

Mr.sc. Julije Skenderović
Marko Valčić
Pomorski fakultet u Rijeci
Studentska 2, Rijeka

Pregledni članak
UDK: 004.032.26
621.165

Primljeno: 08. lipnja 2004.
Prihvaćeno: 23. srpnja 2004.

VIZUALIZACIJA RADNIH PARAMETARA PARNOTURBINSKOG POSTROJENJA POMOĆU UMJETNE NEURONSKE MREŽE

Praćenje rada složenih sustava pomoću umjetnih neuronskih mreža, omogućava kvalitetne informacije o karakteristikama sustava kao i o njihovom međusobnom utjecaju. U radu je opisana Kohonenova samoorganizirajuća neuronska mreža pomoću koje je izvršena klasterizacija, vizualizacija i analiza vrijednosti radnih parametara industrijske trostupanjske parne turbine, nazivne snage 210 MW. Korišteni su programski paketi MATLAB 6.5 i SOM Toolbox 2.0. Dobiveni rezultati predstavljaju klasifikaciju pojedinih parametara u odgovarajuće klustere, kao i njihovu međusobnu ovisnost, a u svrhu kvalitetnijeg nadzora rada parnoturbinskog postrojenja. Posebno je naglašena grafička vizualizacija obrađenih parametara, kako bi se olakšala analiza dobivenih rezultata.

Ključne riječi: umjetne neuronske mreže, klasterizacija, SOM, U-matrice, parne turbine

1. UVOD

Klasterizacija je svrstavanje uzoraka u razrede – klustere po nekim svojstvima. Klasterizacija je izrazita (engl. crisp), ako svaki uzorak pripada jednom i samo jednom klasteru. Drugim riječima, u ovom se slučaju radi o particiji skupa svih uzoraka. Ako svaki uzorak pripada nekom klasteru s određenim stupnjem pripadnosti, klasterizacija je neizrazita (engl. fuzzy). Pri mješovitoj klasterizaciji svaki uzorak pripada određenom klasteru prema vjerojatnosti u distribuciji skupa uzoraka.

U ovom je radu za rješavanje problema klasterizacije korištena samoorganizirajuća umjetna neuronska mreža (SOM, engl. self-organizing map), uz podršku programskih paketa MATLAB 6.5 i SOM Toolbox 2.0.

Navedimo samo neke od prednosti ove mreže. SOM je mreža bez učitelja. Ako je broj uzoraka velik i ako su uzorci velikih dimenzija, postupak klasterizacije je brz. Istraživanje stupnja pripadnosti uzorka određenom klasteru ovisno o parametru

pomoću neizrazite samoorganizirajuće neuronske mreže osobito je pogodno, ali to neće biti predmet ovog rada. SOM omogućava i kvantitativnu analizu skupa uzoraka. U ovom radu ograničili smo se na kvalitativnu analizu.


Neka je svaki uzorak opisan s d numeričkih parametara, a broj uzoraka neka je N . Uzorak je u tom slučaju d -dimenzionalni vektor čije su koordinate ti parametri. Označimo i -ti uzorak-vektor sa

$$\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id}), \quad i = 1, 2, \dots, N.$$

Neuron je također vektor iste dimenzije d kao i uzorak. Neka je broj neurona u mreži S . Taj broj je neovisan o broju i dimenziji uzoraka. Označimo j -ti neuron-vektor sa

$$\mathbf{w}_j = (w_{j1}, w_{j2}, \dots, w_{jd}), \quad j = 1, 2, \dots, S.$$

Koordinate neurona su tzv. težinske varijable. Za SOM je karakteristično organiziranje neurona u razne oblike: pravokutni, cilindrični, toroidni ili neki drugi, što predstavlja topologiju mreže (Sl. 1.).



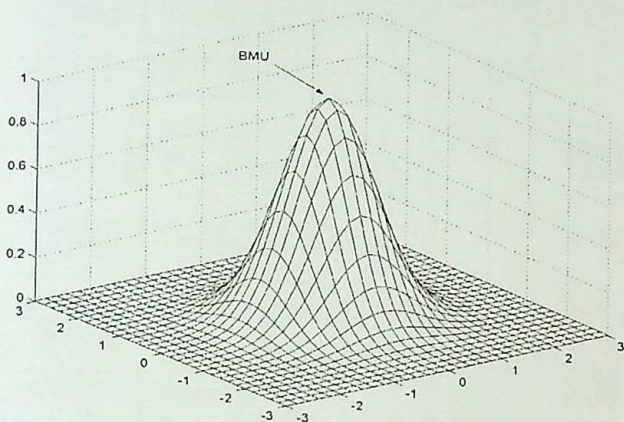
Slika 1. Topologija mreže: a) pravokutna, b) cilindrična i c) toroidna

Izvor: [6, str. 8]

Ovisno o tome koja se topologija koristi, u SOM-u svakom neuronu pripada još i tzv. vektor položaja \mathbf{r} neurona u mreži. Funkcijom susjedstva (engl. neighborhood function) definiraju se susjedi svakog neurona. Mogući su razni tipovi ovih funkcija poput *heksagonalne*, *kvadratne* itd. Funkcijom udaljenosti (engl. distance function) definiraju se udaljenosti između vektora.

Prije pokretanja mreže težinske se varijable proizvoljno biraju. Neuronska mreža funkcionira tako da se računaju udaljenosti između svakog uzorka i svakog neurona. Možemo reći da se neuroni "natječu". "Pobjednik" je onaj čija je udaljenost od uzorka najmanja (BMU, engl. Best-Matching Unit). Nakon ove faze slijedi faza treniranja (engl. train) mreže. Mijenjaju se težinske varijable BMU neurona i njegovih susjeda po određenoj zakonitosti, pri čemu se nove težinske vrijednosti približavaju, *adaptiraju* (engl. adapt), vrijednostima uzorka. Slika 2. prikazuje utjecaj jednog uzorka

na mrežu. Najviše se uzorku približava BMU neuron, njegovi susjedi nešto manje, dok se "nesusjedi" BMU neurona uopće ne odazivaju uzorku.



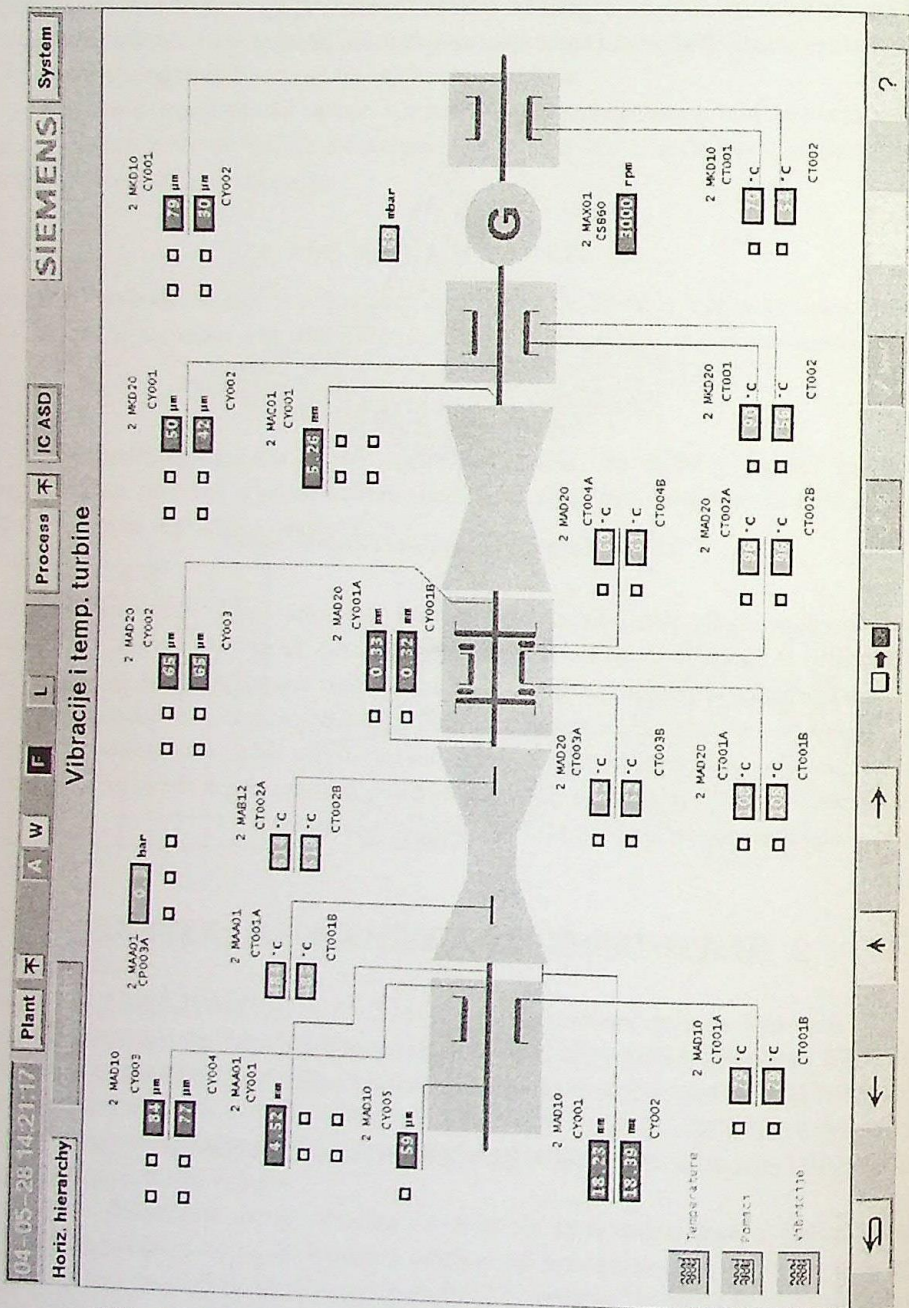
Slika 2. Odziv BMU neurona i njegovih susjeda

Treniranje se može provoditi na dva načina; postupno (engl. sequential training algorithm) ili skupno (engl. batch training algorithm). U prvom slučaju, adaptacija se provodi nakon određivanja BMU neurona za svaki uzorak posebno, a u drugom nakon što su svi uzorci prezentirani mreži. Postupak se provodi sve dok se mreža ne stabilizira. Po svršetku treniranja susjedni neuroni imaju slične vrijednosti. Mreža je klasterizirana. SOM je funkcija koja čuva metrička svojstva skupa uzoraka, zbog čega je klasterizacija mreže ujedno i klasterizacija skupa uzoraka.

2. KLASIFIKACIJA PODATAKA U KLASTERE

Koristeći se programskim paketima SOM Toolbox 2.0 i MATLAB 6.5, analizirani su radni parametri ABB-ove industrijske trostupanjske parne turbine nazivne snage 210 MW koja je smještena unutar HEP-ove radne jedinice, termoelektrane Plomin 2 u Plominu (Slika 3.)

U tablici 1. navedene su karakteristike pojedinih mjerenih parametara.



Slika 3. Shematski prikaz ABB parne turbine nazivne snage 210 MW
 s pripadnim mjernim mjestima

Izvor: HEP, TE Plomin 2 (Sustav mjerenja, regulacije i upravljanja)

	ŠIFRA MJERENE VELIČINE	NAZIV MJERENE VELIČINE	NAZIV VARIJABLE	MJERNA JEDINICA
1.	2 MAD20 CT001A	Temperatura 1 metala ležaja 2 lijevo A	Temp1La	°C
2.	2 MAD20 CT001B	Temperatura 1 metala ležaja 2 lijevo B	Temp1Lb	°C
3.	2 MAD20 CT003A	Temperatura 3 metala ležaja 2 ispred A	Temp3lez2a	°C
4.	2 MAD20 CT003B	Temperatura 3 metala ležaja 2 ispred B	Temp3lez2b	°C
5.	2 MAD20 CY001A	Aksijalni pomak A	AkspomA	mm
6.	2 MAD20 CY001B	Aksijalni pomak B	AkspomB	mm
7.	2 MAD20 CY002A	Relativne vibracije vratilo-ležaj 2 002A	RelvibA	μm
8.	2 MAD20 CY003A	Relativne vibracije vratilo-ležaj 2 003A	RelvibB	μm
9.	2 MAX01 CS860	Brzina vrtnje (broj okretaja u minuti)	Brzvirt	rpm
10.	2 MKA01 CE006	Radna snaga	RadnaP	MW

Tablica 1. Karakteristike mjernih parametara

Promatrane su vrijednosti u dva vremenska intervala. U prvom intervalu, od 21:00:00 do 23:59:00, mijenja se broj okretaja turbine dok generator ne daje snagu, a u drugom, od 01:59:00 do 04:59:00, generator daje promjenljivu snagu pri konstantnom broju okretaja. Mjerene vrijednosti su očitavane u svakoj sekundi odabranog vremenskog intervala.

U tablici 2. navedene su dimenzije i veličine skupa uzoraka i mreže za oba promatrana vremenska intervala.

Vremenski interval analize	od 21:00:00 do 23:59:00 h	od 01:59:00 do 04:59:00 h
Broj obrađenih numeričkih podataka	107410	108010
Broj ulaznih vektora	10741	10801
Dimenzija ulaznih vektora	1 x 10	1 x 10
Broj varijabli	10	10
Dimenzija SOM-a	38 x 14	33 x 16
Broj aktiviranih neurona	532	528

Tablica 2. Podaci o skupu uzoraka i neuronskoj mreži

U oba slučaja topologija mreže je pravokutna. Udaljenost između dva vektora je Euklidska i definirana je izrazom

$$\|\mathbf{x}_i - \mathbf{w}_i\| = \sqrt{\sum_{j=1}^d (x_{ij} - w_{ij})^2}.$$

Klasterizacija je provedena po kriteriju udaljenosti uzoraka. Uzorci čiji su parametri bliži u navedenom smislu udaljenosti, svrstani su u isti klaster. Karakteristike mreže izabrane su tako da se postigne optimalna klasterizacija, tj. da udaljenosti uzoraka unutar istog klastera budu minimalne, a udaljenosti između različitih klastera maksimalne.

Prije izračunavanja udaljenosti izvršena je *normalizacija* (engl. normalization) koordinata uzoraka i neurona čime se one svode na interval $\langle 0, 1 \rangle$. Za uzorke je taj postupak proveden linearnom transformacijom

$$\mathbf{x}' = \frac{\mathbf{x} - \bar{\mathbf{x}}}{\sigma_{\mathbf{x}}},$$

gdje je $\bar{\mathbf{x}}$ matematičko očekivanje, a $\sigma_{\mathbf{x}}$ standardna devijacija skupa uzoraka. Time se postigne vrijednost 0 za matematičko očekivanje, te 1 za varijancu. Za inicijalne vrijednosti neurona koristi se slučajna funkcija (engl. random function) s vrijednostima u tom intervalu. Svrha normalizacije je jednoliko distribuiranje utjecaja svih parametara pri izračunavanju udaljenosti između uzoraka.

Neuron \mathbf{w}_b koji je najbliži nekom uzorku \mathbf{x} određuje se iz uvjeta

$$\|\mathbf{x} - \mathbf{w}_b\| = \min_i \{\|\mathbf{x} - \mathbf{w}_i\|\}.$$

Funkcija susjedstva definirana je izrazom

$$h_{ij}(t) = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2(t)}},$$

gdje je $\sigma(t)$ koeficijent kojim se određuje veličina susjedstva. $\sigma(t)$ je monotono rastuća funkcija. Povećavanjem njene vrijednosti povećava se susjedstvo u mreži čime se postiže ubrzavanje treniranja mreže.

Treniranje mreže je skupno. U tu svrhu su korištene tzv. Voronoi regije.

Voronoi regija nekog neurona \mathbf{w}_i iz skupa neurona $(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_S \in \mathbf{R}^d)$ je skup V_i svih vektora $\xi \in \mathbf{R}^d$ koji su najbliži vektoru \mathbf{w}_i ,

$$V_i = \{ \xi \in \mathbf{R}^d \mid \|\xi - \mathbf{w}_i\| = \min_{j=1, \dots, S} \|\xi - \mathbf{w}_j\| \}.$$

Ako je za neki vektor $\xi \in \mathbf{R}^d$ udaljenost do više vektora jednaka, onda ga se slučajnim izborom uključi u samo jednu regiju. Označimo li sa

$$s_i(t) = \sum_{j=1}^{n_{v_i}} \mathbf{x}_j,$$

gdje je n_{v_i} broj uzoraka koji su se našli u Voronoi regiji neurona \mathbf{w}_i , nove vrijednosti težinskih koeficijenata se računaju prema izrazu

$$\mathbf{w}_i(t+1) = \frac{\sum_{j=1}^S h_{ij}(t) s_j(t)}{\sum_{j=1}^S n_{v_j} h_{ij}(t)}.$$

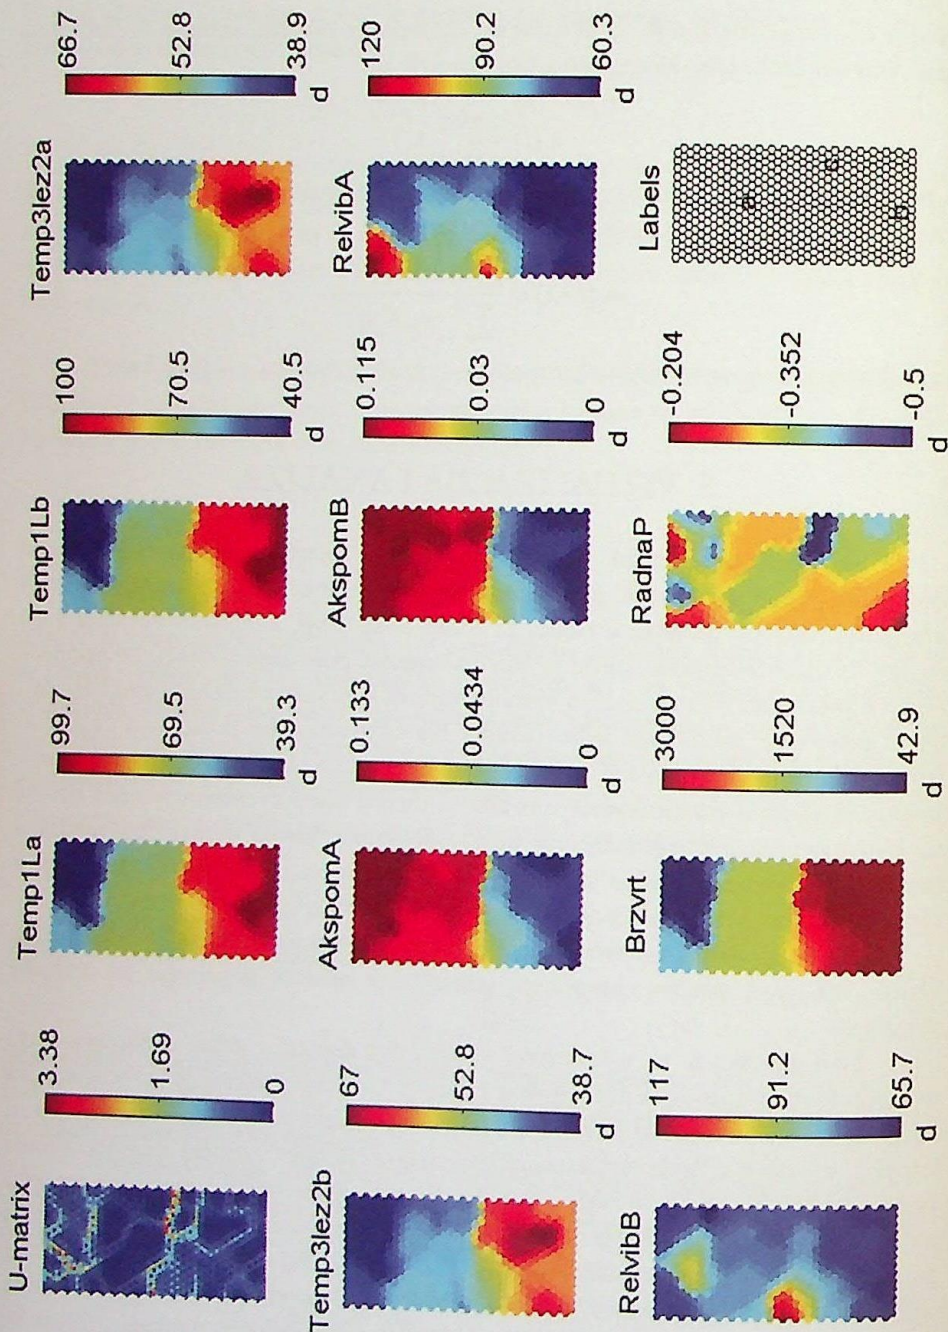
Drugim riječima, nove vrijednosti neurona su prosjeci uzoraka u Voronoi regiji.

3. VIZUALIZACIJA I ANALIZA

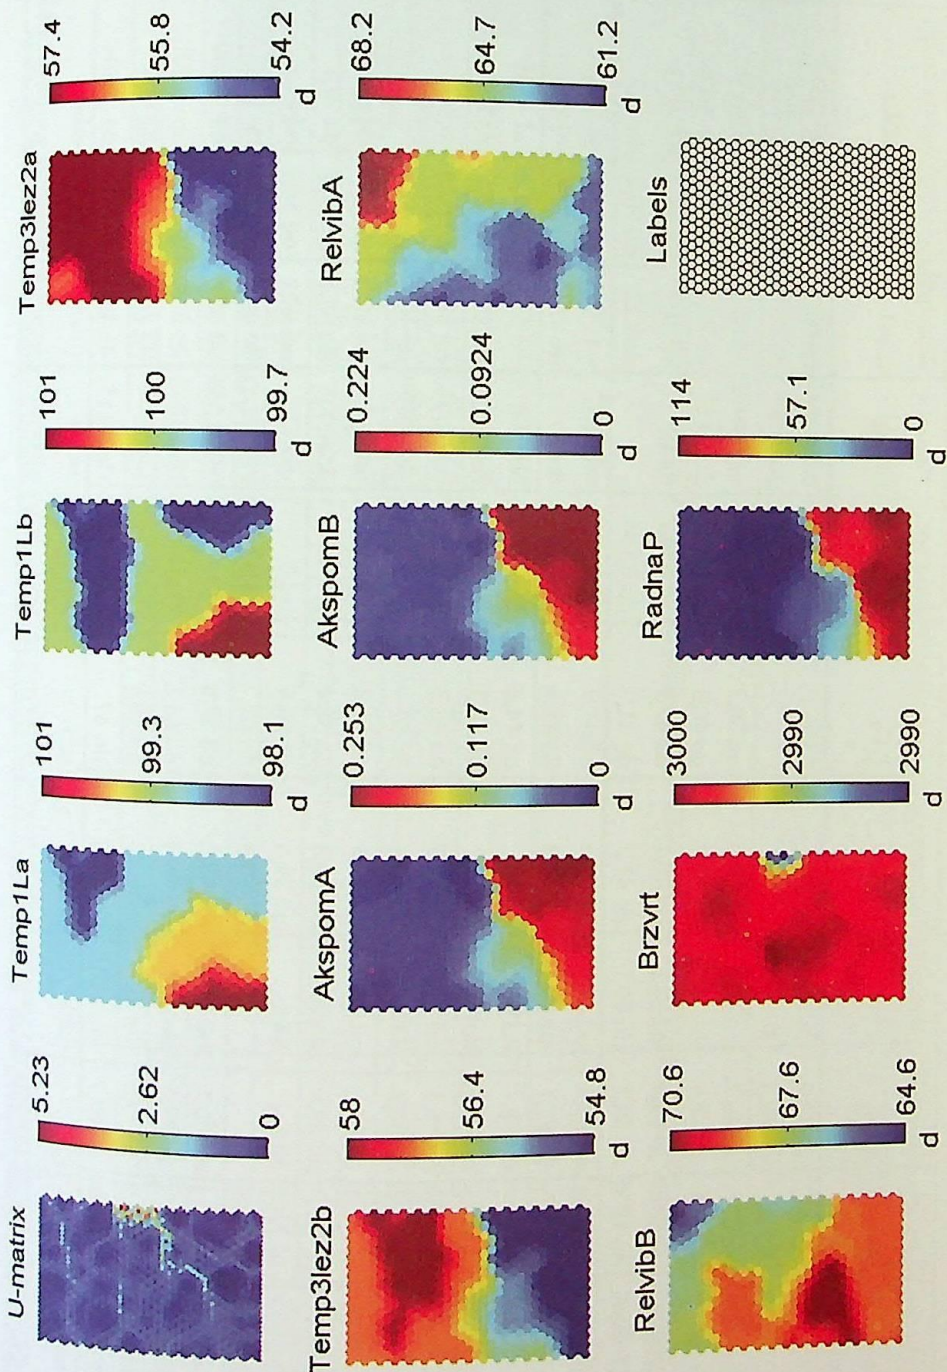
Korišteni programski paketi omogućavaju nekoliko načina vizualizacije dobivenih rezultata. Slika 4. predstavlja vizualizaciju mjerenih parametara za prvi vremenski interval naveden u tablici 2., a slika 5. za drugi. U lijevom gornjem kutu su tzv. U-matrice, potom slijede prikazi parametara pojedinačno (engl. component plane representation) i na kraju, u desnom donjem kutu matrice oznaka (engl. labels). Svaki šesterokut predstavlja jedan neuron. Na odgovarajućim pozicijama nalaze se isti neuroni. Broj neurona u U-matrici je veći u odnosu na broj neurona za parametre pojedinačno, jer U-matrica sadrži osim BMU neurona također i njihove susjede. Brojke uz U-matricu označavaju udaljenost među neuronima. Visoka numerička vrijednost neurona u U-matrici (crvena boja) označava rub klastera, dok jednoliko područje s niskim vrijednostima (plava boja) predstavlja sam klaster.

Brojke i boje u vizualizaciji pojedinačnih parametara označavaju denormalizirane vrijednosti (engl. relative component values) koje neuroni poprimaju po svršetku treniranja.

Npr. na slici 4. su u U-matrici vidljiva dva klastera, jedan u donjem dijelu matrice, a drugi u donjem dijelu gornje polovice U-matrice. Mreža je prepoznala dva klastera za ovaj vremenski interval. Za ilustraciju analize parametara odabrana su tri uzorka: uzorak a iz "gornjeg" klastera, uzorak b iz "donjeg" i uzorak c s ruba. Njihov položaj u mreži je vidljiv u matrici oznaka. Prateći odgovarajuće pozicije tih uzoraka po komponentama, vidljivo je da su za uzorak a parametri *Brzurt*, *Temp1La* i *Temp1Lb* prosječni (zeleno-crvena boja) i stabilni. Parametri *AkspomA* i *AkspomB* imaju relativno visoke vrijednosti (tamno-crvena boja) i stabilni su. Za taj uzorak, parametar *RelvibA* ima relativno nisku vrijednost (plava boja) i nalazi se u nestabilnom području. Slične su karakteristike parametara uzorka b iz "donjeg" klastera, dok je za parametre uzorka c, koji se u U-matrici nalazi na rubu klastera, karakteristična nestabilnost većine parametara (osim *RelvibA* i *RelvibB*).



Slika 4. Vizualizacija samoorganizirajuće neuronske mreže za prvi vremenski interval od 21:00:00 h do 23:59:00 h



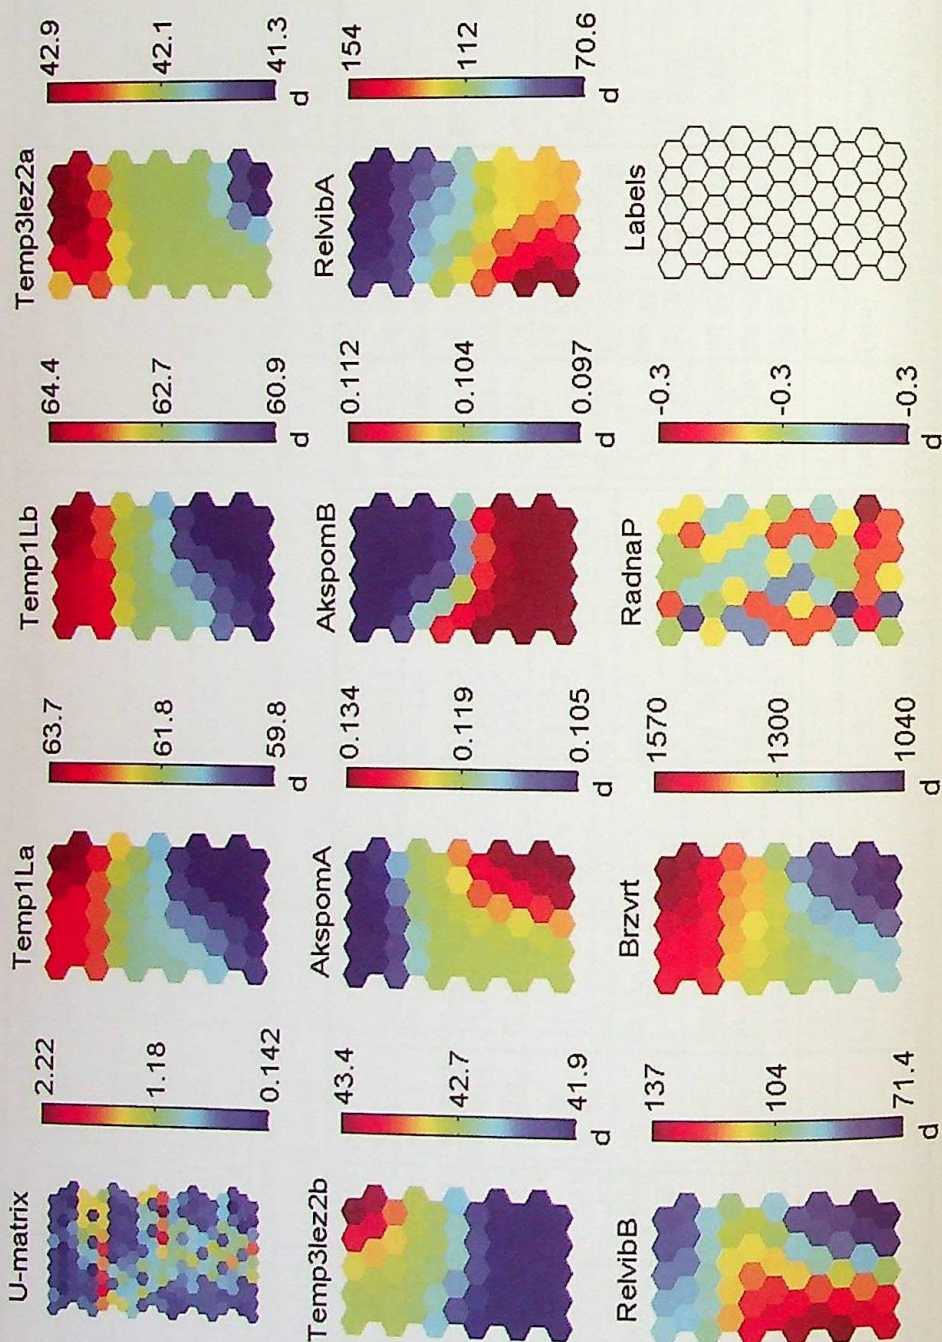
Slika 5. Vizualizacija samoorganizirajuće neuronske mreže za drugi vremenski interval od 01:59:00 h do 04:59:00 h

Vremenski interval (hh:mm:ss)	Brzina vrtanje (rpm)	Temp1La (°C)	Temp1Lb (°C)	Temp3lez2a (°C)	Temp3lez2b (°C)	Akspoma (mm)	Akspom (mm)	RelivbA (µm)	RelivbB (µm)	Radna snaga (MW)
1. od 21:00:00 do 21:35:49	od 34,8 do 53,7	od 38,8 do 40,4	od 39,9 do 41,6	38,9		od 0,119 do 0,134	od 0,0987 do 0,125	od 65 do 75	od 67,5 do 92,4	od -0,537 do -0,2
2. od 21:35:50 do 21:41:41	od 111 do 963	od 40,7 do 54,9	od 41,8 do 56	od 38,9 do 39,7	od 40,3 do 40,3	od 0,106 do 0,149	od 0,0931 do 0,127	od 62,2 do 98,7	od 64,4 do 96,4	od -0,35 do -0,267
3. od 21:41:42 do 21:56:03	od 998 do 1000	od 55,9 do 59,7	od 56,6 do 60,1	od 40,1 do 41,3	od 40,3 do 41,9	od 0,119 do 0,134	0,112	od 105 do 122	od 68,8 do 70,4	od -0,45 do -0,2
4. od 21:56:04 do 21:58:10	od 1040 do 1570	od 59,8 do 63,7	od 60,9 do 64,4	od 41,3 do 42,9	od 41,9 do 43,4	od 0,105 do 0,134	od 0,097 do 0,112	od 70,6 do 154	od 71,4 do 137	-0,3
5. od 21:58:11 do 22:40:53	1600	od 65 do 70,3	od 66 do 70,6	od 44 do 47,7	od 44,2 do 48,3	od 0,105 do 0,12	od 0,0836 do 0,112	od 68,2 do 89	od 74,9 do 82,3	od -0,35 do -0,3
6. od 22:40:54 do 22:48:59	od 1660 do 2830	od 70,3 do 86,8	od 70,7 do 87,8	od 47,8 do 56,5	od 48,3 do 57	od 0,0211 do 0,0845	od 0,003 do 0,0778	od 68,7 do 101	od 80,9 do 111	-0,3
7. od 22:49:00 do 22:54:32	2870	od 88 do 88,8	od 88,8 do 89,6	od 56,8 do 59,8	od 57,2 do 60,4	0,008	od 0 do 0,003	od 64,9 do 66,6	od 79,2 do 80,8	od -0,498 do -0,3
8. od 22:54:33 do 22:55:30	od 2900 do 3000	88,8	89,6	od 59,8 do 60,6	od 60,4 do 62	od 0 do 0,008	-0,012	od 62,1 do 65	od 75,2 do 83	od -1,5 do 0,5
9. od 22:55:31 do 23:59:00	3000	od 86,1 do 99,7	od 87,4 do 100	od 58,2 do 66,4	od 58,8 do 66,7	od -0,047 do -0,0046	od -0,055 do -0,012	od 60,3 do 63,7	od 68,6 do 74,7	od -0,399 do -0,201
10. od 21:00:00 do 23:59:00	od 42,9 do 3000	od 39,3 do 99,7	od 40,5 do 100	od 38,9 do 66,7	od 38,7 do 67	od 0 do 0,133	od 0 do 0,115	od 60,3 do 120	od 65,7 do 117	od -0,5 do -0,204

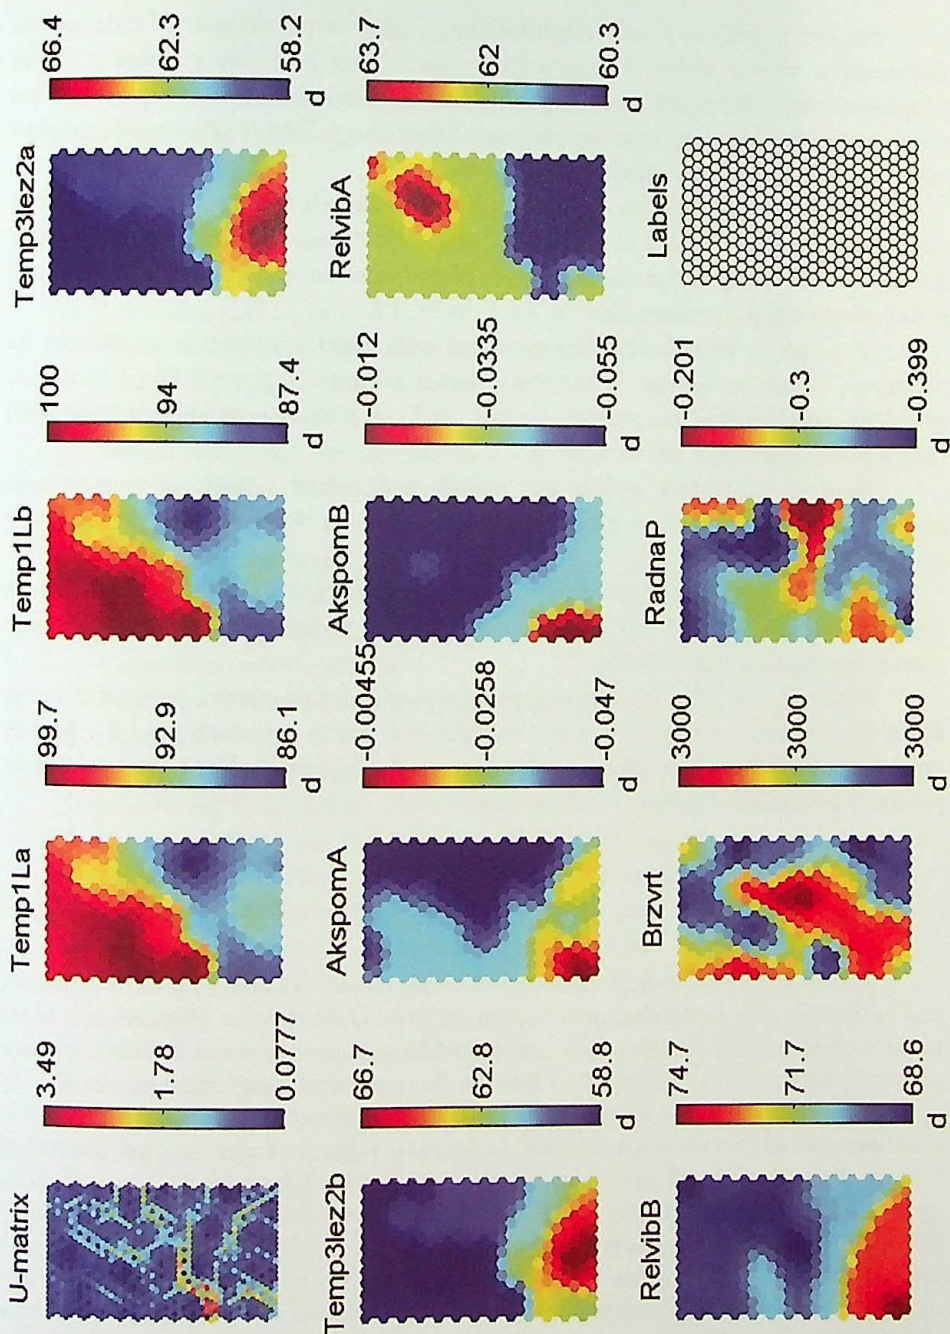
Tablica 3. Ovisnost mjernih parametara o promjeni broja okretaja (rpm) za prvi vremenski interval u slučaju kada generator ne daje snagu

Vremenski interval (hh:mm:ss)	Brzina vrtnje (MW)	Temp1La (°C)	Temp1Lb (°C)	Temp3lez2a (°C)	Temp3lez2b (°C)	Akspoma (mm)	Akspom (mm)	RelvibA (µm)	RelvibB (µm)	Radna snaga (rpm)
1. od 01:59:00 do 02:59:43	od 0 do 0,15	od 98,1 do 98,9	od 99,7 do 100	57,4	od 57,2 do 58	od -0,0188 do -0,004	od -0,026 do -0,011	od 61 do 67,9	od 64,8 do 69,2	3000
2. od 02:59:44 do 03:36:37	od 0 do 4,5	98,9	100	od 56,6 do 57,4	57,2	od 0 do 0,017	od -0,0726 do -0,0023	od 63,5 do 69,5	od 64,5 do 67,6	od 2980 do 3000
3. od 03:36:38 do 03:53:15	od 4,09 do 70,2	od 98,9 do 101	od 100 do 101	od 55 do 56,6	od 55,6 do 57,2	od 0 do 0,12	od 0 do 0,111	od 60,7 do 63,4	od 67,7 do 70,6	3000
4. od 03:53:16 do 03:56:07	od 70,8 do 21,4	101	101	od 55 do 55,8	od 55,6 do 56,4	od 0,022 do 0,12	od 0,015 do 0,1	od 61,3 do 63,3	od 69 do 70,6	3000
5. od 03:56:08 do 04:03:02	od 27,2 do 102	od 98,9 do 101	od 99,7 do 101	od 54,2 do 55,8	od 54,8 do 56,4	od 0,0231 do 0,251	od 0,0152 do 0,224	od 62,3 do 65	od 67,4 do 69	3000
6. od 04:10:00 do 04:59:00	od 108 do 116	od 98,9 do 101	od 99,7 do 101	54,2	54,8	od 0,162 do 0,258	od 0,152 do 0,224	od 62,1 do 65	od 67,6 do 70,6	3000
7. od 01:59:00 do 04:59:00	od 0 do 114	od 98,1 do 101	od 99,7 do 101	od 54,2 do 57,4	od 54,8 do 58	od 0 do 0,253	od 0 do 0,224	od 61,2 do 68,2	od 64,6 do 70,6	od 2990 do 3000

Tablica 4. Ovisnost mjernih parametara o promjeni snage uz konstantan broj okretaja (~3000 rpm) za drugi vremenski interval



Slika 6. Vizualizacija samoorganizirajuće neuronske mreže u uvjetima naglog porasta broja okretaja (Tablica 3., red.br. 4)



Slika 7. Vizualizacija samoorganizirajuće neuronske mreže u uvjetima konstantnog broja okretaja (Tablica 3., red.br. 9)

Na slici 5. vidljivo je iz U-matrice da je za ovaj vremenski interval rada turbine klasterizacija veoma slaba. Vizualizacija komponenata pokazuje stabilnu i visoku vrijednost broja okretaja što je vidljivo iz komponente Brz_{vrt} . U tim uvjetima, pri relativno niskim vrijednostima temperatura $Temp_{3lez2a}$ i $Temp_{3lez2b}$, aksijalni pomaci $AkspomA$ i $AkspomB$ su relativno visoki i obratno.

U tablici 3. prikazani su vremenski podintervali rada turbine u kojima je brzina vrtnje približno konstantna ili naglo raste u uvjetima kada generator ne daje snagu. Također su navedene denormalizirane granice unutar kojih se mijenjaju vrijednosti pojedinih radnih parametara (red. br. od 1 do 9).

U tablici 4. su izabrani karakteristični vremenski podintervali s obzirom na promjenu snage u slučaju konstantnog broja okretaja ($rpm \sim 3000$). I ovdje su navedene denormalizirane granice unutar kojih se mijenjaju vrijednosti pojedinih radnih parametara (red. br. od 1 do 6).

Slika 6. vizualizira vrijednosti radnih parametara turbine u vremenskom podintervalu od 21:56:04 do 21:58:10 (tablica 3., red. br. 4) kada brzina vrtnje naglo poraste za 530 rpm.

Slika 7. vizualizira vrijednosti radnih parametara turbine u vremenskom podintervalu od 22:55:31 do 23:59:00 (tablica 3., red. br. 9) kada je brzina vrtnje gotovo konstantna ($rpm \sim 3000$).

Mreža u oba slučaja registrira promjene vrijednosti parametra brzine vrtnje Brz_{vrt} što ukazuje na osjetljivost ove vizualizacije. Samo u slučaju ako su u nekom vremenskom periodu sve vrijednosti parametra jednake, cijelo područje tog parametra pokazuje prosječnu vrijednost (zelena boja).

4. ZAKLJUČAK

U radu je pokazano da je samoorganizirajuća neuronska mreža (SOM) učinkovit alat za istraživanje podataka, posebno za njihovu klasterizaciju. Primijenjena je na veliki broj uzoraka kojima je opisan rad industrijske parne turbine u različitim radnim uvjetima, tijekom dva vremenska intervala. Pokazali smo mogućnost ove mreže da sama izvrši klasterizaciju skupa uzoraka. SOM je operator koji skup velikog broja višedimenzionalnih vektora preslikava u ravninu u kojoj je numeričkim vrijednostima i bojama omogućena dobra vizualizacija toga skupa. Klasterizacija i vizualizacija omogućavaju kvalitetno praćenje rada složenih sustava, a kako ova mreža i pohranjuje dobivene rezultate, ona postaje vrijedan izvor informacija za kvalitetniji nadzor i upravljanje u radu parnoturbinskog postrojenja. Za sve neuronske mreže, pa tako i za SOM, karakteristična je mogućnost utvrđivanja utjecaja čak i najmanjih promjena vrijednosti jednog parametra na sve ostale, na što je u radu posebno ukazano. Dobivene informacije mogu uspješnije zamijeniti znanje eksperata i operatera o međusobnoj ovisnosti radnih parametara pri radu parne turbine, te poslužiti kao baza znanja neizrazitih sustava upravljanja i regulacije.

5. ZAHVALE

Svi obrađeni podaci dobiveni su susretljivošću osoblja HEP-a, TE Plomin 2 u Plominu, čime im se i ovim putem želimo najiskrenije zahvaliti na suradnji.

LITERATURA

- [1] Tsoukalas, L.H.; Uhrig, R.E.
Fuzzy and Neural Approaches in Engineering
John Wiley & Sons, Inc., New York, 1997.
- [2] Müller, B.; Reinhardt, J.
Neural Networks, An Introduction
Springer-Verlag, Berlin-Heidelberg, 1990.
- [3] Kohonen, T.
Self-Organizing Maps
Springer-Verlag, Berlin-Heidelberg, 2001.
- [4] Novaković, B.; Majetić, D.; Široki, M.
Umjetne neuronske mreže
Fakultet strojarstva i brodogradnje, Zagreb, 1998.
- [5] Hines, J.W.
MATLAB, Supplement to Fuzzy and Neural Approaches in Engineering
John Wiley & Sons, Inc., New York, 1997.
- [6] Vesanto, J.; Himberg, J.; Alhoniemi, E.; Parhankangas, J.
Self-Organizing Map in MATLAB, The SOM Toolbox
Laboratory of Computer and Information Science
Helsinki University of Technology, Finland, 2000.
- [7] Vesanto, J.; Alhoniemi, E.
Clustering of the Self-Organizing Map
IEEE Transaction on Neural Networks, Vol.11, No.3, 2000.
- [8] Simula, O.; Vasar, P.; Vesanto, J.; Helminien, R.R.
The Self-Organizing Map in Industry Analysis
Laboratory of Computer and Information Science
Helsinki University of Technology, Finland, 1997.
- [9] Su, M.C.; Chang, H.T.
Fast Self-Organizing Feature Map Algorithm
IEEE Transaction on Neural Networks, Vol.11, No.3, 2000.

Summary

VISUALIZATION OF PERFORMANCE PARAMETERS ON
STEAM TURBINE ENGINES BY MEANS OF ARTIFICIAL NEURAL
NETWORKS

Observing the operation of complex systems by means of artificial neural networks enables acquirement of high-quality information about the characteristics of the system as well as about the influence of their interrelationships. The paper describes Kohonen's self-organizing neural network by means of which clusterization, visualization and value assessment of operative parameters of the industrial triple-stage steam turbine of 210 MW nominal power was effected. MATLAB 6.5 and SOM Toolbox 2.0 program packages were used. The acquired results represent the classification of certain parameters into corresponding clusters, as well as their interrelationships, for the purpose of enhancement of quality monitoring of the performance of the steam turbine engine. Special emphasis is placed on graphic visualization of the parameters dealt with, so as to facilitate analyzing of the acquired results.

Key words: artificial neural networks, clusterization, SOM, U-matrices, steam turbines

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