

PREDVIĐANJE MESEČNE POTROŠNJE ELEKTRIČNE ENERGIJE NA NIVOU PRIGRADSKE TRAFOSTANICE

Jelena Milojković, ICNT, Niš, Srbija, jelena.milojkovic@icnt.rs,
Vančo Litovski, Elektronski fakultet u Nišu, Niš, Srbija, vanco.litovski@elfak.ni.ac.rs
Miljana Milić, Elektronski fakultet u Nišu, Niš, Srbija, miljana.milic@elfak.ni.ac.rs

Sadržaj – U ovom radu je predstavljeno predviđanje mesečne potrošnje električne energije na nivou trafostanice, zasnovano na kratkim vremenskim nizovima. Kao prvo, ovde će biti prikazano, da pri kratkoročnom predviđanju, iako nam je na raspolaganju veliki broj podataka, samo neki od njih mogu biti od interesa. To dovodi do predviđanja na osnovu ograničene količine podataka. Mi ovde predlažemo korišćenje veštačkih neuronskih mreža kao moguće sistematsko rešenje problema, kao suprotnost u odnosu na heurističke modele koji su u upotrebi. Predlažemo dve arhitekture VNM koje su nezavisno razvijene a čija se predviđanja uporedo koriste i usrednjavaju. Takođe, ovde je predstavljen i novi način izbora broja neurona u skrivenom sloju. Predviđanja su zasnovana na realnim podacima. Postignuta greška je manja od dva procenta što smatramo izuzetnim rezultatom.

Ključne reči: Predviđanje, električna energija, veštačke neuronske mreže

1. UVOD

U svom nadahnutom radu [1] profesor Mendel tvrdi: „Predviđanje kratkih vremenskih nizova predstavlja aktuelan problem. Slučajevi gde je dužina uzorka N suviše mala za dobijanje statistički pouzdanih varijanti, veoma su česti. Ova forma karakteristična je za mnoge važeće probleme kod predviđanja u marketingu, politikologiji, investicionom planiranju, i drugim oblastima.“ On dalje navodi: „Statistička analiza ukazuje da predviđanje osnovnog perioda treba da sadrži nekoliko stotina jedinica da bi se pažljivo uzele u obzir sve komponente. Za periode od nekoliko desetina jedinica, zadovoljavajuća predviđanja mogu se izvesti samo za vremenske nizove koji se mogu predstaviti kao zbir trendovskih, sezonskih i slučajnih komponenti. Sem toga, ovi modeli moraju imati veoma ograničen broj parametara. Nizovi koji se sastoje od zbira komponente trenda i slučajne komponente, ponekad se mogu predvideti i za manji osnovni period. Konačno, za osnovni period predviđanja manji od neke izračunate vrednosti N_{min} , više ili manje zadovoljavajuće predviđanje na osnovu posmatranja sasvim je nemoguće, i potrebni su dodatni podaci.“

Među oblastima koje nisu pomenute u [1], baveći se zaista malim skupom podataka ili „osnovnim periodom predviđanja“, ovde ćemo razmatrati mesečno kratkoročno predviđanje potrošnje električne energije na prigradskom nivou ili na nivou niskonaponske trafostanice. U stvari, količina raspoloživih podataka u ovom slučaju dovoljno je velika da se primeni bilo koji drugi način predviđanja [2,3,4], ali uzimajući u obzir dijagram opterećenja, odnosno vrednosti krive mesečne potrošnje, možemo lako prepoznati da prethodne vrednosti potrošnje električne energije nisu od

velike pomoći kada se radi o predviđanju. To važi čak i za podatke iz prethodnog meseca, a i za podatke iz istog meseca u prethodnoj godini. Shodno tome, predlažemo da se problem predviđanja vrednosti potrošnje u narednom mesecu predstavi kao determinističko predviđanje bazirano na vrlo kratkim vremenskim nizovima. Međutim da bi se na odgovarajući način potpomoglo predviđanje, uvodimo prošle vrednosti npr. potrošnju za isti mesec ali u prethodnoj godini. Ovo je u skladu sa postojećim iskustvom prema kome svaki mesec u godini ima svoj sopstveni profil opšte potrošnje [2].

Imajući sve to u vidu, započeli smo projekat razvijanja metode zasnovane na veštačkoj neuronskoj mreži (VNM) koja će biti pogodna za sistematsku primenu u predviđanju stacionarnih vremenskih nizova sa redukovanim skupom podataka. Naši prvi rezultati bili su primenjeni u predviđanju ekoloških i tehnoloških podataka i objavljeni su u [5, 6, 7]. Analiza o tome zašto se neuronske mreže primenjuju za predviđanje može se naći u [5]. Glavna ideja koja je realizovana bila je sledeća: ako neko želi da stvori neuronsku mrežu koja se može koristiti za predviđanje treba da omogući ovu osobinu tokom obuke za VNM. Pored toga, VNM koja se koristi mora da ima takvu strukturu da može da se prilagodi procesu obuke za predviđanje.

Nakon ovih razmatranja razvijene su nove arhitekture mreža za predviđanja. Naime, predviđanje je aktivnost koja se uvek odnosi na neizvesnost. Potrebno je da imamo najmanje dva rešenja da bi jedno podržalo drugo. Strukture koje su razvijene nazvane su Time Controlled Recurrent (TCR) (rekurentna mreža sa vremenskom kontrolom) i Feed Forward Accommodated for Prediction (FFAP) (nerekurentna mreža prilagođena za predviđanje). Obe su uspešno realizovane za predviđanje u savremenim kretanjima u mikroelektronici [7], kao i u drugim oblastima, uključujući predviđanje potrošnje na godišnjem nivou [8].

Cilj ovog rada je da ove nove metode postavi u širi kontekst implementacije VNM za kratkoročno predviđanje potrošnje električne energije na mesečnom nivou. Naime, kriva mesečne potrošnje na prigradskom nivou (trafostanica) zavisi od nekoliko faktora od kojih je najvažniji godišnje doba. Shodno tome, mreža treba da bude u stanju da približi dve krive istovremeno. Da bi se ovo zadovoljilo, nadgradili smo naše originalne TCR i FFAP VNM strukture kako bi se prilagodili za primenu u oblasti kratkoročnih predviđanja potrošnje električne energije na nivou dva sata. Dobijeni rezultati objavljeni su u [9] i [10], za ETCR i EFFAP, respektivno. Ove ideje će sada biti realizovane za mesečna predviđanja. Pored toga, ovde predlažemo metod usrednjavanja koji će koristiti oba predviđanja kako bi ublažio grešku u predviđanju i tako učinio konačan rezultat pouzdanim, koliko god je to moguće. Na kraju, predlažemo

metod za pronalaženje odgovarajućeg broja neurona u skrivenom sloju za obe mreže.

Struktura ovog rada je sledeća: nakon opštih definicija i navođenja problema, daćemo dati kratak osvrt u vezi sa primenom VNM u predviđanju. Potom ćemo opisati dva rešenja za moguće primene VNM usmerene na isto zadato predviđanje. Na kraju ćemo predstaviti ukratko razmatranje rezultata i ono što treba uzeti u obzir vezano za rad u budućnosti.

2. FORMULACIJA PROBLEMA I REŠENJA

Vremenski niz je skup uzoraka koji su uzeti u ravnomernim vremenskim razmacima. Vremenski niz koji može tačno da se predvidi nazivamo determinističkim. Vremenski niz čije se buduće vrednosti mogu samo delimično da odrede na osnovu prethodnih pri čemu se tačna vrednost ne može znati, nazivaju se stohastičkim. Mi ćemo ovde da razmatramo samo determinističke nizove.


Razmotrimo skalarni vremenski niz obeležen sa $y_i, i=1,2, \dots, m$. On predstavlja skup uzoraka nepoznate funkcije $\hat{y} = \hat{f}(t)$ koji su uzeti u jednakim vremenskim intervalima Δt tako da je $t_{i+1} = t_i + \Delta t$, gde je t vreme, a i brojač uzoraka. Predviđanje jedan korak unapred znači naći funkciju koja obavlja preslikavanje

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

gde je \hat{y}_{m+1} željeni odziv, a ε je prihvatljiva maksimalna greška.

Predviđanje vremenskog niza je sinonim za modeliranje osnovnog fizičkog ili društvenog procesa odgovornog za njegovo stvaranje. To čini razlog težine ovog zadatka. Bilo je mnogo pokušaja da se pronađe rešenje za ovaj problem. Među klasičnim determinističkim metodama možemo pomenuti k—najbližeg suseda [11], u kojoj se traži niz podataka za situacije slične onoj trenutnoj svaki put kada je potrebno da se napravi prognoza. Ovaj metod zahteva periodičnost da bi se koristio a to, kao što je već rečeno, ovde nije mnogo od pomoći.

U proteklih nekoliko decenija VNM su se pojavile kao tehnologija koja mnogo obećava u pogledu identifikovanja i modelovanja podataka koje nije lako uočiti tradicionalnim metodama.



Sl. 1. Potpuno povezana nerekurentna VNM sa jednim skrivenim slojem i više izlaznih priključaka

Sveobuhvatan pregled korišćenja VNM u predviđanju može se naći u [12]. Među mnogim uspešnim implementacijama možemo pomenuti [13]. Međutim, zajednička karakteristika postojećih primena je da one

zahtevaju relativno dug vremenski niz da bi bile delotvorne. Tipično, on ne bi trebalo da bude kraći od 50 jedinica podataka [12]. U slučaju koji razmatramo to znači najmanje pet godina unazad. Ovo je zbog činjenice da svi oni zahtevaju periodičnost korišćenih podataka. U našem slučaju, tretirani su veoma kratki vremenski nizovi [13]. Ovde je vremenskim nizovima dodata dopunska „neuzorkovana informacija“ kako bi se dobila statistička procena iz determinističkih podataka.

Zbog toga smo krenuli u potragu za topološkim strukturama VNM koje obećavaju predviđanje na osnovu kratkih vremenskih nizova. U daljem tekstu ćemo najpre, da uvedemo nerekurentnu VNM koja će kasnije da bude korišćena kao osnovna struktura za razvoj drugih koje ćemo koristiti za predviđanje.

Mreža je prikazana na Sl. 1. Ima samo jedan skriveni sloj što je dovoljno za ovu vrstu primena [14]. Indeksi: „in“, „h“, i „o“, na ovoj slici, označavaju ulazni, skriveni i izlazni sloj, respektivno. Za skup težina, $w(k, l)$, koje povezuju ulazni i skriveni sloj važi: $k=1,2, \dots, m_{in}, l=1,2, \dots, m_h$, a za one koje povezuju skriveni i izlazni sloj važi: $k=1,2, \dots, m_h, l=1,2, \dots, m_o$. Pragovi su obeleženi sa $\theta_{x,mr}, r=1,2, \dots, m_h$ ili m_o , pri čemu x stoji umesto „h“ ili „o“, zavisno od sloja. Neuroni u ulaznom sloju jednostavno distribuiraju signale, a oni u skrivenom sloju imaju sigmoidnu (logističku) aktivacionu funkciju. Najzad, neuroni u izlaznom sloju aktiviraju se linearnom funkcijom. Koristili smo algoritam obuke koji predstavlja modifikovanu verziju metode najbržeg spusta [15]. Broj neurona u skrivenom sloju, m_h , biće od ključnog značaja. Da bi ga odredili biće primenjena procedura data u [16], koja je u ovom radu dodatno razrađena.

Pri predviđanju vremenskih nizova, u našem slučaju, dat je takav skup uzoraka (približno svakih petnaest minuta) da je samo jedan ulazni signal vremenski diskretizovan [17]. Da bi dobili srednju mesečnu potrošnju mi smo izvršili usrednjavanje vrednosti za svaki mesec. Saglasno (1) predviđamo jednu vrednost za dati trenutak, što znači da imamo jedan izlaz, takođe. Vrednost izlaznog signala je broj, odnosno srednja snaga za period od jednog meseca. Da bi problem učinili matematički lakše obradivim obavili smo jednu jednostavnu transformaciju ulaznih i izlaznih podataka. Vreme je redukovano sa t_0 , tako da je:

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

Treba imati u vidu da se t^* odnosi na vremensku promenljivu (u mesecima), tako da je vrednost nula dodeljena prvom uzorku (t_0). Vrednosti izvornih uzoraka smo redukovali prema relaciji


$$y = y^* - M \quad (3)$$

gde y^* stoji umesto trenutne vrednosti tražene funkcije, a M je pogodno izabrana konstanta (ovde $M=596,8595$ i predstavlja srednju mesečnu potrošnju električne energije u toku jedne godine).

Kada bi se implementirala arhitektura prikazana na Sl. 1. (sa jednim ulazom i jednim izlazom), VNM bi bila obučavana da reprodukuje niz: $(t_i, f(t_i)), i=1,2, \dots$

Polazeći sa osnovnom strukturom prikazanom na Sl. 1 u [6] su istraživana moguća rešenja pa su predložene dve nove arhitekture kao najpogodnije za rešavanje problema predviđanja na osnovu kratkog osnovnog vremenskog

intervala. Ovde će, međutim, imajući u vidu dostupnost podataka koji se odnose na prethodnu godinu, ove arhitekture biti adekvatno prilagođene.




Sl. 2. a) Rekurentna VNM kontrolisana vremenom i b) ETCR. Proširena rekurentna VNM kontrolisana vremenom

Prva, *time controlled recurrent* (TCR), bila je inspirisana od tzv. “*time delayed recurrent*” VNM. To je rekurentna arhitektura sa vremenom kao ulaznom promenljivom koje kontroliše vrednost koju predviđamo. Naša namera bila je da imamo koristi od obe: koristimo osobinu generalizacije koju poseduju VNM i uspešnost rekurentne arhitekture. Njena struktura je prikazana na Sl. 2a. Sada proširujemo tu arhitekturu tako da omogućavamo vrednostima potrošnje električne energije, u datom trenutku dnevno, ali istog meseca prethodne godine, da kontrolišu izlaz.

Ovde ćemo dodati pojam „proširen“. Dobijena arhitektura prikazana je na Sl. 2b. Od sada pa nadalje nazivaćemo je Extended Time Controlled Recurrent (ETCR) arhitektura (proširena rekurentna arhitektura vremenski kontrolisana). Ovde u stvari, mreža uči skup podataka u kome je izlazna vrednost koja predstavlja prosečnu potrošnju električne energije za dati mesec u datoj godini, kontrolisana trenutnim vremenom i svojim sopstvenim prethodnim instancama:

$$p_{n,i} = f(t_i, p_{n,i-1}, p_{n,i-2}, p_{n,i-3}, p_{n-1,i}) \quad i = 1, 2, 3, \dots \quad (4)$$

Ovde n stoji za za broj datog meseca (u godini). Na taj način su vrednosti indeksirane sa n iz tekuće godine, dok je vrednost indeksirana sa $n-1$ iz prethodne godine. i se odnosi na i -ti uzorak u izabranoj godini. Stvarna vrednost $p_{n,i}$ je nepoznata i treba da se predvidi. Inkrementirajući i , u stvari, pomeramo prozor predviđanja za jedan korak unapred. Ove količine predstavljene su na Sl. 3. Ona predstavlja krivu opterećenja za dve godine. Treba obratiti pažnju da se x-osa svodi na prvi dostupni mesec dok je y-osa redukovana u odnosu na prosečnu mesečnu vrednost potrošnje.



Sl. 3. Usrednjena vrednost snage (redukovana sa 596,8595) u odnosu na vreme (meseci)

Druga struktura VNM nazvana je “*feed forward accommodated for prediction*” (FFAP) i prikazana na Sl. 4a. Ovde smo se vodili idejom da VNM treba da nauči više puta istu funkciju (na svakom od izlaza) ali sa vremenskim pomerajem. Na taj način, pretpostavili smo, prethodni odzivi mreže će imati veći uticaj na preslikavanje $f(t)$.

U ovoj arhitekturi VNM na ulazu imamo jednu promenljivu, u našem slučaju to je vremenska promenljiva t_i . Izlaz3, na kome se dobija tražena vrednost potrošnje, se u ovom slučaju forsira da aproksimira y_{i+1} . U slučajevima više koračnog predviđanja, Izlaz2 može biti viđen kao vector. Izlaz2 predstavlja trenutnu vrednost odnosno y_i , dok bi Izlaz1 trebalo da uči vrednost iz prošlosti, to jest y_{i-1} . Takođe, ako se želi da se na preslikavanje utiče sa više vrednosti iz prošlih trenutaka, Izlaz1 se može računati kao vector.

Kao jedan primer na kome se može videti funkcionalnost mreže je sledeći:

$$\{y_{i+1}, y_i, y_{i-1}, y_{i-2}\} = f(t_i), \quad i=3, 4, \dots \quad (5)$$


gde $Izlaz = \{y_{i+1}, y_i, y_{i-1}, y_{i-2}\}$, u stvari predstavlja: jednu buduću ($i+1$), jednu sadašnju (i), i dve prethodne ($i-1, i-2$) vrednosti koje mreža treba da nauči (Izlaz1 se vidi kao vector).

Naša iskustva tokom rada sa ovim dvema strukturama VNM su pokazala da FFAP daje bolje rezultate od TCR mreže. Ipak, primenom obe strukture dobijamo rezultate koje upoređujemo, pri čemu odabiramo predviđanje koje ima najviše smisla. Na taj način izbegavamo rešenje koje predstavlja lokalni minimum prilikom optimizacije procesa učenja veštačke neuronske mreže.

U našem slučaju predviđanja potrošnje struje na sat, proširili smo FFAP arhitekturu na indentičan način kao što smo proširili TCR. U tom slučaju, za aproksimaciju funkcije važi sledeće:

$$\{p_{n,i+1}, p_{n,i}, p_{n,i-1}, p_{n,i-2}\} = f(t_i, p_{n-1,i}) \quad i=1, 2, 3, \dots \quad (6)$$

Sada nova VNM uči buduću (nepoznatu) vrednost $p_{n,i+1}$, na osnovu stvarnog vremena t_i , sadašnje potrošnje $p_{n,i}$, vrednostima ranije potrošnje za datu godinu ($p_{n,i-k}, k=1, 2, 3$), i vrednostima ranije potrošnje za isti mesec ali prethodne godine ($p_{n-1,i}$). Nova struktura VNM nazvana je *extended feed forward accommodated for prediction* (EFFAP). Ona je prikazana na Sl. 4b.



Slika 4. a) Nerekurentna VNM prilagođena za predviđanje (FFAP), i b) Proširena nerekurentna VNM prilagođena za predviđanje (EFFAP) saglasno (6)

U narednoj proceduri opisaćemo implementaciju ETCR i EFFAP mreže. Ona se sastoji od sledećih koraka:

KORAK 1. Za dati mesec (i -ti mesec) napravljena je tabela za obuku za obe strukture VNM. Ove konstrukcije prikazane su na Tabeli I i Tabeli II, za ETCR i EFFAP mrežu, respektivno, za $i=18$.

KORAK 2. Obe mreže se u više navrata obučavaju sa istim podacima za obuku ali sa povećanom složenosti, odnosno sa povećanim brojem skrivenih neurona. Počinjemo sa $m_h=3$ i završavamo sa $m_h=10$. Izabrano je da broj neurona bude „mali“ jer problem koji se razmatra nije težak. Ne treba zaboraviti da će ETCR VNM, poput one prikazane na Sl. 2. koja ima 10 skrivenih neurona, imati 70 slobodnih parametara što je znatno iznad potrebe da se približi kriva prikazana na Sl. 3.

KORAK 3. Kako bi našli odgovarajući ETCR i EFFAP broj neurona, upoređujemo predviđene vrednosti. Naime, smatramo da je predviđanje poput koraka u tami, i da bi se dobilo autentično predviđanje, mislimo da su potrebna najmanje dva rešenja koja podržavaju jedno drugo (dobro poznato kao „drugo mišljenje“ u medicini). Na taj način biramo dva između osam ETCR i osam EFFAP rešenja (po jedno od svake vrste) koja su najbližnja.

KORAK 4. Pošto su upravo izabrana ETCR i EFFAP rešenja od iste važnosti, kao krajnji rezultat, usvajamo njihovu prosečnu vrednost.

KORAK 5. Zatim prelazimo na sledeći mesec.

3. PRIMER PRIMENE

Dijagram prikazan na Sl. 3. sačinjen je od UNITE takmičarskih podataka [17]. Pošto postoje podaci samo za dve godine, kreirali smo 24 instance kao što je prikazano na Sl. 3. Međutim, imajući na umu da naš metod zahteva vrednost potrošnje za isti mesec u prethodnoj godini, treba rezervisati prvih 12 instanci. Pored toga, da bi započeli predviđanje potrebne su nam neke vrednosti iz prethodnih meseci. Iz ovih razloga započeli smo predviđanje sa četvrtim delom podataka, to jest od 19-tog meseca.

Tabela 1 i Tabela 2 su primeri seta za obuku za prvo predviđanje. Ostali deo seta za obuku dobija se „klizanjem“ niz tabelu potrošnje kao funkcija datog meseca.

Od rezultata **KORAKA 3.** koji su opisani u prethodnom pasusu, napravljena je Tabela 3. Dok se njen sadržaj može sam po sebi objasniti, ovde ćemo ponovo naglasiti da su između predviđanja za dati mesec, tražena dva najbližnja. Tako, na primer, za dvadeset drugi mesec predviđanja ETCR VNM sa četiri skrivena neurona, i EFFAP VNM sa sedam skrivenih neurona, bila su dva najbližnja. Ova dva su bila odabrana i izračunat je prosek.

Tabela 1: Podaci za jedno učenje za ETCR

t_n	Ulazi				Izlazi
	$p_{n-1,i}$	$p_{n-2,i}$	$p_{n-3,i}$	$p_{n,i-1}$	$p_{n,i}$
13	88.9537	76.16484	23.58744	121.6963	88.54376
14	88.54376	88.9537	76.16484	99.9508	89.14276
15	89.14276	88.54376	88.9537	43.22303	73.22104
16	73.22104	89.14276	88.54376	18.00998	-34.8074
17	-34.8074	73.22104	89.14276	-85.0241	-69.965
18	-69.965	-34.8074	73.22104	-104.965	-89.8928
19	-89.8928	-69.965	-34.8074	-123.849	? = $p_{n,19}$

Tabela 2: Podaci za jedno učenje za EFFAP


t_i	Izlazi				
	$p_{n-1,i}$	$p_{n,i-2}$	$p_{n,i-1}$	$p_{n,i}$	$p_{n,i+1}$
12	121.6963	23.58744	76.16484	88.9537	88.54376
13	99.9508	76.16484	88.9537	88.54376	89.14276
14	43.22303	88.9537	88.54376	89.14276	73.22104
15	18.00998	88.54376	89.14276	73.22104	-34.8074
16	-85.0241	89.14276	73.22104	-34.8074	-69.965
17	-104.965	73.22104	-34.8074	-69.965	-89.8928
18	-123.849	?	?	?	? = $p_{n,19}$

Tabela 3: Najbližnja ETCR i EFFAP rešenja sa transformisanim ulaznim podacima

t_n	ETCR		EFFAP		Srednja vr. (p)	Očekivana vrednost
	m_h	p	m_h	p		
19	3	-95.5011	4	-83.9625	-89.7318	-86.6497
20	9	-94.309	3	-103.751	-99.03	-100.462
21	7	-85.2832	7	-33.3583	-59.3208	-60.1296
22	4	2.09448	7	17.3844	9.73944	20.94362
23	4	87.2713	7	84.9242	86.097	83.82734
24	4	100.231	3	122.701	111.466	120.2991

Tabela 4: Najbližnja ETCR i EFFAP rešenja sa originalnim ulaznim podacima

t_n	ETCR		EFFAP		Srednja vr. (p)	Očekivana vrednost
	m_h	p	m_h	p		
19	3	501,358	4	512,897	507,128	510,2098
20	9	502,551	3	493,109	497,830	496,3975
21	7	511,576	7	563,501	537,539	536,7299
22	4	598,954	7	614,244	606,600	617,8031
23	4	684,131	7	681,784	682,957	680,6868
24	4	697,091	3	719,561	708,326	717,1586




Sl. 5. Vizuelizacija poslednje dve kolone u Tabeli IV

Da bi se dovršilo predviđanje, trebalo je obnoviti vrednosti koje je proizvela redukcija (3). Ovo je praktično značilo da su sve stavke iz Tabele 3 trebalo da budu inkrementirane za 596,8595. Na taj način je kreirana Tabela 4. Slika 5. prikazuje poslednje dve kolone Tabele 4. Naime, očekivane i predviđene vrednosti prikazane su zajedno.

Tabela 5: Greška predviđanja

t_n	Error (%) ECTR	Error (%) EFFAP	Error (%) Average
19	1,735	-0,5267	0,604
20	-1,240	0,6625	-0,289
21	4,687	-4,988	-0,151
22	3,051	0,576	1,813
23	-0,506	-0,161	-0,334
24	2,798	-0,335	1,232



Sl. 6. Greška predviđanja (u %) za ECTR, EFFAP i srednja vrednost (Grafičko objašnjenje Tabele V)

Na kraju, da bismo dobili još bolji uvid u rezultate, izračunali smo grešku predviđanja i prikazana je u Tabeli V. Kao što se može videti greška prosečne vrednosti u odnosu na onu očekivanu, manja je od 2% u svih šest slučajeva. Grafički prikaz Tabele 5 dat je na slici 6.

Zanimljivo je napomenuti da su greške predviđanja ECTR i EFFAP VNM mnogo veće (manje od 6%). To znači da najgore predviđanje nikada neće preći ovu vrednost. U našem slučaju, izračunavanje proseka je dovelo do izuzetno dobrog rezultata.

6. ZAKLJUČAK

Predstavljeno je predviđanje prosečne potrošnje električne energije jedne prigradske trafostanice, na mesečnom nivou, na osnovu kratkih vremenskih nizova. Najpre smo pokazali

da kod kratkoročnog predviđanja potrošnje električne energije, čak i kada je na raspolaganju velika količina podataka, samo oni podaci koji su najnoviji mogu biti od značaja. Ovo daje povoda za predviđanje na osnovu ograničene količine podataka. Ovde smo predložili implementaciju nekih arhitektura veštačkih neuronskih mreža kao potencijalnog sistemskog rešenja tog problema, za razliku od heurističkih koje su u upotrebi. Da bi se dodatno podigla zavisnost predviđenih podataka, predložili smo izračunavanje proseka dva nezavisna predviđanja. Sproveden je poseban pristup u biranju broja skrivenih neurona. Prikazali smo primer u vezi sa mesečnim predviđanjem potrošnje električne energije na prigradskom nivou. Predviđanje je izvršeno na realnim podacima uzetim iz literature. Dobili smo greške predviđanja koje su manje od dva posto.

ZAHVALNOST

Ova su istraživanja delimično finansirana od strane Ministarstva Prosvete, nauke i tehnološkog razvoja Republike Srbije po ugovoru br. TR32004

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, pp. 634-641.
- [2] P., Murto, "Neural Network Models for Short -Term Load Fore-casting", M S Thesis, Helsinki University of Technology, 1998.
- [3] F., Cavallaro, "Electric load analysis using an artificial neural network", Int. J. of Energy Research, Vo l. 29, 2005, pp. 377-392.
- [4] H., Hahn, S., Meyer-Nieberg, and S., Pickl, "Electric load fore-casting methods: Tools for decision making", European J. of Operational Research, Elsevier, Vol. 199, 2009, pp. 902-907.
- [5] J. Milojković, V. B. Litovski, "New methods of prediction implemented for sustainable development", Proc. of the 51th Conf. ETRAN, Herceg Novi, Monte Negro, June 2007, Paper no. EL1.8 (in Serbian).
- [6] J. Milojković, V. B. Litovski, "Comparison of some ANN based forecasting methods implemented on short time series", Proc. of the 9th Symp. NEUREL-2008, Belgrade, ISBN 978-1- 4244-2903-5, Sept. 2008, pp. 175-178.
- [7] J. Milojković, V. B. Litovski, "Short term forecasting in Electronics", Int. J. of Electronics, Vol. 98, No. 2, 2011, pp. 161-172.
- [8] J. Milojković, V. B. Litovski, O., Nieto-Taladriz, and S., Bojanić, "Forecasting Based on Short Time Series Using ANNs and Grey Theory – Some Basic Comparisons", In Proc. of the 11th Int. Work-Conf. on Artificial Neural Networks, IWANN 2011, June 2011, Torremolinos-Málaga (Spain). J. Cabestany, I. Rojas, and G. Joya (Eds.): Part I, LNCS 6691, pp. 183-190, 2011, © Springer-Verlag, Berlin, Heidelberg.
- [9] J. Milojković, V. B. Litovski, „Dynamic Short-Term Fore-casting Of Electricity Load Using Feed-Forward

- ANNs", Int. J. of Engineering Intelligent Systems for Electrical Engineering and Communication, Vol. 17, No. 1, March 2009, pp. 38-48.
- [10] J. Milojković, V. B. Litovski, "Short-term Forecasting of Electricity Load Using Recurrent ANNs", "Electronics", ISSN: 1450-5843, Vol. 14, No. 1, June 2010, pp. 45-49.
- [11] E.A., Plummer, "Time series forecasting with feed-forward neural networks: guidelines and limitations", M.S. Thesis, University of Wyoming, Laramie, USA, July 2000.
- [12] B.G., Zhang, "Forecasting with artificial neural networks: The state of the art", Int. J. of Forecasting, Vol. 14, No. 1, March 1998, pp. 35-62
- [13] K., Brännäs, and J., Hellström, "Forecasting based on Very Small Samples and Additional Non-Sample Information", Umeå Economic Studies 472, Umeå University, Sweden, 1998
- [14] T., Masters, "Practical Neural Network Recipes in C++", Academic Press, San Diego, 1993.
- [15] Z., Zografski, "A novel machine learning algorithm and its use in modeling and simulation of dynamical systems", in Proc. of 5th Annual European Computer Conf., COMPEURO '91, Hamburg, Germany, 1991, pp. 860-864.
- [16] E.B., Baum, and D., Haussler, "What size net gives valid generalization", Neural Computing, 1989, Vol. 1, pp. 151-160.
- [17] World-wide competition within the EUNITE network, 2001, <http://neuron.tuke.sk/competition>.

***Abstract**— One month ahead prediction of suburban average electricity load, based on short time series, is presented. 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 some instances of architectures of artificial neural networks as potential systematic solution of that problem as opposed to heuristics that are in use. To further rise the dependability of the predicted data averaging of two independent predictions is proposed. A specific approach to the choice of the number of hidden neurons will be implemented. Example will be given related to monthly forecasting of the electricity load at suburban level. Prediction is carried out on real data taken from the literature. Prediction errors lower than two percent were obtained.*

ONE MONTH AHEAD PREDICTION OF SUBURBAN AVERAGE ELECTRICITY LOAD

Jelena Milojković, Vančo Litovski, Miljana Milić