* **32** (1993) 1951.
56. P. M. Mills, A. Y. Zomaya, M. O. Tade, *Int. J. Contr.* **60** (6) (1994) 1163.
57. J. Zhang, A. J. Morris, *Neural Comput. & Appl.* **9** (2000) 50.
58. P. Turner, G. A. Montague, A. J. Morris, *Fourth Int. Conf. Artificial Neural Networks*, Cambridge (1995) 284.
59. Y. H. Pao, S. M. Phillips, D. J. Sobajic, *Int. J. Contr.* **56** (2) (1992) 263.
60. D. H. Wang, C. B. Soh, *International Journal of System Science* **31** (1) (2000) 119.
61. S. B. L. Kooi, Khorasani, *Tappi Journal* **75** (1992) 156.
62. K. J. Hunt, D. Sbarbaro, R. Zbikowski, P. J. Gawthrop, *Automatica* **28** (6) (1992) 1083.
63. D. M. Psychogios, L. H. Ungar, *Ind. Eng. Chem. Res.* **30** (1991) 2564.
64. C. G. Economou, M. Morari, B. O. Palsson, *Ind. Engng. Chem. Process Des. Dev.* **25** (1986) 403.
65. G. M. Scott, W. Harmon Ray, *J. Proc. Cont.* **3** (1993) 179.
66. K. Kosanovich, M. Piovoso, *Proc. of the World Congress on NN*, Portland, OR, **1** (1993) 471.
67. E. P. Nahas, M. A. Henson, D. E. Seborg, *Comp. Chem. Engng.* **16** (2) (1992) 1039.
68. B. S. Dayal, P. A. Taylor, J. F. MacGregor, *Can. J. Chem. Engng.* **72** (1994) 1067.
69. M. S. Basualdo, H. A. Ceccatto, *DYCORD Int. Fed. Auto. Cont. IFAC Symp.* (1995) 171.
70. A. Bulsari, B. Saxen, H. Saxen, *Neural control of a fed batch Bioprocess*, In: *Lecture Notes in Computer Science* (No. 686). Springer, Berlin, 1993.
71. G. Lightbody, G. W. Irwin, *Proc. Am. Control. Conf.* (1995) 350.
72. M. J. Piovos, K. A. Kosanovich, A. R. Moser, *Proc. Am. Control. Conf.* (1992) 490.
73. M. A. Shah, P. H. Meckl, *Proc. Am. Control. Conf.* (1995) 4265.
74. M. Nikolaou, V. Hanagandi, *AIChE J.* **39** (11) (1993) 1890.

75. B. M. Riberio, A. Dourado, Bulsari ed., Neural networks for chemical engineers, Chap. 7, 1995.
76. G. D'Áz, M. Sen, K. T. Yang, R. L. McClain, *Int. Journ. of Heat and Mass Transf.* **44** (2001) 1671.
77. T. D. Knapp, H. M. Budman, G. Broderick, *Journal of Process Control* **11** (2001) 53.
78. E. F. Camacho, M. R. Arahal, IFAC Artificial Intelligence in Real Time Control, Valencia, Spain (1994)
79. P. M. Mills, A. Y. Zomaya, M. O. Tade, *Neuro-Adaptive Process Control: A Practical Approach*, John Wiley and Sons Ltd., England, 1995.
80. G. Lightbody, G. W. Irwin, *IEE Proc.-Control Theory Appl.* **142** (1) (1995).
81. D. Psaltis, A. Sideris, A. A. Yamamura, *IEEE Control Systems Magazine* **8** (2). (1988) 17.
82. W. T. Miller, R. E. Sutton, P. J. Werbos, Editors, *Neural Networks for Control*, MIT Press, Cambridge, MA (1990).
83. Y. Ichikawa, T. Sawa, *IEEE Trans. Neural Networks* **3** (1992) 224.
84. K. S. Narendra, in: *Miller, W.T., Sutton, R.S. and Werbos, P.J. Ed, MIT Press, Cambridge, MA, (1990). pp. 115-143.*
85. C. Lightbody, A. Dumdell, *IEE Contr. Engineer. Series* **46** (1992) 51.
86. K. S. Narendra, K. Parthasarathy, *IEE Proc. Neural Networks* **1** (1990) 4.
87. R. M. Sanner, J. J. Slotine, *IEEE Trans. Neural Networks* **3** (6) (1992) 1299.
88. T. D. Knapp, H. M. Budman, G. Broderick, *Jour. of Proc. Cont.* **11** (2001) 53.
89. J. D. Boslovic, K. S. Narendra, *Automatica* **31** (6) (1995) 817.
90. A. P. Loh, K. O. Looi, K. F. Fong, *J. Process Contr.* **5** (6) (1995) 355.
91. T. Chovan, T. Catfolis, K. Meert, *AIChE J.* **42** (2) (1996) 493.
92. Y. Y. Yang, D. A. Linkens, *IEE Proc – Control Theory Applications* **141** (5) (1994) 341.
93. N. D. Ramirez-Beltran, J. A. Montes, *IIE Trans.* **34** (2002) 313.
94. B.E. Ydstie, *Comput. Chem. Engng.* **14** (1990) 583.
95. N. Watanabe, *Adv. Cont. Chem. Process (ADCHEM) 94 Symp.* (1994) 391.
96. B. Lennox, G. A. Montague, A. M. Frith, C. Gent, V. Bevan, *Jour. of Proc. Cont.* **11** (2001) 497.
97. A. Y. Tsen, S. S. Jang, D. S. Wong, B. Joseph, *AIChE J.* **42** (2) (1996) 455.
98. S. K. Doherty, D. Williams, J. B. Gomm, *Inst. Chem. Eng. – Advances in Process Control 4 Meeting* (1995) 57.
99. D. E. Seborg, *IEEE Control 94 Conf.* (1994) 879.
100. A. Draeger, S. Engell, H. Ranke, *IEEE Control Systems* (1995) 61.
101. M. Syu, J. B. Chang, *Ind. Engng. Chem. Res.* **36** (1997) 3756.
102. L. Dirion, M. Cabassud, M. V. Le Lann, G. Casamatta, *Comput. Chem. Engng.* **19S** (1995) S797.
103. M. Khalid, S. Omatu, R. Yusuf, *IEEE Trans. Contr. Syst. Technol.* **1** (4) (1993) 238.
104. R. F. Hinde, D. J. Cooper, *AIChE J.* **41** (1) (1992) 110.
105. C. Wormsley, J. Henry, *Am. Inst. Chem. Eng. Annual Nov. Meeting San Francisco, CA, (1994).*
106. O. Dubois, J. Nicolas, A. Billat, *Colloquium on Advances in Neural Network for Control and Systems, Vol. 8 Germany* (1994) 1.
107. P. Dutta, R. R. Rhinehart, *Proc. Am. Control. Conf.* (1995) 1787.
108. N. V. Joshi, P. Murugan, R. Rhinehart, *Contr. Engng. Practice* **5** (17) (1997) 885.
109. K. O. Temeng, P. D. Schnelle, T. J. McAvoy, *J. Process Contr.* **5** (1) (1995) 19.
110. C. P. Sheppard, C. R. Gant, R. M. Ward, *Proc. Am. Control. Conf.* (1992) 500.
111. Y. Kim, K. C. Moon, B. S. Kang, C. Han, K. S. Chang, *Cont. Eng. Pract.* **6** (1998) 1009.
112. J. T. Evans, P. S. James, H. W. Chandler, *Proc. IEE Colloquium Nonlinear Contr* **12** (1993) 1.
113. D. J. Cooper, L. Megan, R. F. Hinde, *AIChE J.* **38** (1) (1992) 41.
114. H. J. Van Can, H. A. Bracke, C. Hellinga, A. J. Krijgsman, H. B. Verbruggen, K. Ch. A. M. Luyben, J. J. Heijnen, *Chem. Engng. Sci.* **50** (15) (1995) 2419.
115. Ž. Kurtanjek, *Comp. Chem. Eng.* **18** (1994) S627.
116. K. Watanabe, I. Matsuura, M. Abe, M. Kubota and D. M. Himmelblau, *American Institute of Chemical Engineering Journal* **35** (11) (1989) 1803.
117. V. Venkatasubramanian, K. Chan, *American Institute of Chemical Engineering Journal* **35** (12) (1989) 1993.
118. P. A. Lant, M. J. Willis, G. A. Montague, M. T. Tham, A. J. Morris, *Proc. ACC, San Diego* (1990) 2173.
119. M. T. Tham, G. A. Montague, A. J. Morris, *Advanced Methods in Adaptive Control for Industrial Applications, Springer-Verlag Lecture Notes in Control and Information Sciences*, 1991.
120. C. DiMassimo, G. A. Montague, M. J., Willis, M. T. Tham, A. J. Morris, *Comp. And Chemical Engineering* **16** (4) (1992) 283.
121. A. Bhattacharya, *Chem. Eng. and Proc.* **44** (5) (2005) 565.
122. N. Bolf, M. Glasner, I. Jerbić, *Proc. of the Int. Conf. – Intelligent Control Systems, Brno, Czech Republic* (2005) 194.
123. G. A. Montague, A. J. Morris, M. T. Tham, *J. Biotechnology* **25** (1992) 183.
124. M. J. Willis, C. DiMassimo, G. A. Montague, M. T. Tham, A. J. Morris, *Proc. IFAC Symp. ITAC'91, Singapore, Jan. (1991)* 15.
125. M. J. Willis, G. A. Montague, C. DiMassimo, M. T. Tham, A. J. Morris, *Automatica* **28** (6) (1992) 1181.
126. W. H. Verduin, *Better Products Faster: A Practical Guide to Knowledge-Based Systems for Manufacturers*, Irein Provesional Publishing, Burr Ridge, 1995.
127. J. R. Jang, C. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice Hall 1996.
128. E. J. Molga, *Chem. Eng. and Proc.* **42** (2003) 675.

SUMMARY**Application of Artificial Neural Networks for
Process Identification and Control***N. Bolf and I. Jerbić**

During the development of intelligent systems inspired by biological neural system, in the last two decades the researchers from various scientific fields have created neural networks for solving a series of problems from pattern recognition, prediction, diagnostic, software sensor, modelling and identification, control and optimization. In this paper a review of neural network application in the field of chemical engineering with emphasis on identification and process control is given.

The neural networks have been proven useful in the applications which include complex chemical and biochemical reactions. In such a processes use of standard methods of process modelling and control structure are frequently not suitable. The ability of neural network to model dynamics of nonlinear process makes them an important tool for implementation in model-based control. Due to intensively theory development and many practical applications, there are numerous neural network structures and algorithms.

In this paper neural networks are categorized under three major control schemes: model-based predictive control, inverse model-based control, and adaptive control. The major applications are summarized. It reveals prospect of using neural networks in process identification and control.

The future of neural network application lies not only in their explicit use, but in cross connecting to other advanced technologies as well. Fusion of neural networks and fuzzy logic in the form of neural-fuzzy network is one of the possibilities. Other important field is hybrid modelling and identification methods which supplement simplified mechanistic models. Software sensors and their application, especially in controlling of bioprocesses, present a very promising field.

*University of Zagreb, Faculty of Chemical Engineering
and Technology, Savska c. 16/5a, 10 000 Zagreb, Croatia
e-mail: bolf@fkit.hr*

*Received February 28, 2005
Accepted January 10, 2006*

** Ina d. d., Refinery Sisak d. d., A. Kovačića 1, 44 000 Sisak, Croatia
e-mail: ivica.jerbic@ina.hr*