

Marko Valčić

Mr.sc. Julije Skenderović

Pomorski fakultet u Rijeci

Studentska 2, Rijeka

Izvorni znanstveni rad

UDK: 004.032.26

519.876.5

621.165

Primljeno: 24. lipnja 2005.

Prihvaćeno: 07. srpnja 2005.

MODEL IDENTIFIKACIJA I SIMULACIJA RADNIH SUSTAVA TEMELJENI NA UMJEĆNIM NEURONSKIM MREŽAMA

Rezultati identifikacije i simulacije dinamičkog ili statickog radnog sustava značajno ovise o kvaliteti i odabiru ulaznih parametara. U radu je dat uočen model identifikacije i simulacije radnog sustava u ovisnosti o različitim klasama parametara, temeljen na generaliziranoj regresijskoj neuronskoj (GRNN) mreži. Predložen je i model iteracijskog postupka kojim se pomoći vjerovatnosne neuronske (PNN) mreže vrši ocjena uspješnosti dobivenih simulacijskih rezultata nastalih kao odzivni GRNN mreža. Oba modela su testirana na parametrima sustava upravljanja i regulacije parnoturbinskog postrojenja, a u tu svrhu je korišten programski paket MATLAB 7.0.1.

Ključne riječi: umjetne neuronske mreže, identifikacija, simulacija, klasifikacija, parne turbine

1. UVOD

Identifikacija nekog radnog sustava u većini se slučajeva sastoji u postavljanju odgovarajućeg matematičkog modela, kojim se moraju odrediti analitički izrazi funkcija ovisnosti ulaznih o izlaznim parametrima tog sustava. Najveći problemi identifikacije javljaju se kada je analitičke izraze takvih funkcija vrlo teško, ili čak nemoguće odrediti. Model identifikacije pomoći neuronskih mreža je jedno od mogućih rješenja ovoga problema, jer neuronska mreža može aproksimirati te funkcije. U tu svrhu, predložili smo model identifikacije temeljen na generaliziranim regresijskim neuronskim mrežama (engl. generalized regression neural network, GRNN) zbog njenih izvrsnih aproksimacijskih mogućnosti. Predloženi model omogućuje identifikaciju i simulaciju jednog parametra radnog sustava, pomoći bilo koje klase preostalih parametara tog sustava. Nakon izvršenih simulacija, u nastavku rada smo predložili i model iteracijskog postupka za ocjenu uspješnosti dobivenih rezultata pomoći vjerovatnosne neuronske mreže (engl. probabilistic neural network, PNN).

Predloženim modelima simulirali smo snagu i brzinu vrtnje parne turbine termoelektrane Plomin 2 u Plominu, pomoću proizvoljno odabranih sedam klasa radnih parametara. Iteracijskim postupkom dobiven je hijerarhijski niz simulacijskih modela prema njihovoj uspješnosti. Analizom dobivenih rezultata iz tog niza smo izdvojili najuspješniji, optimalan i najlošiji simulacijski model i grafički smo prikazali njihove pripadne odzive GRNN mreža na kojima su temeljeni.

2. NEURONSKE MREŽE S RADIJALNIM BAZNIM FUNKCIJAMA

Neuronske mreže s radijalnim baznim funkcijama (engl. radial basis neural networks RBNN) spadaju u novije metode umjetnih neuronskih mreža i sve se češće primjenjuju, ponavljajući u rješavanju problema interpolacije i aproksimacije kontinuiranih viševarijabilnih funkcija, ali i u rješavanju problema klasifikacije. RBNN mrežama je potreban veći broj neurona, nego primjerice standardnim unaprijednim povratno propagiranim mrežama (engl. feed-forward backpropagation networks, BPNN), ali vrijeme potrebno da se RBNN mreža pripremi za simuliranje predstavlja tek manji dio vremena koje je BPNN mreži potrebno samo za treniranje, tj. učenje [4, str. 59]. Uz iznimno kvalitetne rezultate koje RBNN mreža postiže u aproksimaciji viševarijabilnih funkcija, to je još jedna njena vrlo važna prednost pred ostalim mrežama. Dodamo li tome i velike mogućnosti poopćenja neuronskih mreža temeljenih na radijalnim baznim funkcijama, u konačnici možemo dobiti cijeli skup alata koji se mogu iskoristiti, kako u identifikaciji statičkog ili dinamičkog sustava, tako i u klasifikaciji i ocjeni dobivenih simuliranih podataka, o čemu će više riječi biti u nastavku ovoga rada.

2.1. RADIJALNE BAZNE FUNKCIJE I MODEL RB NEURONA

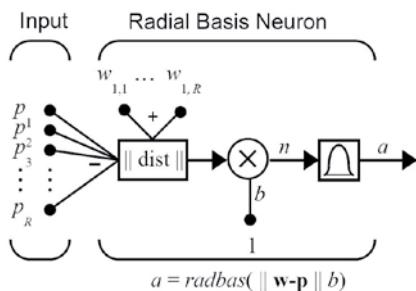
Neka je $\mathbf{x}_0 \in \mathbf{R}^n$. Radijalne bazne funkcije (RB funkcije) su oblika $b: \mathbf{R} \rightarrow \mathbf{R}$, $b: d \mapsto b(d)$, gdje je $d = \|\mathbf{x} - \mathbf{x}_0\|$ Euklidska udaljenost nekog vektora $\mathbf{x} \in \mathbf{R}^n$ od vektora \mathbf{x}_0 . Svojstvo je RB funkcije da $b(d)$ ima istu vrijednost za sve vektore $\mathbf{x} \in \mathbf{R}^n$ jednako udaljene od \mathbf{x}_0 i da ima ekstremnu vrijednost za $d = 0$.

Radijalni bazni neuron (RB neuron) prikazan je shematski na slici 1. Računa se Euklidska udaljenost $\|\mathbf{w} - \mathbf{p}\|$ između težinskog vektora $\mathbf{w} = [w_{1,1} \quad w_{1,2} \quad \dots \quad w_{1,R}]$ i ulaznog vektora $\mathbf{p} = [p_1 \quad p_2 \quad \dots \quad p_R]$ i množi se faktorom b (*bias*) o kojem će kasnije biti više riječi. Za prijenosnu funkciju RB neurona odabrana je radijalna bazna funkcija

$$radbas(n) = e^{-n^2}, \quad (1)$$

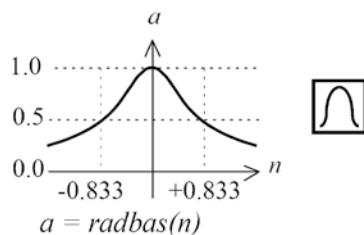
grafički prikazana na slici 2. Na izlazu neurona dobiva se vrijednost

$$a = radbas(n), \text{ za } n = \|\mathbf{w} - \mathbf{p}\| \cdot b. \quad (2)$$



Slika 1. Model RB neurona

Izvor: [1, str. 7-3]



Slika 2. Radijalna bazna funkcija

Radijalna bazna funkcija poprima maksimalnu vrijednost 1 kada je ulaz (argument) jednak 0. Kako se udaljenost između vektora \mathbf{w} i \mathbf{p} smanjuje, vrijednost a na izlazu se povećava. Uz to, radijalni bazni neuron se ponaša kao detektor koji na izlazu daje 1 svaki put kada je ulazni vektor \mathbf{p} jednak težinskom vektoru \mathbf{w} .

Mogućnost promjene vrijednosti b stvara potrebnu osjetljivost neurona, čime se omogućuje njegova adaptivnost, tj. prilagodljivost.

2.2. GENERALIZIRANA REGRESIJSKA NEURONSKA MREŽA

Generalizirana regresijska neuronska (GRNN) mreža je jedna od najčešće korištenih mreža u svrhu aproksimacije funkcija. Iznimno kratko vrijeme potrebno za njenu kreiranje te za kasnije korištenje u svrhu simuliranja, čini je posebno pogodnom.

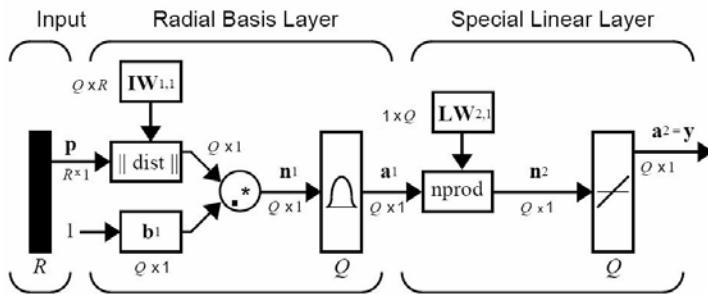
GRNN mreža se sastoji iz četiri sloja. Ulazni sloj ima R neurona, pri čemu je R broj argumenta viševarijabilne funkcije koju aproksimiramo pomoću GRNN mreže. Prvi skriveni *radijalni bazni* i drugi skriveni *linearni* sloj imaju po Q neurona, pri čemu je Q broj uzoraka skupa za učenje. Izlazni sloj ima samo jedan neuron. Skup za učenje sastoji se od $Q \times R$ podataka koji se mogu zapisati u matričnom obliku:

$$\mathbf{P} = \begin{matrix} ? & p_{11} & p_{12} & \cdots & p_{1R} & ? \\ ? & p_{21} & p_{22} & \cdots & p_{2R} & ? \\ ? & \vdots & \vdots & \ddots & \vdots & ? \\ ? & p_{Q1} & p_{Q2} & \cdots & p_{QR} & ? \end{matrix}_{Q \times R}, \quad (3)$$

i od Q podataka - *ciljeva*, koji se mogu zapisati u matričnom obliku

$$\mathbf{T} = \begin{matrix} ? & t_1 & t_2 & \cdots & t_Q \end{matrix}^T_{Q \times 1}. \quad (4)$$

Na slici 3. prikazana je arhitektura GRNN mreže. Nakon što su mreži prezentirane matrice \mathbf{P} i \mathbf{T} formira se *matrica težinskih koeficijenata* prvog radijalnog baznog skrivenog sloja $\mathbf{IW}^{1,1} = \mathbf{P}$ formata $Q \times R$ i *matrica ciljeva* drugog linearног skrivenog sloja $\mathbf{LW}^{2,1} = \mathbf{T}^T$ formata $1 \times Q$. Na taj se način formira po Q neurona u oba skrivena sloja.



Slika 3. Arhitektura generalizirane regresijske neuronske mreže (GRNN)

Izvor: [1, str. 7-9]

Prezentiramo li mreži neki uzorak $\mathbf{p} = [p_1 \ p_2 \ \dots \ p_R]^T$, u prvom skrivenom sloju formira se najprije vektor $\mathbf{n}^1 = [n_1^1 \ n_2^1 \ \dots \ n_Q^1]^T$ dimenzije $Q \times 1$ čije koordinate predstavljaju Euklidsku udaljenost prezentiranog uzorka \mathbf{p} od svih uzoraka iz skupa za učenje (matrica \mathbf{P}) pomnoženu faktorom b . Ako je za neki neuron npr. $b = 1$, prijenosna funkcija će dati vrijednost 0.5 za sve uzorce udaljene za 0.8326 od težinskog vektora tog neurona, jer je

$$\text{radbas}(n) = 0.5 \Rightarrow e^{-n^2} = 0.5 \Rightarrow n = 0.8326. \quad (5)$$

Povećanjem faktora b povećava se i udaljenost uzorka od težinskog vektora neurona i obratno. Veća vrijednost b raspršuje uzorce. U programskom paketu MATLAB faktor b se određuje od strane korisnika i to izborom faktora s (raspršenje, engl. *spread*) prema formuli $b = 0.8326 / s$. Izborom faktora s , faktor b je isti za svaki neuron radijalnog baznog sloja.

Izlaz iz prvog skrivenog sloja je vektor $\mathbf{a}^1 = [a_1^1 \ a_2^1 \ \dots \ a_Q^1]^T$ dimenzije $Q \times 1$ čije koordinate predstavljaju *mjeru* udaljenosti uzorka \mathbf{p} od svakog uzorka iz skupa za učenje; ukoliko je neka vrijednost bliža 1, uzorak \mathbf{p} bliži je pripadnom težinskom vektoru, tj. uzorku iz skupa za učenje, a ukoliko je bliži 0, udaljeniji je.

Koordinate vektora \mathbf{a}^1 ulazni su podaci drugog skrivenog linearne sloja. U ovom se sloju određuje aproksimirana vrijednost funkcije y koju mreža pridružuje ulaznom uzorku \mathbf{p} . Ta se vrijednost određuje pomoću normalizacijske težinske funkcije **nprod** prema formuli

$$n = \frac{\mathbf{a}^1 \cdot \mathbf{T}}{\sum_{i=1}^Q a_i^1} \quad (6)$$

a nakon toga je prijenosna funkcija drugog sloja

$$\text{purelin}(n) = n \quad (7)$$

prenosi u izlazni sloj GRNN mreže čime u konačnici dobivamo izlaznu vrijednost y .

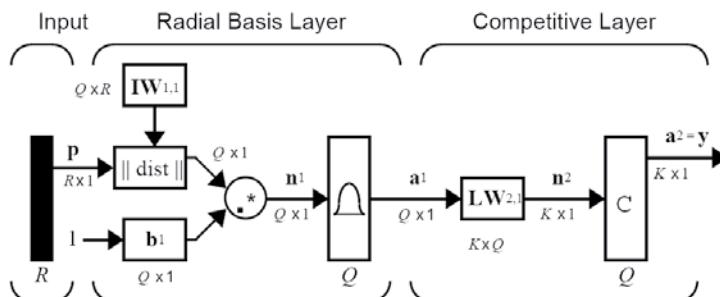
Ukoliko mreži prezentiramo Q uzoraka, na izlazu iz funkcije **nprod** dobit ćemo vektor n^2 dimenzije $Q \times 1$, pri čemu je svaka koordinata tog vektora jedna od Q aproksimiranih vrijednosti funkcije $y = \mathbf{a}^2$ koju dobivamo na izlazu.

2.3. VJEROJATNOSNA NEURONSKA MREŽA

Primjene vjerojatnosne neuronske mreže se uglavnom odnose na klasifikacijske probleme. Prezentirani uzorak mreža svrstava u jednu od unaprijed određenih klasa, prema kriterijima po kojima su uzorci iz skupa za učenje pridruženi tim klasama.

PNN mreža sastoji se, također, od četiri sloja kao i GRNN mreža. Arhitektura ove mreže je prikazana na slici 4. Ulazni sloj i prvi skriveni radikalni bazni sloj imaju istu arhitekturu i funkcionišu identično kao i u slučaju GRNN mreže.

Neka je skup uzoraka za učenje razvrstan u K klase. Oznake klasa zapisujemo u matricu $\mathbf{Tc} = [t_1 \ t_2 \ \cdots \ t_K]$ formata $1 \times K$. Svaki uzorak iz skupa za učenje pridružen je jednoj od tih klasa. Drugi skriveni sloj razlikuje se od linearog sloja u GRNN mreži i naziva se *najecateljski* (engl. competitive) sloj. Ulaz ovoga sloja je izlaz \mathbf{a}^1 prvog skrivenog sloja. Pomoću matrice \mathbf{Tc} formira se matrica \mathbf{T} formata $K \times Q$; svaki stupac ima vrijednost 1 samo u retku koji pripada odgovarajućoj klasi, a sve ostale vrijednosti jednake su 0. Tako formirana matrica $\mathbf{T} = \mathbf{LW}^{2,1}$ je matrica ciljeva.



Slika 4. Arhitektura vjerojatnosne neuronske mreže (PNNN)

Izvor: [1, str. 7-12]

Elementi matrice $\mathbf{n}^2 = \mathbf{T} \cdot \mathbf{a}^1$ formata $K \times 1$ su vjerojatnosti pripadanja ulaznog uzorka prethodno određenim klasama. Konačno, prijenosna funkcija *compet(n)* pridružuje vrijednost 1 koordinati vektora \mathbf{n}^2 koja ima najveću vrijednost, a vrijednost 0 svim ostalim koordinatama. Na taj je način PNN mreža klasificirala ulazni uzorak u jednu od K klasa.

Među mnogim prednostima GRNN i PNN mreža, izdvojiti ćemo i jedan njihov relativno veliki nedostatak. U odnosu na druge neuronske mreže, koje za cilj imaju aproksimaciju ili klasifikaciju, GRNN i PNN mreže rade sporije, ako je broj ulaznih podataka iznimno velik.

3. IDENTIFIKACIJA I SIMULACIJA RADNOG SUSTAVA POMOĆU GRNN MREŽE

U ovom dijelu rada predlažemo model identifikacije i simulacije sustava pomoću GRNN mreže.

Označimo sa $X = \{x_1, x_2, \dots, x_R\}$ skup od R parametara nekog sustava. Neka je poznato Q stanja tog sustava, pri čemu je svako stanje opisano odgovarajućim uzorkom. Prostor tih stanja možemo zapisati u matričnom obliku:

$$\mathbf{M}_S = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1i} & \cdots & x_{1R} \\ x_{21} & x_{22} & \cdots & x_{2i} & \cdots & x_{2R} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{Q1} & x_{Q2} & \cdots & x_{Qi} & \cdots & x_{QR} \end{bmatrix}_{Q \times R}. \quad (8)$$

Problemi teorije sustava vrlo često zahtijevaju određivanje ovisnosti među parametrima nekog sustava. Teoretski, u sustavu sa R parametara, l od njih možemo izraziti preko $m \leq R - l$ parametara na

$$\binom{R}{l} \cdot (2^{R-l} - 1) \quad (9)$$

načina. Uzmemo li još u obzir da vrijedi $l = 1, \dots, R-1$, onda je ukupan broj takvih načina jednak

$$\sum_{l=1}^{R-1} \binom{R}{l} \cdot (2^{R-l} - 1). \quad (10)$$

Budući se tehnički problemi najčešće svode na određivanje ovisnosti jednog parametra ($l = 1$) od određenog broja preostalih, u nastavku rada ćemo se zadržati upravo na tom dijelu. U tu svrhu, neka je x_i proizvoljno odabran parametar iz skupa X . Možemo ga shvatiti kao funkciju od više varijabli čiji su argumenti elementi bilo kojeg r -članog podskupa

$$A = \{x_1, x_2, \dots, x_r\} \subseteq X \setminus \{x_i\}, \quad r = 1, 2, \dots, R-1, \quad (11)$$

tj.

$$x_i = F(x_1, x_2, \dots, x_{i-1}, x_{i+1}, \dots, x_r). \quad (12)$$

Ovakvih funkcija ukupno ima $N = 2^{R-1} - 1$.

Na skupu Q poznatih uzoraka, kojih ukupno ima $Q = \text{card}(Q)$, funkcije x_i iz istog uzorka imaju jednake vrijednosti za vrijednosti argumenata iz tog uzorka, bez obzira na broj argumenata $r < R$.

Neka su uzorci proizvoljno odabranog skupa $Q_1 \subset Q$ uzorci za učenje, a uzorci proizvoljno odabranog skupa $Q_2 \subseteq Q \setminus Q_1$ uzorci za testiranje.

Uzorcima skupa Q_1 identificiramo sustav na način da pomoću GRNN mreže za svaki

uzorak dobijemo N aproksimiranih vrijednosti parametra x_i , tj. $\mathcal{Q}_1 \cdot N$ za svih $\mathcal{Q}_1 = \text{card}(\mathcal{Q}_1)$ uzorka.

Budući da se vrši aproksimacija N funkcija iz (12), kreirat ćemo po jednu GRNN mrežu za svaku od njih. U tu svrhu, svakoj od njih prezentiramo ulaznu matricu \mathbf{P}_1 koja je odgovarajuća podmatrica matrice \mathbf{M}_S i formata je $\mathcal{Q}_1 \times r$, pri čemu je r broj argumenata funkcije (12) koju aproksimiramo. Također, svakoj GRNN mreži prezentiramo uvijek istu matricu cilja \mathbf{T}_1 koja je odgovarajuća podmatrica matrice \mathbf{M}_S i formata je $\mathcal{Q}_1 \times 1$.

Nakon što je formirano N matrica težinskih koeficijenata $\mathbf{IW}^{1,1} = \mathbf{P}_1$ i N pripadnih matrica cilja $\mathbf{LW}^{2,1} = \mathbf{T}_1$, GRNN mreže su kreirane, a sustav je N puta identificiran.

Na svakom od N dobivenih identifikacijskih modela testirat ćemo uzorce iz skupa \mathcal{Q}_2 kojih ukupno ima $\mathcal{Q}_2 = \text{card}(\mathcal{Q}_2)$. Sada više aproksimirane vrijednosti funkcije x_i neće biti jednakе za isti uzorak, već će se mijenjati s obzirom na broj argumenata r , preko kojih je aproksimacija napravljena. Upravo će se u tom dijelu stvarati razlike između N identifikacijskih modela i uspješnost svakog od njih ovisit će upravo o aproksimacijskim mogućnostima GRNN mreža.

Svakom pojedinom modelu, tj. svakoj GRNN mreži prezentirat ćemo ulaznu matricu \mathbf{P}_2 koja je odgovarajuća podmatrica matrice \mathbf{M}_S i formata je $\mathcal{Q}_2 \times r$. Elementi te matrice su iz skupa za testiranje \mathcal{Q}_2 , a njen format ovisi isključivo o broju parametara preko kojih radimo aproksimaciju. Nakon obavljene simulacije, dobit ćemo $\mathcal{Q}_2 \cdot N$ aproksimiranih vrijednosti funkcije (12), pri čemu su za svaku od N funkcija iz (12) njene odgovarajuće aproksimirane vrijednosti zapisane u obliku vektor stupca formata $\mathcal{Q}_2 \times 1$

$$\mathbf{S}_j = x_{ij}^{sim}, \quad j = 1, 2, \dots, N. \quad (13)$$

4. OCJENA USPJEŠNOSTI SIMULACIJSKIH MODELA POMOĆU PNN MREŽA

U nastavku ćemo ponuditi model za ocjenu uspješnosti dobivenih simulacijskih rezultata pomoću PNN mreže.

Iz dobivenih simulacijskih rezultata $\mathbf{S}_j, j = 1, 2, \dots, N$, formirati ćemo matricu

$$\mathbf{S}^1 = \begin{bmatrix} s_{1,1}^i & s_{1,2}^i & \cdots & s_{1,j-1}^i & s_{1,j}^i & s_{1,j+1}^i & \cdots & s_{1,N}^i \\ s_{2,1}^i & s_{2,2}^i & \cdots & s_{2,j-1}^i & s_{2,j}^i & s_{2,j+1}^i & \cdots & s_{2,N}^i \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ s_{\mathcal{Q}_2,1}^i & s_{\mathcal{Q}_2,2}^i & \cdots & s_{\mathcal{Q}_2,j-1}^i & s_{\mathcal{Q}_2,j}^i & s_{\mathcal{Q}_2,j+1}^i & \cdots & s_{\mathcal{Q}_2,N}^i \end{bmatrix}_{\mathcal{Q}_2 \times N} \quad (14)$$

formata $\mathcal{Q}_2 \times N$ i nju ćemo prezentirati PNN mreži kao ulaznu matricu. Svaki vektor

stupac $\mathbf{S}_j = [s_{1,j}^i \ s_{2,j}^i \ \dots \ s_{Q_2,j}^i]^T$ ćemo jednoznačno pridružiti j -toj klasi. Svih N klasa možemo zapisati u obliku vektor retka

$$\mathbf{Tc}_1 = [1 \ 2 \ \dots \ j-1 \ j \ j+1 \ \dots \ N] \quad (15)$$

formata $1 \times N$, a pomoću njega formiramo matricu ciljeva \mathbf{T}^1 formata $N \times N$. Nakon što su PNN mreži prezentirane ulazna matrica \mathbf{S}^1 i matrica cilja \mathbf{T}^1 , formiraju se matrice težinskih koeficijenata $\mathbf{IW}_1^{1,1} = \mathbf{S}^1$ i matrica cilja $\mathbf{LW}_1^{2,1} = \mathbf{T}^1$.

Naučena PNN mreža sada može izvršiti klasifikaciju. Uzorak koji ćemo klasificirati je vektor stupac \mathbf{S}_i dobiven kao odgovarajuća podmatrica matrice \mathbf{M}_S i formata je $Q_2 \times 1$. Elementi vektor stupca \mathbf{S}_i predstavljaju stvarne vrijednosti funkcije x_i za svaki uzorak matrice \mathbf{P}_2 .

Klasifikaciju provodimo *iteracijski* u $N-1$ koraka pomoću $N-1$ PNN mreža. U prvom koraku klasificiramo pomoću prve PNN mreže vektor stupac \mathbf{S}_i u jednu od prethodno N definiranih klasa. Bez gubitka općenitosti, pretpostavimo da je PNN mreža klasificirala uzorak \mathbf{S}_i u j -tu klasu. Time je pokazano da je pripadnost uzorka \mathbf{S}_i j -toj klasi najvjerojatnija. Drugim riječima, j -ti simulacijski model je najbolji.

U drugom koraku, smanjujemo broj uzoraka i broj klasa za jedan izostavljujući j -ti uzorak i j -tu klasu. Drugoj PNN mreži prezentiramo ulaznu matricu

$$\mathbf{S}^2 = \begin{bmatrix} s_{1,1}^j & s_{1,2}^j & \dots & s_{1,j-1}^j & s_{1,j+1}^j & \dots & s_{1,N}^j \\ s_{2,1}^j & s_{2,2}^j & \dots & s_{2,j-1}^j & s_{2,j+1}^j & \dots & s_{2,N}^j \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ s_{Q_2,1}^j & s_{Q_2,2}^j & \dots & s_{Q_2,j-1}^j & s_{Q_2,j+1}^j & \dots & s_{Q_2,N}^j \end{bmatrix}_{Q_2 \times (N-1)} \quad (16)$$

formata $Q_2 \times (N-1)$ i matricu cilja \mathbf{T}^2 formata $(N-1) \times (N-1)$ dobivenu iz vektor retka klasa

$$\mathbf{Tc}_2 = [1 \ 2 \ \dots \ j-1 \ j+1 \ \dots \ N] \quad (17)$$

dimenzije $1 \times (N-1)$. Nakon što se formiraju matrice težinskih koeficijenata $\mathbf{IW}_2^{1,1} = \mathbf{S}^2$ i matrica cilja $\mathbf{LW}_2^{2,1} = \mathbf{T}^2$, druga PNN mreža izvršava klasifikaciju uzorka \mathbf{S}_i u jednu od preostalih $N-1$ klasa kojoj najvjerojatnije pripada.

Iteracijskim ponavljanjem ovog postupka još preostalih $N-3$ puta, formira se hijerarhijski niz N simulacijskih modela

$$\mathbf{S}_1^b, \mathbf{S}_2^b, \dots, \mathbf{S}_N^b \quad (18)$$

prema njihovoj uspješnosti.

Simulacijski model \mathbf{S}_1^b eliminiran u prvom koraku je najuspješniji i prvi je u tom nizu. Drugi simulacijski model \mathbf{S}_2^b u tom nizu je dobiven u drugom koraku iteracijskog postupka.

Posljednji u nizu je simulacijski model \mathbf{S}_N^b dobiven nakon izvršenih $N - 1$ klasifikacija kao jedini preostali.

Uspješnost dobivenih simulacijskih modela možemo ocijeniti i pomoću normaliziranog korijena srednje kvadratne pogreške (engl. normalized root mean square error, NRMS) koji se definira kao

$$\text{NRMS}_j = \frac{1}{\sigma_{\mathbf{S}_i}} \sqrt{\frac{1}{Q_2} \cdot \sum_{k=1}^{Q_2} (S_{j,k}^b - S_{i,k})^2}, \quad j = 1, 2, \dots, N, \quad (19)$$

pri čemu su $S_{j,k}^b$ ($k = 1, 2, \dots, Q_2$) koordinate vektora $\mathbf{S}_{j,k}^b$ ($j = 1, 2, \dots, N$), $S_{i,k}$ ($k = 1, 2, \dots, Q_2$) su koordinate vektora \mathbf{S}_i , a $\sigma_{\mathbf{S}_i}$ je standardna devijacija koordinata vektora \mathbf{S}_i , [4, str. 63].

Što je NRMS nekog simulacijskog modela manji, to je taj model uspješniji. Hiperarhijski niz simulacijskih modela dobiven ovom metodom uspoređuje se s pripadnim hiperarhijskim nizom dobivenim pomoću PNN mreže.

5. IDENTIFIKACIJA I SIMULACIJA PARNOTURBINSKOG POSTROJENJA UZ OCJENU USPJEŠNOSTI

Predložene metode smo primjenili na radne parametre sustava upravljanja i regulacije ABB-ove parne turbine snage 210 MW, smještene u termoelektrani Plomin 2 u Plominu. Analizirano je sljedećih $R = 10$ parametara:

$$t_1 = \text{Temp1 met lez 2 L CT001A} \quad [\text{°C}]$$

$$t_2 = \text{Temp1 met lez 2 L CT001B} \quad [\text{°C}]$$

$$t_3 = \text{Temp3met lez2 axs le ispr CT003A} \quad [\text{°C}]$$

$$t_4 = \text{Temp3met lez2 axs le ispr CT003B} \quad [\text{°C}]$$

$$a_1 = \text{Aks pomic CY001A} \quad [\text{mm}]$$

$$a_2 = \text{Aks pomic CY001B} \quad [\text{mm}]$$

$$r_1 = \text{Relat vib vrat-lez2 CY002A} \quad [\mu\text{m}]$$

$$r_2 = \text{Relat vib vrat-lez2 CY003A} \quad [\mu\text{m}]$$

$$r\text{pm} = \text{Brzina vrtnje CS860} \quad [\text{min}^{-1}]$$

$$P = \text{Radna snaga CE006} \quad [\text{MW}]$$

Detalji o navedenim parametrima i turbini opisani su u [3, str. 81].

Predloženi model smo primjenili na dva vremenska intervala. U prvom intervalu broj okretaja turbine $r\text{pm}$ je bio konstantan, pa na predloženi model taj parametar nije imao značajnog utjecaja. Iz tog razloga, jedan parametar ovisi najviše o osam drugih. Slično je bilo i u drugom vremenskom intervalu u kojem je radna snaga P bila jednaka nuli.

Svaki parametar je funkcija najviše osam varijabli kojih ukupno ima $2^{9-1} - 1 = 255$. Svaka od njih ima svoju pripadnu klasu parametara o kojima ovisi, a za primjenu predloženog modela odabrali smo sljedećih sedam klasa:

1. $\text{temp} = \{t_1, t_2, t_3, t_4\}$
2. $\text{aks} = \{a_1, a_2\}$
3. $\text{rel} = \{r_1, r_2\}$
4. $\text{tempaks} = \{t_1, t_2, t_3, t_4, a_1, a_2\}$
5. $\text{temprel} = \{t_1, t_2, t_3, t_4, r_1, r_2\}$
6. $\text{relaks} = \{r_1, r_2, a_1, a_2\}$
7. $\text{tempaksrel} = \{t_1, t_2, t_3, t_4, a_1, a_2, r_1, r_2\}$.

5.1. ANALIZA SIMULACIJSKIH MODELA U PRVOM VREMENSKOM INTERVALU UZ $\text{rpm} = \text{konst.}$

U prvom vremenskom intervalu u trajanju od približno dva sata, analizirali smo ovisnost snage P o navedenim klasama parametara. Raspolažali smo uzorcima očitanima u svakoj sekundi kojih je ukupno bilo $Q = 7140$. Skup za identifikaciju $Q_1 \subset Q$ formirali smo od uzoraka očitanih svake desete sekunde počev od prve, a skup za simulaciju $Q_2 \subset Q$ od uzoraka očitanih također svake desete sekunde, ali počev od šeste. Broj uzoraka u oba skupa bio je jednak i iznosio je $Q_1 = Q_2 = 714$.

Za svaku od prethodno navedenih sedam klasa, izvršili smo po jednu identifikaciju sustava pomoću GRNN mreža, uz uvijek isto raspršenje $s = 0.4$. U tu svrhu, svakoj mreži je prezentirana odgovarajuća ulazna matrica \mathbf{P}_1 formata $714 \times r$ i matrica cilja \mathbf{T}_1 formata 714×1 . Broj neurona u ulaznom sloju svake GRNN mreže bio je jednak broju varijabli r iz pripadne klase. U oba skrivena sloja broj skrivenih neurona bio je jednak broju uzoraka iz skupa za identifikaciju $Q_1 = 714$, a izlazni sloj svake mreže je imao po jedan neuron.

Nakon izvršenih identifikacija, simulirali smo vrijednosti snage na skupu za testiranje Q_2 pomoću svakog dobivenog identifikacijskog modela. U tu svrhu, svakoj od GRNN mreža je prezentirana ulazna matrica \mathbf{P}_2 formata $Q_2 \times r$. Dobivene vrijednosti simuliranih snaga zapisali smo u obliku vektor stupaca

$$\mathbf{S}_j = [s_{1,j}^i \quad s_{2,j}^i \quad \dots \quad s_{714,j}^i]^T, \quad j = 1, 2, \dots, 7. \quad (20)$$

od kojih smo formirali ulaznu matricu PNN mreže \mathbf{S}^1 formata 714×7 . Svaki vektor stupac \mathbf{S}_j bio je pridružen samo j -toj klasi ($\mathbf{S}_j \rightarrow \mathbf{S}_j^b$) koje smo zapisali u obliku vektor retka

$$\mathbf{Tc}_1 = [1 \quad 2 \quad \dots \quad 7], \quad (21)$$

a pomoću tog vektora smo definirali matricu cilja \mathbf{T}^1 formata 7×7 .

U tablici 1. su za svaki korak iteracije prikazani formati odgovarajućih matrica i brojevi neurona za svaki pojedini sloj korištenih PNN mreža. Posljednji stupac tablice 1. prikazuje rezultat dobiven predloženim iteracijskim postupkom u šest koraka. U svakom koraku iteracije klasificirali smo jednom PNN mrežom vektor stupac \mathbf{S}_i u jednu od sedam klasa pripadnosti. Elementi stupca \mathbf{S}_i predstavljaju referentne, tj. stvarne vrijednosti snage za svaki uzorak matrice \mathbf{P}_2 .

Tablica 1. Karakteristike PNN mreža iteracijskog postupka za prvi vremenski interval uz $rpm = konst.$

korak iteracije k	formati matrica			broj neurona za				klasa pripadno- sti
	\mathbf{S}^k	\mathbf{Tc}_k	\mathbf{T}^k	ulazni sloj	prvi skriveni sloj	drugi skriveni sloj	izlazni sloj	
1	714×7	1×7	7×7	714	7	7	1	7
2	714×6	1×6	6×6	714	6	6	1	5
3	714×5	1×5	5×5	714	5	5	1	4
4	714×4	1×4	4×4	714	4	4	1	1
5	714×3	1×3	3×3	714	3	3	1	6
6	714×2	1×2	2×2	714	2	2	1	3

Iteracijskim postupkom dobili smo hijerarhijski niz simulacijskih modela, s obzirom na klase pripadnosti. Taj niz je prikazan u tablici 2. Posljednji simulacijski model u tom nizu je jedini preostali neklasificirani model nakon šest koraka iteracije.

Tablica 2. Hijerarhijski niz simulacijskih modela prema iteracijskom postupku s pripadnim NRMS vrijednostima, za prvi vremenski interval uz $rpm = konst.$

j	klasa parametara	klasa pripadnosti	$NRMS_j(\mathbf{S}_j^b, \mathbf{S}_i)$
1.	<i>tempaksrel</i>	7	0.0942
2.	<i>temprel</i>	5	0.0947
3.	<i>tempaks</i>	4	0.1415
4.	<i>temp</i>	1	0.1457
5.	<i>relaks</i>	6	0.4172
6.	<i>rel</i>	3	0.4609
7.	<i>aks</i>	2	0.8081

Hijerarhijski niz ukazuje na ocjenu uspješnosti korištenih simulacijskih modela. Najuspješniji simulacijski model ostvaren je simulacijom snage u ovisnosti o klasi svih parametara *tempaksrel* koje smo imali na raspolaganju. No, uspješnost modela nije se bitno smanjila kada smo snagu simulirali pomoću klase parametara *temprel*. Iz toga zaključujemo da klasa parametara *aks* zanemarivo utječe na uspješnost simulacijskog modela. S druge strane,

ako snagu simuliramo samo pomoću klase parametara *aks*, dobivamo najlošije rezultate. Zbog ovih razloga, preporučujemo simulacijske modele bez klase *aks*. Općenito, simulacijski modeli bez klase *temp* daju relativno loše rezultate, iz čega zaključujemo da je za uspješnost simulacijskih modela najznačajnija upravo klasa parametara *temp*.

Uspješnost simulacijskih modela smo ocijenili i pomoću NRMS pogreške

$$NRMS_j(\mathbf{S}_j^b, \mathbf{S}_i) = \frac{1}{\sigma_{\mathbf{S}_i}} \sqrt{\frac{1}{714} \cdot \sum_{k=1}^{714} (S_{j,k}^b - S_{i,k})^2}, \quad j = 1, 2, \dots, 7, \quad (22)$$

pri čemu je $\sigma_{\mathbf{S}_i}$ standardna devijacija koordinata vektora \mathbf{S}_i . Kako smo već ranije rekli, simulacijski model \mathbf{S}_j^b je uspješniji što je njegov pripadni $NRMS_j$ manji, a to je potpuno u skladu s ocjenom uspješnosti dobivenom iteracijskim postupkom.

Na slici 5. je grafički prikazan najuspješniji odziv GRNN mreže za simulaciju snage pomoću klase parametara *tempaksrel*, uz njegov pripadni rezidualni dijagram koji na promatranom vremenskom intervalu prikazuje razlike

$$(rez)_k^1 = S_{1,k}^b - S_{i,k}, \quad k = 1, 2, \dots, 714. \quad (23)$$

Već se iz tog grafičkog prikaza jasno vidi da je GRNN mreža dala dobar odziv čak i u uvjetima nagle promjene režima rada, odnosno pri naglom opterećenju i rasterećenju, a gotovo nikakvih problema nije imala u uvjetima stacionarnog rada.

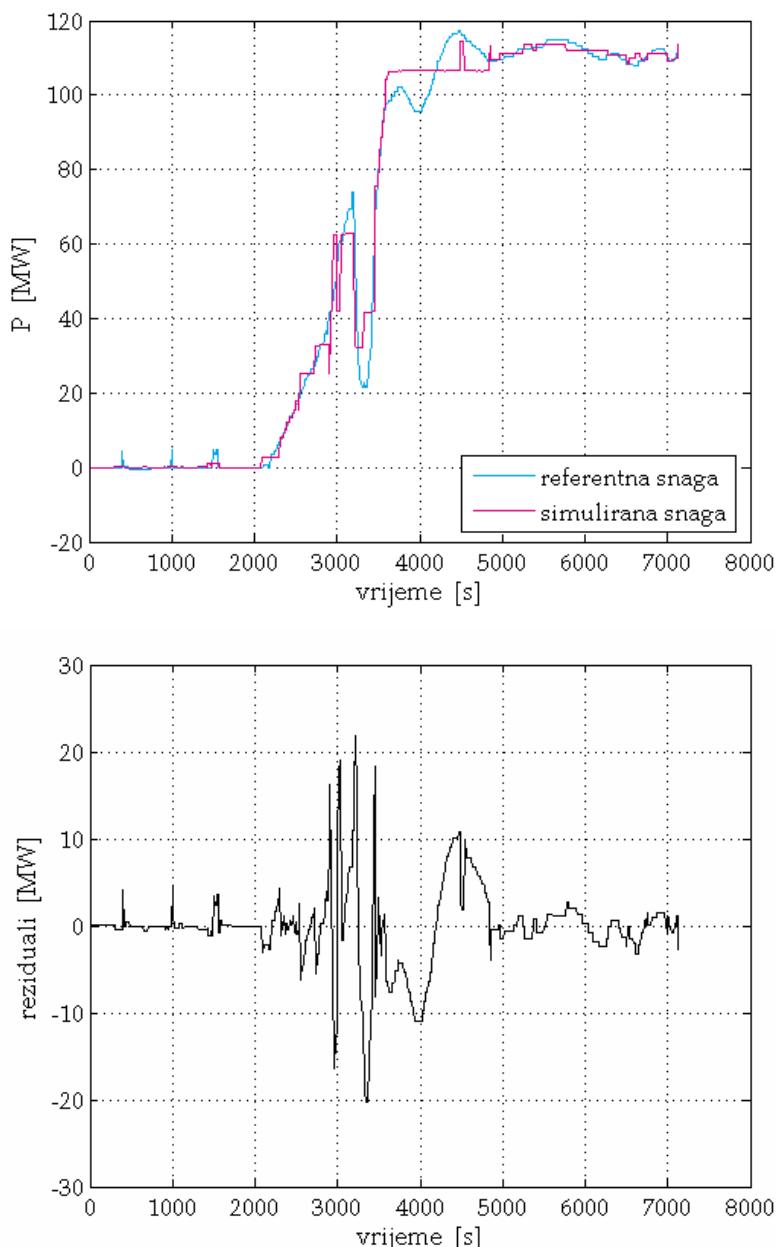
Simulacijski model dobiven pomoću klase parametara *temp* po nama predstavlja optimalan izbor među dobivenim modelima, jer za samo jednu klasu parametara uspješnost tog modela je samo nešto lošija od najboljeg. Razlike se očituju samo u uvjetima nagle promjene režima rada. Ovaj model prikazan je na slici 6., uz njegov pripadni rezidualni dijagram koji prikazuje razlike

$$(rez)_k^4 = S_{4,k}^b - S_{i,k}, \quad k = 1, 2, \dots, 714. \quad (24)$$

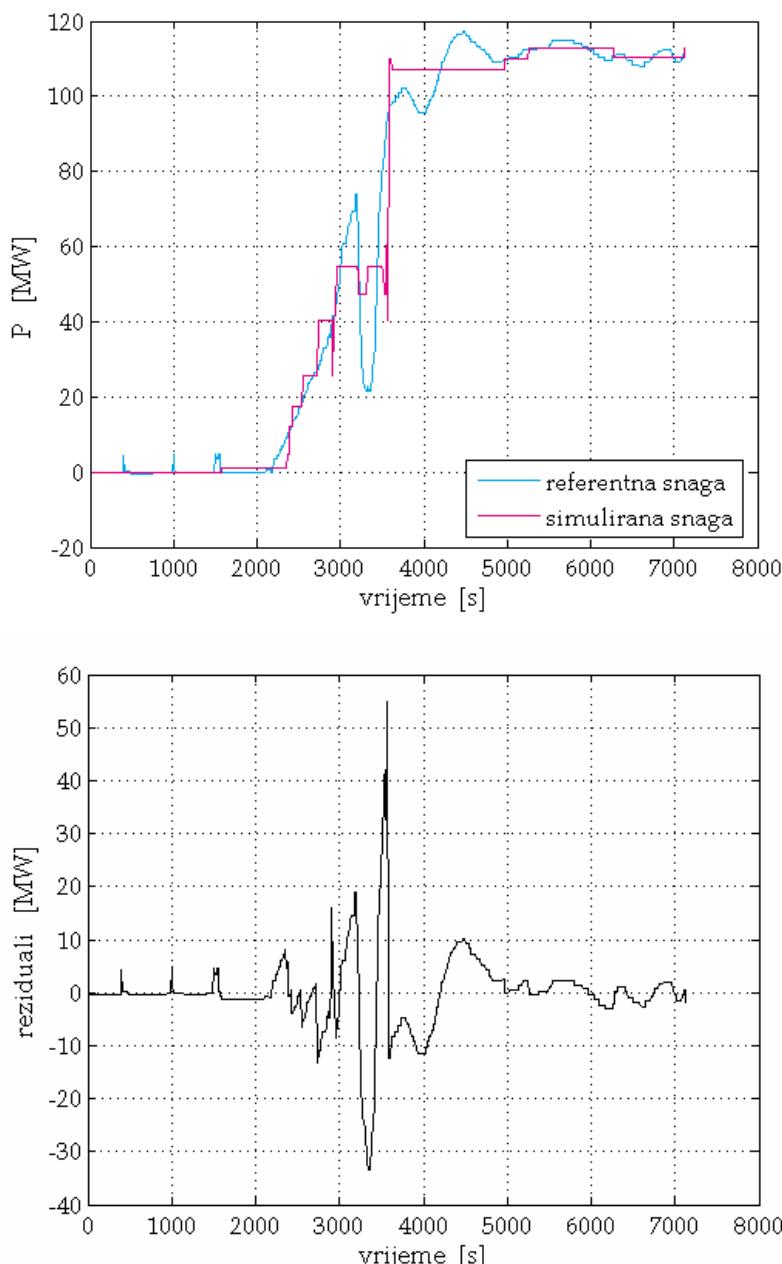
Na slici 7. prikazan je najlošiji odziv GRNN mreže simulacijskog modela ovisnosti snage o klasi parametara *aks*, uz rezidualni dijagram razlike

$$(rez)_k^7 = S_{7,k}^b - S_{i,k}, \quad k = 1, 2, \dots, 714. \quad (25)$$

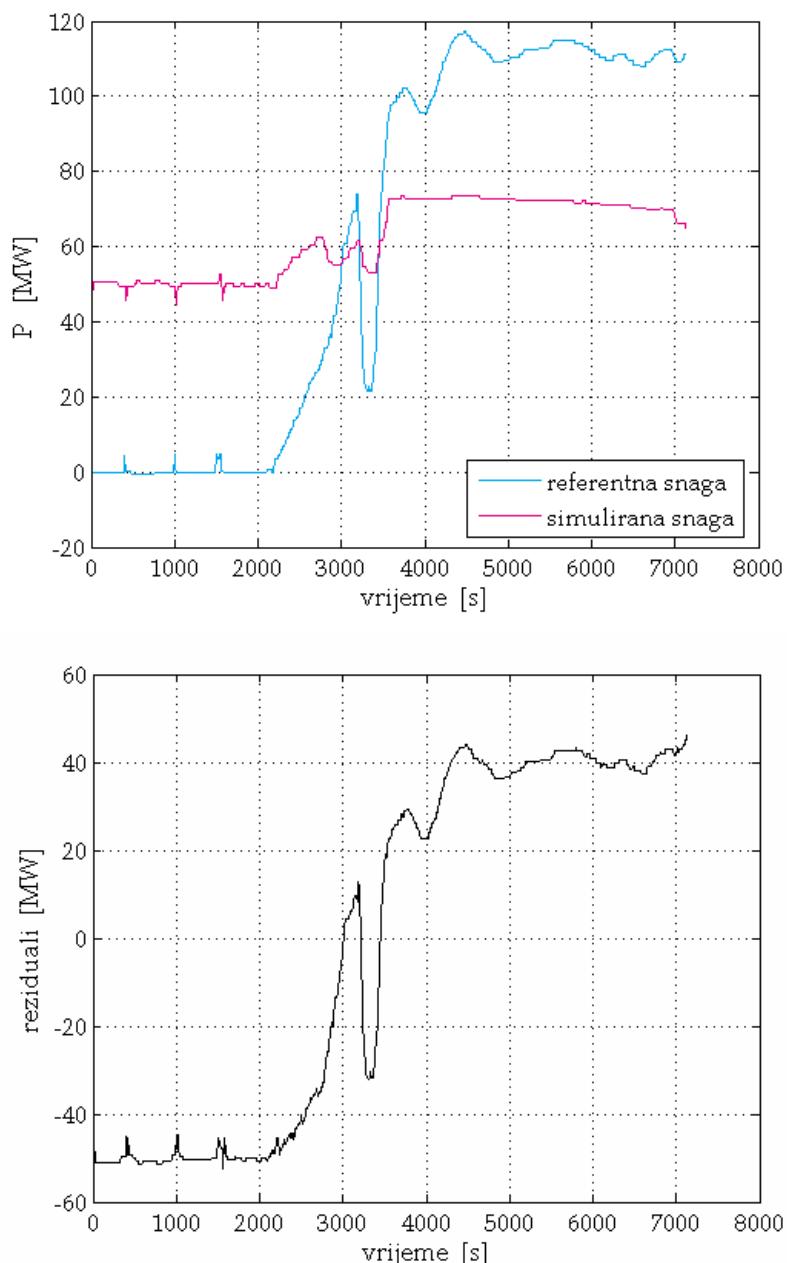
Grafički prikaz ovog modela je već sasvim dovoljan da se dođe do zaključka kako klasa parametara *aks* zanemarivo utječe na uspješnost simulacije snage.



Slika 5. Odziv GRNN mreže za simuliranu snagu u ovisnosti o klasi parametara tempaksrel uz odgovarajući rezidualni dijagram (MATLAB 7.0.1, R14 SP1 Graphics)



Slika 6. Odziv GRNN mreže za simuliranu snagu u ovisnosti o klasi parametara temp uz odgovarajući rezidualni dijagram (MATLAB 7.0.1, R14 SP1 Graphics)



Slika 7. Odziv GRNN mreže za simuliranu snagu u ovisnosti o klasi parametara aks uz odgovarajući rezidualni dijagram (MATLAB 7.0.1. R14 SP1 Graphics)

5.2. ANALIZA SIMULACIJSKIH MODELA U DRUGOM VREMENSKOM INTERVALU UZ $P=0$

U drugom vremenskom intervalu od tri sata analizirali smo ovisnost brzine vrtnje o prethodno navedenim klasama parametara. Skup za identifikaciju $Q_1 \subset Q$ i skup za simulaciju $Q_2 \subset Q$ formirali smo od $Q = 10740$ uzoraka iz skupa svih uzoraka Q koje smo imali na raspolaganju i to smo napravili na isti način kao i u 5.1. I ovdje je broj uzoraka u oba skupa bio jednak i iznosio je $Q_1 = Q_2 = 1074$.

Identifikacije i simulacije za svaku klasu parametara napravili smo kao i u prethodnom dijelu. Isto se odnosi i na ocjenu uspješnosti dobivenih modela pomoću iteracijskog postupka. Osim što je broj uzoraka u ovom slučaju bio nešto veći, jedina razlika je što smo u kreiranju GRNN mreža koristili raspršenje $s = 0.3$. Upravo zbog većeg broja uzoraka i karakteristike PNN mreža iteracijskog postupka bile su nešto drugačije, a prikazane su u tablici 3.

Tablica 3. Karakteristike PNN mreža iteracijskog postupka za drugi vremenski interval uz $P=0$

korak iteracije k	formati matrica			broj neurona za				klasa pripadnosti
	\mathbf{S}^k	\mathbf{Tc}_k	\mathbf{T}^k	ulazni sloj	prvi skriveni sloj	drugi skriveni sloj	izlazni sloj	
1	1074×7	1×7	7×7	1074	7	7	1	7
2	1074×6	1×6	6×6	1074	6	6	1	5
3	1074×5	1×5	5×5	1074	5	5	1	4
4	1074×4	1×4	4×4	1074	4	4	1	1
5	1074×3	1×3	3×3	1074	3	3	1	6
6	1074×2	1×2	2×2	1074	2	2	1	3

Iteracijskim postupkom smo dobili hijerarhijski niz simulacijskih modela s obzirom na klase pripadnosti koji je identičan nizu iz 5.1., a prikazan je u tablici 4. I ovdje je posljednji simulacijski model u tom nizu jedini preostali neklasificirani model, nakon šest koraka iteracije.

Najuspješniji simulacijski model je ostvaren simulacijom brzine vrtnje i ovdje u ovisnosti o klasi svih parametara $tempaksrel$ koje smo imali na raspolaganju. Iz analize svih dobivenih rezultata dolazimo do identičnih zaključaka kao i u slučajevima simulacije snage. Time smo indirektno potvrdili veliku mogućnost poopćenja simulacijskih modela temeljenih na GRNN mrežama, jer smo za iste klase parametara dobili podjednako dobar odziv, neovisno o tome koji se parametar simulira.

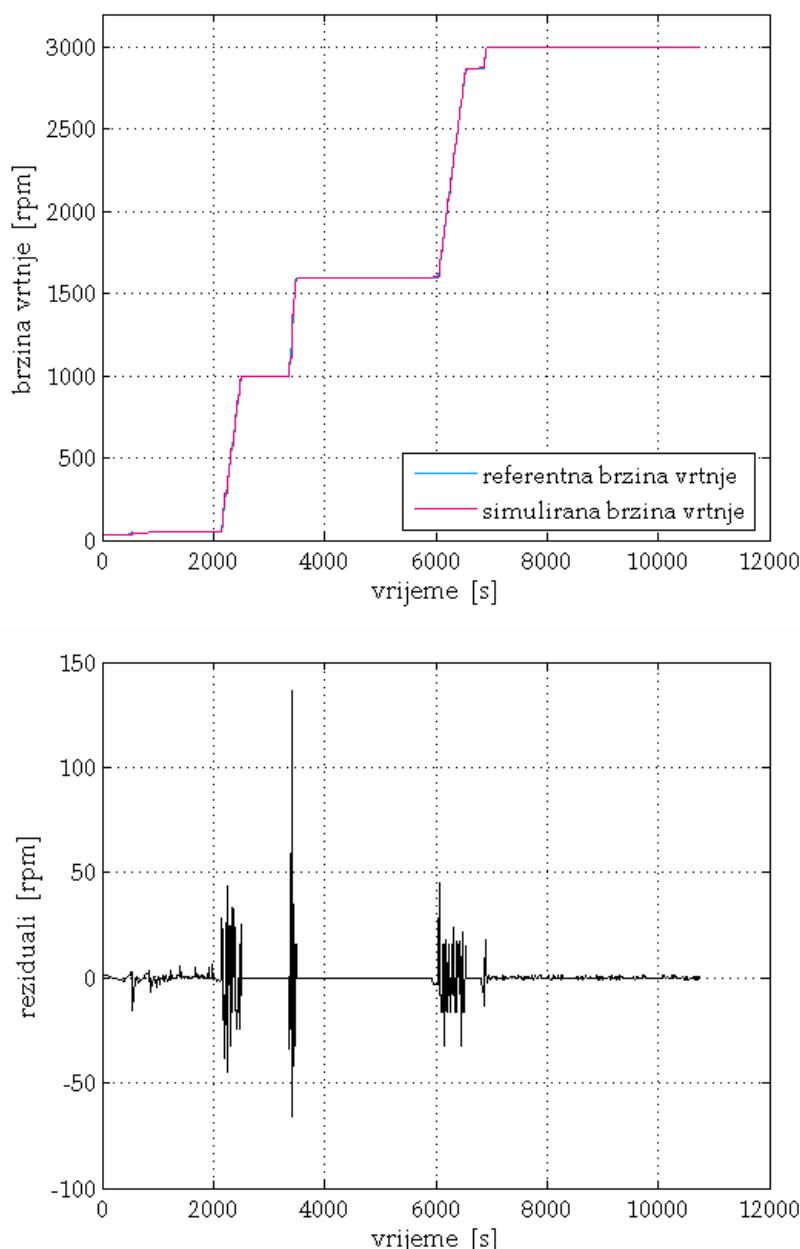
Tablica 4. Hjерархијски низ симулацијских модела према итерациском поступку са припадним NRMS vrijedностима за други временски интервал уз $P=0$

j	klasa parametara	klasa припадности	$NRMS_j(\mathbf{S}_j^b, \mathbf{S}_i)$
1.	<i>tempaksrel</i>	7	0.0070
2.	<i>temprel</i>	5	0.0070
3.	<i>tempaks</i>	4	0.0092
4.	<i>temp</i>	1	0.0092
5.	<i>relaks</i>	6	0.2511
6.	<i>rel</i>	3	0.2585
7.	<i>aks</i>	2	0.8632

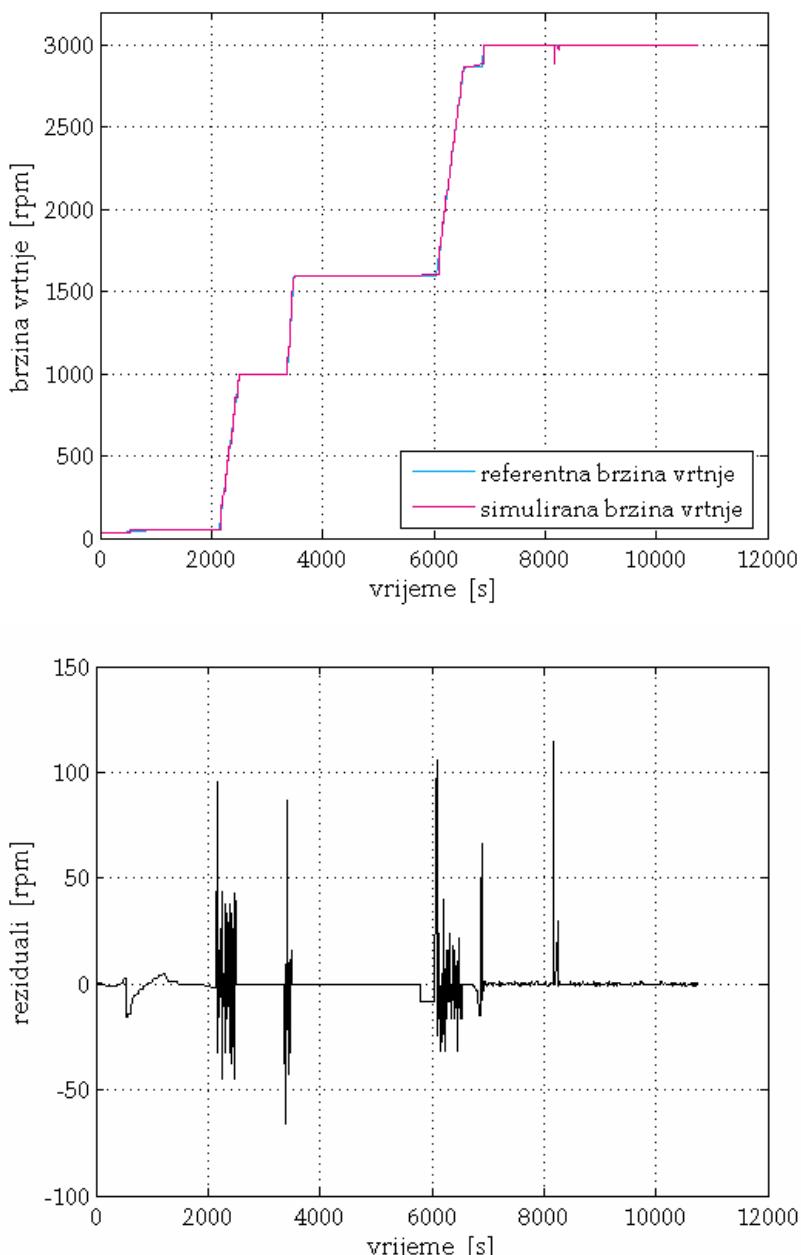
Uspješnost симулацијских модела smo ocijenili i ovdje помоћу NRMS погрешке

$$NRMS_j(\mathbf{S}_j^b, \mathbf{S}_i) = \frac{1}{\sigma_{\mathbf{S}_i}} \sqrt{\frac{1}{1074} \cdot \sum_{k=1}^{1074} (S_{j,k}^b - S_{i,k})^2}, \quad j = 1, 2, \dots, 7. \quad (26)$$

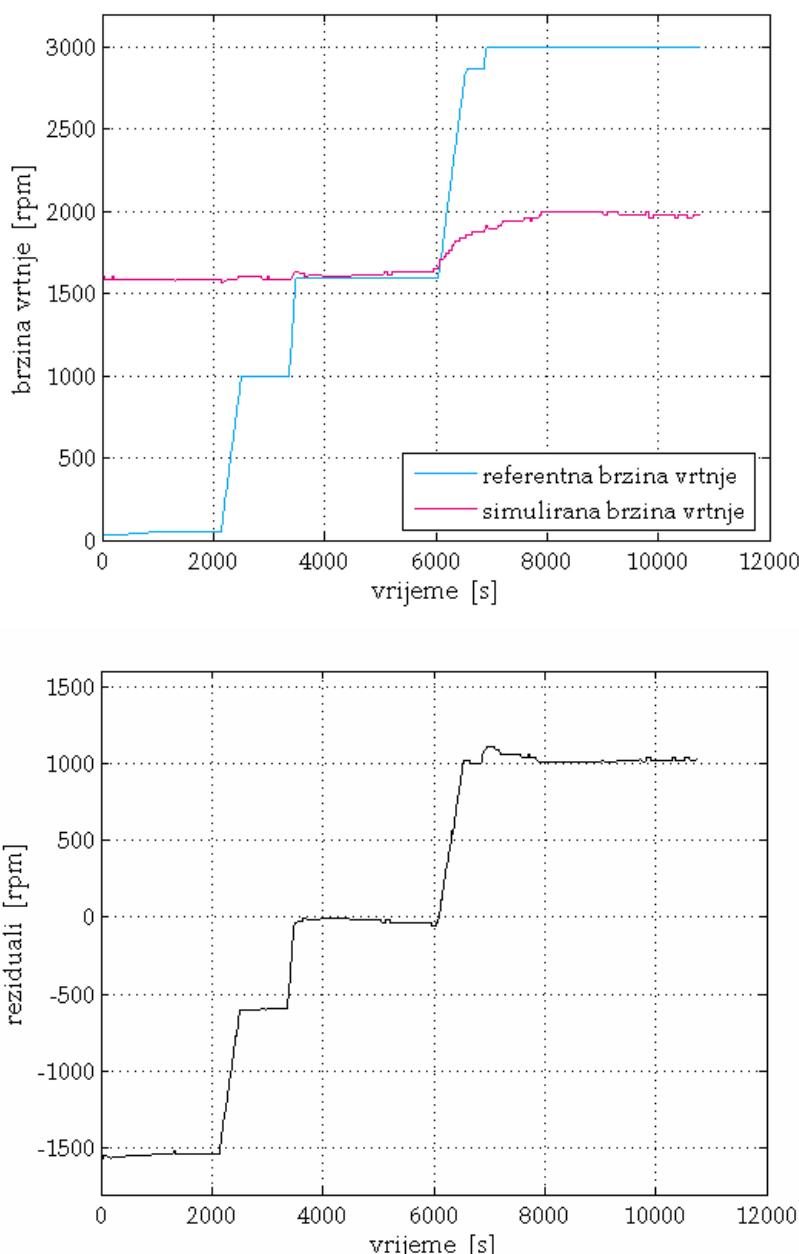
На слици 8. je графички приказан најuspješniji, на слици 9. optimalan, te na слици 10. најлоšiji odziv GRNN мреже за симулацију брзине вртње помоћу класе параметра *tempaksrel*, *temp*, односно *aks*, респективно. Уз сваки приказани одзив налази се и припадни rezidualni dijagram svakoga modela.



Slika 8. Odziv GRNN mreže za simuliranu brzinu vrtnje u ovisnosti o klasi parametara tempaksrel uz odgovarajući rezidualni dijagram (MATLAB 7.0.1, R14 SP1 Graphics)



Slika 9. Odziv GRNN mreže za simuliranu brzinu vrtnje u ovisnosti o klasi parametra temp uz odgovarajući rezidualni dijagram (MATLAB 7.0.1, R14 SP1 Graphics)



Slika 10. Odziv GRNN mreže za simuliranu brzinu vrtnje u ovisnosti o klasi parametara aks uz odgovarajući rezidualni dijagram (MATLAB 7.0.1. R14 SP1 Graphics)

6. ZAKLJUČAK

U radu smo pokazali mogućnost identifikacije i simulacije parametara radnih sustava pomoću GRNN mreža. Dobiveni simulacijski rezultati ukazuju na vrlo dobre odzive GRNN mreža koje na taj način mogu predstavljati ili alternativu ili nadopunu konvencionalnim automatskim sustavima upravljanja, u slučajevima kada su ulazni i izlazni parametri u bilo kakvoj relaciji. Prednost predloženog modela je posebno značajna u slučajevima kada nije poznat analitički izraz ovisnosti izlaznih o ulaznim parametrima. Za iste klase parametara odzivi GRNN mreža bili su podjednako dobri, bez obzira jesu li simulirali snagu ili brzinu vrtnje turbine. Na taj je način omogućeno poopćenje simulacijskih modela pomoću GRNN mreža.

Predloženim iteracijskim postupkom za ocjenu uspješnosti simulacijskih modela temeljenim na PNN mrežama, moguće je utvrditi u svakom iteracijskom koraku jednu od klase simuliranih uzoraka, kojoj referentni uzorak pripada s najvećom vjerojatnošću.

LITERATURA

- [1] Demuth, H.; Beale, M.: Neural Network Toolbox For Use with MATLAB, The Math Works, Inc., 2002., www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf
- [2] Novaković, B.; Majetić, D.; Široki, M., Umjetne neuronske mreže, FSB, Zagreb, 1998.
- [3] Skenderović, J.; Valčić, M.: Vizualizacija radnih parametara parnoturbinskog postrojenja pomoću umjetne neuronske mreže, Pomorstvo, god. 18, str. 79-94, 2004.
- [4] Valčić, M.; Skenderović, J.: Inteligentni sustavi nadzor a i dijagnostike kvarova temeljeni na umjetnim neuronskim mrežama, Pomorstvo, god. 18, str. 53-78, 2004.

*Summary***IDENTIFICATION AND SIMULATION MODELS OF OPERATING SYSTEMS
BASED ON ARTIFICIAL NEURAL NETWORKS**

The identification and simulation results of dynamic and static operating systems significantly depend upon the quality and choice of input parameters. The paper presents a generalised identification and simulation model of an operating system dependant on different classes of parameters based on a generalised regressive neural network (GRNN). In addition the iterative procedure model is proposed here which, in virtue of the probability neural network (PNN), makes it possible to effect efficiency assessment of the results developed as GRNN network responses. Both models have been tested on system parameters for the control and regulation of steam turbine installations utilising for the purpose the software package MATLAB 7.0.1.

Key words: artificial neural networks, identification, simulation, classification, steam turbines

*Faculty of Maritime Studies Rijeka
Studentska 2, 51000 Rijeka
Croatia*