

POREĐENJE KRATKOROČNIH PREDVIĐANJA DOBIJENIH TEORIJOM SIVOG I NEURONSKIM MREŽAMA

Jelena Milojković, *Elektronski fakultet u Nišu, jelena@venus.elfak.ni.ac.rs*
Vančo Litovski, *Elektronski fakultet u Nišu, vanco@elfak.ni.ac.rs*

Sadržaj – U poređena su dva moderna metoda za predviđanje zasnovano na kratkim vremenskim nizovima (VN). Rezultati dobijeni upotrebom veštačkih neuronskih mreža (ANN) suprostavljeni su onima dobijenim upotrebom teorije sivog odnosno sivog modela (GM). Upotrebljene su »Feed-Forward Accommodated for Prediction« (FFAP) i »Time Controlled Recurrent« (TCR) ANN istovremenosa sa GM(1,1) algoritmom za jednokoračno i dvokoračno predviđanje vrednosti različitih veličina (električni potrošači, broj fiksnih telefona, broj zastarelih računara i sl.). Uočene su neke prednosti primene ANN.

1. UVOD

U [1] uveli smo dve strukture ANN koje su pogodnije za predviđanje na osnovu kratkih VN. FFAP i TCR strukture su uspešno primenjen na predviđanje količine zastarelih računara u SAD. Ove ideje su kasnije upotrebljene za predviđanje električnih potrošača [2] i razvoja u mikroelektronici [3,4]. Važan dodatni zaključak ovih istraživanja je da tvrdnja "One major criticism about the NN model is that it demands a great deal of training data and relatively long training period for robust generalization" [5] može lako da se pokaže. Koristili smo ANN sa malim brojem neurona u skrivenom sloju, predviđanje je obavljeno na osnovu vrlo kratkih VN. Dobijeni rezultati bili su poređeni sa nekim od postojećih ali ne i sa onima dobijenim primenom teorije sivog [6,7]. Postoje dva važna razloga zašto se obraćamo kratkim VN. Najpre, u velikom broju slučajeva, pojava se posmatra odskora tako da raniji podaci i ne postoje. Drugo, u ponašanju mnogih prirodnih i društvenih problema, od važnosti su samo najsvježiji podaci. U narednim odeljcima daćemo osnove novog načina primene ANN za predviđanje.

Ovde upoređujemo rezultate predviđanja dobijene korišćenjem FFAP i TCR ANN sa onima koje daje GM(1,1). Biće prikazana predviđanja jedan i dva koraka unapred za razne veličine. Pre prikaza rezultata biće date kratke teorijske osnove primenjenih koncepata.

2. POSTAVKA PROBLEMA

VN je skup opservacija uzetih uzastopno u vremenu. VN koji može da se predvidi tačno naziva determinističkim, a niz čiji budući elementi mogu da se na osnovu prethodnih vrednosti predvide samo približno zove se stohastički [8]. Ovde se razmatraju samo deterministički VN.

Posmatrajmo skalarni VN y^i , $i=1,2, \dots, n$. on predstavlja niz odmeraka nepoznate funkcije $\hat{y} = \hat{f}(t)$ koji su uzeti ekvivalentno sa intervalom Δt tj. $t^{i+1}=t^i+\Delta t$. k -koraka unapred predviđanje znači: naći takvu funkciju $f(\cdot)$ koja će obaviti preslikavanje

$$y^{n+k} = f(t^{n+k}) = \hat{y}^{n+k} + \varepsilon, \quad (1)$$

gde je \hat{y}^{n+k} željeni odziv, sa prihvatljivom greškom ε .

Predviđanje vremenskih nizova je ekvivalentno sa modelovanjem skrivene fizike koja je odgovorna za nastajanje niza [9]. Otuda težina problema. Postoji veliki broj pokušaja rešavanja ovog problema. U literaturi [6,7] se mogu naći tvrdnje da primena teorije sivog je najpovoljnija alternativa svim postojećim konceptima uključujući i ANN.

Naš je cilj ovde da proučimo primenu naših i GM(1,1) modela kako bi stekli informacije za zaključivanje o međusobnim prednostima jednog ili drugog koncepta.

3. PRIMENA ANN ZA PREDVIĐANJE

U poslednjim dekadama ANN su se nametnule kao tehnologija sa velikim mogućnostima za identifikaciju i modelovanje podataka sa kojima se na tradicionalan način teško izlazi na kraj. Zajednička osobina postojećim primenama, međutim, bila je potreba da one zahtevaju relativno duge VN da bi postale uspešne. VN, obično, ne sme da bude kraći od 50 uzoraka [8]. Tome je uglavnom razlog činjenica da se pri predviđanju u VN traži skrivena periodičnost.

Imajući to na umu bili smo prinudjeni da tražimo alternativne načine za primenu ANN za predviđanje. Rezultati su saopšteni u [1,2,3,4] i mogu da se karakterišu na sledeći način: upotreba jednostavnih ANN (mali broj neurona u skrivenom sloju, od 1 do 10) i primena pri kratkim VN.

U primerima koje ćemo posmatrati u ovoj raspravi uzorci se uzimaju jednom godišnje. Da bi se problem predviđanja učinio numerički pogodnim brojne vrednosti će biti transformisane na sledeći način. Vreme će biti redukovano sa t_0-1 tako da će se koristiti

$$t^* = t - (t_0 - 1). \quad (2)$$

Pošto t^* predstavlja tekuću godinu, (2) daje vrednost 1 u godini t_0 koja se odnosi na prvi uzorak. Uzorci se normalizuju pomoću

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

gde je y^* tekuća vrednost funkcije, a M je konstanta koja se bira na pogodan način zavisno od problema koji se razmatra.

Saglasno sa [10], ako se stavi $t_0=1991$, posle normalizacije dobija se Tabela 1. na predstavlja zapreminu zastarelih računara u SAD po godini u milionima kubnih stopa. Ovi podaci bili su upotrebljeni za razvoj metoda za predviđanje zasnovanom na primeni ANN [1].

Tabela 1. Skup podataka posle normalizacije

t	1	2	3	4	5	6	7	8	9
$f(t)$	7.03	8.67	10.0	9.33	9.85	10.18	12.54	14.76	18.4

Prvih 8 uzoraka upotrebljeni su kao podaci za obuku, a poslednji podatak tj. $t=9$ i $f(t)=18.4$, bio je upoređen sa pred-

viđanjima sa ciljem da se provere vrednosti novog metoda.


Do kraja ovog odeljka biće opisana ona rešenja bazirana na ANN koja su se pokazala kao najpovoljnija [1].

A. Primena TCR ANN

Kao što se u literaturi često tvrdi [9], arhitektura koja obećava za primene u predviđanju je "time-delayed recurrent" ANN. Arhitektura koja je rekurentna sa vremenski zakašnjenjem povratnim signalom, kod koje u isto vreme vremenska promenljiva kontroliše izlaznu predviđenu veličinu, prikazana je na Sl. 1. Ova struktura će biti nazvana "time-controlled recurrent" (TCR). Ovdje ANN uči VN koji se sastoji od parova $\{[t^j; f(t^j)], j=0, \dots, q\}; [f(t^{j+1}), j=1, \dots, k]\}$, $i=q, \dots, n-k$, pa je:

$$\{y^{i+k}, \dots, y^{i+j}, \dots, y^{i+1}\} = f(t^i, y^i, y^{i-1}, \dots, y^{i-q}) \quad i=q, \dots, n-k, \quad (4)$$

gde je k broj intervala u budućnosti, a q je broj starih vrednosti koje se saopštavaju mreži prilikom obuke.




Slika 1. "Time controlled recurrent" ANN

Postupak obuke ANN bio je jednak onome koji je opisan u [11]. Posle obuke TCR ANN za $t=9$ dobilo se $f(9)=17.21$ za ANN sa 10 skrivenih neurona.

B. Primena FFAP ANN

U ovom slučaju naša ideja bila je da prinudimo ANN da više puta uči istu funkciju ali pomerenu u vremenu. Na taj način, smatrali smo da će prethodne vrednosti odziva imati veći uticaj na preslikavanje $f(t)$ nego kod TCR mreže.

FFAP mreža prikazana je na Sl.2. Postoji samo jedan ulazni priključak: t . Izlaz $Output_3$, ili budući izlaz, treba da se prinudi da aproksimira y^{i+1} . U slučajevima kada je predviđanje višekoračno $Output_3$ može da se smatra k -vektorom. $Output_2$ treba da predstavlja sadašnju vrednost: y^j . Najzad, $Output_1$ treba da uči prethodnu vrednost: y^{j-1} . Opet, ako želimo da preslikavanje kontrolišemo sa više ranijih vrednosti $Output_1$ može da se smatra q -vektorom. Ova arhitektura nazvana je "feed forward accommodated for prediction".



Slika 2. Struktura FFAP ANN

Funkcionalnost mreže iskazana je sa

$$\{y^{i+k}, \dots, y^{i+1}, y^i, y^{i-1}, \dots, y^{i-q}\} = f(t^i), i=q, \dots, n-k, \quad (5)$$

Gde je $Output_1 = \{y^{i-1}, \dots, y^{i-q}\}$ i $Output_3 = \{y^{i+1}, \dots, y^{i+k}\}$.

Sa ovom strukturom uz $q=2$ i $k=1$, dobili smo $f(9)=18.23$ sa mrežom sa 4 neurona u skrivenom sloju.

4. GM(n,m) MODEL

U teoriji sivog sa $GM(n,m)$ obeležava se model sivog, s tim što je n red diferencne jednačine, a m je broj promenljivih. Najpopularnija je verzija $GM(1,1)$ model, izgovara se "Sivi model prvog reda jedne promenljive", zahvaljujući računskoj efikasnosti [7].

Razmotrimo nenegativni VN X :

$$X = \{x(1), x(2), \dots, x(n)\}, n \geq 4. \quad (6)$$

Kada se na ovaj VN primeni "Accumulating Generation Operator" (AGO), nastaje

$$Y = \{y(1), y(2), \dots, y(n)\}, n \geq 4, \quad (7)$$

gde je

$$y(j) = \sum_{i=1}^j x(i) \quad j = 1, 2, 3, \dots, n. \quad (8)$$

Y je VN koji monotono raste.

Uopšteni niz srednjih vrednosti Z dobijena od Y definiše se kao:

$$Z = \{z(1), z(2), \dots, z(n)\}, \quad (9)$$

gd e je $z(j)$ srednja vrednost para susednih elemenata Y tj.

$$z(j) = 0.5 \cdot [y(j) + y(j-1)], \quad j = 2, 3, \dots, n. \quad (10)$$

Tzv. beljenje dobija se jednačinom:

$$\frac{dy}{dt} + a \cdot y(t) = b. \quad (11a)$$

Ona se odnosi na "srednjekvadratnu procenu sive diferencne jednačine modela $GM(1,1)$ " [7]:

$$x(j) + a \cdot z(j) = b. \quad (11b)$$

gde se $[a \ b]^T$ izračunava iz:

$$(\mathbf{B}^T \mathbf{B}) [a \ b]^T = \mathbf{B}^T \mathbf{R}, \quad (12)$$

sa

$$\mathbf{R} = [x(2) \ x(3) \ \dots \ x(n)]^T, \quad (13)$$

$$\mathbf{B} = \begin{bmatrix} -z(2) & -z(3) & \dots & -z(n) \\ 1 & 1 & \dots & 1 \end{bmatrix}^T. \quad (14)$$

Smenom $[a \ b]^T$ u (11a), rešenje $y(t)$ u trenutku j je:

$$y_p(j+1) = [x(1) - b/a] \cdot e^{-aj} + b/a. \quad (15)$$

Da bi se dobila predviđena vrednost u trenutku $(j+1)$, primenjuje se IAGO (Inverse Accumulating Generation Operation) i nastaje sledeći sivi model

$$x_p(j+1) = y_p(j+1) - y_p(j) = [x(1) - b/a] \cdot (1 - e^{-a}) \cdot e^{-aj}, \quad (16)$$

a predviđena vrednost je u trenutku $(j+k)$ je:

$$x_p(j+k) = [x(1) - b/a] \cdot (1 - e^{-a}) \cdot e^{-a(j+k-1)}. \quad (17)$$

Primena gornjeg postupka na primer iz Tab. 1 daje $f(9) = x_p(9) = 14.887$ kao što je prilazano u 4. redu Tab.2.

Rezultati koji su dobijeni do sada sumirani su u Tab. 2. Jasno je da i TCR i FFAP ANN pokazuju neuporedivo bolje rezultate nego $GM(1,1)$ model. Da bi verifikovali rezultate mi smo primenili TCR i FFAP ANN na različitim problemima iz

literature u kojima je primenjen GM(1,1) model.

Tabela 2. Pregled rešenja, $\hat{f}(9) = 18.4$.

Vrsta rešenja	Broj skrivenih neurona	Broj izlaznih neurona	$f(9)$	greška %
TCR	10	1	17.2114	6.46
FFAP	4	4	18.2274	0.938
GM(1,1)			14.8872	19.56

5. POREĐENJE REZULTATA

U [12] razmatran je problem predviđanja potrošnje električne energije na Tajvanu na osnovu podataka iz perioda 1985-1998. Rezultati dati u Tab. 3 i Tab. 4 su u GW.

U [13] predviđen je broj novih pretplatnika fiksne telefonije u Kini na osnovu podataka iz perioda 1989.- 2004. god. Rezultati dati u Tab. 3 i Tab. 4 su u 100 miliona telefona.

Najzad, u [14] predviđena je potrošnja električne energije u provinciji Hebei u Kini na osnovu podataka za period 1986.-1996. Rezultati dati u Tab. 3 i Tab. 4 su u GW.

Rezultati iz literature zajedno sa našim rezultatima dati su u Tab. 3 i Tab. 4. Sva rešenja sa ANN imaju 5 neurona u skrivenom sloju. Razmatranjem Tab. 3 zaključujemo da su jednokoračna predviđanja sa ANN uvek bolja od GM modela. U slučaju dvokoračnog predviđanja GM model je superioran samo u jednom od tri slučaja.

Tabela 3. Jednokoračno predviđanje

Ref.	Vrednost	Greška		
		GM(1,1)	TCR	FFAP
[12]	131.725	-4.36	3.80	0.18
[13]	31086.8	-17.95	-9.31	-8.17
[14]	2965	-4.485	3.41	4.14

Tabela 4. Dvokoračno predviđanje

REF.	Vrednost	Greška		
		GM(1,1)	Očekivana	GM(1,1)
[12]	142.4	3.39	-1.19	-2.78
[13]	36666.6	17.82	0.39	-8.03
[14]	3012	3.652	6.52	7.17

6. ZAKLJUČAK

Razmatran je niz rešenja problema predviđanja za slučaj kada su na raspolaganju kratki VN. Pokazano je da su dve arhitekture ANN koje smo ranije razvili u prednosti u odnosu na GM(1,1) model. Pored toga, prilikom implementacije GM modela uočili smo problem loše uslovljenosti pri rešavanju (12) koja je od ključne važnosti za primenu GM(1,1) modela.

Ne treba zaboraviti da je većina rešenja sa ANN ostvarena sa samo pet neurona u skrivenom sloju. To treba suprotstaviti tvrdnjama da primena ANN za predviđanje zahteva složene mreže i komplikovan proces obuke [5].

LITERATURA

[1] Milojković, J., Litovski, V., "Comparison of Some ANN Based Forecasting Methods Implemented on Short Time Series", In: 9th Symp. on Neural Network Applications in Electrical Eng., NEUREL-2008, Belgrade, 2008, pp. 179-179.

[2] Milojković, J., Litovski, V., "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, pp. 38-48, 2009.

[3] Milojković, J., Litovski, V., "Short Term Forecasting in Electronics", Int. J. of Electronics, Vol. 98, No. 2, pp. 161-172, 2011.

[4] Milojković, J., Bojanić, S., Litovski, V., "On Prediction in Microelectronics", In: 27th Int. Conf. on Microelectronics, Niš, 2010, pp. 275-278.

[5] Jo, T. C., "The effect of virtual term generation on the neural based approaches to time series prediction", In: Proc. of the IEEE 4th Conf. on Control and Automation, Montreal, 2003, Vol. 3, pp. 516-520.

[6] Deng, J.L., "Grey Control Systems", The Publishing House of Hua Zhong Institute, Wuhan, 1985, na kineskom.

[7] Deng, J., "Introduction to grey system theory", The Journal of Grey System, Vol. 1, No. 1, pp. 1-24, 1989.

[8] Zhang, B. G., Patuwo, E., Hu, M. Y. "Forecasting with artificial neural networks: The state of the art", Int. J. of Forecasting, Vol. 14, No. 1, pp. 35-62, 1998.

[9] Haykin, S. "Neural Networks, A Comprehensive Foundation", Macmillan College Publ. Co., New York, 1994.

[10] Matthews, H. S., et all.: "Disposition and End-of-Life Options for Personal Computers", Green Design Initiative Technical Report #97-10, Carnegie Mellon University, 1997.

[11] A. Bernieri, M. D'Apuzzo, L. Sansone and M. Savastano, "A neural network approach for identification and fault diagnosis on dynamic systems", IEEE Tran. on Instrumentation and Measurements, 43 (1994) pp. 867-873.

[12] Hsu, C.-C., and Chen, C.-Y., "Applications of improved grey prediction model for power demand forecasting", Energy Conversion and Management, Vol. 44, No. 14, pp. 2241-2249, 2003.

[13] Li, G.-D., Yamaguchi, X., and Nagai, M. "A high precision prediction model using hybrid Grey dynamic Model", Int. J. Learning and Change, Vol. 3, No. 1, pp. 92-109, 2008.

[14] Cui, H.-R., "A long-term electrical power load forecasting model based on grey feed-back modification", In: Proc. of the 7th Int. Conf. on Machine Learning and Cybernetics, Kunming, 2008, pp. 2198-2201.

Abstract—Two modern methods of forecasting based on short time series were compared. Results obtained by use of artificial neural nets (ANNs), are contrasted to the ones produced by use of the so called Grey theory or Grey Model (GM). Specifically, the Feed-Forward Accommodated for Prediction (FFAP) and the Time Controlled Recurrent (TCR) ANNs were used along with the GM(1,1) algorithm for one- and two-steps-ahead forecasting of various quantities (electricity loads, number of fixed telephones lines, obsolete computers, etc). Advantages of the ANN concept were observed.

COMPARISON OF FORECASTING METHODS USING ANNS AND THE ONES USING THE GREY MODEL GM(1,1) MODEL

Jelena Milojković i Vančo Litovski