DRAGAN D. KUKOLJ
MIROSLAVA T. BERKO–PUŠIĆ

Fakultet tehničkih nauka,
Novi Sad

NAUČNI RAD

621.02:65.012:66.073.3

RAZVOJ KOMPONENTI INTELIGENTNOG SISTEMA UPRAVLJANJA GASOVODNOM MREŽOM

U radu je opisan postupak projektovanja inteligentnog observera stanja gasovodne mreže. Njime je izvršena nadgradnja postojećeg SCADA sistema gasovodne transportne mreže u cilju detekcije greški, estimacije i predikcije procesnih veličina. Ove funkcije se zasnivaju na dve tehnike računarske inteligencije: veštačkim neuronskim mrežama i Takagi–Sugeno rasplinutim modelima. Razmatran je uticaj više faktora na tačnost ovako primenjenih veštačkih neuronskih mreža ili Takagi–Sugeno rasplinutog modela.

Gasovodna mreža je složeni distribuirani tehnički sistem koji se odlikuje velikim brojem merenih veličina. Raspored i vrsta velikog broja mernih uređaja su u najvećoj meri birani u cilju ispunjavanja obaveza prema potrošačima. Međutim, ni tako veliki broj merenja nije dovoljan da prati složenu nelinearnu dinamiku sistema. Zbog toga je od izuzetnog značaja postojanje funkcija u okviru SCADA (Supervisory Control And Data Acquisition) sistema, koje omogućavaju efektivno i pouzdano upravljanje gasovodnom mrežom. Pomoću takvih funkcija dispečeri mogu i u uslovima preopterećenja i u incidentnim situacijama pravovremeno reagovati. Treba posebno izdvojiti sledeće funkcije: (1) Estimacija stanja – estimacija promena pritiska i protoka [1]; (2) Predikcija stanja – kratkoročna predikcija vrednosti pritisaka i potrošnje gasa, line–pack–a ili bilansa potrošnje; (3) Detekcija greški – rano otkrivanje neželjenih pojava u sistemu kao što su otkazi mernih uređaja, greške u prenosu signala ili curenje gasa [2, 3].

U svetlu gore navedenih funkcija, mogu se uočiti sledeće razlike bitne za izbor ulaznih veličina adekvatnih funkcija. Kada se govori o estimatoru stanja, onda ulazne veličine mogu biti ključne merene veličine ili njihova odstupanja od referentnih vrednosti [4]. Za funkciju predikcije, ulazne veličine su najčešće niz prethodnih vrednosti potrošnje. Takođe, indikatori dana u sedmici i/ili vremenski uslovi mogu biti vrlo značajni. U slučaju dijagnostičke funkcije je važno uočiti promene u stanjima dobijenih merenjem i estimacijom [4].

Da bi SCADA sistem u potpunosti mogao da podrži ove funkcije, neophodno je postojanje modela sistema poznatog pod opštim nazivom kao observer stanja. Observer stanja je matematički model koji služi za rekonstrukciju odabranih promenljivih stanja. Observer stanja posmatranog procesa treba da ispuni nekoliko osnovnih uslova. Sa tačke gledišta dinamike ponašanja sistema, observer stanja treba da što bolje aproksimira proces, a da pri tome bude jednostavan i pogodan za izvršavanje u realnom vremenu. To istovremeno znači da dinamika observera, odnosno dinamika greške izmerenih i restaurisanih stanja mora biti znatno brža od dinamike samog procesa.

Strujanje prirodnog gasa u gasovodnoj mreži je vrlo složen proces. Uz pretpostavke da se radi o jednodimenzionom izotermičkom procesu strujanja stišljivog fluida kroz cevi konstantnog poprečnog preseka, onda se takav proces može opisati sistemom hiperboličnih parcijalnih diferencijalnih jednačina [5]. Ove diferencijalne jednačine predstavljaju jednačine kontinuiteta i momentne jednačine. Na osnovu sistema takvih jednačina nije moguće formirati observer stanja već je potrebno izvršiti njihovu aproksimaciju običnim diferencijalnim jednačinama koje je potrebno nakon toga još linearizovati i diskretizovati. Složenost postupaka i veliki broj aproksimacija koji smanjuju tačnost modela su bili razlog za nalaženje novih pristupa u projektovanju observera stanja. Ovde su u tu svrhu iskorišćene savremene metode računarske inteligencije. Pomoću ovih metoda je moguće dobiti modele dinamičkih sistema visoke složenosti bez poznavanja detaljnog matematičkog modela. Pretpostavka za primenu ovde iskorišćenih metoda je postojanje SCADA baze podataka. Takva baza podataka sadrži numeričke vrednosti merenih veličina koje predstavljaju informaciju o svim promenama koje su se dešavale u sistemu u prošlosti.

U daljem tekstu je prvo dat kratak pregled oba korišćena pristupa računarske inteligencije. Zatim je opisan postupak formiranja i podešavanja modela baziranih na oba modula sa statističkom analizom dobijenih rezultata. Na kraju je prikazan koncept razvijene programske podrške. Završne napomene su date u zaključku rada.

Adresa autora: D. Kukolj, Fakultet tehničkih nauka, Trg Dositeja Obradovića 6, 21000 Novi Sad
Rad primljen: Januar 28, 2000
Rad prihvaćen: April 10, 2000

PREGLED KORIŠĆENIH METODA RAČUNARSKE INTELIGENCIJE

Za projektovanje inteligentnog observera stanja su između velikog broja metoda karakterističnih za računarsku inteligenciju, izabrana dva pristupa: veštačke neuronske mreže tipa višeslojnog perceptrona (VNM) [6] i Takagi–Sugeno rasplinuti model prvog reda (TS model) [7]. Oba ova pristupa imaju sposobnost generalizovanja i skladištenja znanja o procesu na osnovu reprezentativnih uzoraka koji sadrže relevantne informacije o ponašanju sistema u različitim radnim režimima.

Veštačke neuronske mreže

Korišćen je višeslojni perceptron tip VNM [6]. Ovaj tip VNM odlikuju sledeće osobine relevantne za njihovu primenu u identifikaciji i upravljanju: vršenje složenih ulazno–izlaznih preslikavanja, robustnost na ulazne smetnje i sposobnost aproksimacije široke klase nelinearnih funkcija [6, 8]. Pošto struktura višeslojnog perceptrona ne sadrži u sebi dinamičke karakteristike, ponašanje dinamičkog sistema može biti podražavano ulaznom sekvencom od više prethodnih vrednosti ulaza. Obuka VNM je vršena pomoću metode prostiranja greške unazad [6]. Ovom metodom opadajućeg gradijenta se vrši minimizacija greške izlaza VNM.

Korišćene su VNM sa jednim skrivenim slojem neurona. Takve mreže preslikavaju svaki ulazni uzorak **x** u izlaz **y** na način definisan sledećim izrazom:

$$\boldsymbol{y} = \Gamma_O\left[\boldsymbol{W_O} \cdot \Gamma_H\,[\boldsymbol{W_H} \cdot \mathbf{x}\,]\right], \qquad (1)$$

gde su $\mathbf{W_H}$ i $\mathbf{W_O}$ matrice težina sinapsi u skrivenom i izlaznom sloju VNM, respektivno, a $\Gamma_H\,[\,\cdot\,]$ i $\Gamma_O\,[\,\cdot\,]$ su u opštem slučaju nelinearni dijagonalni matrični operatori koji sadrže aktivacione funkcije neurona. Tačnost ovako definisanih VNM se postiže procesom obuke zahvaljujući adaptaciji elemenata koeficijenata sinapsi matrica $\mathbf{W_H}$ i $\mathbf{W_O}$.

Samo–organizujući Takagi–Sugeno rasplinuti logički model

Kao drugi pristup je korišćen Takagi–Sugeno (TS) rasplinuti model prvog reda [9]. U daljem tekstu je opisan automatizovani postupak dobijanja ovog modela. To znači da je za ovaj postupak neohodno postojanje reprezentativnog obučavajućeg skupa uzoraka, kao što je to bilo neophodno i kod prvog pristupa, kod VNM. Proizvoljni TS fuzzy model može sadržati K fuzzy pravila sledećeg oblika:

$$\mathbf{R}_i:\ \textbf{If } x_1 \text{ is } \mathbf{A}_{i1} \textbf{ and } x_2 \textbf{ is } \mathbf{A}_{i2} \textbf{ and } \ldots \textbf{ and } x_n \textbf{ is } \mathbf{A}_{in} \qquad (2)$$

$$\textbf{then } y_i = \mathbf{a}_i\, x + b_i, \qquad i = 1, 2, 3\ldots, K$$

Prethodni izraz prikazuje izgled $\boldsymbol{R}_i$ pravila, gde su: ulazne varijable $x_1, x_2, \ldots, x_n$, kojima su dodeljeni odgovarajući fuzzy skupovi $\boldsymbol{A}_{i1}, \boldsymbol{A}_{i2}, \ldots, \boldsymbol{A}_{in}$; promenljiva y_i predstavlja vrednost izlaza *i*–tog pravila; a parametri posledične funkcije su $\boldsymbol{a}_i$ i b_i.

Postupak formiranja TS fuzzy modela se odvija u dve faze: identifikacije strukture i identifikacije parametara. U okviru prve faze se vrši identifikacija strukture, odnosno, formira se *K* klastera kojima odgovara *K* pravila TS fuzzy modela. U okviru ove faze se pomoću Fuzzy c–means (FCM), Gustafson–Kessel (GK) [10] ili neke druge klastering metode vrši particioniranje ulazno–izlaznog prostora. Metoda koristi obučavajući skup koji sadrži N ulazno–izlaznih uzoraka $z_k = [x_k; y_k]^T$, $k = 1, \ldots, N$, gde je *N* ukupan broj uzoraka. Svaki dobijeni klaster predstavlja izvestan radni režim sistema, gde su ulazno–izlazni parovi vrednosti koncentrisani prema nekoj usvojenoj metrici. Kod FCM metode se koristi Euklidska metrika koja za posledicu ima klastera u obliku hipersfera. GK metoda koristi modifikovanu Euklidovu normu, što za posledicu ima klastere u obliku hiperelipsoida. Obučavajući parovi podataka koji su grupisani u takve informacione klastere se zatim intrpretiraju kao fuzzy pravila.

Po završetku definisanja strukture rasplinutog modela se pristupa drugoj fuzzy, a to je identifikacija parametara. Pomoću ove faze se vrši izračunavanje parametara funkcija iz posledičnog dela pravila. Za određivanje parametara posledične funkcije je potrebno izračunati stepen aktivacije *i*–tog pravila β_i i u tu svrhu se koristi metoda najmanjih kvadrata.

Izračunavanjem parametara $\boldsymbol{a}_i$ i b_i je uspostavljena funkcionalna zavisnost između ulaza i izlaza modeliranog sistema. Konačan izlaz TS fuzzy modela se računa kao pondrerisana srednja vrednost izlaza svih aktiviranih pravila po obrascu:

$$y_k = \frac{\sum_{i=1}^{K} [\beta_i(\mathbf{x}_k)\,(\mathbf{x}_k \boldsymbol{a}_i + b_i)]}{\sum_{i=1}^{K} \beta_i(\mathbf{x}_k)}, \quad k = 1,2,3,\ldots,N. \qquad (4)$$

POSTUPAK EKSPERIMENTALNOG PROJEKTOVANJA VNM I TS FUZZY MODELA

Nezavisno od tipa razmatrane upravljačke funkcije, postupak njihovog projektovanja se uvek zasniva na formiranju modela preslikavanja ulazno–izlaznih podataka. Uspešno ulazno–izlazno preslikavanje zavisi od spoljnih uticaja koji potiču od ulaznog vektora uzoraka i od unutrašnjih karakteristika korišćenog modela. Spoljni uticaji mogu biti količina podataka, njihova reprezentativnost, kompletnost, informativnost itd. Grupu unutrašnjih uticaja čine broj skrivenih slojeva i broj neurona u njima, tip aktivacione funkcije neurona, veze među neuronima, načina obuke ili tip funkcije pripadnosti, broj pravila, metoda klasterisanja itd. Uticaj tih faktora na izlaz modela može se izraziti funkcionalnom zavisnošću $\mathbf{y} = f(x_1, x_2, \ldots x_i, \ldots x_m)$, gde je x_i i–ti faktor, a *m* je ukupan broj faktora.

Da bi se opisao uticaj spoljnih i unutrašnih faktora na tačnost modela, izveden je eksperiment koji se sastojao od tri faze. Kvalitet informacija sadržanih u uzorcima je opisan kroz dva različita spoljna faktora: izbor obele-

žja i količina podataka. Pomoću korelacione analize utvrđena je priroda veze koja postoji među obeležjima. Podaci za obuku mogu se redukovati korišćenjem neke metode klasterisanja ili obukom bez nadzora [11].

U drugoj fazi je iskorišćena "*10-fold cross validation*" sa Taguči metodom da bi se analizirale mogućnosti obuke i generalizacije oba modela [12]. Sa "*n-fold cross validation*" i početnim skupom podataka veličine N, izvedeno je n pokušaja testiranja. Za svaki pokušaj se uzima $N - N/n$ uzoraka za obuku, a ostatak od N/n uzoraka za test. U ovom eksperimentu je korišćena "*10-fold cross validation*", što znači da je početni skup podataka η podeljen na deset jednakih skupova η_1, η_2, ... η_{10}. Tokom k-tog pokušaja, skup $\eta - \eta_k$ je korišćen za obuku, a η_k za test.

Poslednja faza eksperimenta se sastoji od disperzione analize, pomoću koje se može utvrditi statistička značajnost faktora Fišerovim testom.

Postignuta tačnost observera stanja za estimaciju pritiska je vrlo dobra i greška je reda veličine 0.01–0.1% u zavisnosti od posmatranog čvora i ispitivanih procesnih veličina. Za ilustraciju može poslužiti primer estimacije pritiska u čvoru Bečej (slika 1). Pošto je postignuta vrlo dobra tačnost observera stanja sa 4 ulazne procesne veličine (srednja relativna greška na obuci je bila 0.0602%, a na testu 0.0974%), pokušalo se sa redukucijom broja ulaza radi smanjenja složenosti konfigurisane VNM. I sa smanjenim brojem ulaznih veličina (2 i 3) postignuta je vrlo dobra tačnost (srednja relativna greška na obuci je bila 0.0635%, a na testu 0.0901%) tako da se observer stanja može projektovati i na taj način. Na slikama 1. i 2. je isprekidanom linijom prikazana izračunata vrednost, a punom linijom tačna vrednost izlaza za test podatke.

Upoređujući podatke za greške VNM na obuci i testu za 4, odnosno 2 i 3 ulaza u VNM, respektivno, može se uočiti da se redukcijom broja ulaznih veličina u VNM malo gubi na tačnosti observera stanja, ali se zato

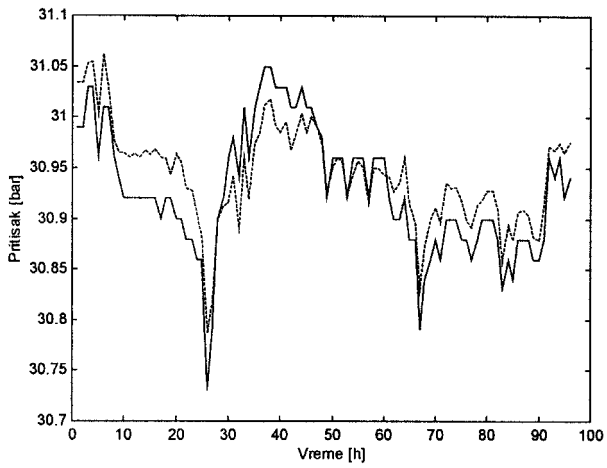

Slika 1. Estimacija pritiska u čvoru Bečej
Figure 1. Pressure estimation in Bečej

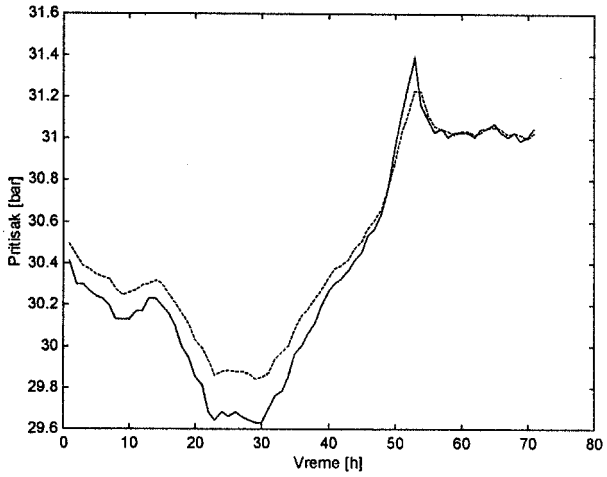

Slika 2. Estimacija pritiska u čvoru Bečej sa redukovanim brojem ulaznih veličina
Figure 2. Pressure estimation in Bečej performed on the basis of a reduced number of initial parameters

znatno uprošćava arhitektura VNM pa je stoga opravdano smanjiti broj ulaza u VNM.

Ispitan je jedan nov pristup rešavanju problema detekcije curenja [3]. Za to su iskorišćene VNM koje su obučene za estimaciju pritiska. Kao test podaci, na ulaz takve VNM su dovedeni ulazi koji su sadržali loše vrednosti, tj. mogući kvar ili neku drugu neregularnu situaciju. Pretpostavljeno je da će se na izlazu VNM dobiti velika greška koja će označiti da nešto nije u redu, pošto VNM nije obučena da prepoznaje pogrešne vrednosti (tako su bili formirani skupovi za obuku). Opisani postupak je ispitan za slučaj estimacije pritiska u čvoru Bečej za mesec oktobar '96 sa redukovanim brojem ulaza (dva).

Na slici 3.a) je isprekidanom linijom prikazana izračunata vrednost, a punom linijom tačna vrednost izlaza za test podatke, a na slici 3.b) je prikazana relativna greška testa izražena u procentima koja je dobijena kao razlika tačne i izračunate vrednosti.

Na slici 3.a) se vidi da obučena VNM nije dobro odgovorila na zadate ulaze, jer nije ni bila obučena za takve situacije. VNM je "loše" ulazne podatke usrednjila na vrednosti približno jednake donjoj granici opsega vrednosti koje pripadaju normalnom režimu rada. Srednja relativna greška testa je bila 8.4175% što je znatno slabije od slučaja kada su za testiranje estimacije pritiska bili korišteni ispravni podaci bez curenja (tada je greška bila reda veličine ~0.1%) te se može koristiti kao pokazatelj alarmantne situacije (isticanja gasa ili kvar nekog uređaja).

Opisani modifikovani pristup za rešavanje problema detekcije curenja je primenjen i na slučaj estimacije protoka. Zaključak je isti kao i u slučaju detekcije curenja pomoću VNM obučene za estimaciju pritiska. VNM je jako loše odgovorila na vrednosti koje su izlazile iz opsega koji obuhvata normalne situacije, a koji je korišten u obuci VNM. Srednja relativna greška testa je bila

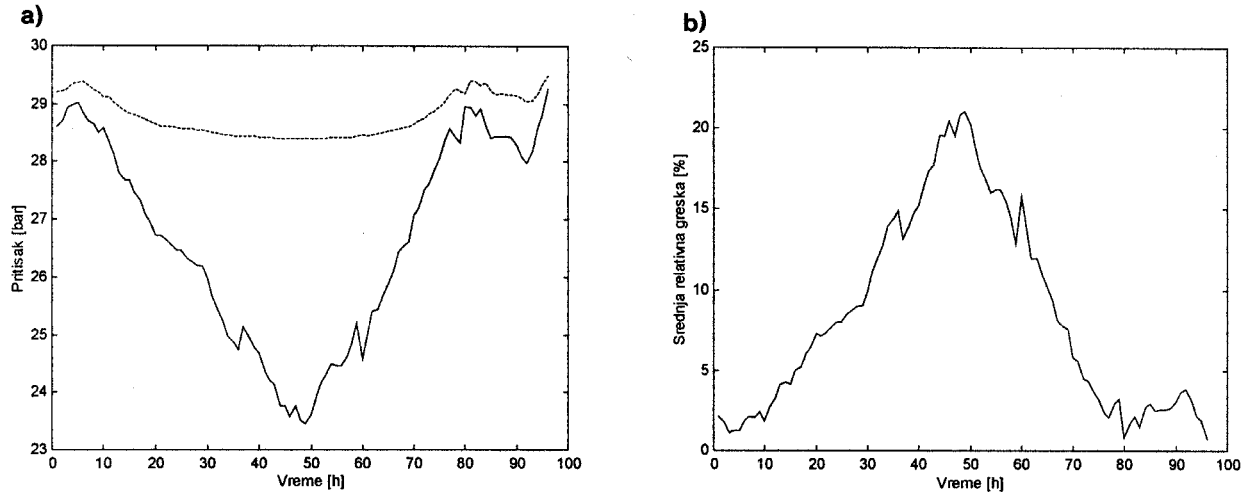

Slika 3. Rezultati novog pristupa rešavanju problema detekcije curenja gasa; a) Detekcija curenja gasa, b) Relativna greška testa
Figure 3. Results of the solution obtained on the basis of a new approach to the gas leak detection problem; a) Gas leak detection, b) Relative test error

41.5309% što je znatno slabije od slučaja kada su za testiranje estimacije protoka bili korišteni ispravni podaci bez curenja (tada je greška bila reda veličine ~1%).

Taguči metoda

U drugoj fazi eksperimenta je na osnovu tabelarne metode sa statističkom obradom podataka (Taguči metoda) [12] izvršena finalna klasifikacija parametara obuke i određivanje najuticajnijih. Taguči metoda omogućava da se proceni koji od promenljivih faktora ima najveći uticaj na željeni izlaz. Pošto je cilj eksperimenta bio smanjenje greške observera stanja, prihvatljivo je da se iskoristi ova metoda. Sledi kratak prikaz Taguči metode. Pretpostavlja se da je eksperimentalni izlaz ν funkcija nekoliko promenljivih u_1, u_2, ..., u_n čijim vrednostima se može upravljati, tj. $\nu = f(u_1, u_2, ..., u_n)$. Te upravljačke promenljive su faktori. Zadatak je pronaći one faktore koji imaju najveći uticaj na ν. Ovo može da se uradi menjanjem svakog faktora nezavisno jedan od drugog i praćenjem odgovarajućih promena u izlazu ν ili menjanjem faktora simultano po nekom utvrđenom redosledu da bi se odredilo koliki uticaj imaju pojedini faktori na promenu u izlazu ν. Taguči metoda primenjuje utvrđeni redosled variranja dva ili više faktora simultano. Da bi se eksperiment izveo do kraja moraju se proveriti sve moguće kombinacije vrednosti faktora. Ako je njihov broj jako velik, onda se može koristiti neki podskup od svih njihovih mogućih kombinacija.

Disperziona analiza

U poslednjoj fazi sprovedenog eksperimenta je izvršena disperziona analiza kojom se određuje statistička značajnost odabranih faktora pomoću Fišerovog testa. Obrada rezultata eksperimenta metodama matematičke statistike daje najviše informacija sa poznatom pouzdanošću. One omogućuju da se sa poznatom verodostojnošću utvrdi da li neki faktor ima ili nema uticaja na rezultat.

Faktorni eksperiment [13] je eksperiment sa više faktora, u kome se javljaju sve kombinacije nivoa faktora, tako da je svaki efekat svakog od faktora određen na svim nivoima ostalih faktora. Faktorni eksperiment K^n je eksperiment sa n faktora od kojih svaki ima K nivoa.

U posmatranom slučaju, eksperiment sadrži tri faktora, od kojih svaki može imati dva različita nivoa pa spada u grupu tzv. faktornih eksperimenata 2^3. U potpunom faktornom eksperimentu se eksperimentalne jedinice moraju načiniti od svih kombinacija nivoa faktora, što ovde iznosi $2^3 = 8$. Kriterijum ν_0, koji se poredi sa Fišerovim kriterijumom iz tablice [14] zbog provere značajnosti faktora, računa se za svaki faktor posebno.

Rezultati

Pošto je zaključeno da je opravdano izvršiti smanjenja broja ulaza, Taguči analiza je urađena za tako obučene VNM, odnosno TS fuzzy model za čvor Bečej. Uvedene su sledeće oznake za pojedine faktore: X – izbor obeležja, Y – broj ulaza i Z – period uzorkovanja podataka. Broj ulaza je bio dva i tri, a period uzorkovanja podataka 60 minuta i 5 sati. Obučene VNM su imale arhitekturu u kojoj je broj skrivenih neurona bio određen prema formuli (2 · broj ulaza + 1), a aktivacione funkcije na skrivenom i izlaznom sloju su bile logistička sigmoida i linearna funkcija. U tabeli 1. su prikazani konačni rezultati Taguči analize za čvor Bečej.

Iz rezultata prikazanih u tabeli 1. vidi se da su, za ispitivani čvor, međusobni uticaji pojedinih faktora vrlo mali u poređenju sa uticajem svakog od njih posebno. Najveći uticaj na tačnost VNM ima faktor označen sa Z, period uzorkovanja, dok preostala dva faktora imaju mnogo manji uticaj. Može se zaključiti da podatke za obuku VNM treba uzeti sa periodom uzorkovanja od 60 minuta, dok su broj ulaza i njihova struktura manje bitni.

Tabela 1. Efekti tri eksperimentalna faktora izraženi preko greške obuke i testa VNM za čvor Bečej sa redukovanim brojem ulaza
Table 1. The effects of three experimental factors expressed as the training test and VNM test for Bečej with a reduced number of input values

	X	Y	Z	XY	XZ	YZ	XYZ
Obuka	–0.0132	–0.1189	0.3018	0.0228	0.0312	0.1041	–0.0325
Test	–0.0057	–0.1155	0.3401	0.0366	0.0166	0.1136	–0.0464

Tabela 2. Efekti tri eksperimentalna faktora izraženi preko greške obuke i testa TS fuzzy modela za čvor Bečej sa redukovanim brojem
Table 2. The effects of three experimental factors expressed as the training test and TS fuzzy for Bečej with reduced number of input values

	X	Y	Z	XY	XZ	YZ	XYZ
Obuka	–0.0489	–0.1105	0.2539	0.0054	0.0537	0.0939	–0.0123
Test	–0.0059	–0.1247	0.3355	0.0478	–0.0096	0.1136	–0.0567

Iz tabele se vidi da bi bolju tačnost imala VNM sa tri ulaza.

U tabeli 2. su prikazani konačni rezultati Taguči analize za čvor Bečej za slučaj TS fuzzy modela. Radi se o potpuno istom eksperimentu kao u slučaju VNM sa redukovanim brojem ulaza (pa su iste i oznake za pojedine faktore), samo što je ovde formiran TS fuzzy model prvog reda sa 5 klastera.

Pošto su u tabeli 2. efekti pojednih faktora vrlo slični onima u tabeli 1. mogu se izvesti isti zaključci za TS fuzzy model kao i za VNM.

Disperziona analiza je takođe urađena za iste slučajeve kao i Taguči analiza. U tabelama 3. i 4. su prikazani dobijeni rezultati.

Iz tabele 3 se vidi da najveći uticaj ima faktor označen sa C, tj. period uzorkovanja, jer je veličina v_0 u oba slučaja mnogo veća od veličine c za koeficijent pouzdanosti α = 99% i za obuku i za test. Faktor označen sa B, broj ulaza je zadovoljio statističku značajnost sa 95% na obuci za čvor Bečej, a faktor A, izbor obeležja nije statistički značajan ni u jednom ispitivanom slučaju.

Pošto su u tabeli 4. efekti pojednih faktora vrlo slični onima u tabeli 3. mogu se izvesti isti zaključci za TS fuzzy model kao i za VNM. Poređenjem rezultata dobijenih primenom Taguči metode i disperzione analize faktornog eksperimenta može se uočiti da se oni u potpunosti slažu što se tiče važnosti pojedinih faktora.

Tabela 3. Rezultati disperzione analize za čvor Bečej, VNM
Table 3. The results of dispersion analysis for Bečej (VNM test)

Izvor promena	v_0 obuka	v_0 test	c V=95%	C V=99%	Značenje
A	0.0589	0.0047	3.98	7.01	Izbor obeležja
B	4.7543	1.9372	3.98	7.01	Broj ulaza
AB	0.1759	0.1948			
C	30.6727	16.7965	3.98	7.01	Period uzorkovanja
AC	0.3268	0.0398			
BC	3.6524	1.8748			
ABC	0.3551	0.3121			

Tabela 4. Rezultati disperzione analize za čvor Bečej, TS fuzzy model
Table 4. The results of dispersion analysis for Bečej (TS fuzzy model)

Izvor promena	v_0 obuka	v_0 test	c V=95%	C V=99%	Značenje
A	1.0629	0.0045	3.98	7.01	Izbor obeležja
B	5.4300	2.0127	3.98	7.01	Broj ulaza
AB	0.0129	0.2951			
C	28.6389	14.5590	3.98	7.01	Period uzorkovanja
AC	1.2811	0.0119			
BC	3.9186	1.6682			
ABC	0.0675	0.4159			

ZAKLJUČAK

Realizovani sistem je projektovan i testiran sa podacima iz SCADA gasovodne mreže "NIS–GAS" na teritoriji Vojvodine. Vršena je predikcija i estimacija pritisaka i protoka gasa na određenim lokacijama. U tu svrhu su korišćeni podaci koji odgovaraju različitim vremenskim intervalima iz višegodišnjeg perioda. Svi ispitivani modeli su pokazali visoku tačnost, koja se kretala manje od 1% za pritiske, a do 5% za protoke.

Upoređivanjem rezultata mnogobrojnih testova se došlo do zaključka da nema značajne razlike između aproksimacija baziranih na VNM i TS fuzzy modelima. Slika 4 prikazuje uporedne vrednosti greški za 8 testova modula observera stanja sa ova dva pristupa.

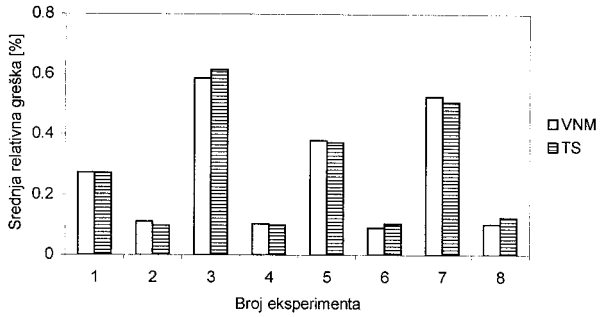

Slika 4. Uporedni prikaz greški modula baziranih na VNM i TS modelima

Figure 4. Comparative results of the module error based on the VNM and TS models

Poređenjem dve korišćene metode računarske inteligencije može se zaključiti da su obe dale približno jednake rezultate što samo potvrđuje ispravnost formiranog modela kojim se zamenjuje deterministički matematički model sistema za prenos prirodnog gasa. Projektovani observer se lako može obogatiti novim znanjem i preporučljivo je da se to radi periodično, na primer, jednom mesečno. Pri tome bi se deo najstarijih podataka iz skupa za obuku zamenio najnovijim, a uradilo bi se doobučavanje.

Eksperimentalno je pokazano da pri projektovanju modula observera stanja, između više razmatranih faktora, period uzorkovanja i broj ulaza imaju najčešće najveći uticaj na grešku modela. To znači da se njihovim promenama može najviše uticati na smanjenje greške funkcijskih komponenti observera stanja, bilo da se radi o veštačkim neuronskim mrežama ili Takagi–Sugeno rasplinutim modelima. Ovi moduli su robustni i računarski vrlo efikasni u eksploataciji.

LITERATURA

[1] R. Isermann, Process Fault Detection Based on Modeling and Estimation Methods – A survey, Automatica **20** (1984) 387–405

[2] D. Kukolj i M. Berko, The Experimental Design of the Diagnostic System Based on Unsupervised and Supervised Learning Methods, Neural Network World **8** (1998) 375–386

[3] D. Kukolj, V. Bajović, M. Berko, G. Bojković, Komparativna analiza dijagnostičkih stabala odlučivanja i veštačkih neuronskih mreža, Hemijska industrija **51** (1997) 106–112

[4] R. Isermann, On Fuzzy Logic Applications For Automatic Control, Supervision And Fault Diagnosis, IEEE Trans. on Syst, Man, Cybern.–Part A **28** (1998) 221–235

[5] J. Osiadacz, Simulation and Analysis of Gas Networks, Gas Publ. Co., Houston, USA, 1987

[6] S. Haykin, Neural Networks, Macmillan Publ. Co., New York, 1994

[7] J.R. Jang, C. Sun and E. Mizutani, Neuro–Fuzzy and Soft Computing, Prentice Hall, NJ, 1997

[8] S.K. Narendra, Neural networks for control: theory and practice, Proc. of the IEEE **84** (1996) 1385–1406

[9] M. Setnes, R. Babuška and H.B. Verburger, Rule–Based Modeling: Precision and Transparency, IEEE Transactions on Systems, Man, and Cybernetics – Part C **28** (1998) 65–169

[10] F. Klawonn, R. Kruse, Constructing a fuzzy controler from data, Fuzzy sets and systems **85** (1997) 177–193

[11] D. Kukolj, D. Popović and M. Borota, Applied Unsupervised Learning in Model Reduction of Linear Dynamic Systems, Computers & Mathematics with Applications **33** (1997) 95–103

[12] G.E. Peterson, D.C. Clair, S.R. Aylward and W.E.Bond, Using Taguchi's method of experimental design to control errors in layered perceptrons, IEEE Trans. on Neural Networks **6** (1995) 949–960

[13] I. Pantelić, Uvod u teoriju inženjerskog eksperimenta, Radnički univerzitet "Radivoj Ćirpanov", Novi Sad, 1976

[14] S.V. Vukadinović, Elementi teorije verovatnoće i matematičke statistike, Privredni pregled, Beograd, 1990

SUMMARY

DEVELOPMENT OF THE INTELLIGENT CONTROL SYSTEM COMPONENTS IN NATURAL GAS TRANSMISSION NETWORK

(Scientific paper)

Dragan D. Kukolj, Miroslava T. Berko–Pušić
Faculty of Engineering, Novi Sad

The paper deals with the design methodology of an intelligent state observer of a natural gas transmission network. This state observer enables advanced features within the SCADA system of a natural gas pipeline transmission network, such as fault detection, estimation and prediction of process variables. These features were developed using two computational intelligence techniques, namely artificial neural networks and Takagi–Sugeno fuzzy models. The impact of a number of factors on the accuracy of artificial neural networks and the Takagi–Sugeno fuzzy models employed in the SCADA system were analysed.

Key words: natural gas • supervisory control • computational intelligence •
Ključne reči: prirodan gas • nadgledanje i upravljanje • računarska inteligencija •