

Rad po pozivu

PREDVIĐANJE MAKSIMUMA DNEVNE POTROŠNJE ELEKTRIČNE ENERGIJE POMOĆU VEŠTAČKIH NEURONSKIH MREŽA

Jelena Milojković, ICNT, Niš, Srbija, jelena.milojkovic@icnt.rs,
Vančo Litovski, NiKNT, Niš, Srbija, vanco@elfak.ni.ac.rs

Sadržaj – U ovom radu je predstavljen metod predviđanja maksimuma dnevne potrošnje električne energije jedan dan unapred. Metod koji je primenjen zasnovan je na primeni veštačkih neuronskih mreža. Koriste se dve vrste arhitektura neuronskih mreža za predviđanje prosečne vrednosti vršne potrošnje. Glavni napredak u odnosu na ranije primere je da je set ulaznih podataka pogodno prilagođen oslanjajući se na podatke iz prethodnog perioda čime se postiže veći procenat tačnosti prilikom predviđanja. U ovom radu se potvrđuje izvodljivost metode na datim primerima što nas upućuje na dalja istraživanja.

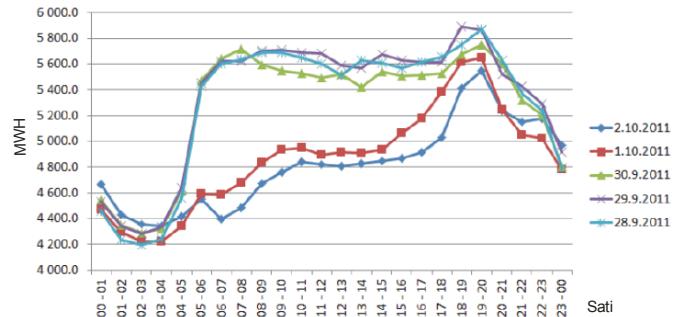
Ključne reči: predviđanje, maksimalna električna potrošnja, neuronske mreže

1. UVOD

Potreba da se predviđi potrošnja električne energije je danas prepoznata u velikoj meri. Predviđanje potrošnje pomaže da se isporučiocu i proizvođaču odluče o angažovanju proizvodnih jedinica, da redukuju kapacitete koji služe kao aktivna rezerva i da pravilno planiraju održavanje podsistema. Kao što je rečeno u [1] posebna potreba za što tačnijim predviđanjem se uočava u slučajevima kada nastaju periodi neprimerene vršne potrošnje.

Period na kome se predviđa potrošnja električne energije može da obuhvata od nekoliko desetina minuta do više godina. Na taj način prepoznajemo predviđanje na veoma kratkom roku (nivo nekoliko desetina minuta), predviđanje na sat ili nekoliko sati, na dan, na sedmicu, na mesec i na godinu odnosno više godina. Ovaj rad bavi se predviđanjem vršne vrednosti potrošnje jedan dan unapred. Razmatranja će ovde biti zasnovana na dvema grupama naših radova. U prvoj grupi su radovi u kojima smo po prvi put opisali naše metode predviđanja na kratak rok [2,3,4], a u drugoj su radovi koji se odnose baš na predviđanje vršne vrednosti potrošnje električne energije za sutrašnji dan na nivou predgrađa [5,6]. Ovde će biti prikazani naši najnoviji rezultati u ovoj oblasti koji se odnose na verifikaciju već opisanih metoda kao i na njihovu optimizaciju. Podaci koji će biti korišćeni za verifikaciju algoritma biće uzeti iz "1999 UNITE competition" [7].

Da bi se stekla predstava o svojstvima problema koji posmatramo na Sl. 1 prikazana su pet profila potrošnje za jedan finski grad na kraju septembra i početku oktobra 2011. god. Lako je uočiti da je vreme nastajanja maksimalne potrošnje u ranim večernjim časovima nezavisno od toga da li se radi o radnom danu ili o vikendu. Izuzeći od ovog pravila nastaju kada se u prepodnevnim časovima, za vreme prazničnih dana, dešavaju neke značajne manifestacije pa je porodica na okupu.



Sl. 1. Potrošnja u jednom finskom gradu u pet uzastopnih dana počevši od srede završavajući sa nedeljom

Naš metod polazi od nekoliko pretpostavki. Najpre, mi smatramo da najveći uticaj na buduću vrednost imaju vrednosti iz neposredne prošlosti. One sadrže najsvežiju informaciju o trendu, periodičnosti i o vremenskim prilikama. Zatim, mi verujemo da ako se namerava da se generiše kvalitetno predviđanje na osnovu koga mogu da se preduzimaju ozbiljni koraci, ne treba da se predviđa više koraka unapred. Najviše što možemo da priuštimo je jedan ili dva koraka. Zato naše vremenske nizove ovde posmatramo kao determinističku pojavu i primenjujemo jednokoračno predviđanje. Da bi pomogli predviđanje, međutim, potrebno je da se ugradi i svojstvo periodičnosti i zato podatke iz prošlosti grupišemo u dve kategorije: na one iz dana neposredno pre predviđanja i na one prethodne koji se ponavljaju sa periodom od 7 dana. Ovo se slaže sa postojećim iskustvima koja govore o tome da svaki dan u nedelji ima svoj specifični profil potrošnje [8].

U velikom broju postupaka predviđanja potrošnje električne energije kao osnova koriste se i podaci o vremenskim prilikama odnosno o temperaturi. Mi imamo specifično mišljenje o upotrebi podataka o vremenskim prilikama. Najpre, kao što je pokazano eksperimentima u [9] nije lako uspostaviti značajnu korelaciju između parametara vremenskih prilika i maksimalne dnevne potrošnje. Drugo, ne postoji raspoloživi podaci o temperaturi baš za trenutak kada nastaje maksimalna potrošnja odnosno, trenutak nastajanja maksimalne potrošnje nije unapred poznat i varira kao što se vidi sa Sl. 1. Temperaturu možemo predviđati posebnim postupkom pre nego što pristupimo predviđanju potrošnje ali će to predviđanje da nosi grešku čija veličina nam nije poznata. Najzad, a veoma važno, poznate vrednosti potrošnje iz neposredne prošlosti u sebi implicitno sadrže informaciju o vremenskim prilikama prethodnih dana i njihova upotreba će svakako preslikati međusobnu zavisnost temperature i potrošnje ako ona uopšte i postoji.

Problem predviđanja maksimalne dnevne potrošnje razmatran je u literaturi više puta [10,11,12]. Lako je ustanoviti, međutim, da se publikovane metode bave stohastičkim procesima sa ciljem da predvide trend i devijaciju, a ne tačnu vrednost.

Jedan od pristupa rešavanju problema predviđanja potrošnje električne energije jeste upotreba veštačkih neuronskih mreža (VNM) [13,14]. Glavna prednost ovog pristupa leži u činjenici da su VNM univerzalni aproksimatori i da se njihovom upotrebom rešava glavni problem nelinearne regresije: izbor aproksimacione funkcije. Zajedničko svojstvo objavljenih metoda, međutim, jeste potreba za velikim vremenskim nizovima. Obično najkraći niz ne sme imati manje od 50 članova [15].

Polazeći od ovih razmatranja u [2,3,4] razvili smo nove arhitekture VNM koje su pogodne za predviđanje. Naime, predviđanje je aktivnost koja je uvek povezana sa stepenom neizvesnosti. Da bi moglo da se kreira iole prihvatljivo rešenje potrebno je da se generišu bar dva predviđanja koja podržavaju jedno drugo. Razvijene strukture VNM nazvane su "Time Controlled Recurrent" (TCR) i "Feed Forward Accommodated for Prediction" (FFAP). Obe su bile uspešno primenjene za predviđanje u modernoj mikroelektronici [2] kao i u drugim oblastima kao što su predviđanje potrošnje električne energije na nivou sata [3,4] i na nivou godine [15].

Ovdje će biti prikazana priširenja pomenutih VNM koja, po našem mišljenju, omogućavaju predviđanje vršne vrednosti. To su "Extended TCR" (ETCR) i "Extended FFAP" (EFFAP).

U ovom radu biće ponovo posećeni rezultati koji su saopšteni u [5]. Naime, radi potvrde uspešnosti metoda, predviđanje će biti obavljeno na znatno većem uzorku nego u [5]. Pored toga, biće sproveden eksperiment kako bi se ustanovio uticaj podataka iz prethodnih sedmica i na osnovu toga definisao skup ulaznih podataka za obuku VNM.

Struktura članka je sledeća. Posle navođenja opštih definicija i postavke problema biće dat kratak opis rešenja koje nudimo. Zatim će biti prikazani eksperimentalni podaci koje smo dobili primenom ovog metoda što će omogućiti da se postave neki značajni zaključci.

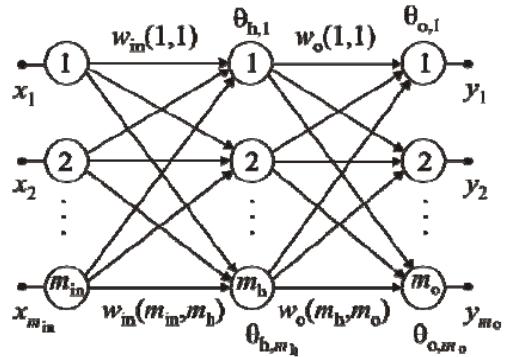
2. FORMULACIJA PROBLEMA

Vremenski niz je skup uzoraka koji su uzeti u ravnometrim 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.



Sl. 2. Potpuno povezana nerekurentna VNM sa jednim skrivenim slojem i više izlaznih priključaka

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.

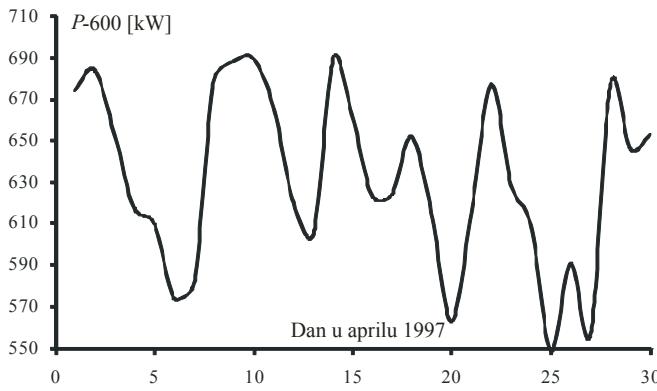
Mreža je prikazana na Sl. 2. Ima samo jedan skriveni sloj što je dovoljno za ovu vrstu primena [16]. Indeksi: "in", "h", i "o", na ovoj slici, označavaju ulazni, skriveni i izlazni sloj, respektivno. Za skup težina, $w(k, l)$, koje povezuju ulazni i skriveni sloj važi: $k=1,2, \dots, m_{\text{in}}$, $l=1,2, \dots, m_h$, 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 θ_{x_r, \square_r} , $r=1,2, \dots, m_h$ 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 linearom funkcijom. Koristili smo algoritam obuke koji predstavlja modifikovanu verziju metode najbržeg spusta [17]. Broj neurona u skrivenom sloju, m_h , biće od ključnog značaja. Da bi ga odredili u svakom od 90 primera koji će kasnije biti naveđeni biće primenjivana procedura data u [16], a koja se sastoji u postepenom povećanju ovog broja dok se ne dostigne prihvatljiv rezultat. U našem slučaju, umesto toga, iz razloga koji će biti jasniji kasnije, m_h smo povećavali od 3 do 10.

Pri predviđanju vremenskih nizova, u našem slučaju, skup uzoraka je ekstrahovan (jedna dnevna vršna vrednost) iz petnaestominutnih datih u UNITE 1997 datoteci. Saglasno sa (1) mi predviđamo jedan korak unapred odnosno sutrašnju vrednost maksimalne dnevne potrošnje na nivou predgrađa. Da bi problem učinili matematički lakše obradivim obavili smo jednu jednostavnu transformaciju ulaznih podataka. Naime, vrednosti izvornih uzoraka smo redukovali prema relaciji

$$y = y^* - M \quad (2)$$

gde y^* stoji umesto merenih vrednosti (UNITE 1997), a M je pogodno izabrana konstanta (ovde $M=600$ kW).

Napomenimo da kada bi koristili arhitekturu VNM koja je prikazana na Sl. 2 (sa jednim ulazom i jednim izlazom), VNM bi bila obučavana da reprodukuje niz: $(t_i, f(t_i))$, $i=1,2, \dots$



Sl. 3. Maksimalna dnevna potrošnja za prethodni mesec

Radi sagledavanja složenosti problema predviđanja koji razmatramo, na Sl. 3 prikazan je tok krive vršnih vrednosti potrošnje za trideset dana u aprilu 1997. Kao što se vidi, nije lako da se prepozna četiri sedmice u mesecu s obzirom da u dvema sedmicama možemo da uočimo minimume krive što znači da iz nekog razloga u tim sedmicama srednji dani su imali manju potrošnju od uobičajene. Time je narušena periodičnost i otežan proces predviđanja.

3. ETCR METODA

Polazeći sa osnovnom strukturu prikazanom na Sl. 2 u [2,3,4] istraživana su moguća rešenja pa su predložene dve nove arhitekture kao najpogodnije za rešavanje problema predviđanja na osnovu kratkog osnovnog vremenskog intervala.

Prvi, nazvan "extended time controlled recurrent" (ETCR) bio je inspirisan od tzv. "time delayed recurrent" VNM. To je rekurentna arhitektura sa vremenom kao ulaznom promenljivom koje kontroliše vrednost koju predviđamo. Njena struktura je prikazana na Sl. 4. Na ovoj slici i označava brojač uzoraka i u stvari predstavlja vremensku promenljivu odnosno redni broj dana. y_i je dnevna vršna vrednost. Karakteristično za naše rešenje je da ova mreža u suštini uči dve krive. Prva od njih je iskazana skupom tačaka iz neposredne prošlosti koje su na Sl. 4 grafički prikazane u unutrašnjoj povratnoj petlji. Ovde je rastojanje između uzoraka jedan dan. Druga kriva se odnosi na skup uzoraka koji su razdvojeni vremenskim intervalom od jedne sedmice i na Sl. 4 su grafički prikazane spoljnom petljom povratne sprege. Analitički bi se obe funkcije sakupile u jednu kao

$$y_i = f(i, y_{i-1}, y_{i-2}, y_{i-3}, y_{i-4}, y_{i-7}, y_{i-14}), \quad i=8,9,\dots \quad (3)$$

U [5,6] su korišćena samo dva uzorka iz prethodnih sedmica što je ilustrovano sa (3) i sa Sl. 4. Za ovaj slučaj obuka ETCR VNM bi se obavljala na osnovu skupa podataka kakav je prikazan u Tabeli 1 što će biti predmet dalje detaljnije rasprave.

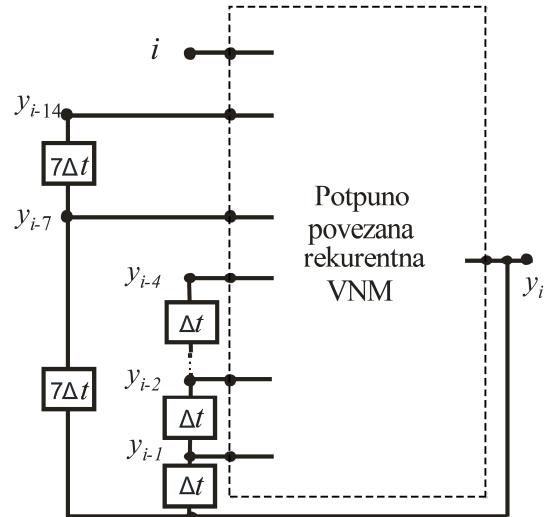
Saglasno (3) kada se pripremaju podaci za obuku ETCR VNM kreiraju se skupovi vektora (vrste u Tabeli 1) tako što se ekstrahuju iz početnog niza (koji je kao na Sl. 3). Pri tome se koristi tzv. tehnika slična rekonstrukciji vremenskih nizova koja se oslanja na teoremu o ugradnji iskazanoj u [17,18]. i -ti ulazni vektor za obuku bio bi:

$$\mathbf{x}_i = \{i, y_{i-1}, y_{i-2}, y_{i-3}, y_{i-4}, y_{i-7}, y_{i-14}\},$$

a odgovarajući izlazni vektor za obuku bio bi

$$\mathbf{z}_i = \{y_i\}.$$

U našim razmatranjima je $i \in \{8,28\}$. Naime, korišćene su 21 lekcija za obuku. Kompletni podaci za obuku dati su u Tabeli 1.



Sl. 4. "Proširena rekurentna mreža sa vremenskom kontrolom" (ETCR)

Tabela 1. Podaci za obuku ETCR VNM za 30.04.1997. god.

i	y^{i-1}	y^{i-2}	y^{i-3}	y^{i-4}	\dots	y^{i-7}	y^{i-14}	y^i
8	84	74	82	13		103	167	53
9	53	84	74	82		97	140	17
10	17	53	84	74		51	137	10
11	10	17	53	84		13	76	-26
12	-26	10	17	53		82	135	-19
13	-19	-26	10	17		74	21	79
14	79	-19	-26	10		84	94	88
15	88	79	-19	-26		53	103	89
16	89	88	79	-19		17	97	66
17	66	89	88	79		10	51	20
18	20	66	89	88		-26	13	05
19	05	20	66	89		-19	82	89
20	89	05	20	66		79	74	63
21	63	89	05	20		88	84	24
22	24	63	89	05		89	53	24
23	24	24	63	89		66	17	52
24	52	24	24	63		20	10	15
25	15	52	24	24		05	-26	-37
26	-37	15	52	24		89	-19	15
27	15	-37	15	52		63	79	77
28	77	15	-37	15		24	88	29
29	29	77	15	-37		24	89	

Zadatak koji je bio postavljen u ovom primeru bio je da se predviđi vrednost maksimalne potrošnje dana 30.04.1997. god. Ta vrednost prema literaturi [5] bila je 609 kW. Posle sprovođenja kompletног procesa projektovanja i obuke ETCR VNM nastala je mreža sa 7 ulaznih, jednim izlaznim i 5 skrivenih neurona. Kada je ta mreža bila pobudena odgovarajućom pobudom, dobio se rezultat $y_{29}=\{625,3241\}$. Relativno odstupanje u odnosu na željenu vrednost bilo je $a_{29}=2,68\%$. Odličan rezultat ali ne treba zaboraviti da prilikom predviđanja, u realnoj situaciji, nama željena

vrednost nije poznata, a time i dobrota rezultata koji smo dobili.

Sumirajući primer, da bi stekli predstavu o istraživanjima koja treba da se obavljuju, ovde ćemo ustanoviti spisak parametara koji treba da se postave unapred kako bi postupak predviđanja postao stabilan, ponovljiv i pouzdan. Postoje dva međusobno spregnuta domena koji treba da se parametrizuju: domen podataka i domen strukture VNM. U domenu podataka najpre je potrebno je da definišemo broj neposredno prošlih podataka koje ćemo da uvrstimo u vektor \mathbf{x} . Ovu veličinu ćemo obeležiti sa q . Zatim, odredićemo ukupni broj uzoraka iz neposredne prošlosti koji ćemo koristiti, p . Saglasno tome broj lekcija će biti $p+q$. Pri tome, svaki vektor nastaje prostim pomeranjem prozora od q uzoraka za jedno mesto ka budućnosti. Kao što vidimo iz Tabele 1, u našem primeru $q=4$ i $p=25$ (niz počinje sa $i=4$ i završava sa $i=28$). Dalje, pošto želimo da koristimo i podatke od istog dana iz prethodnih sedmica, vektor \mathbf{x} kompletiramo sa dodatnih s elemenata ali tako da je $s+q+1=7$. Dakle u gornjem primeru $s=2$. U slučajevima kada povećavamo broj sedmica iz kojih ćemo uzimati podatke za formiranje \mathbf{x} , s će rasti, ukupni broj ulaznih priključaka će biti uvećan tako da će ukupni broj ulaznih priključaka VNM biti $q+s+1$. Sve u svemu, sa stanovišta podataka potrebno je odrediti tri parametra: s , p i q . Vrednosti poslednja dva broja (p i q) odredili smo heuristički ranije u okviru istraživanja koja su opisana u [2,3,4], vrednost s je predmet istraživanja u ovom radu i biće eksperimentalno određena. Kada se imaju ova tri broja, možemo da kažemo da je broj ulaznih i izlaznih priključaka VNM određen strukturon podataka. Ostaje da se odredi samo još četvrti parametar: broj neurona u skrivenom sloju, m_h . Kao što je gore pomenuto, u slučajevima kada se VNM koristi za aproksimaciju njegova vrednost određuje se tako što se krene sa minimalnom vrednosti (kod nas je to bila $m_h \min=3$, i povećava se za jedan sve dok se ne dobije prihvatljiva aproksimacija odnosno sve dok se ne dobije novo rešenje lošije od prethodnog. U našem slučaju, međutim, još uvek ne postoji kriterijum za odlučivanje koje je rešenje dobro pa smo mi povećavali m_h do 10. Dobijena rešenja bila su zapamćena sve dok nije dobijen još jedan takav niz ali generisan drugom metodom.

4. EFFAP METODA

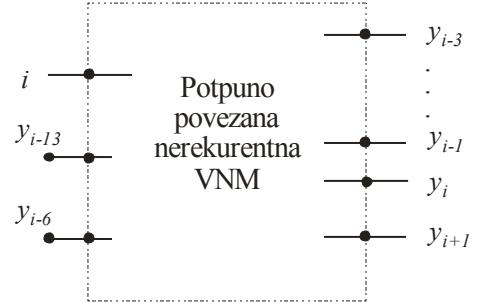
Druga struktura VNM nazvana je "extended feed forward accommodated for prediction"(FFAP) i prikazana na Sl. 5. Koristi se identična notacija kao na Sl. 4. ovde smo se vodili idejom da VNM treba da nauči više puta istu funkciju (na svakom od izlaza) ali sa vremenskim pomerajem. Na taj način, prepostavili smo, prethodni odzivi mreže će imati veći uticaj na preslokavanje $f(t)$. Treba primetiti da se sada uči i y_{i+1} tako da je, u ovom slučaju, celokupni niz pomeren za jedno mesto prema budućnosti.

Imajući u vidu Sl. 5, za analitički izraz preslikavanja možemo da pišemo

$$\{y_{i+1}, y_i, y_{i-1}, y_{i-2}, y_{i-3}\} = \mathbf{f}(i, y_{i-6}, y_{i-13}), \\ i=7,8, \dots \quad (3)$$

Ova mreža aproksimira buduću vrednost y_{i+1} na osnovu trenutne vrednosti vremena i , sadašnje koordinate odziva (y_i), tri neposredno prethodnih koordinata odziva (y_{i-k} , $k=1,2,3$) i dve koordinate odziva iz prethodnih dveju sedmica (y_{i-6}, y_{i-13}). Ako se pažljivo posmatra vrednosti p, q i s ostaju iste.

Posle obuke sa podacima iz Tabele 1 koji su preuređeni na odgovarajući način, dobijena VNM je imala 3 ulazna, 5 izlaznih i 5 skrivenih neurona. Posle odgovarajuće pobude dala je sledeće predviđanje $y_{29} = \{653,2675\}$.



Sl. 5. "Proširena nerekurentna VNM prilagođena za predviđanje" (EFFAP)

Odgovarajuće odstupanje u odnosu na željenu vrednost je $a=7,27\%$. Nešto gore nego ETCR ali, opet, unapred to nije poznato.

Tabela 2. Rezultati predviđanja

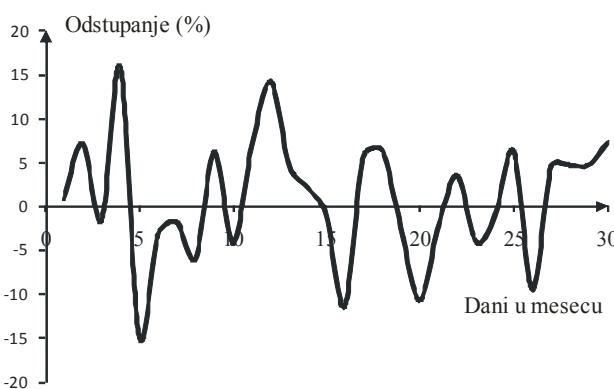
Br.	Očekivana vrednost	a(%) 4 sedmice	a(%) 3 sedmice	a(%) 2 sedmice
1	609	-0,0031	0,908	4,63
2	549	8,4559	7,211	16,95
3	591	-6,4454	-1,684	7,03
4	557	8,9646	15,88	10,32
5	677	-19,894	-14,78	-13,34
6	646	-6,8933	-3,265	-13,44
7	653	-0,3894	-1,822	-5,53
8	621	-9,4798	-5,973	-4,48
9	553	13,4993	6,261	2,07
10	571	-9,1484	-4,25	6,85
11	519	17,349	6,874	15,47
12	579	17,5587	14,23	3,115
13	599	4,6318	4,591	3,034
14	606	10,1419	2,142	-4,009
15	606	1,0024	-0,752	1,656
16	605	-0,8203	-11,42	-4,628
17	585	4,1671	5,738	8,925
18	571	4,0248	6,522	2,005
19	648	-2,4099	-2,466	-7,011
20	666	-7,7875	-10,72	-9,751
21	623	-1,9345	-2,272	-2,899
22	606	3,5128	3,587	-4,396
23	632	-16,07	-4,114	-7,357
24	635	-2,1392	-1,0948	-7,513
25	570	-5,2948	6,327	14,203
26	647	-4,9508	-9,466	-7,15
27	621	12,327	4,6125	3,778
28	595	9,4963	4,7709	7,873
29	595	4,7656	4,766	2,6342

5. KOMPLETAN POSTUPAK I REZULTATI

Kada su prikazani rezultati obuke ETCR i EFFAP mreža za gornji primer izostavljeno je da se napomene da je promenom m_h od 3 do 10, u oba slučaja generisano po 8 rešenja koja su, u startu, bila sva podjednako dobra. Izbor i u jednom i u drugom skupu napravljen je tako što se poredila ETCR i

EFFAP rešenja i tražio se par koji je najsličniji odnosno par predviđanja koja podržavaju jedno drugo. Tako su nastali brojevi y_{29} koji su gore navedeni.

Postoji još jedan aspekt o kome treba reći nešto ukratko. Naime, pošto nemamo nikakav kriterijum o dobroti rezultata obuke VNM za datu vrednost m_h brojne vrednosti predviđanja koja se dobijaju mogu da budu veoma raštrkane odnosno da pripadaju intervalu koji je znatno širi od one realnog. Zato je potreban jedan dodatni kriterijum koji će nas zaštiti od takvih ekstremi. Mi smo, na osnovu analize ulaznih podataka ustanovili jedan interval dozvoljenih vrednosti predviđanja i na taj način uokvirili moguće konačne vrednost. Tako, za najveću dozvoljenu vrednost predviđanja uzeli smo broj koji je za 10% veći od najvećeg u nizu za obuku, a za najmanju dozvoljenu vrednost onu koja je 10% manja od najmanje u nizu za obuku. Na primer, za podatke sa Sl. 2, najveća vrednost bila je $735 \cdot 1.1 = 808.5$, a najmanja $563 \cdot 0.9 = 506.7$.



Sl. 6. Relativno odstupanje između očekivanog i predviđenog za slučaj tri sedmice

Tabela 3. Standardna devijacija odstupanja predviđanja o željene vrednosti za 30 uzoraka iz Tabele 2.

	a_i (%) 4 sedmice	a_i (%) 3 sedmice	a_i (%) 2 sedmice
Standardna devijacija	9,1494	7,1833	8,3508

Tabela 4. Statistika uspeha pojedinih slučajeva. Greška je:

	2 sedmice	3 sedmice	4 sedmice
Puta najmanja	8	11	11
Puta najveća	13	5,5	11,5

Ostaje još jedan korak do konačnog rešenja. Naime, pošto nam željena vrednost nije poznata ne postoji kriterijum o izboru između predviđanja koja su dobijena ETCR i EFFAP metodama. Da bi se tu donela odluka razmišljali smo na sledeći način. Pošto su obe vrednosti bliske rešenju, pretpostavljamo, da bi izbor bilo koje od ovih dve mogao da dà i konačno rešenje s tim što nam uvek ostaje sumnja da je možda ono drugo bliže željenom. Zato smo predložili oportunistički izlaz koji se sastoji u tome da kao konačno predviđanje upotrebimo aritmetičku sredinu rešenja koja su dobijena ETCR i EFFAP metodom.

Polazeći od ovog zaključka pristupili smo verifikaciji metoda tako što smo ga ponovili 30 puta (pomeranjem za jedan dan) i sa tri vrednosti parametra s : dve sedmice unazad,

tri sedmice unazad i četiri sedmice unazad. Ukupno je bilo potrebno obaviti 1440 obuka VNM. Dobijeni rezultati prikazani su u Tabeli 2. Sa $a(\%)$ obeleženo je odstupanje od željene vrednosti koja je takođe prikazana.

Ostaje da se doneše zaključak o optimalnoj vrednosti s . Pošto Tabela 2 sadrži veliki broj cifara teško je zaključiti koja je od kola (koja vrednost s) je najpogodnija. Zato smo izračunali standardnu devijaciju za svaku kolonu $a(\%)$ i rezultat prikazali u Tabeli 3. Zaključujemo da slučaj $s=3$ je najpovoljniji. Vrednost standardne devijacije za $s=3$ je za preko 16% manja nego sledeća najmanja. Do sličnog se zaključka dolazi i analizom Tabele 4. Ovde je data statistika. Za svaki dan ustanovljavano je koje je najbolje, a koje najgore predviđanje. Vidi se da je slučaj $s=3$ bio 11 puta najbolji, a 5,5 puta najgori što ga čini ukupnim pobednikom.

Na Sl. 6 dat je tok odstupanja koje se dobija pri $s=3$.

6. ZAKLJUČAK

Opisali smo jedan sistematski postupak predviđanja vršne dnevne potrošnje električne energije na nivou predgrađa. Razvijeni metodi na sistematičan, ustaljen i ponovljiv način generišu predviđanja čija su odstupanja od željениh vrednosti uvek prihvatljiva, a najčešće veoma dobra.

ZAHVALNOST

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

LITERATURA

- [1] Taylor, J.W., "An evaluation of methods for very short-term load forecasting using minute-by-minute British data", *International Journal of Forecasting (Energy Forecasting)*, Vol. 24, No. 4, 2008, pp.645–658.
- [2] Milojković, J.B., Litovski, V.B., "Short term forecasting in Electronics", *International Journal of Electronics*, ISSN: 0020-7217, Vol. 98, No. 2, 2011, pp. 161-172.
- [3] Milojković, J. and Litovski, V.B., „Dynamic Short-Term Forecasting of Electricity Load Using Feed-Forward ANNs“, *Int. J. of Engineering Intelligent Systems for Electrical Engineering and Communication*, ISSN 1472-8915, Vol. 17, No. 1, March 2009, pp. 38-48.
- [4] Milojković, J., and Litovski, V., „Dynamic One Step Ahead Prediction of Electricity Loads at Suburban Level“, *Proc. of the First IEEE Int. Workshop on Smart grid Modeling and Simulation – at IEEE SmartGridComm 2011*, SGMS2011, Brussels, October 2011, Proc. on disc, paper no. 25.
- [5] Milojković, J., and Litovski, V., „One day ahead peak electricity load prediction“, Proceedings of the IX Int. Symp. On Industrial Electronics, INDEL 2012, Banja Luka, November 2012, pp. 263-267.
- [6] Milojković, J., Litovski, I., and Litovski, V., "ANN Application for the Next DayPeak Electricity Load Prediction", Proc. of the 11th Symp. on Neural Network Application in Electronic Engineering, NEUREL 2012, Belgrade, Sept. 2012, pp. 237-241.
- [7] World wide competition within the eunit network. (2001). [Online] Available: <http://neuron.tuke.sk/competition>.
- [8] Murto P., 'Neural Network Models for Short-Term Load Forecasting', MS Thesis, Helsinki University of Technology, 1998.
- [9] Hyndman, R.J., and Fan, S., "Forecasting long-term peak half-hourly electricity demand for South Australia", Report for Electricity Supply Industry Planning Council (South Australia, Monash University, Australia, 2009.)
- [10] Elattar, E.E., Goulermas, J., and Wu, Q. H., "Electric Load Forecasting Based on Locally Weighted Support Vector Regression", *IEEE Transactions On Systems, Man, and Cybernetics—Part C: Applications and Reviews*, Vol. 40, No. 4, July 2010, pp. 438-447.
- [11] As'ad, M., "Finding the Best ARIMA Model to Forecast Daily Peak Electricity Demand", *Applied Statistics education and Research Collaboration (ASEARC) – Conf. Papers*, Uni. of Wollongong, Australia, 2012, Paper 11.
- [12] Sigauke, C., and Chikobvu, D., "Prediction of daily peak electricity demand in South Africa using volatility forecasting models", *Energy Economics*, Elsevier, Vol. 33, No. 5, Sept. 2011, pp. 882-888.

- [13] 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.
- [14] Hippert, H. S., Pedreira, C. E., and Souza, R. C., "Neural networks for short-term load forecasting: A review and evaluation," *IEEE Transactions on Power Systems*, vol. 16, pp. 44–55, February 2001.
- [15] Milojković, J., Litovski, V., Nieto-Taladriz, O., and Bojanić, S., "Forecasting Based on Short Time Series Using ANNs and Grey Theory – Some Basic Comparisons", In *J. Cabestany, I. Rojas, and G. Joya (Eds.): Part I, LNCS 6691*, pp. 183–190, 2011, © Springer-Verlag, Berlin, Heidelberg.
- [16] Masters, T., "Practical Neural Network Recipes in C++", Academic Press, San Diego, 1993.
- [17] Zografski, Z., "A novel machine learning algorithm and its use in modeling and simulation of dynamical systems", *Proc. of 5th Annual European Computer Con.*, COMPEURO '91, Hamburg, Germany, 1991, pp. 860-864.
- [18] Baum, E.B., and Haussler, D., "What size net gives valid generalization", *Neural Computing*, 1989, Vol. 1, pp. 151-160.
- [19] Takens, F., "Detecting strange attractors in turbulence," *Lecture Notes in Mathematics* (Springer Berlin), Vol. 898, 1981, pp. 366–381.
- [20] Sauer, T., Yorke, J. A., and Casdagli, M., "Embedology," *Journal of Statistical Physics*, Vol. 65, May 1991, pp. 579–616.

Abstract – One step ahead prediction method for peak daily electricity loads based on artificial neural networks (ANN) is presented. Two architectures of ANN were implemented to produce predictions that used to generate the final value as an average. Suitable adapted set of input data from the previous weeks are the main improvement compared to the earlier examples. In this way, we obtained higher accuracy of prediction. Examples will be given confirming both the feasibility of the method and the need for further elaboration of the procedure.

PREDICTION OF DAILY PEAK ELECTRICITY LOAD BASED ON ANN

Jelena Milojković, Vančo Litovski