

## NOVI MODELI PREDVIĐANJA POTROŠNJE ELEKTRIČNE ENERGIJE ZASNOVANI NA VNM

Jelena Milojković, jelena@venus.elfak.ni.ac.rs, Vančo Litovski, vanco.litovski@elfak.ni.ac.rs,

**Sadržaj** – Razmatrano je kratkoročno predviđanje potrošnje električne energije. Biće, najpre, pokazano da su za kratkoročno predviđanje potrošnje električne energije, mada na raspolaganju stoje obimni podaci, važni samo podaci o najskorijoj potrošnji. To znači da će biti korišćeni metodi za predviđanje koji se zasnivaju na ograničenom skupu podataka. Nasuprot heurističnim rešenjima koja su u upotrebi, ovde predlažemo upotrebu nerekurzivnih veštačkih neuronskih mreža (VNM) koje će poslužiti kao sistematsko rešenje. Biće prikazani primeri za kratkoročno (nekoliko sati unapred) jedno- i dvokoračno predviđanje potrošnje na nivou lokalne trafostanice.

### 1. UVOD


U inspirisanom radu [1] Prof. Mendel' tvrdi: "Predviđanje vremenskih nizova je savremen problem. Sve se češće susreću slučajevi u kojima je dužina uzorka  $N$  suviše mala da bi se dobila statistički pouzdana rešenja. Ovo je karakteristika više pojava koje susrećemo pri predviđanju u marketingu, politologiji, investiranju, planiranju i drugim poljima". On dalje tvrdi: "Statistička analiza sugerise da, da bi se pažljivo uzele u račun sve komponente, osnovni period za predviđanje treba da sadrži više stotina elemenata. Kada period ima samo nekoliko desetina elemenata, zadovoljavajući rezultati u predviđanju mogu se postići samo ako vremenski niz može da se razloži na svoje komponente: trend, periodičnu (sezonsku) i slučajnu komponentu. Štaviše, razvijeni modeli moraju imati ograničen broj parametara. Nizovi sastavljeni od trenda, sezonske i slučajne komponente, ponekad, mogu da se predvide i u slučaju da je osnovni period za predviđanje manji. Najzad, za osnovne periode predviđanja koji su manji od neke unapred određene vrednosti  $N_{min}$ , više ili manje zadovoljavajuća predviđanja zasnovana na postojećim osmatranjima ne mogu uopšte da se postignu i, saglasno tome, moraju da se traže dodatni podaci."

Među oblastima koje nisu pomenute u [1], a kod kojih ćemo raditi sa malim skupom podataka odnosno „osnovnim periodom predviđanja“, ovde ćemo posmatrati kratkoročno (na nekoliko sati) predviđanje potrošnje električne energije na nivou lokalne trafostanice. U stvari, obim raspoloživih podataka u ovom slučaju dovoljno je veliki da mogu da se primene i drugi metodi [2,3,4] ali posmatranjem zavisnosti potrošnje od vremena lako zaključujemo da udaljene pređašnje vrednosti nisu od velike pomoći pri kratkoročnom predviđanju. To čak važi i za potrošnju iz prethodnog dana i prethodne sedmice.


Kao ilustracija ove tvrdnje na Sl. 1 dajemo tri dijagrama koja predstavljaju potrošnju: a) u petak 31. januara 2009, b) u četvrtak 30. januara 2009. i c) u petak 24. januara 2009. Snaga je normalizovana sa 200 što predstavlja odnos transformacije u stanici. Može se uočiti sličnost opšteg toka triju krivih i značajne razlike u svim detaljima koji su važni za predviđanje. To potvrđuje izuzetni značaj najsvežijih podataka.

Saglasno tome, predlažemo da se problem rešava kao determinističko predviđanje zasnovano na kratkom, jednodnevnom nizu. Da bi se, međutim, na pogodan način pomogli, u osnovni period predviđanja uvodimo neke znatno starije vrednosti, a to su vrednosti potrošnje u trenutku predviđanja,

u prethodnoj sedmici istoga dana kada predviđamo. Ovo razmišljanje saglasno je sa postojećim iskustvom koje kaže da svaki dan u sedmici ima svoj opšti profil potrošnje [2]. Osnovna ideja se lakše razume ako se ima u vidu Sl. 2 gde pune tačke označavaju vrednosti iz prethodnih sedmica, a puna linija na kraju dijagrama predstavlja stvarne vrednosti koje se koriste za kreiranje vremenskog niza za predviđanje.



Slika 1. Srednje vrednosti potrošnje električne energije za tri različita dana



Slika 2. Podaci za kratkoročno predviđanje (Srednje vrednosti potrošnje na posmatranom mestu u januaru 2009. god.)

Polazeći od svega toga otvoren je projekt razvoja metoda zasnovanog na VNM koji će biti pogodan za sistematsku primenu u predviđanju determinističkih vremenskih nizova sa ograničenim nizom podataka. Ovaj metod je najpre bio primenjen za predviđanje ekoloških kao i tehnoloških podataka [5, 6]. Pri tome pri odlučivanju zašto baš VNM treba da se koriste za ovu primenu pošlo se od [5]. U ovim radovima date su osnovne ideje o konstrukciji VNM za predviđanje. Kasnije one su unapređene sa ciljem da se primene za predviđanje potrošnje električne energije [7].

Struktura rada je sledeća. Posle opšteg opisa problema biće dat kratak osvrt na primenu VNM za predviđanje. Zatim će biti opisan metod za predviđanje potrošnje električne energije. Primeri će se odnositi na predviđanje jedan i dva

koraka unapred pri čemu je, u ovom radu, jedan korak, u stvari, period od dva sata.


## 2. FORMULACIJA PROBLEMA I PREDVIĐANJE JEDAN KORAK UNAPRED

Vremenski niz je skup opservacija koje su uzete u uzastopnim vremenskim trenucima. Vremenski niz koji može precizno da se predvidi naziva se determinističkim. S druge strane vremenski niz čije se buduće vrednosti mogu samo delimično da predvide na osnovu ranije izmerenih vrednosti naziva se stohastički. Ovde će biti razmatrani samo deterministički nizovi.

Razmotrimo skalarni niz označen sa  $y_i, i=1,2, \dots, m$ . On predstavlja skup uzoraka nepoznate funkcije  $\hat{y} = \hat{f}(t)$ , koji su uzeti ekvidistantno na vremenskoj osi, razdvojeni jednakim vremenskim intervalima jednakim  $\Delta t$  tako da je  $t_{i+1} = t_i + \Delta t$ . Predviđanje jedan korak unapred predstavlja nalaženje takve funkcije  $f$  koja obavlja preslikavanje

$$(1) \quad y_{m+1} = f(t_{m+1}) = \hat{y}_{m+1} + \varepsilon,$$

gde je  $\hat{y}_{m+1}$  željeni odziv, sa prihvatljivom greškom  $\varepsilon$ .



Slika 3. Potpuno povezana nereкурентna VNM sa jednim skrivenim slojem i više izlaza

Bilo je više pokušaja da se reši ovaj problem. Među klasičnim metodama pomenućemo metod  $k$ -najbližeg suseda [8], po kome se vremenski niz pretražuje sa ciljem da se pronađe situacija koja je slična tekućoj kako bi se nastavilo na način kako su ranije događaji sledili. Drugim rečima, ovaj metod pretražuje periodičnost u nizu i pokušava da je iskoristi. S obzirom na ono što je rečeno o uticaju najsvežijih podataka na predviđanje on ne može da se smatra pogodnim metodom. Ipak, kako ćemo videti, osnovna ideja može korisno da se upotrebi.

U poslednjih nekoliko decenija VNM su postale tehnologija koja mnogo obećava u primenama za predviđanje kada su podaci teško obradivi postojećim metodama. Iscrpan pregled primene VNM za predviđanje dat je u [9]. Među većim brojem uspešnih primena ovde možemo pomenuti [10]. Zajedničko svojstvo postojećih metoda, međutim, jeste da zahtevaju duge vremenske nizove kako bi postale efikasne. Tipično, potrebno je najmanje 50 uzoraka [9]. To je posledica činjenice da sve pokušavaju da traže periodičnost u podacima koji su zadati. Postoje i primeri gde su obrađivani i veoma kratki nizovi [10]. U tim slučajevima da bi se dobila statistička procena odziva na osnovu determinističkih podataka, moralo je da se doda i nova usvojena informacija.


Imajući sve to na umu pošli smo u istraživanje topološke strukture VNM koja obećava uspešno predviđanje zasnovano na kratkom vremenskom nizu. U tom cilju, u daljem tekstu

ćemo, najpre, uvesti osnovnu strukturu nereкурентne VNM koja je korišćena u daljem radu.

Mreža je prikazana na Sl. 3. Ima samo jedan skriveni sloj što se pokazalo dovoljnim za ovakve primene [11]. Objašnjenja oznaka mogu se naći u [7]. Neuronu u ulaznom sloju jednostavno distribuiraju signale, a oni u skrivenom se aktiviraju sigmoidnom (logističkom) funkcijom. Najзад, izlazni neuroni se aktiviraju linearnom funkcijom. Korišćen je algoritam za obuku koji je zasnovan na metodi najbržeg spusta [12]. Od najvećeg je značaja odrediti broj skrivenih neurona  $m_h$ . Da bi se on odredio primenili smo postupak saglasan onom u [13].

U našem slučaju na raspolaganju stoji niz merenih vrednosti dobijenih na približno dva sata što znači da će VNM da ima samo jedan ulaz – diskretizovano vreme. Saglasno sa (1) predviđamo samo jednu vrednost što znači da će biti potreban samo jedan izlaz VNM. Vrednosti izraza su brojevi koji predstavljaju normalizovanu srednju potrošnju za period od dva sata. Da bi se problem numerički pojednostavio, vremenska promenljiva je transformisana tako što je oduzeto  $t_0$ , pa imamo

$$(2) \quad t = t^* - t_0.$$



Slika 4. Nereкурентna mreža prilagođena za predviđanje (FFAP)

Imajući u vidu da je  $t^*$  vreme (u minutima) tokom jednog dana, ova redukcija vremena dovodi nulu ( $t=0$  min) u trenutak  $t_0$  koji označava prvi uzorak.

Kada bi se primenila arhitektura sa Sl. 4, mreža bi učila sledeći niz:  $(t_i, f(t_i)), i=1, \dots, m$ .

Polazeći sa osnovnom strukturom sa Sl. 3, u [6] razmatrana su moguća rešenja i sugerisana je nova struktura koja bi bila najpogodnija za rešavanje problema kratkoročnog predviđanja zasnovanog na kratkim vremenskim nizovima. Ovde, međutim, imajući u vidu raspoloživost merenih podataka iz prethodnih sedmica, ova nova arhitektura biće proširena na pogodan način.

Struktura je nazvana FFAP od *feed forward accommodated for prediction*) i prikazana na Sl. 4. Ideja je bila da se prinudi VNM da uči isto preslikavanje više puta istovremeno ali pomeneno u vremenu. Na taj način, prepostavili smo, prethodne vrednosti odziva će imati veći uticaj na preslikavanje  $f(t)$ . I u ovoj strukturi postoji samo jedan ulazni priključak  $t_i$ .


Izlazni priključak  $Output_3$  ili priključak budućnosti, forsira se da uči da aproksimira  $y_{i+1}$ . U slučajevima kada planiramo predviđanje više koraka unapred,  $Output_3$  može da predstavlja vektor. Alternativno (kako je i učinjeno kasnije u ovom radu), kada predviđamo više koraka unapred,  $Output_3$  može da se posmatra i kao skalar koji se forsira da aproksimira  $y_{i+k}$ , gde je  $k$  broj koraka u budućnosti u odnosu na poslednji mereni uzorak čija je vrednost poznata unapred

odnosno u odnosu na sadašnju informaciju.  $Output_2$  treba da predstavlja sadašnju informaciju odnosno  $y_i$ . Najzad,  $Output_1$  treba da uči prošle vrednosti odnosno  $y_{i-1}$ . Opet, ako se želi da se preslikavanje kontroliše pomoću niza ranijih vrednosti  $Output_1$  može da se posmatra kao vektor.

Funkcionalnost FFAP mreže možemo da iskažemo kao

$$(3) \quad \{y_{i+k}, y_i, y_{i-1}, \dots, y_{i-q}\} = \mathbf{f}(t_i), \quad i=q+1, \dots, m,$$

gde je  $Output_1 = \{y_{i-1}, \dots, y_{i-q}\}$ , što znači treba da se uče jedan budući ( $k$ -koraka unapred), jedan sadašnji i  $q$  ranijih odziva.



Slika 5. EFFAP. Prošireni FFAP VNM ( $q=3$ )

Za primene u predviđanju potrošnje električne energije FFAP mrežu smo proširili tako što smo omogućili uticaj odziva iz datog dana ranijih sedmica za dato vreme dana. Na taj način ekstrapolacionu funkciju možemo da pišemo na sledeći način:

$$(4) \quad \{p_{n,i+k}, p_{n,i}, p_{n,i-1}, p_{n,i-2}, \dots, p_{n,i-q}\} = \mathbf{f}(t_i, p_{n-1,i+k}, p_{n-2,i+k}, p_{n-3,i+k}, p_{n-4,i+k}), \quad i=q, \dots, m.$$

Sada VNM uči buduću (nepoznatu) vrednost  $p_{n,i+k}$ , na osnovu stvarnog vremena  $t_i$ , sadašnje potrošnje  $p_{n,i}$ , vrednostima ranije potrošnje tokom datog dana u  $n$ -toj (sadašnjoj) sedmici  $p_{n,i-j}$ ,  $j=1,2,\dots,q$  i vrednostima potrošnje u budućem trenutku istog dana u prethodnim sedmicama  $p_{n-j,i+k}$ ,  $j=1,2,3,4$ . Smatralo se dovoljnim da se posmatraju samo četiri prethodne sedmice. Nova struktura VNM nazvana je extended feed forward accommodated for prediction (EFFAP). Ona je prikazana na Sl. 5.

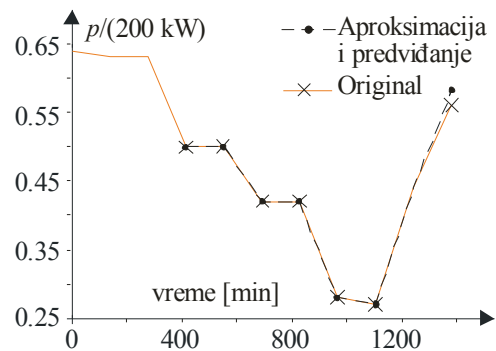
U narednom odeljku biće dat primer primene ove metode za predviđanje jedan korak unapred.

### 3. PRIMER PRIMENE PREDVIĐANJA JEDAN KORAK UNAPRED

Posle obuke EFFAP VNM i primene odgovarajuće pobude za predviđanje za četvrtak 30.01.2009. god. dobila se vrednost 0,581574. To je odstupanje od svega 3.85% od očekivane vrednosti 0,5. Pored toga EFFAP VNM odlično obavljala aproksimaciju što se može videti sa Sl. 6 gde ulazna kriva i aproksimacija se poklapaju u celom aproksimacionom intervalu  $t \in \{0, 1382\}$ . Ovaj rezultat bio je dobijen sa pet neurona u skrivenom sloju i sa  $q=3$ , upravo kako je pokazano na Sl. 5.

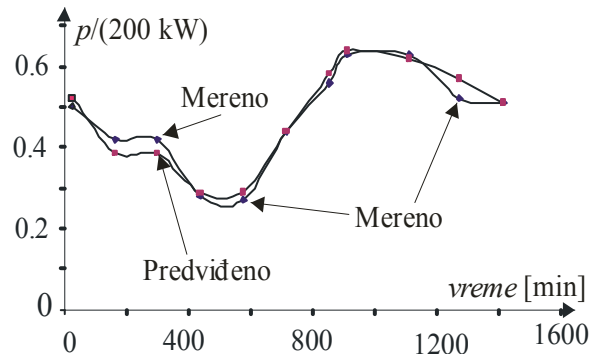
Imajući u vidu oblik krive za gornji primer predviđanja možemo da kažemo da je uspešan. Da bi proverili ponašanje metoda na većem broju primera, ponovili smo gore opisani

proces 11 puta pomerajući se u vremenu za jedan korak. Dobijeni rezultati su prikazani na Sl. 7. Sva predviđanja su dobijena sa VNM sa pet neurona u skrivenom sloju i za svaku od njih je u procesu obuke korišćeno isto početno rešenje.



Slika 6. Stvarna potrošnja (puna linija) i aproksimacija (isprekidana linija) dobijena sa EFFAP VNM. Poslednji segment isprekidane linije je predviđanje

Kao što se može videti sa Sl. 7, nisu sva predviđanja tako uspešna kao ono prikazano na Sl. 6. Ipak, većina ih je u okviru od samo 1% od očekivane vrednosti i samo dva su приметно udaljena od nje. Najveće odstupanje bilo je samo 9.38%.



Slika 7. Predviđene i stvarne vrednosti

### 4. PRIMENA NA DVOKORAČNO PREDVIĐANJE

Glavni cilj istraživanja u ovom projektu bio je da se razvije metod za predviđanje jedan korak unapred polazeći od ograničenog niza podataka. Mada je primena na dugoročnije predviđanje uvek izazov mi smo bili svesni da je teško verovati da se može predviđati u budućnost onoliko daleko koliki je raspoloživi osnovni period predviđanja. Zato ćemo u ovom odeljku opisati jedan rezultat predviđanja za dvostruko duži period od jednog koraka.

Po našem mišljenju moguća su dva pristupa predviđanju na duži vremenski period. Najpre, moguće je upotrebiti rezultate dobijene predviđanjem u trenutku  $t_{i+1}$ , dakle  $y_{i+1}$ , i proširiti osnovni skup predviđanja konkatencijom. Sa ovako proširenim skupom može početi postupak predviđanja za naredni korak  $t_{i+2}$ . Ova procedura može da se ponovi onoliko puta koliko se želi. Problem sa primenom ove ideje je da se greška u predviđanju vrednosti  $y_{i+1}$  ugrađuje u novo predviđanje i tako sve do kraja. Na samom kraju teško je imati poverenja u dobijeni rezultat. Primeri primene ove ideje mogu se naći u [14]. Bilo je eksplicitno uočeno da se greška akumulira.

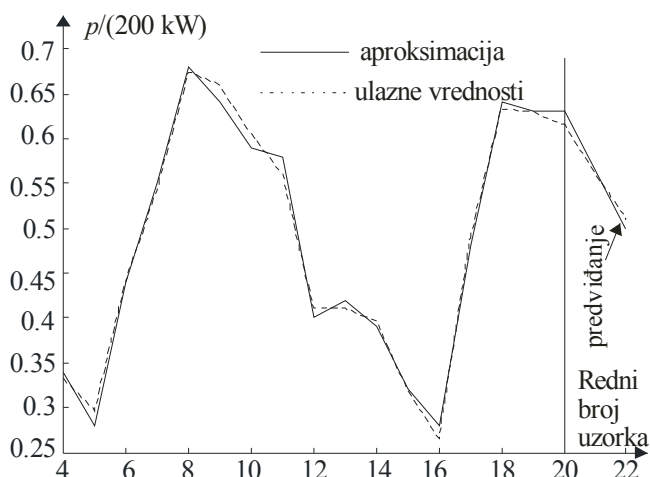
Alternativno, može se predviđati dva ili više koraka unapred direktno, preskačući međuvrednosti. Za te primene u (4) treba staviti  $k=2$  ili više i, naravno, kreirati podatke za odgovarajuću obuku VNM.

Pri razmatranju ovog metoda uočavamo da za jednokoračno predviđanje ( $k=1$ ) raspoložemo sa  $m$  uzoraka koji mogu da

se koriste za obuku i  $b=m-1-q$  "lekcija za obuku". S druge strane, kod višekoračnog predviđanja, broj lekcija za obuku postaje  $b=m-k-q$ . Ako broj intervala u budućnosti,  $k$ , raste,  $b$  se smanjuje. To odgovara skraćivanju osnovnog perioda predviđanja što u krajnjoj liniji ugrožava kvalitet predikcije.

Ovaj metod je proveravan na jednom primeru predviđanja potrošnje električne energije dva koraka (četiri sata) unapred. Dobijeni rezultat predviđanja prikazan je na Sl. 8. Preglednosti radi na ovoj slici vremenska osa je prikazana preko rednih brojeva uzoraka. Očekivana vrednost bila je 0,5, a predviđeno je da će biti 0,5094. Odstupanje je iznosilo samo 1.88% što je veoma ohrabrujući rezultat. Treba primetiti da je ekstrapolacija učinjena u tački u kojoj kriva menja znak prvog izvoda. Ovaj je rezultat dobijen, međutim, uz dodatne napore odnosno uz dodatnu složenost i potrebne strukture podataka i same VNM. Da bi se dobio broj uzoraka na krivoj iz prethodnog intervala koji je uzet za obuku bio je  $m=17$  što je dva puta više nego u slučaju jednokoračnog predviđanja mada su tada bile potrebne dve mreže da se dostigne isti vremenski trenutak. Pored toga broj skrivenih neurona je povećan na  $m_h=7$ , a upotrebljeno je  $q=4$ . Imajući to u vidu bilo je korišćeno  $b=17-2-4=11$  lekcija za obuku.

Ovaj rezultat smatramo početnim uspehom. Naša je namera da pronađemo parametre za sintezu VNM (broj uzoraka -  $m$ , broj vrednosti iz prošlosti -  $q$ , i broj skrivenih neurona -  $m_h$ ) tako da se omogući automatsko (u realnom vremenu) generisanje rešenja odmah posle trenutka kada su mereni rezultati raspoloživi što je bilo učinjeno sa jednokoračnim predviđanjem prikazanim na Sl. 7.



Slika 8. Aproximacija i dvokoračna ekstrapolacija sa EFFAP

#### 4. ZAKLJUČAK

Bio je razmotren problem predviđanja potrošnje električne energije na nivou transformatorske stanice odnosno na nivou predgrađa. Najpre je utvrđeno da i pored "periodičnosti" krive potrošnje, vrednosti potrošnje iz prethodnih dana i onih iz proteklih sedmica ali istoga dana, nisu pogodni za direktnu upotrebu. Zatim je predložena struktura VNM koja predstavlja potencijalno rešenje problema. Korišćeni su podaci o potrošnji iz datog dana i iz istog dana prethodnih sedmica na pogodan način. Dobijeni su ohrabrujući rezultati za jednokoračno (dva sata unapred) predviđanje. Pokazano je da je metod pogodan za upotrebu u sistemu za automatsko predviđanje u realnom vremenu. Pokušaj da se primeni isti metod na dvokoračno predviđanje je u eksperimentalnoj fazi sa izgledima za uspeh što je pokazano jednim primerom. Biće potrebno da se ulože dodatni naponi kako bi se pronašli parametri VNM koji obezbeđuju automatizaciju dvokoračnog predviđanja.

#### ZAHVALNOST

Rezultati prikazani u ovom radu ostvareni su u okviru projekta TR 11007. čiju je realizaciju finansira Ministarstvo nauke Republike Srbije.

#### 5. LITERATURA

- [1] A. S. Mandel', "Method of Analogs in Prediction of Short Time Series: An Expert-statistical Approach", Automation and Remote Control, Vol. 65, No. 4, April 2004, 634-641.
- [2] Murto P., „Neural Network Models for Short-Term Load Forecasting“. MS Thesis, Helsinki University of Technology, 1998.
- [3] Gross, G., F. D. Galiana, 1987, "Short-term load forecasting", Proceedings of the IEEE, Vol. 75, No. 12, December 1987, pp. 1558-1573.
- [4] Fausto Cavallaro, "Electric load analysis using an artificial neural network", Int. J. of Energy Research, Vol. 29, 2005, pp. 377-392
- [5] Milojković, J. i Litovski, V. B., "Novi postupci predviđanja za potrebe održivog razvoja", 51va Konf. ETRANA, Herceg Novi, Crna Gora, Juni 2007, Rad br. EL1.8.
- [6] Milojković, J. i Litovski, V. B., "Comparison of some ANN based forecasting methods implemented on short time series", 9th Symposium NEUREL-2008, Belgrade, Sept. 2008, pp. 175-178.
- [7] Milojković, J. and Litovski, V.B., „Dynamic Short-Term Forecasting Of Electricity Load Using Feed-Forward ANNs“, Int. J. of Eng. Intelligent Systems for Electrical Eng. and Communication, Vol. 17, No. 1, March 2009, pp. 38-48.
- [8] E.A. Plummer, "Time series forecasting with feed-forward neural networks: guidelines and limitations", M.S. Thesis, University of Wyoming, Laramie, July 2000.
- [9] Zhang, B.G., "Forecasting with artificial neural networks: The state of the art", Int. J. of Forecasting, Vol. 14, No. 1, March 1998, pp. 35-62
- [10] K. Brännäs and J. Hellström, "Forecasting based on Very Small Samples and Additional Non-Sample Information", Umeå Economic Studies 472, Umeå University, Sweden, 1998
- [11] T. Masters, "Practical Neural Network Recipes in C++", Academic Press, San Diego, 1993.
- [12] Zografski, Z., "A novel machine learning algorithm and its use in modeling and simulation of dynamical systems", in Proc. of 5<sup>th</sup> Annual European Computer Conference, COMPEURO '91, Hamburg, Germany, 1991, pp. 860-864.
- [13] E.B. Baum and D. Haussler, "What size net gives valid generalization", Neural Computing, 1989, Vol. 1, pp. 151-160.
- [14] Milojković, J., Litovski, V., „Short Term Forecasting in Electronics“, Int. J. of Electronics, ISSN 0020-7217, 2010, accepted.

**Abstract:** Short term prediction of electricity load is discussed. It will be shown here first that for the subject of short term prediction of electricity load, even though a large amount of data may be available, only the most recent of it may be of importance. That gives rise to prediction based on limited amount of data. We here propose implementation of feed-forward artificial neural network models for a potentially systematic solution of that problem as opposed to heuristics that are in use. Examples will be given related to short-term (hourly) one- and two-steps-ahead forecasting of the electricity load at suburban level.

#### NEW ANN MODELS FOR SHORT TERM FORECASTING OF ELECTRICITY LOADS

Jelena Milojković, and Vančo Litovski